

Гидрометеорология и экология. 2024. № 76. С. 407—421.

Hydrometeorology and Ecology. 2024;(76):407—421.

ГЕОФИЗИКА

Научная статья

УДК [551.524+551.558.1]:004.032.26

doi: 10.33933/2713-3001-2024-76-407-421

Поиск термоконвективных структур в потоке данных

**Елена Александровна Малиновская¹, Савелий Дмитриевич Калинин^{2, 1},
Ирина Владимировна Зайцева^{2, 1}**

¹ Институт физики атмосферы им. А. М. Обухова РАН, Москва, Россия, elen_am@inbox.ru

² Российский государственный гидрометеорологический университет

Аннотация. Идентификация термоконвективных структур в данных высокочастотных пульсационных измерений температуры воздуха в приповерхностном слое на опустыненной территории проведена с использованием алгоритмического и нейросетевого методов. На основе результатов визуального анализа данных создана обучающая выборка образов термоконвективных структур (так называемых «рэмпов»), используемая далее в нейронной сети, анализирующей измерения. Данные о распределении подобных структур по размерам и интенсивности позволяют связать термоконвективные характеристики со скоростью и интенсивностью выноса пылевого аэрозоля с аридных и субаридных территорий.

Ключевые слова: конвекция, база образов, рэмп-структуры, нейронная сеть.

Благодарности: Исследование выполнено при поддержке Российского научного фонда, проект №23–27–00480.

Для цитирования: Малиновская Е. А., Калинин С. Д., Зайцева И. В. Поиск термоконвективных структур в потоке данных // Гидрометеорология и экология. 2024. № 76. С. 407—421. doi: 10.33933/2713-3001-2024-76-407-421.

GEOPHYSICS

Original article

Search for thermoconvective structures in the data stream

Elena A. Malinovskaya¹, Saveliy D. Kalinin^{2, 1}, Irina V. Zaitseva^{2, 1}

¹ Obukhov Institute of Atmospheric Physics of the Russian Academy of Sciences, Moscow, Russia, elen_am@inbox.ru

² Russian State Hydrometeorological University, St. Petersburg, Russia

Summary. The problem of automating the search for coherent structures that appear as sawtooth bursts in the measurement data series is considered. As a source of data, we take data from high-frequency measurements of air temperature conducted at heights of less than a meter in conditions of developed convection

(Kalmykia, 2022). Due to the movement of thermal structures under the influence of wind, the sensor detects asymmetric bursts. Therefore, two methods are used to find such a waveform: a filtering algorithm for maxima with a fixed deviation from the mean value and visual pattern recognition using a neural network. The algorithm for searching for “ramp” structures based on statistical data includes three steps: filtering for the value of the standard deviation, determination of local maxima, and the condition of exceeding the mean value for neighboring values. The algorithm allows determining “ramp” structures of a certain size for selected parameters. The distribution of the number of “ramp” structures by size is close to normal. To apply the neural network to search for “ramp” structures within the framework of the problem of pattern recognition, a database of images (about 1000) prepared by an expert was formed. The trained neural network detects “ramps” of the structure from the base from the data stream with an error of 12%. In addition to them, “ramps” with a duration of 0.1–0.2 s are also detected. The distribution of the number of particles by size is determined by a logarithmic function with a preponderance in the number of instances in the direction of short bursts, which is associated with the self-similarity property of thermal structures.

Keywords: convection, image database, “ramp” structures, neural network.

Acknowledgments: The study was supported by the Russian Science Foundation – project No. 23–27–00480.

For citation: Malinovskaya E. A., Kalinin S. D., Zaitseva I. V. Search for thermoconvective structures in the data stream. *Gidrometeorologiya i Ekologiya = Journal of Hydrometeorology and Ecology*. 2024;(76):407–421. (In Russ.). doi: 10.33933/2713-3001-2024-76-407-421.

Введение

При конвекции на опустыненных территориях возникают восходящие движения с выносом пылевого субмикронного аэрозоля [1, 2]. Здесь последовательно чередуются прогретые объемы воздуха, переносящие 60–70 % от общего потока ощутимого тепла, составляющие $\frac{1}{4}$ всех фиксируемых событий, за счет чего они обуславливают колебания теплового потока до 30 % [3]. В флуктуациях скорости и температуры, демонстрирующих в целом сложное поведение, наблюдаются типовые частично организованные (когерентные) структуры. При этом для пульсационных составляющих часто выявляются в различных природных и лабораторных наблюдениях пилообразные всплески — рэмпы [4], имеющие несимметричную треугольную форму [5]. С высотой размеры наблюдаемых структур, пульсации температуры и вертикальной компоненты скорости увеличиваются [4], причем замечается возрастание скоррелированности для пульсаций скорости и температуры [6].

Рэмпы выявляются на разной высоте в приповерхностном слое воздуха [5]. Они заметно отделены друг от друга и обладают более четкой структурой на малых, менее 1 метра высотах, и временными масштабами порядка 0,1–0,3 сек [7].

Размеры и амплитуды рэмпов отражают условия возникновения неустойчивых состояний, при которых постепенный рост температуры в результате прогрева поверхности приводит к конвективному вертикальному выбросу теплых масс и возникновению вынужденного перемещения вниз более холодных масс [8].

Рэмп-структуры обнаруживаются при разных временных осреднениях от 1 до 10 мин. данных измерений пульсационных составляющих и демонстрируют определённые свойства самоподобия [7]. Поиск и анализ в больших объемах данных сведений о временных размерах и амплитудах рэмп-структур необходим для получения информации о пространственных характеристиках теплового потока, а также для оценки интенсивности вертикального выноса пылевого аэрозоля с аридных и субаридных территорий.

Схожесть основных параметров рэмп-структур (всплески дисперсии, наличие локальных максимумов и серий и др.) позволяет использовать для их выявления алгоритм трехшаговой фильтрации данных с оценкой статистических характеристик [9].

В современных научных исследованиях все большую популярность приобретает метод поиска объектов с использованием нейронных сетей [10, 11]. Поиск рэмп-структур близок, в частности, к задаче распознавания образов. В работе [12] при исследовании турбулентных структур проводился поиск геометрических всплесков (кластеров) величины напряжения сдвига с помощью многослойных перцептронов и рекуррентных нейронных сетей. Сверточные нейронные сети успешно применяются для прогнозирования динамики изменения временных последовательностей реальных данных (причинно-следственные свертки) [13] и прогнозирования временной эволюции когерентных структур в турбулентном потоке в турбине [14] и в канале [15].

В связи с этим целью данного исследования является сравнение применения для поиска рэмп-структур двух способов: алгоритмического и нейросетевого.

В первом разделе приведены сведения об источниках данных. Во втором разделе дается описание объекта исследований — рэмп-структур. В третьем разделе приведено краткое описание алгоритма поиска рэмп-структур на основе статистических данных. В четвертом разделе — результаты применения алгоритмического метода. В пятом разделе — алгоритм подготовки данных, обучение и применение нейронной сети. В шестом разделе представлены результаты применения нейронной сети для поиска рэмп-структур. В седьмом разделе приведено сравнение двух методов.

Источники данных

Для анализа взята выборка одного часа (10:56—11:56) 29.07.2022 на высоте 20 см над поверхностью, полученная при комплексных полевых измерениях Института физики атмосферы им. А. М. Обухова РАН (ИФА им. А. М. Обухова РАН) на аридных территориях с подвижными песками в Калмыкии. В этот день температура воздуха на высоте 2 м варьировалась в пределах 27—40 °С, температура поверхности — 35—50 °С. Измерения проводились в жаркую солнечную погоду в условиях преобладания слабых ветров. Такие условия хороши для возникновения и развития конвективных структур. Для требуемых здесь высокочастотных измерений температуры и скорости воздуха применялись проволочные температурные датчики и термоанемометры. Толщина используемой здесь платинированной вольфрамовой нити составляла 10 мкм, частота регистрации — 1000 Гц [7]. Указанные параметры дают возможность наблюдать мелкомасштабные конвективные структуры у поверхности.

О форме наблюдаемого сигнала

Используем модель-аналог — пламя свечи на ветру. Со стороны ветра имеется четкая граница между пламенем и воздухом, а противоположная сторона




Рис. 1. Визуальное представление переноса термоконвективной структуры ветром относительно вертикальной нити.

Fig. 1. Visual representation of thermoconvective structure transport by wind relative to a vertical filament.

представляет собой более размытую форму и границы. При отсутствии ветра поднимающийся от ровной нагретой поверхности объем воздуха имеет почти симметричную форму. При воздействии ветра тепловая структура уже теряет симметрию, как и пламя свечи (рис. 1). Структура, переносимая ветром и пересекающая нить датчика, отразится в регистрируемом распределении температуры. В центре тепловой структуры температура немного выше внешнего от центра окружения (более яркая область), а во внешних слоях уменьшается. При перемещении структуры по ветру (слева-направо на рис. 2) регистрируется сначала постепенный рост температуры. На правой границе тепловой структуры, где большее воздействие ветра, рост прекращается, и температура резко падает.




Рис. 2. Два типа рэмп-структур во временном ряду: вершинами вверх и вершинами вниз.

Fig. 2. Two types of ramp-structures in the time series: vertices up and vertices down.

В результате рэмп-структуры могут быть выявлены визуально в силу особенностей роста и падения температуры. При конвективном подъеме теплых масс возникает вынужденная конвекция, когда менее нагретый воздух вытесняется в нижние слои более нагретым, поэтому в условиях прогрева поверхности и восходящих тепловых движений помимо треугольных структур с вершинами вверх отмечаются также аналогичные структуры с вершинами вниз (рис. 2 а, б).

Алгоритмический способ поиска рэмп-структур

Далее используем алгоритм поиска рэмп-структур, направленных вершинами вверх, предложенный при обработке данных лабораторного эксперимента в [9]. Предполагается одновременное выполнение трех условий:

1. Отклонение от среднего больше доли от среднеквадратического отклонения: $\delta T > \alpha T_r$, где $\delta T = T(t + \tau) - T(t)$ — вариации величины T , T_r — стандартное отклонение.

2. В выбранном для анализа интервале имеется максимум значений: $T(t) = \max[T(t_1), T(t_2)]$.

3. Среднее двух близких по времени значений $T(t_1)$ и $T(t_2)$ больше среднего для некоторого интервала: $\frac{T(t_1) + T(t_2)}{2} > \langle T \rangle$.

Для настройки работы алгоритма используются 5 параметров (табл. 1).

Таблица 1

Параметры, используемые в алгоритме поиска рэмп-структур

Parameters used in the algorithm for searching ramp structures

Обозначение	Расшифровка
α	параметр из условия 1
τ	разность времени из условия 1
n	интервал времени, для которого определяется стандартное отклонение
$n_{\max}$	интервал времени, для которого определяется максимальное значение
$t_2 - t_1$	расстояние между точками на третьем шаге
$n_{\langle T \rangle}$	интервал времени, для которого среднее арифметическое для третьего шага

Для рэмп-структур вершинами вниз алгоритм будет аналогичным за исключением знаков неравенств, а максимум заменится минимумом. В следующем разделе описаны некоторые результаты применения алгоритма поиска рэмп-структур вершинами вверх.

Результат применения алгоритмического способа поиска

На рис. 1 приведены примеры рэмп-структур, найденных с использованием алгоритмического метода. Это несколько четких структур близкого временного размера двух масштабов: около 0,2—0,4 с (рис. 3 а) и около 1—4 с (рис. 3 б).




Рис. 3. Обнаруженные алгоритмически рэмпы
(а — $\alpha = 0,5$, $\tau = 0,3$ с, $n_{T-(T)} = 2,5$ с, $n_{\max} = 0,7$ с, $t_2 - t_1 = 0,04$ с, $n_{(T)} = 0,5$ с;
б — $\alpha = 0,5$, $\tau = 4,5$ с, $n_{T-(T)} = 30$ с, $t_2 - t_1 = 0,04$ с, $n_{(T)} = 5$ с).

Fig. 3. Algorithmically detected ramps
(a — $\alpha = 0,5$, $\tau = 0,3$ s, $n_{T-(T)} = 2,5$ s, $n_{\max} = 0,7$ s, $t_2 - t_1 = 0,04$ s, $n_{(T)} = 0,5$ s;
б — $\alpha = 0,5$, $\tau = 4,5$ s, $n_{T-(T)} = 30$ s, $t_2 - t_1 = 0,04$ s, $n_{(T)} = 5$ s).

Второй тип обладает более сложной формой, содержит более мелкие подструктуры. Для поиска более крупных структур необходимо провести осреднение и повторить процедуру для более крупного масштаба на других временных масштабах. Параметры, используемые в алгоритме (табл. 1), подбираются вручную.

Для выбранного интервала 600 с алгоритм может определить до 30 рэмп-структур длительностью от 0,1 до 0,4 с и относительной амплитудой от 0,2 до 1 с (табл. 2).

Таблица 2

Примеры временных размеров и относительных амплитуд рэмп-структур
Examples of temporal dimensions and relative amplitudes of ramp-structures

$t, 10^{-2}, \text{с}$	$t_R, \text{с}$	$(T' / T_{\max})_A$
3201	0,30	0,8
3294	0,35	0,6
3370	0,35	0,8
3504	0,15	0,6
3598	0,15	0,6
3624	0,25	0,3
3702	0,30	1,0

Окончание табл. 2

$t, 10^{-2}, \text{с}$	$t_R, \text{с}$	$(T' / T_{\max})_A$
3769	0,25	1,0
3882	0,20	0,5
3901	0,20	0,8
3924	0,30	0,6
4181	0,25	0,8
4301	0,30	0,7
4389	0,35	0,7
4554	0,35	0,6

Из распределений числа рэмп-структур по длительности и по амплитуде определяем, что наиболее часто встречаются временные размеры 0,3 с и амплитуды 0,6 (60 % от максимальной) (рис. 4).




Рис. 4. Распределение числа рэмп-структур:
 a — по длительности (t); $б$ — по относительной амплитуде (a).

Fig. 4. Distribution of the number of ramp-structures:
 a — by duration (t); $б$ — by relative amplitude (a).

Алгоритмический метод для значений ряда позволяет определить по статистическим данным наличие рэмп-структуры определенного масштаба. Параметры при этом подбираются вручную. Далее рассматривается альтернативная методика применения нейронных сетей для поиска рэмп-структур.

Нейронная сеть для поиска рэмп-структур

Использование нейронной сети для поиска рэмп-структур реализовано на той же выборке данных измерений, как и в алгоритмическом методе. Для процедуры идентификации отдельных рэмпов, которую можно отнести к известной задаче

распознавания образов [16], применена тестовая вариация трехслойной сверточной нейронной сети [10].

Для реализации этого метода выполняются следующие подготовительные работы:

1. Определяется X координата начала рэмп-структуры (*not*) и временная длительность (*size*) в результате визуального просмотра разверток по 1000 точек (10 с) (рис. 2). Каждый выбранный двумерный образ сохраняется в цифровом виде как двумерный массив (первый столбец — это исходные данные относительных значений пульсационных составляющих $\tilde{T}'$, другие — разностные характеристики типа $\tilde{T}'(t) - \tilde{T}'(t + dt)$) (рис. 5). Такая процедура используется в связи с известной теорией структурных функций, по которой, исходя из разностных характеристик, определяются масштабы конвективных процессов [7].

2. Формируются три списка сохраненных файлов: рэмп-вверх (579 файлов), рэмп-вниз (167 файлов) и не-рэмп (14 файлов).

3. Вводятся коэффициенты пропорциональности вследствие того, что временные размеры рэмп-структур отличаются по длительности (варьируются от 200 до 3000 мс). В результате исходные данные в обучающей выборке сведены к одному масштабу.

4. Создается двухслойная нейронная сеть:

- на входной слой (40 нейронов) подаются данные обучающей выборки — параметры из файлов $\tilde{T}'$ и $\tilde{T}'(t) - \tilde{T}'(t + dt)$;

- первый слой (40 нейронов) содержит скрытые нейроны;

- второй слой (3 нейрона) позволяет определить вид рэмп-структур на выходе в конечном слое в соответствии с указанной на шаге 2 классификации образов.

5. Выполняется тестирование нейронной сети первоначально на первых двух столбцах базы образов.




Рис. 5. Участок исходных данных рэмп-структуры (а) и диаграмма рэмп-структуры (б), составленная из столбцов базы образов.

Fig. 5. Plot of the raw data ramp-structure and a diagram of the ramp-structure made from the columns of the image base.

Далее приведен анализ результатов поиска рэмп-структур с использованием нейронной сети.

Результат применения нейронной сети для поиска рэмп-структур

Тестирование обученной нейронной сети для поиска рэмп-структур выполнено на том же наборе данных, что и в алгоритмическом методе. Сопоставление исходных данных с результатами идентификации двумерных образов нейронной сетью дают удовлетворительные результаты (рис. 6). На рис. 6 а показан участок графика исходных данных, которые тестировала нейронная сеть. На рис. 6 б приведены вероятности соответствия анализируемого образа тому или иному виду (рэмп-вниз, рэмп-вверх, не-рэмп) по результатам оценки нейронной сети для этого участка. В результате обучения сети ошибка нейронной сети составляет 12 %. Как видно из рис. 6 в, нейронная сеть при заданном масштабном коэффициенте, равном 5, определяет несколько рэмпов.

Если построить распределение по длительности для найденных моментов времени, то получается, что нейронная сеть определяет более мелкие рэмп-структуры, которые получены первым способом с преобладающей длительностью 0,1 с, что, вероятно, вызвано самоподобием рэмп-структур. Распределение числа частиц по размерам может быть аппроксимировано функцией вида: $N = A \log(-x) + B$.




Рис. 6. Отрезок исходных данных в сравнении с результатами анализа нейронной сети.

Fig. 6. Plot of raw data versus neural network analysis results.

Сравнение методов

Применение двух методов для поиска рэмп-структур позволило выявить моменты их возникновения. Алгоритмический метод требует настройки вручную, подбора параметров, которые определяются масштабами обнаруживаемых рэмп-структур. С использованием алгоритма определяется около 50 % рэмпов преимущественно среднего размера из числа выбранных экспертом для базы образов (табл. 3).

Таблица 3

Сравнение выявленных рэмпов,
выбранных экспертом из базы образов, с использованием алгоритма
(жирным выделены моменты времени, совпадающие с алгоритмом)

Comparison of detected raps using the algorithm with expert selection for the image base
(time points matching the algorithm are in bold)

$t, 10^{-2}, c$								
0	150	225	290	400	500	700	1150	1200
1450	1625	1800	1970	2120	2430	2620	2790	2845
3020	3130	3440	3510	3585	3630	3680	3715	3760
3840	4000	4075	4220	4325	4360	4515	4700	4750
4860	4885	5115	5200	5270	5470	5600	5730	5950
6080	6260	6420	6500	6710	6915	7090	7190	7300
7330	7445	7580	7690	7805	8000	8150	8280	8478
8530	8810	8880						




Рис. 7. Распределение рэмп-структур по длительности (t),
выделенных с использованием нейронной сети.

Fig. 7. Distribution of ramp-structures by duration (t) extracted using neural network.




Рис. 8. Примеры отсутствующих в списке эксперта рэмпов, которые определила нейронная сеть (моменты времени a — 3,60; 4,50; 4,55; b — 8,60; 9,35; 9,55 с).

Fig. 8. Examples of missing ramps in the expert's list, which were identified by the neural network (time moments a — 3,60; 4,50; 4,55; b — 8,60; 9,35; 9,55 s).

Тестовое применение нейронной сети позволяет обнаружить большее число мелких рэмп-структур (табл. 4), которые составляют более крупные, найденные первым способом. Определяемые нейронной сетью рэмп-структуры пополняют мелкие образы, которые отсутствуют в базе образов и в алгоритмическом способе определения. Примеры типичных структур, отсутствующих в базе, представлены на рис. 8. Нейронная сеть определила почти все точки с рэмп-структурами, выделенными с использованием алгоритмического метода.

Таблица 4

Сравнение выявленных рэмпов, выбранных экспертом из базы образов, с использованием алгоритма (жирным выделены моменты времени, совпадающие с выбором нейронной сети)

Comparison of detected ramps using the algorithm with expert selection for the image base (time moments coinciding with the neural network selection are marked in bold)

$t, 10^{-2}, \text{с}$								
0	150	225	290	400	500	700	1150	1200
1450	1625	1800	1970	2120	2430	2620	2790	2845
3020	3130	3440	3510	3585	3630	3680	3715	3760
3840	4000	4075	4220	4325	4360	4515	4700	4750
4860	4885	5115	5200	5270	5470	5600	5730	5950
6080	6260	6420	6500	6710	6915	7090	7190	7300
7330	7445	7580	7690	7805	8000	8150	8280	8478
8530	8810	8880						

Заключение

Конвективные движения над нагретой поверхностью отмечаются чередованием подъемов разных объемов прогретого воздуха. Под влиянием ветра эти тепловые структуры приобретают несимметричную форму (подобно пламени свечи на ветру). Соответственно, при фиксации данных, когда эти структуры переносятся ветром через измерительный датчик, отмечаются треугольные несимметричные сигналы, называемые рэмпам. Их число и амплитуда определяют свойства теплового потока. Значительные объемы данных пульсационных высокочастотных измерений требуют автоматизации процесса их обработки с целью поиска и исследования свойств таких структур.

Для анализа исходных данных измерений температуры с частотой 1000 Гц применены два метода: алгоритмический и нейросетевой.

Первый метод основан на статистической обработке данных с последующей фильтрацией в соответствии с конкретным алгоритмом.

Второй метод предполагает представление рэмп-структур в виде двумерных массивов по типу изображений. Далее решается задача распознавания образов с применением нейронной сети. Построена база образов, в которой помимо исходных данных имеются разностные значения величин с разным шагом по аналогии с использованием построения структурных функций. На первом этапе бралась пара исходный сигнал и минимальное смещение. Обучение двухслойной нейронной сети на относительно небольшой базе изображений (около 1000) дает ошибку 12 %.

Применение алгоритмического метода позволяет при подобранных параметрах определять рэмп-структуры определенного размера, зависящего от исходных параметров. Нейронная сеть позволяет определять рэмп-структуры трех типов: вершинами вверх, вершинами вниз и не являющиеся рэмпам.

При сравнении с алгоритмическим методом выявлено, что нейронная сеть выбирает в три раза больше рэмп-структур, включая выбранные первым методом, а также большинство рэмпов из базы образов. Также появляются новые мелкие рэмпы с временной длительностью около 0,1 с. Нейронная сеть отработала в тестовом режиме с ограниченным функционалом и небольшой базой образов, но понятно, что в целом она применима для поиска рэмпов.

Использование подобных методик анализа больших данных необходимо для изучения пространственной структуры теплового потока. Определение рэмп-структур позволит использовать автоматизацию процессов обработки больших объемов высокочастотных измерений и получения данных об их статистических распределениях по размерам и интенсивности, необходимых для оценок интенсивности и скорости вертикального выноса пылевого аэрозоля с аридных и субаридных территорий.

Список литературы

1. Krishnamurti R., Howard L. N. Large-scale flow generation in turbulent convection // Proceedings of the National Academy of Sciences. 1981. Vol. 78(4). P. 1981—1985. doi: 10.1073/pnas.78.4.198.

2. Chkhetiani, O. G., Gledzer, E. B., Artamonova, M. S., Iordanskii, M. A. Dust Resuspension under Weak Wind Conditions: Direct Observations and Model // *Atmospheric Chemistry and Physics*, 2012. V. 12(11). P. 5147—5162. doi: 10.5194/acp-12-5147-2012.
3. Garai A., Pardyjak E., Steeneveld G. et al. Surface temperature and surface-layer turbulence in a convective boundary layer // *Boundary-layer meteorology*. 2013. V. 148. P. 51—72. doi: 10.1007/s10546-013-9803-4.
4. Frisch A. S., Businger J. A. A study of convective elements in the atmospheric surface layer // *Boundary-Layer Meteorology*. 1973, V. 3(3). P. 301—328. doi: 10.1007/BF00736183.
5. Малиновская Е. А., Чхетиани О. Г., Голицын Г. С., Лебедев В. А. О вертикальном распределении пылевого аэрозоля в условиях слабых и умеренных ветров // *Доклады Академии Наук. Науки о Земле*. 2023. Т. 509. Вып. 2. С. 250—258. doi: 10.31857/S0002351523050085.
6. Koprov B. M., Zubkovsky S. L., Koprov V. M. et al. Statistics of air temperature spatial variability in the atmospheric surface layer // *Boundary-layer meteorology*. 1998, V. 88(3). P. 399—423. doi: 10.1023/A:1001517403557.
7. Malinovskaya E. A., Chkhetiani O. G., Azizyan G. V. On the Structure of Temperature Pulsations near the Surface under Convective Conditions // *Doklady Earth Sciences*. 2024. V. 516(1). P. 888—895. doi: 10.1134/S1028334X24601159.
8. Snyder R. L., Spano D., Pawu K. T. Surface renewal analysis for sensible and latent heat flux density // *Boundary-Layer Meteorology*. 1996. V. 77. C. 249—266. doi: 10.1007/BF00123527.
9. Zhou S. Q., Xie Yi.Ch., Sun Ch. et al. Statistical characterization of thermal plumes in turbulent thermal convection // *Physical Review Fluids*. 2016. V.1(5). P. 054301. doi: 10.1103/PhysRevFluids.1.054301.
10. Сирота А. А., Митрофанова Е. Ю., Милованова А. И. Анализ алгоритмов поиска объектов на изображениях с использованием различных модификаций сверточных нейронных сетей // *Вестник ВГУ. Серия: Системный анализ и информационные технологии*. 2019. № 3. С. 123—137. doi: 10.17308/sait.2019.3/1313.
11. Egmont-Petersen M., de Ridder D., Handels H. Image processing with neural networks—a review // *Pattern recognition*. 2002. № 35(10). P. 2279—2301. doi: 10.1016/S0031-3203(01)00178-9.
12. Aguilar-Fuertes J. J., Noguero-Rodriguez F., Jaen Ruiz J. C. et al. Tracking turbulent coherent structures by means of neural networks // *Energies*. 2021. № 14(4). P. 984—998. doi: 10.3390/en14040984.
13. Wan R., Mei Sh., Wang J. et al. Multivariate temporal convolutional network: A deep neural networks approach for multivariate time series forecasting // *Electronics*. 2019. №8.8. P. 876—894. doi: 10.3390/electronics8080876.
14. Mikhaylov K., Rigopoulos S., Papadakis G. Three-dimensional characterisation of macro-instabilities in a turbulent stirred tank flow and reconstruction from sparse measurements using machine learning methods // *Chemical Engineering Research and Design*. 2023. №196. P. 276—296. doi: 10.1016/j.cherd.2023.06.044.
15. Schmekel D., Alcántara-Ávila F., Hoyas S. et al. Predicting coherent turbulent structures via deep learning // *Frontiers in Physics*. 2022. №10. P. 888832. doi: 10.3389/fphy.2022.888832.
16. Ростовцев В. С. Искусственные нейронные сети. Киров: Изд-во ВятГУ, 2014. 208 с.

References

1. Krishnamurti R., Howard L. N. Large-scale flow generation in turbulent convection. *Proceedings of the National Academy of Sciences*. 1981; 78(4): 1981—1985. doi: 10.1073/pnas.78.4.198.
2. Chkhetiani O. G., Gledzer E. B., Artamonova M. S., Iordanskii M. A. Dust Resuspension under Weak Wind Conditions: Direct Observations and Model. *Atmospheric Chemistry and Physics*. 2012; 12(11):5147—5162. doi: 10.5194/acp-12-5147-2012.
3. Garai A., Pardyjak E., Steeneveld G. et al. Surface temperature and surface-layer turbulence in a convective boundary layer. *Boundary-layer meteorology*. 2013; 148: 51—72. doi: 10.1007/s10546-013-9803-4.
4. Frisch A. S., Businger J. A. A study of convective elements in the atmospheric surface layer. *Boundary-Layer Meteorology*. 1973; 3(3). 301—328. doi: 10.1007/BF00736183.
5. Malinovskaya E. A., Chkhetiani O. G., Golistyn G. S., Lebedev V. A. Stability of the Vertical Distribution of Dust Aerosol in Light and Moderate Winds. *Doklady Akademii Nauk. Nauki o Zemle = Izvestiya*,

- Atmospheric and Oceanic Physics*. 2023; 59(5):(623—634). doi: 10.31857/S0002351523050085. (In Russ.).
6. Koprov B. M., Zubkovsky S. L., Koprov V. M. et al. Statistics of air temperature spatial variability in the atmospheric surface layer. *Boundary-layer meteorology*. 1998; 88(3). 399—423. doi: 10.1023/A:1001517403557.
 7. Malinovskaya E. A., Chkhetiani O. G., Azizyan G. V. On the Structure of Temperature Pulsations near the Surface under Convective Conditions. *Doklady Earth Sciences*. 2024; 516(1): (888—895). doi: 10.1134/S1028334X24601159.
 8. Snyder R. L., Spano D., Pawu K. T. Surface renewal analysis for sensible and latent heat flux density. *Boundary-Layer Meteorology*. 1996; 77: 249—266. doi: 10.1007/BF00123527.
 9. Zhou S. Q., Xie Yi.Ch., Sun Ch. et al. Statistical characterization of thermal plumes in turbulent thermal convection. *Physical Review Fluids*. 2016; 1(5). 054301. doi: 10.1103/PhysRevFluids.1.054301.
 10. Sirota A. A., Mitrofanova E. Yu., Milovanova A. I. Analysis of algorithms for searching objects in images using different modifications of convolutional neural networks. *Vestnik VSU. Series: System Analysis and Information Technologies*. 2019;(3):(123—137). (In Russ.). doi: 10.17308/sait.2019.3/1313.
 11. Egmont-Petersen M., de Ridder D., Handels H. Image processing with neural networks—a review. *Pattern recognition*. 2002; 35(10). 2279—2301. doi: 10.1016/S0031-3203(01)00178-9.
 12. Aguilar-Fuentes J. J., Noguero-Rodriguez F., Jaen Ruiz J. C. et al. Tracking turbulent coherent structures by means of neural networks. *Energies*. 2021; 14(4): 984—998. doi: 10.3390/en14040984.
 13. Wan R. Mei Sh., Wang J. et al. Multivariate temporal convolutional network: A deep neural networks approach for multivariate time series forecasting. *Electronics*. 2019; (8.8):(876—894). doi: 10.3390/electronics8080876
 14. Mikhaylov K., Rigopoulos S., Papadakis G. Three-dimensional characterisation of macro-instabilities in a turbulent stirred tank flow and reconstruction from sparse measurements using machine learning methods. *Chemical Engineering Research and Design*. 2023; (196):(276—296). doi: 10.1016/j.cherd.2023.06.044
 15. Schmekel D., Alcántara-Ávila F., Hoyas S. et al. Predicting coherent turbulent structures via deep learning. *Frontiers in Physics*. 2022; 10. 888832. doi: 10.3389/fphy.2022.888832.
 16. Rostovtsev V.S. *Iskusstvennye neyronnye seti = Artificial neural networks*. Kirov: Izd-vo VyatSU. 2014. 208 p. (In Russ.).

Информация об авторах

Малиновская Елена Александровна, кандидат физико-математических наук, Институт физики атмосферы им. А. М. Обухова РАН, лаборатория геофизической гидродинамики, ст. научный сотрудник, elen_am@inbox.ru.

Калинин Савелий Дмитриевич, Российский государственный гидрометеорологический университет, кафедра высшей математики и физики, студент; Институт физики атмосферы им. А. М. Обухова РАН, лаборатория геофизической гидродинамики, стажер-исследователь, fixinit8@yandex.ru.

Зайцева Ирина Владимировна, кандидат физико-математических наук, Российский государственный гидрометеорологический университет, кафедра высшей математики и физики, зав. кафедрой; Институт физики атмосферы им. А. М. Обухова РАН, лаборатория геофизической гидродинамики, ведущий математик, ziki@mail.ru.

Information about authors

Malinovskaya Elena Alexandrovna, Candidate of Physics and Mathematics, A. M. Obukhov Institute of Atmospheric Physics, Russian Academy of Sciences, Laboratory of Geophysical Hydrodynamics, Senior Researcher.

Kalinin Saveliy Dmitrievich, Russian State Hydrometeorological University, Department of Higher Mathematics and Physics, student; A. M. Obukhov Institute of Atmospheric Physics, Russian Academy of Sciences, Laboratory of Geophysical Hydrodynamics, Research Intern.

Zaitseva Irina Vladimirovna, Candidate of Physics and Mathematics, Russian State Hydrometeorological University, head of department, Department of Higher Mathematics and Physics; A. M. Obukhov Institute of Atmospheric Physics, Russian Academy of Sciences, Laboratory of Geophysical Hydrodynamics, Leading Mathematician.

Конфликт интересов: конфликт интересов отсутствует.

Статья поступила 12.07.2024

Принята к печати 28.08.2024

The article was received on 12.07.2024

The article was accepted on 28.08.2024