

Алгоритм восстановления оптической толщины однослойной горизонтально неоднородной облачности с использованием нейронной сети

Т. В. Русскова, А. В. Скороходов

Институт оптики атмосферы им. В. Е. Зуева, Томск, 634055, Россия
E-mails: btv@iao.ru, vazime@yandex.ru

Представлена нейросетевая методика восстановления оптической толщины горизонтально неоднородной облачности. Для обучения нейронной сети использованы наборы интенсивности отражённого солнечного излучения в видимой и коротковолновой инфракрасной областях спектра. Моделирование переноса излучения осуществлялось в морской слоисто-кучевой облачности методом Монте-Карло, а для генерации облачных полей применялась фрактальная модель на основе метода ограниченных каскадов. Отличие представленной методики от классических схем IPA/NIPA (*англ.* Independent Pixel Approximation/Nonlocal Independent Pixel Approximation) заключается в том, что она позволяет интегрировать радиометрические данные в необходимом количестве и учитывать эффекты горизонтального переноса радиации не только в пределах целевого пикселя, но и смежных областях. Кроме того, без существенного увеличения трудоёмкости алгоритма в вектор восстанавливаемых характеристик могут быть включены дополнительные параметры, в частности показатель относительной неоднородности оптической толщины и балл облачности в пределах пикселя наблюдения. В работе исследуется зависимость точности решения обратной задачи от архитектуры и гиперпараметров нейронной сети, объёма и структуры обучающей выборки. Достигнуты высокие коэффициенты корреляции (0,95–0,99) между исходными и восстановленными значениями оптической толщины при фиксированном эффективном радиусе облачных частиц. Показано, что при использовании дополнительной информации об отражённой радиации в смежных пикселях и снижении пространственного разрешения в пределах рассматриваемого диапазона среднеквадратическое отклонение оптической толщины падает, а коэффициент корреляции возрастает.

Ключевые слова: дистанционное зондирование, разорванная облачность, оптическая толщина, обратные задачи, численное моделирование, перенос солнечного излучения, метод Монте-Карло, нейронные сети

Одобрена к печати: 11.12.2023

DOI: 10.21046/2070-7401-2024-21-1-88-105

Облачность — один из ключевых климатообразующих факторов. Отражая приходящее коротковолновое излучение обратно в космическое пространство, поглощая или в значительной степени рассеивая его, облака оказывают существенное влияние на формирование радиационного баланса Земли. Ввиду высокой вариативности оптико-микроструктурных свойств, многообразия типов и форм облачности определение функциональной связи между характеристиками облаков и наблюдаемыми энергетическими характеристиками — чрезвычайно сложная задача. В то же время информация об облачности в глобальном масштабе, источником которой служат результаты дистанционного зондирования Земли (ДЗЗ) из космоса, выступает важным звеном в решении задач мониторинга, прогноза погоды и климата. Высокий интерес к исследованиям в области интерпретации данных спутникового зондирования сохраняется также благодаря расширению функционала и повышению точности измерительной аппаратуры, влекущих за собой изменения в требованиях к детализированности имитационного моделирования, потребность в совершенствовании имеющихся, а также разработке альтернативных методов решения обратных задач.

На сегодняшний день имеется целый ряд технологий обработки данных пассивного зондирования атмосферы с целью оценки тех или иных параметров облачности, однако в большинстве своём они базируются на традиционных подходах. Для восстановления оптической

толщины облаков (ОТО) и эффективного радиуса облачных капель реализованы классические способы обращения данных измерений рассеянной радиации (King, 1987). Базовым среди них считается биспектральный подход, применяемый при обработке данных измерений спектрорадиометра MODIS (*англ.* Moderate Resolution Imaging Spectroradiometer) (Platnick et al., 2003). Метод предполагает использование LUT-таблиц (*англ.* look-up-table) с предварительно рассчитанными значениями интенсивности восходящего излучения в двух спектральных каналах из SWIR- и VIS/NIR-диапазонов (*англ.* Short-Wave InfraRed/VISible/Near Infrared): соответственно 1,63/2,13/3,79 и 0,65/0,86/1,24 мкм. В VIS/NIR-интервале процессы рассеяния солнечного излучения на частицах облаков являются доминирующими, определяя высокую чувствительность интенсивности излучения к ОТО. В SWIR-диапазоне наблюдается рост поглощательной способности газовых компонент атмосферы, а также снижение доли рассеянного излучения: альbedo однократного рассеяния уменьшается, с увеличением размера капель фактор асимметрии индикатрисы рассеяния растёт, что приводит к сильной зависимости отражённой радиации от радиуса облачных частиц.

Особенностью базового подхода представляется использование в пределах каждого пикселя не точных, а приближённых значений характеристик отражённой радиации, полученных с помощью IPA-приближения (Cahalan et al., 1994b). В классическом его варианте радиационные характеристики R_{IPA} (отражённое излучение) и T_{IPA} (пропущенное излучение) рассчитываются с использованием простых аппроксимационных формул в предположении мезомасштабной плоскопараллельной сплошной однородной облачности для каждого пикселя спутниковых данных. Эта мера значительно снижает трудоёмкость вычислений, однако соответствие результатов расчётов и измерений существенно зависит от условий эксперимента. Обоснованность использования такой аппроксимации всё ещё вызывает вопросы (Buriez et al., 2001; Loeb et al., 1997).

В рамках IPA-приближения расчёты радиационных характеристик осуществляют для каждого пикселя отдельно, пренебрегая эффектами горизонтального переноса излучения в неоднородной облачности, который становится одной из причин неоднозначной зависимости между оптической толщиной и радиационными свойствами пикселя (Titov, 1998). Ошибки, обусловленные пренебрежением горизонтальным переносом, могут превышать 50 % (Cahalan et al., 1994a; Marshak et al., 1998) даже при зенитальном положении Солнца. Установлено, что использование IPA-приближения приводит к большим расхождениям в значениях ОТО на масштабах менее 0,5–1,0 км. Соответствие между результатами моделирования и данными ДЗЗ достигается лишь при условии использования в радиационных кодах значений ОТО, соответствующих меньшим (по сравнению с наблюдаемыми) значениям водности (Barker, 1996; Cahalan et al., 1994a). Вопрос о возможности использования IPA для отличных от слоистообразных типов облачности до сих пор представляет собой предмет дискуссий. В первую очередь это касается облаков вертикального развития, где закономерности переноса излучения в значительной мере определяются 3D-эффектами (Benner, Evans, 2001; Zhang, Platnick, 2011).

Идея приблизить IPA-результаты к результатам громоздких, но более точных вычислений методом Монте-Карло с сохранением простоты и быстродействия IPA-приближения привела к разработке его модификации — аппроксимации NIPA (Marshak et al., 1998). NIPA не ограничивается локальными значениями ОТО и учитывает горизонтальный перенос излучения между пикселями благодаря использованию операции свёртки R_{IPA} с функцией Грина, рассчитанной методом Монте-Карло. NIPA оказывает на результаты вычислений сглаживающий эффект за счёт учёта многократного рассеяния света. Несмотря на очевидные достоинства, данная модификация всё ещё не свободна от недостатков: предложенная коррекция по-прежнему не зависит от направления падения солнечных лучей и, как следствие, не учитывает эффекты затенения (Loeb, Davies, 1996); NIPA не позволяет получать значения R_{IPA} выше единицы (вследствие конвертации горизонтальных потоков из пикселя уходит больше энергии, чем входит в него), что часто наблюдается при низком положении Солнца и наиболее изменчивых облаках; предполагается однородность свойств облаков по вертикали, однако эффекты затенения могут оказывать значительное влияние на радиаци-

онные характеристики в облаках с вертикальной флуктуацией оптических свойств, например кучево-дождевых.

Накопление больших объёмов данных наблюдений наряду с перманентно возрастающим уровнем вычислительных возможностей способствовало появлению альтернативных методов, состоящих в использовании преимуществ искусственного интеллекта для решения задач, в которых сложность связей между наблюдаемыми характеристиками и определяемыми параметрами исследуемого объекта или недостаточная формализованность данных затрудняет применение классических методов обработки, что отражается на точности и/или быстродействии поиска решений. Сегодня методы машинного обучения применяются повсеместно, в том числе для решения обратных задач оптики и физики атмосферы. Если не принимать во внимание достигнутые успехи в решении задач классификации и распознавания объектов на спутниковых изображениях, то среди российских исследований количество работ, посвящённых решению обратных задач с использованием нейронной сети, пока невелико (Грибанов и др., 2009; Матвиенко и др., 2018; Nikitin et al., 2020 и др.), а с использованием данных среднего и низкого пространственного разрешения они и вовсе отсутствуют. Попытки восстановить оптико-микроструктурные характеристики облаков по данным ДЗЗ с помощью нейросетевых технологий отражены лишь в зарубежных публикациях Т. Фора (*фр.* T. Faure) (Faure et al., 2001), С. Корнет (*фр.* C. Cornet) (Cornet et al., 2004), Р. Окамура (*англ.* R. Okamura) (Okamura et al., 2017) и др. Для решения задачи требуется обучить нейронную сеть с использованием реалистичных моделей облачных полей и результатов 3D-моделирования переноса излучения в облачной атмосфере. Подход позволяет интегрировать радиометрические данные с учётом эффектов горизонтального переноса радиации не только в пределах целевого пикселя, но и в смежных областях. Анализ предварительных расчётов показал, что результаты восстановления ОТО новым способом более точны по сравнению с результатами, полученными в рамках действующего LUT-подхода (Cornet et al., 2005).

Цель настоящего исследования состояла в реализации нейросетевого подхода и оценке его применимости к восстановлению оптической толщины горизонтально неоднородной облачности с помощью имитационного моделирования мультиспектральных полей отражённой солнечной радиации. Проработка алгоритмического аппарата на модельной задаче позволит выявить приоритетный вектор реализации и упростить в дальнейшем адаптацию алгоритма к данным натурных измерений, выполненных одним из действующих в настоящее время спектрометрических спутникового базирования, среди которых следует отметить MODIS (<https://modis.gsfc.nasa.gov/>), VIIRS (*англ.* Visible Infrared Imaging Radiometer Suite) (<https://www.earthdata.nasa.gov/sensors/viirs>), AGRI (*англ.* Advanced Geosynchronous Radiation Imager) (<https://fy4.nsmc.org.cn/nsmc/en/instrument/AGRI.html>). В настоящей работе входные параметры модельной задачи подбирались в соответствии с характеристиками сканера MODIS.

Постановка задачи и метод её решения

Рассматривается плоскопараллельная, вертикально неоднородная модель атмосферы с однослойной горизонтально неоднородной слоистообразной облачностью. Предполагается, что оптические характеристики аэрозольного и молекулярного светорассеяния, газового поглощения излучения, а также альbedo подстилающей поверхности известны априори. Необходимо по имитационным данным пассивных спутниковых измерений интенсивности отражённой солнечной радиации в направлении в надир определить оптические характеристики облаков в пределах каждого пикселя. Решение обратной задачи в рамках нейросетевого подхода включает в себя: а) формирование большого набора независимых образцов — двумерного распределения интенсивности отражённого излучения в поле сплошной и разорванной оптически неоднородной облачности, б) обучение нейронной сети с использованием этих образцов. Обучение нейронной сети заключается в коррекции весовых коэффициентов нейронов таким образом, чтобы при предъявлении ей схожих по значениям полей отражённой радиации она относила их к определённым значениям оптических характеристик целевого пикселя с минимальной ошибкой.

Модель облачного поля

Для моделирования независимых реализаций горизонтально неоднородной облачности использована фрактальная модель на основе метода ограниченных каскадов, предложенная в работах (Cahalan et al., 1994a; Marshak et al., 1998) для имитации полей морских слоисто-кучевых облаков, являющихся одними из наиболее изученных и распространённых типов облаков. Отражая от 30 до 60 % приходящей радиации, они оказывают преимущественно охлаждающий эффект и играют важную роль в поддержании радиационного баланса Земли (Schneider et al., 2019). Фрактальный подход позволяет учесть изменчивость водозапаса LWP (*англ.* Liquid Water Path) таких облаков в широком диапазоне его значений, который, в свою очередь, связан с оптической толщиной τ и эффективным радиусом капель r_{eff} соотношением:

$$\tau = 3LWP / (2\rho r_{eff}),$$

где ρ — плотность воды, кг/м^3 . Каскадная модель имеет степенной спектр и плотность вероятности LWP, соответствующие морским слоисто-кучевым облакам. Сильной стороной модели является то, что различные структуры распределения жидкой воды (а значит, и двумерного распределения τ), пространственные корреляции которых соответствуют наблюдаемым, можно получать путём вариации сравнительно легко измеряемых входных параметров.

Для генерации горизонтального распределения оптической толщины облачного поля (эффективный радиус фиксирован) со средним значением $\langle \tau \rangle$ используется трёхпараметрическая ограниченная каскадная модель на плоскости, для которой

$$0 < \tau_{\min} \leq \tau \leq \tau_{\max} < \left\langle \tau \right\rangle \exp \left(\frac{1-2p}{1-2^{-H}} \right) < \infty,$$

параметр p характеризует вариации оптической толщины; H — параметр масштаба (Marshak et al., 1994). Рекуррентная процедура алгоритма построения каскадной модели может быть интерпретирована как последовательное перераспределение некоторой массы внутри квадрата $S = [0, T] \times [0, T]$ (Ельцов и др., 2008). Первоначально масса $\langle \tau \rangle T^2$ равномерно распределена по области S , затем происходит перераспределение этой массы по четырём меньшим квадратам площадью $S/4$ каждый (каскад уровня 1). Внутри каждого из четырёх квадратов происходит очередное перераспределение массы (каскад уровня 2 с общим числом квадратов $2^2 \times 2^2$). Каскад уровня l задан на разбиении множества S , состоящего из $2^l \times 2^l$ квадратов. При такой интерпретации каскады являются плотностью распределения массы. Свойства модели полностью определяются весами $V_{l,i}(x, y)$, $i = 1, \dots, 4$, которые моделируются случайной перестановкой из набора чисел

$$\begin{cases} V_{l,1}(x, y) = 1 + (1 - 2p_1) / 2^{(l-1)H}, \\ V_{l,2}(x, y) = 2 - V_{l,1}(x, y), \\ V_{l,3}(x, y) = 1 + (1 - 2p_2) / 2^{(l-1)H}, \\ V_{l,4}(x, y) = 2 - V_{l,3}(x, y) \end{cases}$$

таким образом, что выполняется равенство:

$$\sum_{i_1, i_2, \dots, i_l=1}^4 V_{l,i_1}(x, y) V_{l,i_2}(x, y) \dots V_{l,i_l}(x, y) = 4^l, \quad l > 1.$$

В результате выполнения описанной процедуры формируется сплошное облачное поле с горизонтально неоднородным распределением оптической толщины. Для построения поля разорванной облачности необходимо обнулить значения некоторых из его ячеек. Ввиду отсутствия обоснованной теории перехода от 2D-распределения ОТО в сплошном облачном поле к разорванному, для конструирования последнего был использован подход из работы (Barker, Davies, 1992):

$$\tau_{br}(x, y) = \gamma [\tau(x, y) - \varepsilon, 0],$$

где $\varepsilon > 0$, $\gamma > 0$. Предполагается, что геометрическая толщина облаков фиксирована, а коэффициент ослабления излучения облачными частицами не изменяется по высоте.

Модель переноса излучения

Расчёт интенсивности восходящего излучения на уровне верхней границы атмосферы в поле неоднородной облачности осуществлялся методом Монте-Карло с учётом всех кратностей рассеяния (Марчук и др., 1976). Моделирование поглощения излучения атмосферными газами реализовано на основе предположения, что акты поглощения и рассеяния оптического излучения независимы друг от друга. Учёт молекулярного поглощения в каждой точке столкновения осуществляется введением статистического веса фотона, который определяется функцией пропускания и убывает по мере увеличения пройденного пути (Радиация..., 1981). Функция пропускания атмосферными газами представляется в виде короткого ряда экспонент (метод k -распределения), через параметры разложения которого учитывается также спектральная чувствительность каналов. При расчётах в инфракрасной области спектра учёт вклада теплового излучения в суммарную интенсивность не предусмотрен, поскольку предполагается, что результаты спутниковых измерений будут скорректированы соответствующим образом до того, как будут использованы при решении обратной задачи. При вылете фотона за пределы области моделирования применяются периодические граничные условия.

Массовые расчёты интенсивности отражённой радиации в неоднородной облачности являются наиболее трудоёмким этапом реализации подхода, поскольку стохастическая природа метода Монте-Карло обуславливает высокие временные затраты на вычисления. В то же время использование параллелизма алгоритмов метода может существенно снизить его трудоёмкость (Русскова, 2017). Следует также отметить, что банк данных рассчитывается лишь единожды, а обучение нейронной сети и последующая обработка измерений с её помощью занимают незначительное время.

Входные параметры для формирования базы данных

С помощью описанной выше фрактальной модели было сгенерировано множество независимых реализаций двумерных облачных полей с уровнем каскада $l = 7$, что обеспечило получение облачных реализаций для области, состоящей из 128×128 пикселей (более высокий уровень l приведёт к чрезмерной детализированности поля и повышенным требованиям к имеющимся временным и вычислительным ресурсам при моделировании переноса излучения, а более низкий — к слабой вариативности оптической толщины в пределах поля). «Базовый» размер пикселей d полагается равным 50 м, так чтобы на их основе можно было построить облачную реализацию с меньшим разрешением. Параметры каскадной модели H , p_1 , p_2 принимались равными $1/3$, $0,24$ и $0,36$ соответственно, что обеспечило изменение распределения жидкой воды в соответствии со степенным спектром. Облачные реализации были сгенерированы для различных значений балла облачности в диапазоне от $0,5$ до $1,0$ ($0,5$; $0,6$; $0,7$; $0,8$; $0,9$; $1,0$), а средняя по области моделирования оптическая толщина облаков варьировалась от 5 до 20 (5 , 10 , 15 , 20) (значения указаны для спектрального канала $\lambda = 0,55$ мкм). Для каждой комбинации этих параметров моделировалось по пять независимых облачных реализаций, все они были использованы в дальнейших радиационных расчётах. Максимальное значение ОТО в пределах пикселя было ограничено величиной $\tau_{\max} = 100$. На гистограмме (рис. 1, см. с. 93) представлено статистическое распределение ОТО из обучающей выборки.

Эффективный радиус облачных частиц принимался равным 11 мкм, что близко к верхней границе значений, наблюдаемых для слоисто-кучевых облаков (Magaritz-Rohen et al., 2016). Индикатриса и альbedo однократного рассеяния излучения облачными каплями рассчитывались по формулам теории Ми. В расчётах использованы параметры модели ОРАС

(англ. Optical Properties of Aerosols and Clouds) для облаков типа *stratus maritime* (Hess et al., 1998). Геометрическая толщина облачного слоя полагалась равной 0,3 км, а его нижняя граница — 0,7 км.

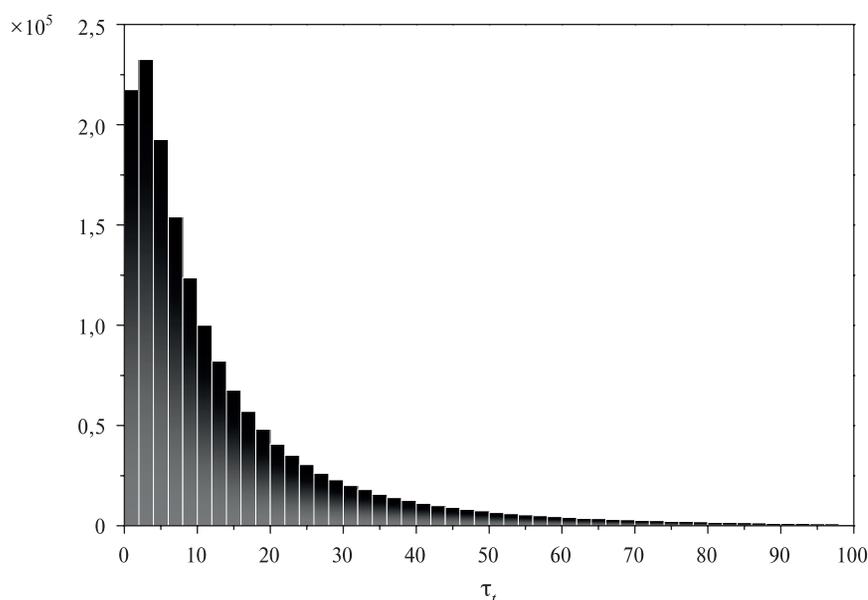


Рис. 1. Частотное распределение значений ОТО из обучающей выборки

Модель атмосферы состоит из аэрозольных и рэлеевских частиц, а также газов, характеристики которых имеют вертикальную изменчивость и задаются в виде кусочно-постоянных функций. Оптические свойства аэрозоля определяются тремя типами смесей частиц: *maritime summer* (от 0 до 2 км), *continental* (от 2 до 12 км) и *stratospheric* (от 12 до 100 км), описанными в работе (Hess et al., 1998). Эффективные коэффициенты молекулярного поглощения рассчитывались на основе базы данных HITRAN-2008 (High Resolution Transmission) (Rothman et al., 2009) и модели континуума MT_CKD2.4 (<http://rtweb.aer.com>).

Предполагается, что зондирование атмосферы осуществляется в надир. Рассматривается подстилающая поверхность, которая полностью поглощает солнечные лучи, что позволяет более детально исследовать эффекты облачности. Интенсивность отражённого излучения на уровне верхней границы атмосферы рассчитывалась для зенитного угла Солнца 60° и спектральных каналов сканера MODIS 0,55; 0,64; 0,87; 1,64; 2,13 и 3,7 мкм в пределах каждого пикселя с разрешением 50 м. Результаты радиационных расчётов усреднены в пределах 250, 500 и 1000 м в соответствии с пространственным разрешением MODIS. Каждую из таких областей будем называть «пикселем наблюдения». В процессе усреднения значений интенсивности вычисляется также величина её среднеквадратического отклонения σ_r .

Для каждой облачной сцены при численном моделировании переноса излучения было сгенерировано по 600 млн траекторий фотонов, так чтобы на верхнюю границу каждого пикселя попадало примерно по 36 тыс. фотонов. Указанного количества достаточно для обеспечения точности расчётов не менее 95 %. Будем рассматривать среднеквадратическую ошибку вычисления интенсивности излучения в качестве погрешности или шума соответствующих измерений.

На рис. 2 (см. с. 94) приведён пример моделирования поля оптической толщины облаков с помощью каскадной модели (нижний ряд) и соответствующего ему двумерного распределения интенсивности отражённой радиации на уровне верхней границы атмосферы при разном пространственном разрешении (верхний ряд): исходном (50 м) и производных от исходного (250 и 500 м). Проиллюстрированные результаты получены для спектрального канала 0,87 мкм при балле облачности 0,7 и среднем значении ОТО, равным 20.

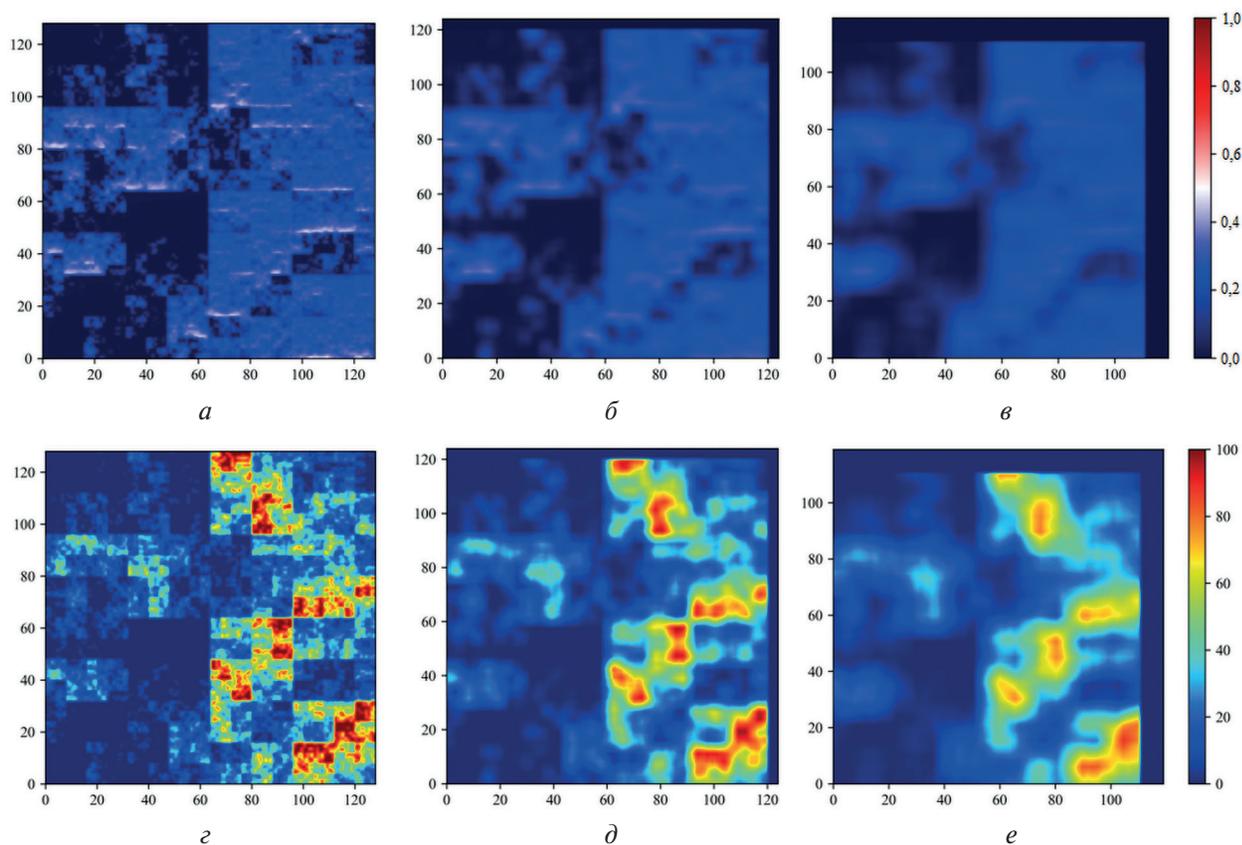


Рис. 2. 2D-распределение нормированных значений интенсивности отражённой радиации (верхний ряд) для сгенерированного поля оптической толщины облаков (нижний ряд) при разном пространственном разрешении: 50 м (а, г), 250 м (б, д) и 500 м (в, е)

Модель нейронной сети и выбор её гиперпараметров

Среди множества видов моделей машинного обучения для решения поставленной обратной задачи выбран многослойный персептрон, в котором каждый нейрон осуществляет линейную регрессию с последующим применением нелинейной функции активации. Результатом обучения нейронной сети на данных обучающей выборки становятся весовая матрица W и вектор коэффициентов смещения b . Обучающая выборка содержит m_0 пар $(a_{0,i}, q_i)$, $i = 1, \dots, m_0$, состоящих из входного вектора a_0 (спектральные характеристики отражённого излучения) и искомого вектора q (характеристики облачности). Функциональная связь между входным и выходным векторами k -го слоя выражается соотношением:

$$x_k = W_k a_{k-1} + b_k, \quad x_k = f_k(x_k),$$

где f_k — функция активации; W_k — весовая матрица; b_k — вектор смещения. Матрица весовых коэффициентов, а также вектор b определяются путём минимизации среднеквадратичной функции ошибки, представленной в виде суммы квадратов отклонений предсказанных значений от истинных:

$$f_L = \sum_{i=1}^{m_k} (a_{k,i} - q_i)^2,$$

где m_k — количество нейронов в k -м слое. На вход персептрона подаётся спектральная интенсивность излучения I_λ , нормированная с учётом всего диапазона возможных значений, а также среднеквадратическое отклонение σ_I на одной из длин волн:

$$a_{0,i} = \left(I_{\lambda_1}^0, I_{\lambda_2}^0, \dots, I_{\lambda_{N_\lambda}}^0, \sigma_I \right)_i, \quad i = \overline{1, m_0},$$

N_λ — количество спектральных каналов, используемых при моделировании. В качестве одного образца принимается пара векторов $(a_{0,i}, q_i)$, $i = 1, \dots, m_0$. Пусть целевой вектор q включает в себя три элемента: оптическую толщину τ , показатель относительной неоднородности облаков δ_τ и балл облачности c_f в пределах пикселя наблюдения:

$$q_i = \begin{pmatrix} \tau \\ \delta_\tau \\ c_f \end{pmatrix}_i, \quad i = \overline{1, m_0}.$$

Показатель относительной неоднородности определим как величину отношения среднеквадратического отклонения флуктуации оптической толщины σ_τ к среднему значению оптической толщины в пределах пикселя наблюдения: $\delta_\tau = \sigma_\tau / \langle \tau \rangle$. Величина δ_τ не является параметром модели облачного поля, а представляет собой результат статистического анализа. Привлечение к решению обратной задачи таких характеристик, как σ_f и σ_τ , позволяет учесть эффекты оптической неоднородности облаков.

Вся обучающая выборка разбивается на отдельные партии — мини-батчи, после предъявления которых происходит коррекция весовых коэффициентов сети. Отметим, что обучение нейронной сети осуществляется для каждого варианта пространственного разрешения отдельно. Всего в обучении задействовано до 1 млн образцов.

Для выбора оптимальной структуры нейронной сети и настройки её гиперпараметров были проведены соответствующие вычислительные эксперименты. При обучении моделей разной архитектуры было выявлено, что сеть с двумя скрытыми слоями по 50 и 15 нейронов в каждом обеспечивает наиболее высокую точность восстановления искомых характеристик при приемлемых временных затратах на обучение. Среди градиентных методов оптимизации наилучшую эффективность показал метод адаптивной оценки моментов Adam (англ. Adaptive Moment Estimation) (Пантелеев, Лобанов, 2019). В качестве функции активации была выбрана кусочно-постоянная функция «логистический сигмоид» (Николенко и др., 2022), исторически используемая в нелинейных персептронах. С целью сравнения были рассмотрены также функции ReLU, LeakyReLU, ELU и exponential. На рис. 3 продемонстрировано, что наилучшие показатели обучения достигаются при использовании логистического сигмоида. Обеспечивая медленную, но наилучшую сходимость функции потерь f_L (см. рис. 3а), логистический сигмоид приводит к наиболее высоким значениям функции точности f_A (см. рис. 3б).

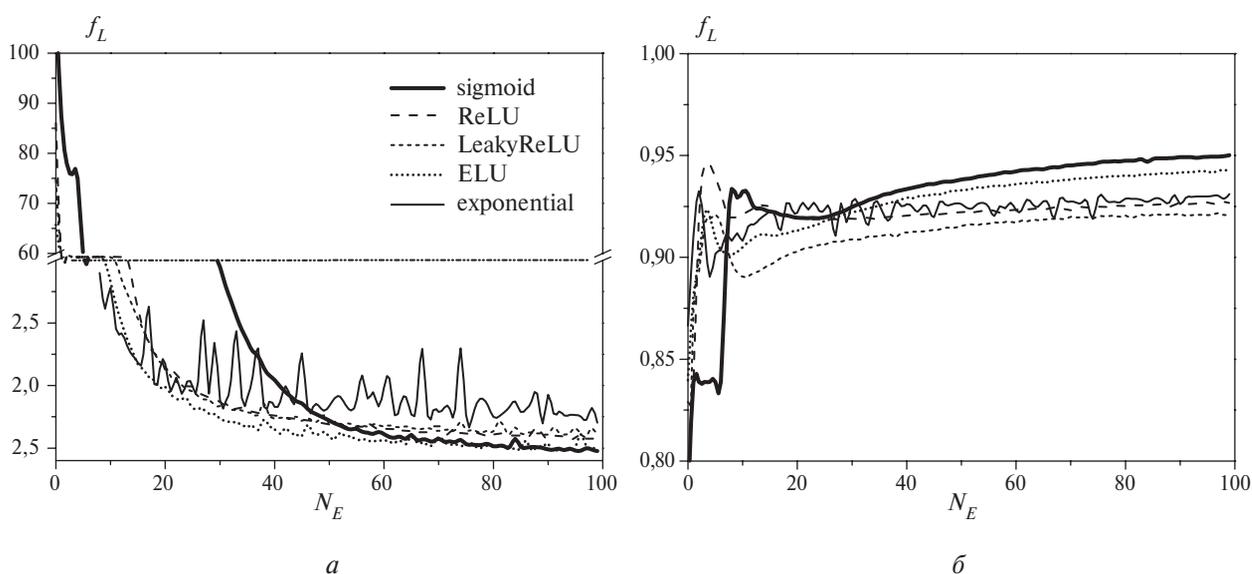


Рис. 3. Функция потерь (а) и функция точности (б), полученные при обучении нейросети на тренировочном множестве с использованием различных функций активации нейронов

Обсуждение результатов

На основе разработанного программного обеспечения была проведена серия численных экспериментов. В дополнение к коэффициенту корреляции для оценки степени соответствия между прогнозируемыми значениями оптической толщины и данными обучающей выборки рассчитывалось среднеквадратическое отклонение вида:

$$s_{\tau} = \sqrt{\frac{1}{m0} \sum_{i=1}^{m0} (\tau_{k,i} - \tau_i)^2},$$

где $\tau_{k,i}$ — прогнозируемое значение оптической толщины в k -м слое, соответствующее значению τ_i из обучающей выборки.

Одним из наиболее важных вопросов, касающихся реализации нейроалгоритма, является выбор такой комбинации спектральных каналов, которая бы обеспечила наиболее высокую точность восстановления искомым параметров. Известно, что эффекты, связанные с вариациями размеров облачных частиц, в наибольшей степени проявляются в инфракрасной области спектра. Поскольку на данном этапе исследований предполагается, что значение эффективного радиуса капель фиксировано в пределах всего облачного поля, то для решения задачи потребуется более узкий спектральный интервал.

В *табл. 1* приведены статистические характеристики: среднеквадратическое отклонение s_{τ} , коэффициенты корреляции r_{τ} , r_{δ} и r_c для τ , δ_{τ} и c_f соответственно, а также минимальное значение функции потерь f_L и максимальное значение функции точности f_A , которые были получены при разных комбинациях длин волн ($\lambda_1 = 0,55$ мкм, $\lambda_2 = 0,64$ мкм, $\lambda_3 = 0,87$ мкм, $\lambda_4 = 1,64$ мкм, $\lambda_5 = 2,13$ мкм, $\lambda_6 = 3,7$ мкм). Кроме того, в таблице представлены средние значения оптической толщины $\langle \tau_r \rangle$ и балла облачности $\langle c_{f,r} \rangle$, рассчитанные для всего облачного поля на основе их восстановленных значений. Для всех комбинаций используются одна и та же архитектура нейронной сети и одинаковые значения гиперпараметров. Средние значения оптической толщины $\langle \tau_i \rangle$ и балла облачности $c_{f,i}$ из обучающей выборки равны 15 и 0,6 соответственно.

Таблица 1. Статистические характеристики решения обратной задачи; $d = 500$ м

λ	s_{τ}	r_{τ}	r_{δ}	r_c	$\min\{f_L\}$	$\min\{f_A\}$	$\langle \tau_r \rangle$	$\langle c_{f,r} \rangle$
1. λ_1, λ_3	12,9	0,91	0,63	0,90	6,1	0,94	25,1	0,62
2. λ_1, λ_4	10,6	0,97	0,67	0,91	2,2	0,95	25,8	0,47
3. $\lambda_1, \lambda_4, \lambda_5$	7,5	0,98	0,58	0,83	2,1	0,95	22,6	0,29
4. λ_2, λ_3	13,6	0,91	0,64	0,90	7,1	0,95	25,7	0,57
5. λ_2, λ_4	7,0	0,98	0,66	0,93	2,0	0,94	21,9	0,52
6. λ_2, λ_5	4,1	0,98	0,62	0,97	1,8	0,96	17,6	0,60
7. λ_2, λ_6	5,3	0,96	0,62	0,97	3,5	0,96	17,1	0,65
8. λ_3, λ_4	4,1	0,98	0,64	0,85	1,9	0,95	13,7	0,39
9. λ_3, λ_5	5,5	0,98	0,61	0,96	2,2	0,95	12,9	0,70
10. λ_3, λ_6	4,8	0,96	0,59	0,97	4,4	0,95	14,7	0,79
11. $\lambda_2, \lambda_3, \lambda_4$	4,1	0,99	0,61	0,85	1,8	0,94	17,8	0,46
12. $\lambda_2, \lambda_3, \lambda_5$	4,3	0,99	0,58	0,96	1,9	0,94	14,9	0,70
13. $\lambda_3, \lambda_4, \lambda_5$	3,3	0,99	0,64	0,97	1,9	0,95	14,5	0,59
14. $\lambda_3, \lambda_4, \lambda_5, \lambda_6$	4,4	0,98	0,62	0,84	1,4	0,96	13,3	0,38

Для тех комбинаций длин волн, при использовании которых наблюдаются минимальные значения s_τ , r_τ и f_L , было построено статистическое распределение относительной ошибки ($\Delta\tau$, %) восстановления оптической толщины (рис. 4).

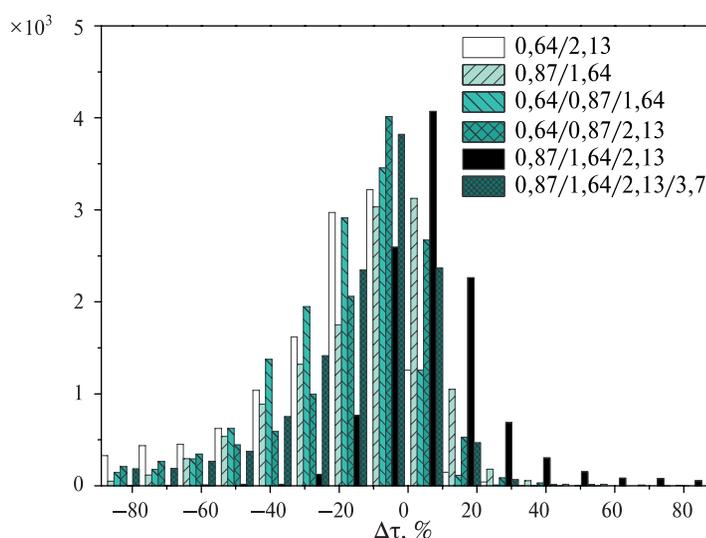


Рис. 4. Частотное распределение $\Delta\tau$ для разных комбинаций спектральных каналов

Сопоставление данных, представленных в табл. 1 и на рис. 4, позволяет выявить наиболее информативную комбинацию длин волн. Среди рассмотренных вариантов наилучшие показатели решения обратной задачи имеют место при выборе таких спектральных каналов, как 0,87; 1,64 и 2,13 мкм, которые и были использованы в дальнейших расчётах.

Результаты из табл. 1 были получены при решении обратной задачи непосредственно в пределах каждого целевого пикселя. Рассмотрим возможности нейронной сети при восстановлении параметров облачности с учётом информации, содержащейся в областях, смежных к целевому пикселю. Таким образом могут быть учтены эффекты, обусловленные горизонтальным переносом излучения между пикселями. С этой целью расширим вектор a_0 , добавив к его элементам спектральные значения интенсивности отражённой радиации смежных пикселей $X_j, j = 1, N_p$, в виде:

$$X = X_0 - X_j, \quad j = \overline{1, N_p},$$

где X_0 — спектральные значения интенсивности целевого пикселя; N_p — количество смежных пикселей.

В табл. 2 представлены статистические характеристики, достигнутые в результате обучения нейросети с разным количеством дополнительных пикселей наблюдения в одном образце. Из обучающей выборки были выбраны две реализации со средней оптической толщиной 10 и 20 и баллом облачности 0,7. Следует отметить снижение разброса восстановленных значений ОТО с увеличением N_p . Благодаря учёту дополнительной информации наблюдается существенный рост значений коэффициента корреляции для показателя оптической неоднородности облаков и балла облачности, а также снижение значений функции потерь f_L .

Также обращает на себя внимание то, что результаты для случаев с $N_p = 4$ и $N_p = 8$ различаются незначительно. Вероятно, это обусловлено тем, что при $N_p = 4$ в решении участвуют пиксели, имеющие одну общую грань с целевым пикселем, в то время как при $N_p = 8$ другие четыре пикселя её не имеют и воздействуют на целевой пиксель посредством четырёх других, оказывая менее выраженное влияние. Таким образом, для случаев с невысоким баллом облачности (в данном случае 0,7) при обучении сети достаточно использовать смежные пиксели, непосредственно граничащие с целевым. Следует отметить, что реализуемый подход

позволяет учесть эффекты горизонтального переноса излучения без существенного увеличения трудоёмкости алгоритма.

Таблица 2. Статистические характеристики решения обратной задачи; $d = 500$ м

Образец	N_p	s_τ	r_τ	r_δ	r_c	$\min\{f_L\}$	$\min\{f_A\}$	$\langle\tau_r\rangle$	$\langle c_{f,r}\rangle$
$\langle\tau_r\rangle = 10$ $c_{f,t} = 0,7$	0	2,4	0,97	0,61	0,81	1,9	0,95	10,6	42,7
	4	2,2	0,98	0,75	0,94	1,4	0,95	10,0	64,0
	8	2,2	0,98	0,78	0,97	1,4	0,95	12,0	75,6
$\langle\tau_r\rangle = 20$ $c_{f,t} = 0,7$	0	5,1	0,98	0,62	0,80	1,9	0,95	18,0	39,6
	4	4,4	0,99	0,75	0,97	1,5	0,95	18,5	61,1
	8	3,2	0,99	0,75	0,96	1,5	0,95	20,8	65,8

Выбор того или иного пространственного разрешения при решении обратной задачи с использованием реальных измерений зависит от возможностей спутниковых измерительных систем. У спектрорадиометра MODIS максимальное разрешение, при котором измеряются радиационные характеристики во всех используемых в алгоритме спектральных каналах, составляет 500 м. Исследуем то, как выбор пространственного разрешения влияет на точность решения обратной задачи. Рассмотрим облачную реализацию с $\langle\tau_r\rangle = 20$ и $c_{f,t} = 0,8$. Обратная задача решалась с использованием восьми дополнительных смежных пикселей. С целью сравнения расчёты проведены также для $d = 250$ м и $d = 1000$ м. Из табл. 3 следует, что результаты восстановления улучшаются существенно при снижении пространственного разрешения. Слабая корреляция наблюдается лишь для показателя относительной неоднородности облаков.

Таблица 3. Статистические характеристики решения обратной задачи при разном пространственном разрешении

d , м	s_τ	r_τ	r_δ	r_c	$\min\{f_L\}$	$\min\{f_A\}$	$\langle\tau_r\rangle$	$\langle c_{f,r}\rangle$
250	6,2	0,96	0,67	0,95	3,4	0,88	23,3	0,85
500	3,7	0,98	0,84	0,97	1,5	0,94	20,7	0,80
1000	1,9	0,99	0,55	0,99	0,6	0,91	20,5	0,79

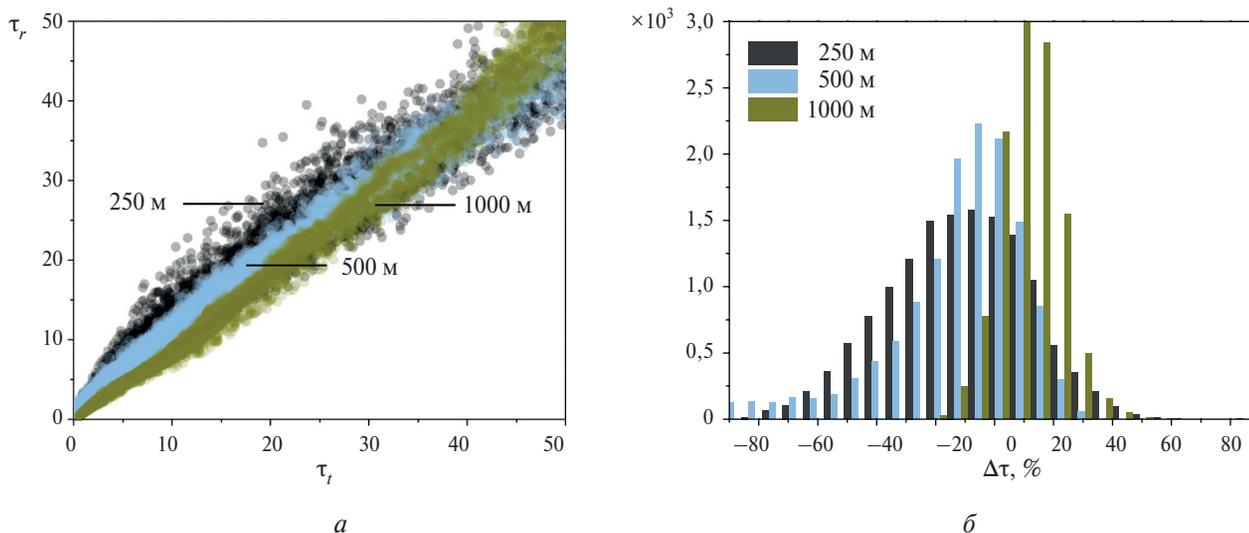


Рис. 5. Сравнение исходных и восстановленных значений ОТО (а) и гистограмма относительной ошибки $\Delta\tau$ (б) при разном пространственном разрешении

На диаграмме рассеяния (рис. 5а) визуализировано сопоставление исходных и восстановленных значений ОТО при использовании разных вариантов d . Очевидно, что корреляция тем больше, а разброс значений ОТО тем меньше, чем ниже разрешение. Так, коэффициент корреляции r_τ растёт от 0,96 (250 м) до 0,99 (1000 м), а r_c — от 0,95 (250 м) до 0,99 (1000 м). Разброс относительной ошибки восстановления оптической толщины облаков $\Delta\tau$ (%) тем шире, чем выше разрешение (рис. 5б).

При практическом использовании нейроалгоритма допустима ситуация, когда тестовая выборка, содержащая данные натуральных измерений, может не принадлежать тому же классу данных, что и обучающая выборка. В этом случае сложно спрогнозировать предсказуемость конечного результата. Рассмотрим такую ситуацию на примере численного моделирования. Разделим обучающую выборку на две категории: K_1 (разорванная облачность: $0,5 \leq c_f \leq 0,8$) и K_2 (сплошная и квазисплошная облачность: $0,9 \leq c_f \leq 1,0$). Возьмём в качестве тестовой выборки одну из реализаций для сплошной облачности и решим обратную задачу, обучив нейросеть с использованием данных из категории K_1 . И наоборот, пусть при обучении данными из категории K_2 тестовая выборка будет соответствовать полю разорванной облачности. Результаты расчётов представлены в табл. 4 и 5.

Таблица 4. Статистические характеристики решения обратной задачи при обучении нейросети данными из категории K_1 для восстановления параметров облачных реализаций с баллом облачности 1,0

$\langle\tau_r\rangle$	$d = 250$ м								$d = 500$ м							
	s_τ	r_τ	r_δ	r_c	$\min\{f_L\}$	$\min\{f_A\}$	$\langle\tau_r\rangle$	$\langle c_{f,r}\rangle$	s_τ	r_τ	r_δ	r_c	$\min\{f_L\}$	$\min\{f_A\}$	$\langle\tau_r\rangle$	$\langle c_{f,r}\rangle$
5	1,3	0,96	0,75	0,92	1,2	0,98	6,9	1	1,8	0,99	0,84	0,99	0,4	0,99	5,9	1
10	2,6	0,96	0,81	0,96	1,2	0,98	11,3	1	1,4	0,99	0,72	0,99	0,4	0,99	10,2	1
20	8,9	0,95	0,83	0,99	1,1	0,99	15,0	1	5,4	0,98	0,83	0,99	0,4	0,99	16,9	1

Таблица 5. Статистические характеристики решения обратной задачи при обучении нейросети данными из категории K_2 для восстановления параметров облачных реализаций с баллом облачности 0,7

$\langle\tau_r\rangle$	$d = 250$ м								$d = 500$ м							
	s_τ	r_τ	r_δ	r_c	$\min\{f_L\}$	$\min\{f_A\}$	$\langle\tau_r\rangle$	$\langle c_{f,r}\rangle$	s_τ	r_τ	r_δ	r_c	$\min\{f_L\}$	$\min\{f_A\}$	$\langle\tau_r\rangle$	$\langle c_{f,r}\rangle$
5	1,9	0,95	0,59	0,95	4,1	0,84	4,9	0,73	1,0	0,98	0,70	0,92	1,8	0,92	5,4	0,64
10	3,8	0,96	0,59	0,96	4,1	0,83	12,2	0,74	2,2	0,99	0,77	0,98	1,7	0,92	9,9	0,81
20	6,4	0,96	0,61	0,93	4,1	0,84	20,8	0,81	6,4	0,96	0,60	0,96	4,0	0,84	20,4	0,72

Анализ результатов вычислений показывает, что отсутствие информации о том или ином классе данных при обучении нейросети не препятствует достижению высоких показателей решения обратной задачи. Таким образом, созданная модель нейронной сети работоспособна даже в случае, когда обрабатываемые данные не принадлежат используемой при обучении категории данных.

Приведём пример решения обратной задачи, наглядно проиллюстрировав исходные и восстановленные данные. В качестве тестовой выборки использована облачная реализация с баллом облачности 0,6 и средним значением ОТО, равным 15. На рис. 6 (см. с. 100) представлены результаты моделирования двумерного распределения интенсивности отражённого излучения (см. рис. 6а) для исходного поля разорванной облачности ($d = 50$ м) (см. рис. 6б), а также исходные (см. рис. 6в, д, ж) и восстановленные с использованием данных смежных пикселей (см. рис. 6г, е, и) распределение оптической толщины облаков с пространственным разрешением 250 м (см. рис. 6в, з), 500 м (см. рис. 6д, е) и 1000 м (см. рис. 6ж, и). Очевидно, что нейросетевая модель детально воспроизводит исходное двумерное распределение оптической толщины облаков, однако наилучшие результаты наблюдаются в случаях более низкого пространственного разрешения.

На рис. 7а–в (см. с. 100) представлены диаграммы рассеяния для τ , δ_r и $c_{f,r}$ при использовании максимально возможного в MODIS пространственного разрешения 500 м.

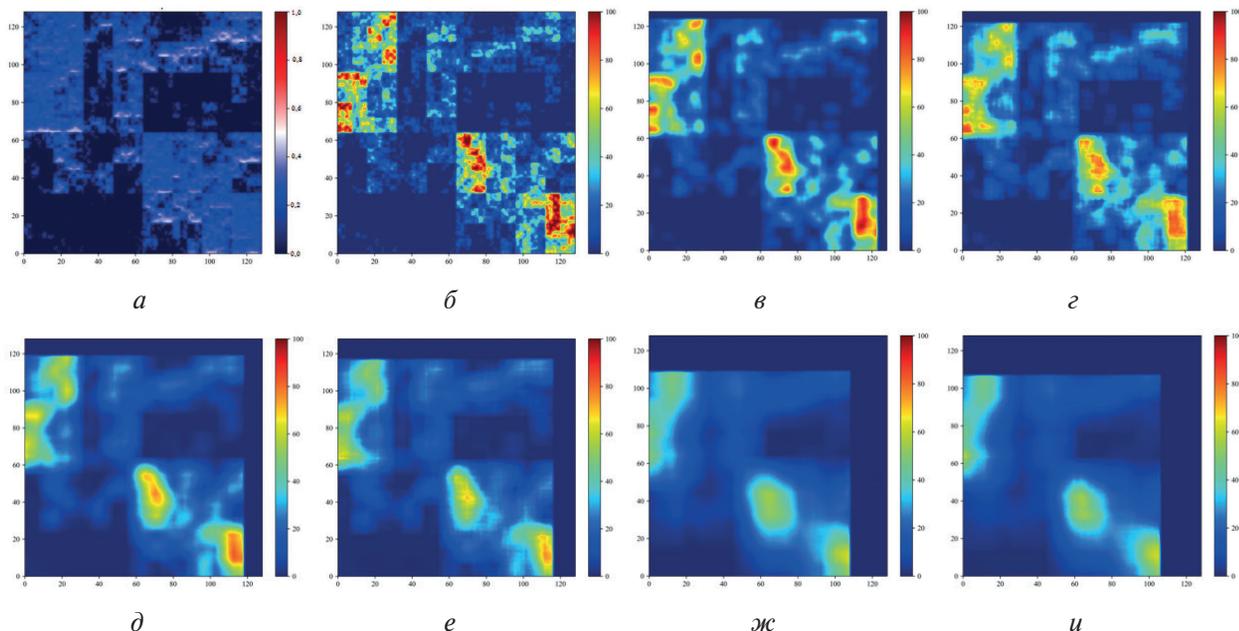


Рис. 6. Исходное двумерное распределение интенсивности отражённого излучения (а) и оптической толщины облаков (б) из обучающей выборки с разрешением 50 м; исходное и восстановленное поле ОТО с разрешением 250 м (в, з), 500 м (д, е) и 1000 м (ж, и)

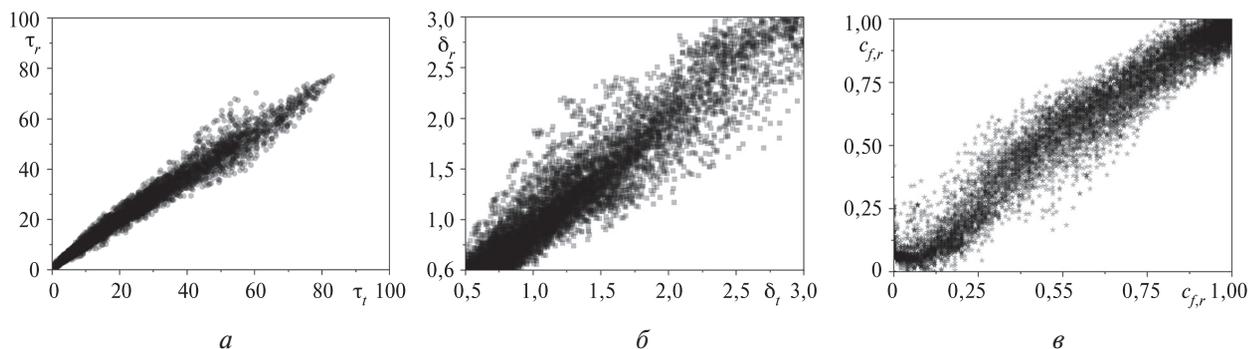


Рис. 7. Сравнение исходных и восстановленных значений параметров поля облачности: ОТО (а), показатель относительной неоднородности облаков (б) и балл облачности (в)

Заключение

Результаты проведённых исследований демонстрируют применимость методов искусственного интеллекта в определении оптической толщины горизонтально неоднородных облаков. С помощью численного моделирования показано, что реализованный нейроалгоритм позволяет без существенного увеличения трудоёмкости оценить не только ОТО, но также показатель относительной неоднородности и балл облачности в пределах пикселя наблюдения. Предлагаемая модель нейронной сети естественным образом интегрирует дополнительную информацию об отражённой радиации в смежных пикселях и успешно связывает различные входные и выходные данные между собой, что едва ли возможно при решении задачи классическими методами.

Для заданного диапазона изменения значений входных параметров задачи определены оптимальные конфигурация и значения гиперпараметров сети, проведено исследование чув-

ствительности результатов восстановления искомым характеристикам к выбору спектральных каналов. Показано, что точность решения обратной задачи повышается при использовании дополнительной информации, содержащейся в пикселях, смежных с целевым, и снижении пространственного разрешения в рамках рассматриваемого диапазона. Полученные результаты свидетельствуют о работоспособности созданной модели нейронной сети даже в случае, когда обрабатываемые данные не принадлежат используемой при обучении категории данных.

Таким образом, на модельном эксперименте проработана технология восстановления характеристик облаков с помощью нейронной сети и создана основа для разработки отечественного продукта, который, в отличие от предложенных ранее схем, позволяет интегрировать радиометрические данные в необходимом количестве и использовать разное пространственное разрешение данных. Дальнейшее развитие нейроалгоритма состоит в оценке возможности его применения в случаях, когда оптическая неоднородность облачности обусловлена вариациями не только оптической толщины, но и эффективного радиуса облачных капель. Представляет интерес также учёт вертикальной изменчивости этих характеристик, стохастичности верхней границы облачного слоя, апробация других схем обучения, с помощью которых можно улучшить способность сети к обобщению. Накопление обучающей выборки благодаря учёту новых направлений визирования и освещения также расширит границы применимости модели и возможности её приложения к данным натуральных спутниковых измерений.

Исследование выполнено за счёт гранта Российского научного фонда № 21-71-10076, <https://rscf.ru/project/21-71-10076>.

Литература

1. Грибанов К. Г., Имасу Р., Захаров В. И. Нейронные сети для определения высотных профилей CO₂ по данным GOSAT/TANSO-FTS // Оптика атмосферы и океана. 2009. Т. 22. № 9. С. 890–895.
2. Ельцов Н. П., Огородников В. А., Пригарин С. М. Исследование ограниченных каскадных моделей случайных полей на плоскости // Сибирский журн. вычислит. математики. 2008. Т. 11. № 4. С. 405–412. DOI: 10.1134/S1995423908040034.
3. Марчук Г. И., Михайлов Г. А., Назаралиев М. А. и др. Метод Монте-Карло в атмосферной оптике. Новосибирск: Наука, 1976. 280 с.
4. Матвиенко Г. Г., Суханов А. Я., Бабченко С. В. Анализ возможностей нейронных сетей при IPDA космическом зондировании CO₂ с привлечением разнородных априорных данных // Оптика атмосферы и океана. 2018. Т. 31. № 12. С. 974–980. DOI: 10.15372/AOO20181206.
5. Николенко С., Кадури А., Архангельская Е. Глубокое обучение. Погружение в мир нейронных сетей. СПб.: Питер, 2022. 440 с.
6. Пантелеев А. В., Лобанов А. В. Градиентные методы оптимизации в машинном обучении идентификации параметров динамических систем // Моделирование и анализ данных. 2019. Т. 9. № 4. С. 88–99. DOI: 10.17759/mda.2019090407.
7. Радиация в облачной атмосфере / под ред. Е. М. Фейгельсон. Л.: Гидрометеиздат, 1981. 280 с.
8. Русскова Т. В. Моделирование переноса солнечного излучения в облачной атмосфере методом Монте-Карло с использованием графического процессора и технологии NVIDIA CUDA // Оптика атмосферы и океана. 2017. Т. 30. № 11. С. 915–926. DOI: 10.15372/AOO20171103.
9. Barker H. A parameterization for computing grid-averaged solar fluxes for inhomogeneous marine boundary layer clouds. Part I: Methodology and homogeneous biases // J. Atmospheric Sciences. 1996. V. 53. Iss. 16. P. 2289–2303. DOI: 10.1175/1520-0469(1996)053<2289:APFCGA>2.0.CO;2.
10. Barker H., Davies J. A. Cumulus cloud radiative properties and the characteristics of satellite radiance wavenumber spectra // Remote Sensing of Environment. 1992. V. 42. Iss. 1. P. 51–64. DOI: 10.1016/0034-4257(92)90067-T.
11. Benner T. C., Evans K. F. Three dimensional solar radiative transfer in small tropical cumulus fields derived from high-resolution imagery // J. Geophysical Research. 2001. V. 106. Iss. D14. P. 14975–14984. DOI: 10.1029/2001JD900158.
12. Buriez J. C., Doutriaux-Boucher M., Parol F., Loeb N. G. Angular variability of the liquid water cloud optical thickness retrieved from ADEOS-POLDER // J. Atmospheric Sciences. 2001. V. 58. Iss. 20. P. 3007–3018. DOI: 10.1175/1520-0469(2001)058<3007:AVOTLW>2.0.CO;2.

13. *Cahalan R. F., Ridgway W., Wiscombe W. J., Bell T. L.* (1994a) The albedo of fractal stratocumulus clouds // *J. Atmospheric Sciences*. 1994. V. 51. Iss. 16. P. 2434–2455. DOI: 10.1175/1520-0469(1994)051<2434:TAOFSC>2.0.CO;2.
14. *Cahalan R. F., Ridgway W., Wiscombe W. J. et al.* (1994b) Independent pixel and Monte Carlo estimates of stratocumulus albedo // *J. Atmospheric Sciences*. 1994. V. 51. No. 51. P. 3776–3790. DOI: 10.1175/1520-0469(1994)051<3776:IPAMCE>2.0.CO;2.
15. *Cornet C., Isaka H., Guillemet B., Szczap F.* Neural network retrieval of cloud parameters of inhomogeneous clouds from multispectral and multiscale radiance data: Feasibility study // *J. Geophysical Research: Atmospheres*. 2004. V. 109. Article D12203. DOI: 10.1029/2003JD004186.
16. *Cornet C., Buriez J.-C., Riédi J. et al.* Case study of inhomogeneous cloud parameter retrieval from MODIS data // *Geophysical Research Letters*. 2005. V. 32. Article L13807. DOI: 10.1029/2005GL022791.
17. *Faure T., Isaka H., Guillemet B.* Neural network retrieval of cloud parameters of inhomogeneous and fractional clouds: Feasibility study // *Remote Sensing of Environment*. 2001. V. 77. Iss. 2. P. 123–138. DOI: 10.1016/S0034-4257(01)00199-7.
18. *Hess M., Koepke P., Schult I.* Optical Properties of Aerosols and Clouds: The software package OPAC // *Bull. American Meteorological Society*. 1998. V. 79. Iss. 5. P. 831–844. DOI: 10.1175/1520-0477(1998)079<0831:OPOAAC>2.0.CO;2.
19. *King M. D.* Determination of the Scaled Optical Thickness of Clouds from Reflected Solar Radiation Measurements // *J. Atmospheric Sciences*. 1987. V. 44. No. 13. P. 1734–1751. DOI: 10.1175/1520-0469(1987)044<1734:DOTSOT>2.0.CO;2.
20. *Loeb N. G., Davies R.* Observational evidence of plane parallel model biases: Apparent dependence of cloud optical depth on solar zenith angle // *J. Geophysical Research*. 1996. V. 101. Iss. D1. P. 1621–1634. DOI: 10.1029/95JD03298.
21. *Loeb N. G., Varnai T., Davies R.* Effect of cloud inhomogeneities on the solar zenith angle dependence of nadir reflectance // *J. Geophysical Research*. 1997. V. 102. Iss. D8. P. 9387–9395. DOI: 10.1029/96Jd03719.
22. *Magaritz-Rohen L., Khain A., Pinsky M.* About the horizontal variability of effective radius in stratocumulus clouds // *J. Geophysical Research: Atmospheres*. 2016. V. 121. P. 9640–9660. DOI: 10.1002/2016JD024977.
23. *Marshak A., Davis A., Cahalan R., Wiscombe W.* Bounded cascade models as nonstationary multifractals // *Physical Review E*. 1994. V. 49. Iss. 1. P. 55–69. DOI: 10.1103/PHYSREVE.49.55.
24. *Marshak A., Davis A., Cahalan R., Wiscombe W. J.* Nonlocal independent pixel approximation: direct and inverse problems // *IEEE Trans. Geoscience and Remote Sensing*. 1998. V. 36. Iss. 1. P. 192–205. DOI: 10.1109/36.655329.
25. *Nikitin S. V., Chulichkov A. I., Borovski A. N., Postilyakov O. V.* On estimation of atmospheric scattering characteristics from spectral measurements of solar radiation using machine learning algorithms // *Proc. SPIE*. 2020. V. 11531. Article 115310V. DOI: 10.1117/12.2574237.
26. *Okamura R., Iwabuchi H., Schmidt K. S.* Feasibility study of multi-pixel retrieval of optical thickness and droplet effective radius of inhomogeneous clouds using deep learning // *Atmospheric Measurement Techniques*. 2017. V. 10. P. 4747–4759. DOI: 10.5194/amt-10-4747-2017.
27. *Platnick S., King M. D., Ackerman S. A. et al.* The MODIS cloud products: Algorithms and examples from Terra // *IEEE Trans. Geoscience and Remote Sensing*. 2003. V. 41. No. 2. P. 459–473. DOI: 10.1109/TGRS.2002.808301.
28. *Rothman L. S., Gordon I. E., Barbe A. et al.* The HITRAN 2008 molecular spectroscopic database // *J. Quantitative Spectroscopy and Radiative Transfer*. 2009. V. 110. No. 9–10. P. 533–572. DOI: 10.1016/j.jqsrt.2009.02.013.
29. *Schneider T., Kaul C. M., Pressel K. G.* Possible climate transitions from breakup of stratocumulus decks under greenhouse warming // *Nature Geoscience*. 2019. V. 12. P. 163–167. DOI: 10.1038/s41561-019-0310-1.
30. *Titov G. A.* Radiative Horizontal Transport and Absorption in Stratocumulus Clouds // *J. Atmospheric Sciences*. 1998. V. 55. Iss. 15. P. 2549–2560. DOI: 10.1175/1520-0469(1998)055<2549:RHTAAI>2.0.CO;2.
31. *Zhang Z., Platnick S.* An assessment of differences between cloud effective particle radius retrievals for marine water clouds from three MODIS spectral bands // *J. Geophysical Research*. 2011. V. 116. Article D20215. DOI: 10.1029/2011JD016216.

Algorithm for retrieving the optical depth of single-layer horizontally inhomogeneous clouds using a neural network

T. V. Russkova, A. V. Skorokhodov

V. E. Zuev Institute of Atmospheric Optics, Tomsk 634055, Russia

E-mails: btv@iao.ru, vazime@yandex.ru

A neural network technique for retrieving the optical thickness of horizontally inhomogeneous clouds is presented. To train the neural network, sets of reflected solar radiation intensity values in the visible and short-wave infrared regions of the spectrum were used. Radiative transfer simulation in marine stratocumulus clouds was carried out using the Monte Carlo method, and a fractal model based on the method of limited cascades was used to generate cloud fields. The difference between the presented technique and the classical IPA/NIPA (Independent Pixel Approximation/Nonlocal Independent Pixel Approximation) schemes is that the former allows you to integrate radiometric data in the required quantity and take into account the effects of horizontal radiation transfer not only within the target pixel, but also adjacent areas. In addition, without significantly increasing the complexity of the algorithm, additional parameters can be included in the vector of retrieved characteristics, in particular, the indicator of the relative heterogeneity of the optical thickness and the cloud fraction within the observation pixel. The paper examines the dependence of the accuracy of solving the inverse problem on the architecture and values of the hyperparameters of the neural network, the volume and structure of the training sample. High values of the correlation coefficient (0.95–0.99) were achieved between the original and retrieved values of the optical thickness at a fixed value of the effective radius of cloud particles. It is shown that when additional information about the reflected radiation in adjacent pixels is used and the spatial resolution is reduced within the considered range, the standard deviation of the optical thickness decreases and the correlation coefficient increases.

Keywords: remote sensing, broken clouds, optical thickness, inverse problems, numerical simulation, solar radiative transfer, Monte Carlo method, neural networks

Accepted: 11.12.2023

DOI: 10.21046/2070-7401-2024-21-1-88-105

References

1. Griбанov K. G., Imasu R., Zakharov V. I., Neural Networks for CO₂ Profile Retrieval from the Data of GOSAT/TANSO-FTS, *Atmospheric and Oceanic Optics*, 2010, Vol. 23, No. 01, pp. 42–47, DOI: 10.1134/S1024856010010094.
2. Eltsov N. P., Ogorodnikov V. A., Prigarin S. M., A study of bounded cascade models of random fields on a plane, *Numerical Analysis and Applications*, 2008, Vol. 1, Issue 4, pp. 332–338, DOI: 10.1134/S1995423908040034.
3. Marchuk G. I., Mikhailov G. A., Nazaraliev M. A. et al., *The Monte Carlo Methods in Atmospheric Optics*, Heidelberg: Springer-Verlag Berlin, 1980, 210 p., DOI: 10.1007/978-3-540-35237-2.
4. Matvienko G. G., Sukhanov A. Ya., Babchenko S. V., The Analysis of Capabilities of Neural Networks in CO₂ Sounding with Spaceborne IPDA-Lidar with the Use of Different a Priori Data, *Atmospheric and Oceanic Optics*, 2019, Vol. 32, No. 02, pp. 165–170, DOI: 10.1134/S102485601902009X.
5. Nikolenko S., Kadurin A., Arkhangelskaya E., *Glubokoe obuchenie. Pogruzhenie v mir neironnykh setei* (Deep learning. Dive into the world of neural networks), Saint Petersburg: Piter, 2022, 440 p. (in Russian).
6. Panteleev A. V., Lobanov A. V., Gradient optimization methods in machine learning for the identification of dynamic systems parameters, *Modelirovanie i analiz dannykh*, 2019, Vol. 09, No. 4, pp. 88–99 (in Russian), DOI: 10.17759/mda.2019090407.
7. Feigelson E. M., *Radiation in a Cloudy Atmosphere*, Dordrecht: D. Reidel Publishing Company, 1984, 293 p., DOI: 10.1007/978-94-009-6443-3.
8. Russkova T. V., Monte Carlo Simulation of the Solar Radiation Transfer in a Cloudy Atmosphere with the Use of Graphic Processor and NVIDIA CUDA Technology, *Atmospheric and Oceanic Optics*, 2018, Vol. 31, No. 02, pp. 119–130, DOI: 10.1134/S1024856018020100.
9. Barker H., A parameterization for computing grid-averaged solar fluxes for inhomogeneous marine boundary layer clouds. Part I: Methodology and homogeneous biases, *J. Atmospheric Sciences*, 1996, Vol. 53, Issue 16, pp. 2289–2303, DOI: 10.1175/1520-0469(1996)053<2289:APFCGA>2.0.CO;2.

10. Barker H., Davies J.A., Cumulus cloud radiative properties and the characteristics of satellite radiance wavenumber spectra, *Remote Sensing of Environment*, 1992, Vol. 42, Issue 1, pp. 51–64, DOI: 10.1016/0034-4257(92)90067-T.
11. Benner T. C., Evans K. F., Three dimensional solar radiative transfer in small tropical cumulus fields derived from high-resolution imagery, *J. Geophysical Res Research*, 2001, Vol. 106, Issue D14, pp. 14975–14984, DOI: 10.1029/2001JD900158.
12. Buriez J. C., Doutriaux-Boucher M., Parol F., Loeb N. G., Angular variability of the liquid water cloud optical thickness retrieved from ADEOS-POLDER, *J. Atmospheric Sciences*, 2001, Vol. 58, Issue 20, pp. 3007–3018, DOI: 10.1175/1520-0469(2001)058<3007:AVOTLW>2.0.CO;2.
13. Cahalan R. F., Ridgway W., Wiscombe W.J., Bell T.L. (1994a), The albedo of fractal stratocumulus clouds, *J. Atmospheric Sciences*, 1994, Vol. 51, Issue 16, pp. 2434–2455, DOI: 10.1175/1520-0469(1994)051<2434:TAOFSC>2.0.CO;2.
14. Cahalan R. F., Ridgway W., Wiscombe W.J. et al. (1994b), Independent pixel and Monte Carlo estimates of stratocumulus albedo, *J. Atmospheric Sciences*, 1994, Vol. 51, No. 51, pp. 3776–3790, DOI: 10.1175/1520-0469(1994)051<3776:IPAMCE>2.0.CO;2.
15. Cornet C., Isaka H., Guillemet B., Szczap F., Neural network retrieval of cloud parameters of inhomogeneous clouds from multispectral and multiscale radiance data: Feasibility study, *J. Geophysical Research: Atmospheres*, 2004, Vol. 109, Article D12203, DOI: 10.1029/2003JD004186.
16. Cornet C., Buriez J.-C., Riédi J. et al., Case study of inhomogeneous cloud parameter retrieval from MODIS data, *Geophysical Research Letters*, 2005, Vol. 32, Article L13807, DOI: 10.1029/2005GL022791.
17. Faure T., Isaka H., Guillemet B., Neural network retrieval of cloud parameters of inhomogeneous and fractional clouds: Feasibility study, *Remote Sensing of Environment*, 2001, Vol. 77, Issue 2, pp. 123–138, DOI: 10.1016/S0034-4257(01)00199-7.
18. Hess M., Koepke P., Schult I., Optical Properties of Aerosols and Clouds: The software package OPAC, *Bull. American Meteorological Society*, 1998, Vol. 79, Issue 5, pp. 831–844, DOI: 10.1175/1520-0477(1998)079<0831:OPOAAC>2.0.CO;2.
19. King M. D., Determination of the Scaled Optical Thickness of Clouds from Reflected Solar Radiation Measurements, *J. Atmospheric Sciences*, 1987, Vol. 44, No. 13, pp. 1734–1751, DOI: 10.1175/1520-0469(1987)044<1734:DOTSOT>2.0.CO;2.
20. Loeb N. G., Davies R., Observational evidence of plane parallel model biases: Apparent dependence of cloud optical depth on solar zenith angle, *J. Geophysical Research*, 1996, Vol. 101, Issue D1, pp. 1621–1634, DOI: 10.1029/95JD03298.
21. Loeb N. G., Varnai T., Davies R., Effect of cloud inhomogeneities on the solar zenith angle dependence of nadir reflectance, *J. Geophysical Research*, 1997, Vol. 102, Issue D8, pp. 9387–9395, DOI: 10.1029/96Jd03719.
22. Magaritz-Rohen L., Khain A., Pinsky M., About the horizontal variability of effective radius in stratocumulus clouds, *J. Geophysical Research: Atmospheres*, 2016, Vol. 121, pp. 9640–9660, DOI: 10.1002/2016JD024977.
23. Marshak A., Davis A., Cahalan R., Wiscombe W., Bounded cascade models as nonstationary multifractals, *Physical Review E*, 1994, Vol. 49, Issue 1, pp. 55–69, DOI: 10.1103/PHYSREVE.49.55.
24. Marshak A., Davis A., Cahalan R., Wiscombe W.J., Nonlocal independent pixel approximation: direct and inverse problems, *IEEE Trans. Geoscience and Remote Sensing*, 1998, Vol. 36, Issue 1, pp. 192–205, DOI: 10.1109/36.655329.
25. Nikitin S. V., Chulichkov A. I., Borovski A. N., Postlyakov O. V., On estimation of atmospheric scattering characteristics from spectral measurements of solar radiation using machine learning algorithms, *Proc. SPIE*, 2020, Vol. 11531, Article 115310V, DOI: 10.1117/12.2574237.
26. Okamura R., Iwabuchi H., Schmidt K. S., Feasibility study of multi-pixel retrieval of optical thickness and droplet effective radius of inhomogeneous clouds using deep learning, *Atmospheric Measurement Techniques*, 2017, Vol. 10, pp. 4747–4759, DOI: 10.5194/amt-10-4747-2017.
27. Platnick S., King M. D., Ackerman S.A. et al., The MODIS cloud products: Algorithms and examples from Terra, *IEEE Trans. Geoscience and Remote Sensing*, 2003, Vol. 41, No. 2, pp. 459–473, DOI: 10.1109/TGRS.2002.808301.
28. Rothman L. S., Gordon I. E., Barbe A. et al., The HITRAN 2008 molecular spectroscopic database, *J. Quantitative Spectroscopy and Radiative Transfer*, 2009, Vol. 110, No. 9–10, pp. 533–572, DOI: 10.1016/j.jqsrt.2009.02.013.
29. Schneider T., Kaul C. M., Pressel K. G., Possible climate transitions from breakup of stratocumulus decks under greenhouse warming, *Nature Geoscience*, 2019, Vol. 12, pp. 163–167, DOI: 10.1038/s41561-019-0310-1.
30. Titov G. A., Radiative Horizontal Transport and Absorption in Stratocumulus Clouds, *J. Atmospheric Sciences*, 1998, Vol. 55, Issue 15, pp. 2549–2560, DOI: 10.1175/1520-0469(1998)055<2549:RHTAAI>2.0.CO;2.

31. Zhang Z., Platnick S., An assessment of differences between cloud effective particle radius retrievals for marine water clouds from three MODIS spectral bands, *J. Geophysical Research*, 2011, Vol. 116, Article D20215, DOI: 10.1029/2011JD016216.