

Нейросетевой метод определения водозапаса облачности по данным радиометра МСУ-ГС КА «Электро-Л» № 4

А. А. Филей, А. И. Андреев

Дальневосточный центр НИЦ «Планета», Хабаровск, 680000, Россия

E-mail: andreym-61@mail.ru

В настоящей работе представлена нейросетевая методика определения водозапаса облачности по данным дневных измерений радиометра МСУ-ГС (Многозональное сканирующее устройство), установленного на борту российского гидрометеорологического спутника «Электро-Л» № 4. Методика оценки водозапаса облачности основывается на физических принципах взаимодействия электромагнитного излучения с частицами облачности в каналах радиометра МСУ-ГС на длинах волн 0,6 и 3,7 мкм. Используя полносвязную нейронную сеть прямого распространения, устанавливается зависимость между измерениями коэффициентов отражения облачности в каналах спутникового прибора и её микрофизическими параметрами: оптической толщиной и эффективным радиусом. При обучении нейронной сети в качестве эталонного источника информации выступал массив смоделированных с помощью радиационной модели Libradtran измерений МСУ-ГС и соответствующих им значений водозапаса, рассчитанного по данным оптической толщины и эффективного радиуса частиц для капельной и кристаллической облачности. Полученная в ходе обучения нейросетевая модель использовалась для оценки водозапаса по данным непосредственных измерений МСУ-ГС, которые затем сопоставлялись с аналогичными оценками, полученными классическим алгоритмом решения обратной задачи методом статистической регуляризации. По результатам сопоставления среднеквадратическая ошибка искомых оценок водозапаса не превышала 44 г/м^2 . В среднем оценка водозапаса кристаллической облачности была завышена на 12 г/м^2 , капельной облачности занижена на 4 г/м^2 . Полученные результаты позволяют сделать вывод о работоспособности нейросетевого алгоритма, который может быть использован в оперативной практике наряду с классическим статистическим алгоритмом, не уступая при этом в точности и выигрывая в простоте реализации и скорости расчёта.

Ключевые слова: МСУ-ГС, «Электро-Л» № 4, нейронные сети, водозапас, оптическая толщина, эффективный радиус, облачность

Одобрена к печати: 21.03.2025

DOI: 10.21046/2070-7401-2025-22-3-53-63

Введение

Облачность играет важную роль в формировании температуры атмосферы и подстилающей поверхности, а также представляется главным фактором, влияющим на радиационные процессы, протекающие в атмосфере. Необходимость изучения оптических и микрофизических характеристик облачности в различных пространственно-временных масштабах выступает на сегодняшний день актуальной научной и практической задачей оптики и физики атмосферы. Одной из таких характеристик является водозапас LWP (*англ.* Liquid Water Path) облачности, который позволяет оценить общую массу сконденсированной воды в облаке с целью прогноза погоды, проверки климатических моделей и мониторинга изменения климата.

Одним из важных и эффективных, а порой и единственных инструментов для получения обширной информации о LWP на сегодняшний день становятся данные дистанционного зондирования Земли из космоса. Космические аппараты (КА) способны получать информацию о содержании капель воды и кристаллов льда в облаке в разных спектральных диапазонах, с различным временным и спектральным разрешением. При восстановлении LWP по спутниковым данным широкое распространение преимущественно получила методика, основанная на двухспектральной отражательной способности облачности. Принцип этого метода заключается в том, что коэффициент отражения (КО) облаков в видимом диапазоне длин волн в первую очередь зависит от оптической толщины облака (τ_c), а КО в ближнем

инфракрасном диапазоне длин волн — от эффективного радиуса (r_e) облачных частиц. При этом облако рассматривается как оптически однородный слой, а все радиационные процессы осуществляются в рамках каждого независимого пикселя в каналах прибора. Таким образом, зная величины τ_c и r_e облачных частиц, можно рассчитать LWP, используя при этом одну из представленных в работах (Матвеев, 1984; Bennartz, 2007; Heymsfield et al., 2003; Walther, Heidinger, 2012) параметризаций для капельных и кристаллических облаков. Данный метод хорошо себя зарекомендовал при определении LWP по данным таких радиометров, как AVHRR (*англ.* Advanced Very-High-Resolution Radiometer) (Han et al., 1994), MODIS (*англ.* Moderate Resolution Imaging Spectroradiometer) (Platnick et al., 2003), SEVIRI (*англ.* Spinning Enhanced Visible Infra-Red Imager) (Roebeling et al., 2006), ABI (*англ.* Advanced Baseline Imager) (Walther, Heidinger, 2012), а также для радиометра МСУ-ГС (Многозональное сканирующее устройство) КА «Арктика-М» № 1 (Филей, Шамилова, 2023). В основе представленных выше работ лежит использование справочных таблиц LUT (*англ.* lookup table), описывающих оптические характеристики объёмного рассеяния частиц льда и капель воды. Согласно методике, для каждого пикселя, помеченного маской облачности, в зависимости от фазового состояния и геометрии наблюдения проводится сопоставление измеренных спутниковым радиометром и смоделированных значений КО с целью определения значений τ_c и r_e . То есть решается обратная задача, например, методом статистической регуляризации, которая имеет широкое применение в задачах дистанционного зондирования Земли из космоса и позволяет находить несколько зависящих между собой целевых параметров по нескольким измерениям спутникового прибора.

Восстановление LWP с использованием полносвязной искусственной нейронной сети (ИНС) рассматривается в настоящей работе применительно к дневным измерениям радиометра МСУ-ГС, установленного на борту российского КА «Электро-Л» № 4. Применение ИНС представляется альтернативным походом классическому методу решения обратной задачи с использованием справочных LUT, упрощает программно-математическую реализацию восстановления LWP при сохранении требуемых критериев точности.

Краткое описание аппаратуры МСУ-ГС

Радиометр МСУ-ГС — прибор на борту российских геостационарных КА серии «Электро-Л», позволяет получать изображение земной поверхности с разрешением 1 км в трёх спектральных каналах видимого диапазона и семи каналах инфракрасного диапазона с разрешением 4 км и периодичностью съёмки 15 мин. Прибор МСУ-ГС используется для оперативного обеспечения информацией различных служб Российской Федерации при выполнении следующих основных задач: анализа и прогноза погоды в региональном и глобальном масштабах, мониторинга климата, анализа и прогноза состояния акваторий морей и океанов, мониторинга состояния лесов и т.д. При создании МСУ-ГС максимально использовались современные отечественные электронные компоненты — многоэлементные приёмники излучения в инфракрасном диапазоне спектра и пассивная система их радиационного охлаждения до криогенной температуры. Это позволило создать прибор, не уступающий по своим характеристикам зарубежным аналогам. Основные параметры спектральных каналов прибора представлены в *табл. 1* (https://space.oscar.wmo.int/instruments/view/msu_gs).

Таблица 1. Параметры спектральных каналов МСУ-ГС

Центральная длина волны, мкм	Спектральный интервал, мкм	Сигнал @ шум
0,57	0,50–0,65	200 @ 100 % albedo
0,72	0,65–0,80	200 @ 100 % albedo
0,86	0,80–0,90	200 @ 100 % albedo
3,75	3,50–4,00	0,35 K @ 300 K

Окончание табл. 1

Центральная длина волны, мкм	Спектральный интервал, мкм	Сигнал @ шум
6,35	5,70–7,00	0,40 К @ 300 К
8,00	7,50–8,50	0,10 К @ 300 К
8,70	8,20–9,20	0,15 К @ 300 К
9,70	9,20–10,20	0,20 К @ 300 К
10,70	10,20–11,20	0,15 К @ 300 К
11,70	11,20–12,50	0,25 К @ 300 К

Физические основы определения LWP

С подробными физическими аспектами восстановления LWP по данным радиометра МСУ-ГС можно ознакомиться в работе (Филей, Шаилова, 2023). Остановимся только лишь на теории переноса электромагнитного излучения в коротковолновой области спектра в облачной атмосфере. Процесс взаимодействия электромагнитного излучения с частицами облачности определяется КО (R_c), который вычисляется следующим образом:

$$R_c(\theta_0, \theta, \Delta\varphi, \tau_c, r_e) = \frac{\pi I_c(\theta_0, \theta, \Delta\varphi, \tau_c, r_e)}{F_0 \cos(\theta_0)}, \quad (1)$$

где I_c — интенсивность излучения на верхней границе облачности; F_0 — эффективный интегральный поток солнечного излучения в спектральном канале; θ_0 — зенитный угол Солнца; θ — зенитный угол спутника; $\Delta\varphi$ — относительный азимутальный угол.

Согласно выражению (1), КО облачности напрямую зависит от её оптических и микрофизических параметров, а именно от τ_c и r_e , для определения которых чаще всего используют каналы с длинами волн 0,6 мкм (0,86 или 1,24) и 1,6 мкм (2,13 или 3,7). На длине волны 0,6 мкм достигается максимум рассеяния электромагнитного излучения облачностью, которое зависит от её оптической толщины, в то время как на длине волны 1,6 мкм рассеяние уменьшается с ростом размеров частиц облачности, эффективно поглощающих электромагнитное излучение на этой длине волны. В силу своих конструктивных особенностей радиометр МСУ-ГС не имеет канала в окрестности длины волны 1,6 мкм, в связи с чем для определения микрофизических параметров используется канал на длине волны 3,7 мкм.

Стоит отметить, что в системе «подстилающая поверхность — атмосфера» отражённое солнечное излучение будет зависеть не только от оптических свойств облачности, но и от оптических свойств самой атмосферы и отражающих свойств подстилающей поверхности. С учётом вышеперечисленных факторов выражение (1) можно представить в следующем виде (Walther, Heidinger, 2012):

$$R_{\text{ТОА}} = \left[R_c(\theta_0, \theta, \Delta\varphi, \tau_c, r_e) + \frac{A_g T_c(\theta_0, \tau, r_e) T_c(\theta, \tau, r_e)}{1 - A_g A_{\text{sph}}(\tau_c, r_e)} \right] T_g, \quad (2)$$

где $R_{\text{ТОА}}$ — КО на верхней границе атмосферы; T_g — коэффициент пропускания атмосферы; T_c — коэффициент пропускания облачности; A_{sph} — сферическое альбедо; A_g — альбедо подстилающей поверхности.

Зная оптические свойства атмосферы и подстилающей поверхности, а также измерения в каналах спутникового прибора, можно определить τ_c и r_e и рассчитать LWP, используя, например, следующее выражение (Мазин, Хргиан, 1989):

$$\text{LWP} = \frac{3}{4} \tau_c r_e \rho, \quad (3)$$

где ρ — плотность частицы (1 г/см³ — капли воды; 0,917 г/см³ — кристаллы льда).

Выражение (3) позволяет оценить общую массу сконденсированной воды (капель воды или кристаллов льда) в столбе облачного слоя. Однако для оценки водозапаса разных типов облачности применяются различные выражения, полученные на основе некоторого набора статистических данных (Матвеев, 1984). Так, в работе (Bennartz, 2007) для определения LWP предлагается использовать множитель 5/9 вместо 3/4 как для капельной, так и кристаллической облачности. В то же время исследования работы (Heymssfield et al., 2003) показывают, что с увеличением размера частиц кристаллов льда их массовый коэффициент ослабления практически не изменяется, и LWP зависит напрямую от τ_c .

Как уже было отмечено ранее, для расчёта τ_c и r_e можно воспользоваться классическим методом, используя статистическую регуляризацию и справочные таблицы, описывающие оптические характеристики объёмного рассеяния частиц льда и капель воды в каналах спутникового прибора. Либо вместо статистической регуляризации для решения обратной задачи использовать ИНС, что и было сделано в рамках настоящего исследования. Подробно об архитектуре нейронной сети и её обучении будет рассказано в следующем разделе.

Используемые данные

С целью формирования обучающих и тестовых наборов данных были предварительно рассчитаны LUT, содержащие смоделированные значения R_{TOA} в коротковолновых каналах МСУ-ГС, для каждого типа облачности (капельная и кристаллическая) и для различных комбинаций τ_c , r_e , θ_0 , θ , $\Delta\phi$, A_g . В рамках настоящей работы моделирование осуществлялось для каналов с длинами волн 0,6 и 3,7 мкм с помощью быстрой радиационной модели на основе программного кода DISORT (англ. DIScrete Ordinate Radiative Transfer) (Buras et al., 2011), входящего в состав библиотеки Libradtran (Mayer et al., 2017). Для моделирования оптических свойств объёмного рассеяния кристаллов льда облачности использовалась модель рассеяния Baum (Baum et al., 2005a, b), а для капель воды — модель Hu (Hu, Stamnes, 1993). Учёт поглощения солнечного излучения газовыми компонентами атмосферы осуществлялся с использованием параметризации Reptran (Gasteiger et al., 2014). Для упрощения моделирования атмосфера рассматривалась как однослойный однородный распределённый облачный слой без аэрозолей и малых газовых составляющих.

Список параметров в LUT представлен в *табл. 2*.

Таблица 2. Используемые параметры для обучения ИНС

Параметр	Капельная облачность	Кристаллическая облачность
r_e , мкм	0,4–1,5 с шагом 0,2*	0,7–2,0 с шагом 0,2*
τ_c	–0,6...2,4 с шагом 0,2*	
θ_0	0–100° с шагом 20°	
θ	0–80° с шагом 5°	
$\Delta\phi$	0–180° с шагом 30°	
A_g	0–1 с шагом 0,2	
$R_{\text{TOA}}(0,6)$	0–100 %	
$R_{\text{TOA}}(3,7)$		

* 10^{τ_e} .

Представленный в *табл. 2* набор данных подобен тому, который использовался авторами работы (Филей, Шапилова, 2023) для определения LWP по данным КА «Арктика-М» № 1 путём расчёта τ_c и r_e методом статистической регуляризации. В настоящей работе параметры

τ_c и r_e пересчитываются в значения LWP в соответствии с выражением (3) на этапе формирования выборки перед обучением ИНС. Таким образом, на вход ИНС подаются значения $R_{\text{TOA}}(0,6)$, $R_{\text{TOA}}(3,7)$, θ_0 , θ , $\Delta\phi$, A_g , а выходной информацией является значение LWP.

Так как формирование обучающей выборки осуществляется для измерений «чистой» атмосферы, без аэрозолей и малых газовых составляющих, то перед подачей на вход ИНС непосредственных измерений R_{TOA} необходимо проводить атмосферную коррекцию. Атмосферная коррекция выполнялась по методике, описанной в работе (Филей, 2019).

Архитектура и обучение нейронной сети

В качестве архитектуры при построении ИНС используется модель нейронной сети прямого распространения на основе многослойного персептрона (Svozil et al., 1997). Данная архитектура нашла своё применение во многих прикладных областях исследований, в том числе при решении задач дистанционного зондирования Земли, благодаря своей универсальности, позволяя аппроксимировать сложные нелинейные функции на основе данных (Mas, Flores, 2008).

Для решаемой задачи регрессии экспериментальным путём была подобрана конфигурация нейронной сети, обеспечивающая наибольшую точность при отсутствии эффекта переобучения модели на тренировочном и валидационном наборах данных. Для контроля переобучения используется известный протокол, согласно которому исходная выборка перемешивалась случайным образом и разделялась на две независимые подвыборки (25 % для валидации, остальное для обучения), используемые для обучения модели, её настройки (в том числе для контроля переобучения) и итоговой оценки после обучения. Общая обучающая выборка, сформированная по данным LUT, составила порядка 6 млн измерений.

Нейронная сеть состоит из входного слоя с размерностью, равной количеству используемых параметров, а также четырёх скрытых слоёв с количеством нейронов 32-64-128-256. Сигнал каждого нейрона пропускается через активационную функцию на основе гиперболического тангенса. В качестве выходного слоя используется один нейрон, значение которого соответствует восстанавливаемому параметру LWP.

Процесс обучения нейронной сети формулируется как задача оптимизации, результатом которой становится минимизация некоторой функции ошибки (среднеквадратической в настоящей работе) между выходным сигналом сети и фактическим значением LWP. С этой целью осуществляется поиск набора параметров нейронной сети (значений весовых коэффициентов нейронов) таких, чтобы значение ошибки было минимальным. В работе данная задача решалась методом стохастического градиентного спуска с использованием алгоритма Adam (англ. Adaptive Momentum). Алгоритм достаточно универсален применительно к обучению различных архитектур, прост в настройке и не требует большого количества вычислительных ресурсов (Kingma, Ba, 2014). Критерием завершения обучения становится продолжительное отсутствие улучшений значений ошибки для валидационной выборки. Дополнительным критерием становится малая величина разности между ошибками для обучающей и валидационной выборки. Полученные наборы весовых коэффициентов, удовлетворяющие этим критериям, сохраняются для дальнейшего использования модели ИНС.

Результаты и валидация

После обучения нейронной сети осуществлялся расчёт LWP по данным радиометра МСУ-ГС КА «Электро-Л» № 4, информация с которого была получена на приёмную станцию Дальневосточного центра НИЦ «Планета». Использовались измерения КО в каналах 0,6 и 3,7 мкм, прошедшие процедуру атмосферной коррекции по методике, описанной в работе (Филей, 2019). Применяя атмосферно-скорректированные КО в каналах 0,6 и 3,7 мкм, рассчитанные углы наблюдения и освещения, а также альбедо поверхности с помощью полученной ранее нейросетевой модели, вычисляется LWP (в г/м²). Значения альбедо для суши брались

из 16-дневных композитов продукта MOD43 радиометра MODIS (<https://modis.gsfc.nasa.gov/data/dataproduct/mod43.php>), альбедо для воды принималось постоянным, со значением 0,03.

В рамках настоящей работы валидация восстановленных оценок LWP по данным КА «Электро-Л» № 4 проводилась сопоставлением с аналогичными оценками, полученными разработанным ранее авторами (Филей, Шамилова, 2023) алгоритмом на основе решения обратной задачи методом статистической регуляризации с использованием LUT. Была рассмотрена серия сеансов съёмки «Электро-Л» № 4 за разные сезоны 2024 г. с целью охватить максимально возможные вариации водозапаса облаков. Учитывая большой географический охват территории, валидация проводилась для различных климатических зон со своими уникальными природными особенностями. Пример пространственного охвата съёмки КА «Электро-Л» № 4 представлен на *рис. 1*.




Рис. 1. Пространственный охват КА «Электро-Л» № 4 (01.07.2024, 02:00 UTC (англ. Coordinated Universal Time))

Обозначим водозапас, восстановленный представленным нейросетевым алгоритмом, как LWP(NEURO), а восстановленный методом статистической регуляризации — как LWP(LUT). При сопоставлении оценок LWP измерения ограничивались по широте, не превышающей 60°, так как для геостационарных КА выше данной широты имеют место серьёзные спектральные и геометрические искажения. Кроме этого, чтобы исключить многократное рассеяние солнечного излучения, было принято решение также ограничить измерения по углу Солнца, не превышающему 65°. Согласно работе (Walther, Heidinger, 2012) погрешность

определения LWP не должна быть больше 50 г/м^2 для капельной облачности и 100 г/м^2 для кристаллической облачности. Заявленная величина точности восстановления LWP достигается только при благоприятных условиях. Наличие осадков, многослойной облачности, а также неопределённостей представленного алгоритма могут увеличить ошибку в несколько раз. При этом сама оценка точности восстановления LWP по спутниковым данным часто может быть не объективна из-за использования в сравнении результатов других алгоритмов, которые также обладают погрешностями восстановления. Учитывая тот факт, что и для нейросетевого алгоритма, и для классического алгоритма на основе метода статистической регуляризации решения обратной задачи использовались одни и те же смоделированные КО в каналах радиометра МСУ-ГС, ожидается, что и восстановленные оценки LWP будут максимально похожи.

На *рис. 2* приводится диаграмма рассеяния оценок LWP, полученных по данным прибора МСУ-ГС нейросетевым и классическим алгоритмами. В *табл. 3* представлены объём выборки и статистика ошибок.




Рис. 2. Диаграмма рассеяния оценок LWP

Таблица 3. Объём выборки и статистика ошибок

Фазовое состояние	Объём выборки (N)	Смещение (BIAS), г/м^2	Среднеквадратическая ошибка (RMSE), г/м^2
Капельное	2 234 200	3,94	16,21
Кристаллическое	1 237 870	-12,07	70,21

Результаты, представленные на *рис. 2* и в *табл. 3*, свидетельствуют о хорошей согласованности оценок LWP облачности. Как и следовало ожидать, среднеквадратическая ошибка (RMSE) LWP кристаллической облачности выше, чем капельной. Связано это в первую очередь с тем, что отражательная способность капель воды на длине волны 4 мкм (канал № 4) выше, чем у кристаллов льда. С увеличением размера частиц повышается неопределённость при восстановлении LWP кристаллической облачности, неважно нейросетевым или классическим алгоритмом. Кроме этого, канал на длине волны 3,7 мкм регистрирует только малую часть солнечного излучения, в связи с чем с увеличением зенитного угла Солнца будет уменьшаться отношение сигнал/шум в этом канале, что в свою очередь также приведёт к повышению

неопределённости при восстановлении LWP. Несмотря на ограничения, результаты, полученные нейросетевым алгоритмом, достаточно близки к результатам классического алгоритма. При этом по результатам исследования нейросетевой алгоритм показал почти 20-кратное преимущество в быстродействии по сравнению с классическим алгоритмом на вычислительной машине с центральным процессором Intel i7 7700K и графическим ускорителем Nvidia RTX 3060.

Пример восстановленных оценок LWP по данным МСУ-ГС 01.07.2024, 02:00 UTC представлен на *рис. 3*.




Рис. 3. Восстановленные оценки LWP по данным МСУ-ГС 01.07.2024, 02:00 UTC:
а — классический алгоритм; б — нейросетевой алгоритм

Визуально на *рис. 3* области LWP по данным двух алгоритмов совпадают. Принимая во внимание все полученные результаты, можно сказать, что нейросетевой алгоритм не уступает по точности классическому алгоритму и может использоваться в оперативной работе для оценок общей массы сконденсированной воды/льда в облаках с целью определения типов облачности и вероятности выпадения осадков.

Заключение

В ходе работы представлена нейросетевая методика восстановления LWP по данным дневных измерений радиометра МСУ-ГС КА «Электро-Л» № 4. Были описаны физические основы определения LWP с применением ИНС. Результаты сравнения оценок LWP, полученных по данным МСУ-ГС с использованием нейросетевого и статистического алгоритмов, показали высокую согласованность. При этом ошибка RMSE составила 16,21 г/м² для капельной облачности и 70,21 г/м² для кристаллической. Стоит отметить, что оценка LWP кристаллической облачности в среднем завышена на 12 г/м², капельной облачности занижена на 4 г/м². Полученные результаты сравнения оценок LPW двух алгоритмов позволяют сделать вывод о работоспособности нейросетевого подхода, который может быть использован в оперативной практике наряду с классическим статистическим алгоритмом, не уступая при этом в точности и выигрывая в простоте реализации и скорости расчёта. Это в очередной раз доказывает потенциальную возможность применения методов искусственного интеллекта в решении сложных обратных задач для восстановления параметров атмосферы без существенного увеличения трудоёмкости.

Литература

1. Мазин И. П., Хргиан А. Х. Облака и облачная атмосфера. Справ. Л.: Гидрометеиздат, 1989. 647 с.
2. Матвеев Л. Т. Курс общей метеорологии. Физика атмосферы. Л.: Гидрометеиздат, 1984. 751 с.
3. Филей А. А. Восстановление оптической толщины и эффективного радиуса частиц облачности по данным дневных измерений спутникового радиометра МСУ-МР // Оптика атмосферы и океана. 2019. Т. 32. № 8. С. 650–656. DOI: 10.15372/AOO20190807.
4. Филей А. А., Шамилова Ю. А. Определение водозапаса облачности по данным радиометра МСУ-ГС КА Арктика-М № 1 // Исслед. Земли из космоса. 2023. № 3. С. 70–80. DOI: 10.31857/S0205961423030028.
5. Baum B. A., Heymsfield A. J., Yang P., Bedka S. T. (2005a) Bulk scattering models for the remote sensing of ice clouds. Part I: Microphysical data and models // J. Applied Meteorology and Climatology. 2005. V. 44. No. 12. P. 1885–1895. DOI: 10.1175/JAM2308.1.
6. Baum B. A., Yang P., Heymsfield A. J. et al. (2005b) Bulk scattering models for the remote sensing of ice clouds. Part II: Narrowband models // J. Applied Meteorology and Climatology. 2005. V. 44. No. 12. P. 1896–1911. DOI: 10.1175/JAM2309.1.
7. Bennartz R. Global assessment of marine boundary layer cloud droplet number concentration from satellite // J. Geophysical Research: Atmospheres. 2007. V. 112. Iss. D2. Article D02201. 16 p. DOI: 10.1029/2006JD007547.
8. Buras R., Dowling T., Emde C. New secondary-scattering correction in DISORT with increased efficiency for forward scattering // J. Quantitative Spectroscopy and Radiative Transfer. 2011. V. 112. Iss. 12. P. 2028–2034. DOI: 10.1016/j.jqsrt.2011.03.019.
9. Gasteiger J., Emde C., Mayer B. et al. Representative wavelengths absorption parameterization applied to satellite channels and spectral bands // J. Quantitative Spectroscopy and Radiative Transfer. 2014. V. 148. P. 99–115. DOI: 10.1016/j.jqsrt.2014.06.024.
10. Han Q., Rossow W. B., Lacis A. A. Near-global survey of effective droplet radii in liquid water clouds using ISCCP data // J. of Climate. 1994. V. 7. P. 465–497. DOI: 10.1175/1520-0442(1994)007<0465:NGSOED>2.0.CO;2.
11. Heymsfield A. J., Matrosov S., Baum B. Ice water path-optical relationships for cirrus and deep stratiform ice cloud layers // J. Applied Meteorology and Climatology. 2003. V. 42. No. 10. P. 1369–1390. DOI: 10.1175/1520-0450(2003)042<1369:IWPDRF>2.0.CO;2.
12. Hu Y. X., Stamnes K. An accurate parameterization of the radiative properties of water clouds suitable for use in climate models // J. of Climate. 1993. V. 6. P. 728–742. DOI: 10.1175/1520-0442(1993)006<0728:AAPOTR>2.0.CO;2.
13. Kingma D. P., Ba J. Adam: A method for stochastic optimization // <https://arxiv.org/>. arXiv:1412.6980. 2014. 15 p. DOI: 10.48550/arXiv.1412.6980.
14. Mas J. F., Flores J. J. The application of artificial neural networks to the analysis of remotely sensed data // Intern. J. Remote Sensing. 2008. V. 29. Iss. 3. P. 617–663. DOI: 10.1080/01431160701352154.
15. Mayer B., Kylling A., Emde C., Buras R., Hamann U., Gasteiger J., Richter B. LibRadtran user's guide. 2017. 155 p.

16. 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. P. 459–473. DOI: 10.1109/TGRS.2002.808301.
17. Roebeling R. A., Feijt A. J., Stammes P. Cloud property retrievals for climate monitoring: Implications of differences between Spinning Enhanced Visible and Infrared Imager (SEVIRI) on METEOSAT-8 and Advanced Very High Resolution Radiometer (AVHRR) on NOAA-17 // J. Geophysical Research: Atmospheres. 2006. V. 111. Iss. D20. Article D20210. 16 p. DOI: 10.1029/2005JD006990.
18. Svozil D., Kvasnicka V., Pospichal J. Introduction to multi-layer feed-forward neural networks // Chemometrics and Intelligent Laboratory Systems. 1997. V. 39. Iss. 1. P. 43–62. DOI: 10.1016/S0169-7439(97)00061-0.
19. Walther A., Heidinger A. Implementation of the Daytime Cloud Optical and Microphysical Properties. Algorithm (DCOMP) in PATMOS-x // J. Applied Meteorology and Climatology. 2012. V. 51. No. 7. P. 1371–1390. DOI: 10.1175/JAMC-D-11-0108.1.

Using neural network to retrieve cloud water path from MSU-GS radiometer measurements on board the Electro-L No. 4 satellite

A. A. Filei, A. I. Andreev

*Far Eastern Center of SRC “Planeta”, Khabarovsk 680000, Russia
E-mail: vmer@dvrcpod.ru*

The paper presents a neural network method for the retrieval of cloud water path using MSU-GS radiometer daytime measurements on board the Electro-L No. 4 Russian hydrometeorological satellite. The method is based on physical principles of interaction of electromagnetic radiation with cloud particles in the MSU-GS radiometer channels at wavelengths of 0.6 and 4.0 μm . Using a fully connected feedforward neural network, a relationship is established between the measurements of cloud reflectivity in the satellite radiometer channels and its microphysical parameters: optical thickness and effective radius. When training the neural network, the role of a reference source of information was assigned to an MSU-GS measurements array simulated using the Libradtran radiation transfer model and the corresponding cloud water path values calculated based on optical thickness and effective radius of particles for droplet and crystal clouds. The neural network model obtained during training was used to estimate cloud water path on the basis of direct measurements of MSU-GS, which were then compared with similar estimates obtained by the classical algorithm for solving the inverse problem using statistical regularization method. According to the comparison results, the root-mean-square error of the cloud water path estimates did not exceed 44 g/m^2 . On average, the value of cloud water path of crystal cloudiness was overestimated by 12 g/m^2 , and that of droplet cloudiness underestimated by 4 g/m^2 . The obtained results allow us to conclude that the neural network algorithm is efficient and can be used in operational practice along with classical statistical algorithm, without being inferior in accuracy and winning in ease of implementation and calculation speed.

Keywords: MSU-GS, Electro-L No. 4, neural networks, cloud water path, optical thickness, effective radius, cloudiness

Accepted: 21.03.2025

DOI: 10.21046/2070-7401-2025-22-3-53-63

References

1. Mazin I. P., Hrgian A. H., *Oblaka i oblachnaya atmosfera* (Clouds and cloudy atmosphere), Leningrad: Gidrometeoizdat, 1989, 647 p. (in Russian).
2. Matveev L. T., *Kurs obshchei meteorologii. Fizika atmosfery* (Course of general meteorology. Atmospheric physics), Leningrad: Gidrometeoizdat, 1984, 751 p. (in Russian).

3. Filei A.A., Retrieval of the cloud optical depth and particle effective radii from MSU-MR daytime measurements, *Optika atmosfery i okeana*, 2019, V. 32, No. 8, pp. 650–656 (in Russian), DOI: 10.15372/AOO20190807.
4. Filei A.A., Shamilova Yu.A., Retrieval of cloud liquid water path from MSU-GS data onboard Arktika-M 1, *Izvestiya, Atmospheric and Oceanic Physics*, 2023, V. 59, No. 9, pp. 1189–1197, DOI: 10.1134/S0001433823090062.
5. Baum B.A., Heymsfield A.J., Yang P., Bedka S.T. (2005a), Bulk scattering models for the remote sensing of ice clouds. Part I: Microphysical data and models, *J. Applied Meteorology and Climatology*, 2005, V. 44, No. 12, pp. 1885–1895, DOI: 10.1175/JAM2308.1.
6. Baum B.A., Yang P., Heymsfield A.J. et al. (2005b), Bulk scattering models for the remote sensing of ice clouds. Part II: Narrowband models, *J. Applied Meteorology and Climatology*, 2005, V. 44, No. 12, pp. 1896–1911, DOI: 10.1175/JAM2309.1.
7. Bennartz R., Global assessment of marine boundary layer cloud droplet number concentration from satellite, *J. Geophysical Research: Atmospheres*, 2007, V. 112, Iss. D2, Article D02201, 16 p., DOI: 10.1029/2006JD007547.
8. Buras R., Dowling T., Emde C., New secondary-scattering correction in DISORT with increased efficiency for forward scattering, *J. Quantitative Spectroscopy and Radiative Transfer*, 2011, V. 112, Iss. 12, pp. 2028–2034, DOI: 10.1016/j.jqsrt.2011.03.019.
9. Gasteiger J., Emde C., Mayer B. et al., Representative wavelengths absorption parameterization applied to satellite channels and spectral bands, *J. Quantitative Spectroscopy and Radiative Transfer*, 2014, V. 148, pp. 99–115, DOI: 10.1016/j.jqsrt.2014.06.024.
10. Han Q., Rossow W.B., Lacis A.A., Near-global survey of effective droplet radii in liquid water clouds using ISCCP data, *J. of Climate*, 1994, V. 7, pp. 465–497, DOI: 10.1175/1520-0442(1994)007<0465:NGSOED>2.0.CO;2.
11. Heymsfield A.J., Matrosov S., Baum B., Ice water path-optical relationships for cirrus and deep stratiform ice cloud layers, *J. Applied Meteorology and Climatology*, 2003, V. 42, No. 10, pp. 1369–1390, DOI: 10.1175/1520-0450(2003)042<1369:IWPDRF>2.0.CO;2.
12. Hu Y.X., Stamnes K., An accurate parameterization of the radiative properties of water clouds suitable for use in climate models, *J. of Climate*, 1993, V. 6, pp. 728–742, DOI: 10.1175/1520-0442(1993)006<0728:AAPOTR>2.0.CO;2.
13. Kingma D.P., Ba J., Adam: A method for stochastic optimization, <https://arxiv.org/>, arXiv:1412.6980, 2014, 15 p., DOI: 10.48550/arXiv.1412.6980.
14. Mas J.F., Flores J.J., The application of artificial neural networks to the analysis of remotely sensed data, *Intern. J. Remote Sensing*, 2008, V. 29, Iss. 3, pp. 617–663, DOI: 10.1080/01431160701352154.
15. Mayer B., Kylling A., Emde C., Buras R., Hamann U., Gasteiger J., Richter B., *LibRadtran user's guide*, 2017, 155 p.
16. 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, pp. 459–473, DOI: 10.1109/TGRS.2002.808301.
17. Roebeling R.A., Feijt A.J., Stammes P., Cloud property retrievals for climate monitoring: Implications of differences between Spinning Enhanced Visible and Infrared Imager (SEVIRI) on METEOSAT-8 and Advanced Very High Resolution Radiometer (AVHRR) on NOAA-17, *J. Geophysical Research: Atmospheres*, 2006, V. 111, Iss. D20, Article D20210, 16 p., DOI: 10.1029/2005JD006990.
18. Svozil D., Kvasnicka V., Pospichal J., Introduction to multi-layer feed-forward neural networks, *Chemometrics and Intelligent Laboratory Systems*, 1997, V. 39, Iss. 1, pp. 43–62, DOI: 10.1016/S0169-7439(97)00061-0.
19. Walther A., Heidinger A., Implementation of the Daytime Cloud Optical and Microphysical Properties. Algorithm (DCOMP) in PATMOS-x, *J. Applied Meteorology and Climatology*, 2012, V. 51, No. 7, pp. 1371–1390, DOI: 10.1175/JAMC-D-11-0108.1.