

## **Использование нейронных сетей при восстановлении высотного профиля влажности атмосферы по данным СВЧ радиометрии**

Д.П. Егоров<sup>1</sup>, А.А. Козлова<sup>2</sup>, А.Л. Афанасьев<sup>2</sup>

<sup>1</sup> Институт радиотехники и электроники им. В.А. Котельникова РАН  
125009, г. Москва, ул. Моховая, 11, корп. 7.

E-mail: [e-mail@lab329.ru](mailto:e-mail@lab329.ru)

<sup>2</sup> Московский физико-технический институт  
141701, г. Долгопрудный, Институтский переулок, 9

E-mail: [anna.k@lab329.ru](mailto:anna.k@lab329.ru)

*В докладе обсуждаются возможности применения нейросетевых моделей для восстановления высотного профиля влажности атмосферы по данным многоканальных СВЧ радиометров. Рассмотрен полусинтетический подход к формированию обучающих выборок на основе профилей метеорологических параметров, полученных методом радиозондирования. Проведен сравнительный анализ эффективности некоторых моделей для случая наземной радиометрии в условиях ясного неба и кучевой облачности. Предложены пути дальнейшего повышения точности и надёжности нейросетевых алгоритмов восстановления атмосферных профилей. Ключевые слова: атмосфера, высотный профиль, влажность, водность, облака, радиометрия, яркостная температура, нейронная сеть*

## **The use of neural networks for the reconstruction of atmospheric humidity altitude profiles based on microwave radiometry data**

D.P. Egorov<sup>1</sup>, A.A. Kozlova<sup>2</sup>, A.L. Afanasyev<sup>2</sup>

<sup>1</sup> Kotel'nikov Institute of Radioengineering and Electronics of RAS.

<sup>2</sup> Moscow Institute of Physics and Technology (MIPT).

*The possibilities of neural network models for atmospheric humidity altitude profile retrieval from passive microwave sensors' data are discussed. A semi-synthetic approach to shaping the learning datasets using meteorological parameters obtained via radiosondes is considered. A comparative analysis of several models for the case of ground-based radiometry under conditions of clear sky and cumulus cloudiness is performed. The ways to further improve the accuracy and reliability of neural network algorithms for atmospheric profiles reconstruction are proposed.*

*Keywords: atmosphere, altitude profile, humidity, liquid water, clouds, radiometry, brightness temperature, neural network*

### **Введение**

Совершенствование методов дистанционного определения температурно-влажностных характеристик атмосферы является ключевым фактором повышения эффективности систем метеорологического мониторинга и предупреждения опасных погодных явлений, что приобретает особую актуальность в свете глобальных климатических изменений и нарастающей антропогенной нагрузки на экосистемы. Вместе с тем среди прочих методов ДЗЗ именно СВЧ радиометрия выделяется как наиболее универсальный и надёжный способ восстановления геофизических параметров атмосферы и почвенного покрова. Метод СВЧ радиометрии в широком диапазоне погодных условий демонстрирует большую точность при восстановлении атмосферных профилей, а также при оценке влажности и засоленности почв, уступая, тем не менее, инфракрасным и радиолокационным методам в пространственном разрешении. Однако

микроминиатюризация пассивных СВЧ сенсоров на основе технологии монолитных интегральных схем (МИС) с использованием планарных антенн – при сохранении угловой разрешающей способности и флуктуационной чувствительности – уже сейчас позволяет размещать эти сенсоры на мобильных платформах, включая беспилотные летательные аппараты малых и предельно малых высот, что фактически снимает проблему низкого пространственного разрешения в рамках локального или регионального мониторинга. Более того, такое размещение способствует повышению оперативности сбора радиометрических данных, а также многократному увеличению их объема. Появляется возможность проведения одновременно мультисенсорной, мультиспектральной и многополяризационной съемки, согласованных измерений в СВЧ и инфракрасном диапазонах, синхронного наблюдения излучательных характеристик атмосферы и подстилающей поверхности, что открывает принципиально новые перспективы для дальнейшего повышения точности восстановления геофизических параметров и качества прогнозных моделей в различных конечных сферах применения предоставляемых продуктов мониторинга.

При этом имеющиеся алгоритмы радиометрического восстановления температурно-влажностных параметров и их высотных распределений – как в случае атмосферы, так и в случае почвенного покрова – не адаптированы для работы с такими данными. Существующие решения либо характеризуются высокой вычислительной сложностью, низкой пропускной способностью, либо пока не гарантируют достаточной точности и надежности восстановления, требуя существенной переработки. Это предопределяет острую необходимость модернизации расчетных алгоритмов СВЧ радиометрии с учетом передовых достижений в области математического аппарата обратных задач и машинного обучения.

В последние годы нейросетевые модели зарекомендовали себя как перспективный инструмент для решения обратных задач в самых различных областях науки. Обзор современных алгоритмов, использующих искусственные нейронные сети (ИНС) для восстановления температурно-влажностных профилей атмосферы, представлен, например, в работах [1-3]. Их ключевыми преимуществами являются высокая скорость и возможность обработки больших объемов спектральных данных в режиме реального времени. Тем не менее, вопрос о повышении точности и надёжности таких алгоритмов остаётся открытым.

### **Подготовка данных**

Основным этапом разработки нейросетевых моделей является сбор и подготовка данных для обучения – обучающей выборки, удовлетворяющей условиям полноты и репрезентативности. В подавляющем большинстве работ по СВЧ радиометрическому восстановлению атмосферных профилей с применением ИНС обучающие выборки формируются на основе данных реанализа профилей, с одной стороны, и экспериментально измеренных радиояркостных температур – с другой. При этом не рассматривается потенциальная возможность аугментации имеющихся выборок или их частичного расширения синтетическими данными. Действительно, прямое моделирование излучательных характеристик почвенного покрова сталкивается с существенными трудностями из-за многообразия типов почв, их значительной разнородности по составу и структуре, сложностью учета влияния внешних метеорологических факторов. В свою очередь, расчет излучательных и отражательных характеристик водной поверхности сопряжен с трудностями учета влияния поверхностного волнения с его шероховатостью и пенным покровом. В то же время для атмосферы яркостные температуры её собственного излучения в различных частотных каналах могут быть довольно точно рассчитаны методом суммирования спектральных

линий [4] из известных (или моделируемых) высотных распределений основных метеорологических параметров: термодинамической температуры  $T$ , атмосферного давления  $P$ , абсолютной  $\rho$  или относительной влажности воздуха, а также водности  $w$  (при наличии облаков). По крайней мере, это позволяет синтезировать обучающие примеры для случая зондирования атмосферы с поверхности Земли, когда вклад от подстилающей поверхности отсутствует.

В рамках текущего исследования для синтеза обучающих наборов данных применялся разработанный авторами ранее программный инструмент расчета спектров яркостной температуры «Atmrad» [5]. Ключевым преимуществом этого инструмента является возможность существенного ускорения вычислений за счёт использования мощностей графических процессоров (GPU). Дополнительно разработан программный модуль, см. [5], обеспечивающий интеграцию инструмента «Atmrad» в рабочие конвейеры (пайплайны) машинного обучения на базе фреймворка «PyTorch» [6]. В качестве исходных данных для моделирования яркостных температур использовались многочисленные сеансы радиозондирования (р/з) атмосферы из архива университета Вайоминга [7], проведенные в период с 2000 по 2026 гг. на территории Российской Федерации (за исключением регионов, расположенных за полярным кругом). Из общего массива данных случайным образом отобрано порядка 60 тыс. сеансов, удовлетворяющих следующим критериям: 1) теплое время года (1 апреля – 30 сентября); 2) высота первого измерения – не более 200 м; 3) высота последнего измерения – не менее 15 км. Из рассмотрения были также исключены сеансы, содержащие физически невозможные значения параметров. Профили  $T_{p/z}(h)$ ,  $P_{p/z}(h)$  и  $\rho_{p/z}(h)$  далее сводились к единой сетке высот  $h$  от 0.2 до 15 км с шагом 100 м путем линейной интерполяции значений.

Расчет спектров яркостной температуры нисходящего излучения атмосферы производился как в предположении нулевой водности (выборка I – ясное небо), так и для условий облачности (выборка II – жидкокапельные облака). Во втором случае профиль водности  $w_{\text{мод.}}(h)$  варьировался в соответствии с моделью для кучевых облаков, рассмотренной в [8-9]. При этом вертикальная протяжённость  $H$  изменялась в пределах до 5 км, что соответствует развитой кучевой облачности. Архивы с результатами расчетов доступны для скачивания на сайте лаборатории 325 ИРЭ РАН [10]. Нейросетевые модели, приведенные в следующем разделе, используют для предсказания профиля абсолютной влажности величины яркостных температур нисходящего в надир излучения в частотных каналах 18–40 ГГц, 50–55 ГГц, 65–70 ГГц и 178.3–188 ГГц (с шагом 200 МГц). Следует отметить, что такое количество каналов является заведомо избыточным. Возможность его существенного сокращения будет рассмотрена в дальнейших работах.

### Смеси экспертов

Хотя определенные попытки были предприняты [11], в литературе по СВЧ радиометрии атмосферы пока мало сведений о применении в задаче восстановления высотных профилей метеорологических параметров передовых нейросетевых архитектур, например, ИНС со встроенными механизмами самовнимания (self-attention) или перекрестного внимания (cross-attention). Авторам также неизвестны работы, рассматривающие в этом контексте нейросетевые модели типа «смесь экспертов» (MoE – Mixture of Experts). Тем не менее, результаты сравнения таких моделей с классической архитектурой нейронной сети – многослойным персептроном (MLP – Multilayer perceptron), изложенные далее, указывают на перспективность подхода MoE.

Для сравнения моделей сформированные на предыдущем этапе выборки I и II были разделены на тренировочные, валидационные и тестовые подмножества примеров в

соотношении 60/20/20%. На тренировочных подмножествах с использованием алгоритма стохастической оптимизации [12] были обучены MLP-I, МоЕ-I, MLP-II и МоЕ-II, соответственно. Модели MLP-I/II здесь включают два скрытых слоя по 1024 нейрона и третий скрытый слой с 512 нейронами. На входной слой помимо яркостных температур в различных частотных каналах подаётся информация о приповерхностных величинах метеорологических параметров ( $T_{p/z}$ ,  $P_{p/z}$  и  $\rho_{p/z}$  при  $h = 200$  м), а также месяц в числовом выражении (4–9). В качестве активации входного и скрытого слоёв используется функция GELU [13]. Величины яркостных температур  $T_y$  (К) предварительно масштабируются по формуле

$$\tilde{T}_y = \frac{T_y - T_{\text{std}}}{T_{\text{std}}}, \quad (1)$$

где  $T_{\text{std}}$  – спектр яркостной температуры (К) стандартной атмосферы ( $T_0 = 15^\circ\text{C}$ ,  $P_0 = 1013$  кПа,  $\rho_0 = 7.5$  г/м<sup>3</sup>). Нейроны выходного слоя соответствуют значениям абсолютной влажности на высотах от 0.2 до 15 км с шагом 100 м – всего 149 нейронов. Целевые значения абсолютной влажности  $\rho_{p/z}$  (г/м<sup>3</sup>) также масштабируются

$$\tilde{\rho}_{p/z} = \frac{\rho_{p/z} - \rho_{\text{std}}}{\rho_{\text{std}}}, \quad \text{где } \rho_{\text{std}}(h) = 7.5 \cdot \exp\left(-\frac{h}{2.1}\right). \quad (2)$$

Структурная схема сети типа МоЕ представлена в [10]. Ключевой особенностью МоЕ-I/II является наличие входной группы из 28-ми ИНС-«экспертов» – персептронов с одним скрытым слоем в 512 нейронов и выходным слоем из 10 нейронов, обучаемых предсказывать небольшие (по 1 км), перекрывающиеся по высоте (на 500 м) участки профиля влажности  $\tilde{\rho}_{p/z}$ . При этом каждому такому эксперту доступна вся имеющаяся информация: полный спектр  $\tilde{T}_y$ , приповерхностные величины метеопараметров и месяц в числовом выражении. Итоговое приближение полного профиля  $\tilde{\rho}_{p/z}$  затем выполняет «шлюзовая» сеть (также персептрон), основываясь как на показаниях  $\tilde{T}_y$ , так и на предсказаниях отдельных экспертов. Количество и размерность скрытых слоев шлюзовой сети не отличается от MLP-I/II. Функция активации слоёв (кроме выходного) ИНС-экспертов и шлюзовой сети – GELU.

**Таблица 1. Сравнительная оценка качества восстановления профиля влажности на высотах 0.2–15 км**


Метрика	MLP-I	МоЕ-I	MLP-II	МоЕ-II
MAE	0.1481	<b>0.1449</b>	0.1788	<b>0.1596</b>
MAPE	0.3484	<b>0.2983</b>	0.3959	<b>0.3406</b>
SMAPE	0.2807	<b>0.2438</b>	0.3067	<b>0.2731</b>
MSE	0.1064	<b>0.1026</b>	0.1505	<b>0.1202</b>
MSLE	0.0081	<b>0.0066</b>	0.0109	<b>0.0088</b>
R2	0.6731	<b>0.7765</b>	0.6062	<b>0.6835</b>
EV	0.6749	<b>0.7840</b>	0.6086	<b>0.6850</b>

**Таблица 2. Восстановление профиля влажности на высотах 0.2–10 км**

Метрика	MLP-I	МоЕ-I	MLP-II	МоЕ-II
MAE	0.2177	<b>0.2133</b>	0.2633	<b>0.2348</b>
MAPE	0.2775	<b>0.2312</b>	0.3198	<b>0.2861</b>
SMAPE	0.2317	<b>0.1979</b>	0.2632	<b>0.2341</b>
MSE	0.1585	<b>0.1528</b>	0.2243	<b>0.1790</b>
MSLE	0.0121	<b>0.0099</b>	0.0162	<b>0.0131</b>
R2	0.8198	<b>0.8783</b>	0.7487	<b>0.8034</b>
EV	0.8202	<b>0.8817</b>	0.7495	<b>0.8048</b>


Модели MLP-I/II, ИНС-эксперты и шлюзовые сети МоЕ-I/II проходили обучение в течение 100 эпох. Скорость обучения для всех моделей установлена равной 0.001. Функция ошибки во всех случаях – среднеквадратическая. Для последующего тестирования были использованы сохраненные состояния этих моделей, показавшие наименьшую величину среднеквадратической ошибки на валидации.

В таблице 1 приведены значения различных оценочных метрик как функций  $f(\tilde{\rho}_{p/3}, \bar{\rho}_{пред.})$  от референсных  $\tilde{\rho}_{p/3}(h)$  и предсказанных  $\bar{\rho}_{пред.}(h)$  профилей абсолютной влажности при  $h$  от 0.2 до 15 км. Значения получены для перечисленных моделей на соответствующих тестовых подмножествах примеров, которые не использовались в процессе обучения ни как тренировочные, ни как валидационные. Здесь MAE – средняя абсолютная ошибка, MAPE – средняя абсолютная процентная погрешность, SMAPE – симметричная средняя абсолютная процентная погрешность, MSE – среднеквадратическая ошибка, MSLE – среднеквадратичная логарифмическая ошибка, R2 – коэффициент детерминации, EV – объясненная дисперсия [14]. В таблице 2 для расчета тех же метрик референсные  $\tilde{\rho}_{p/3}(h)$  и предсказанные  $\bar{\rho}_{пред.}(h)$  профили абсолютной влажности рассматриваются при  $h$  от 0.2 до 10 км. При восстановлении профиля влажности как в условиях ясного неба (I), так и в случае кучевой облачности (II) модель «смеси экспертов» по всем параметрам превосходит обычный персептрон (MLP).




**Рис. 1. Высотное распределение коэффициента корреляции Пирсона между референсными и восстановленными значениями абсолютной влажности (ясное небо)**


На рис. 1 показано распределение коэффициента корреляции Пирсона по высоте  $h$ , рассчитанного для  $\{\tilde{\rho}_{p/3}^i(h)\}_i$  и  $\{\bar{\rho}_{пред.}^i(h)\}_i$  при  $i = 1, \dots, N$ , где  $N$  – размер тестового подмножества примеров выборки I (ясное небо), и  $h$  от 0.2 до 15 км. Отметим, что на интервале высот от 0.2 до 8 км коэффициент корреляции для MLP-1 падает от уровня около 0.95 до 0.85. В то же время для МоЕ-1 коэффициент корреляции на данном интервале не опускается ниже 0.93-0.94.



(а)



(б)



(в)

Рис. 2. Результаты восстановления профилей абсолютной влажности с использованием модели «смеси экспертов» в условиях ясного неба (МоЕ-1)

На рис. 2 (а)-(в) представлены некоторые результаты восстановления профилей абсолютной влажности (также в условиях ясного неба) с использованием модели «смеси экспертов» МоЕ-I. Здесь а) на высотах 2–8 км наблюдается существенное превышение значений восстанавливаемого профиля относительно эталонного профиля абсолютной влажности (для стандартной атмосферы); б) наблюдается инверсия профиля влажности в нижнем слое атмосферы и существенное занижение значений по сравнению с эталонным профилем в среднем высотном диапазоне; в) отмечается высокая влажность в слое до 2 км, и затем ярко выраженная аномалия в интервале высот от 2 до 4 км.

### **Выводы**

Проведен сравнительный анализ нейросетевых моделей MLP и МоЕ для СВЧ радиометрического восстановления высотного профиля абсолютной влажности атмосферы. Рассмотрены два сценария тёплого времени года: условия ясного неба и наличие кучевой облачности с вертикальным развитием до 5 км. В обоих случаях показано преимущество модели МоЕ перед MLP. Например, среднеквадратическая ошибка при наличии облаков для МоЕ составила 12.02%, тогда как для MLP данный показатель составил 15.05% в аналогичных условиях облачности. Полученные результаты в части оценки эффективности MLP согласуются с оценками, представленными в работах [15-17]. При этом модификации модели MLP, такие как изменение числа нейронов в скрытых слоях или изменение количества самих скрытых слоёв, в проведенных экспериментах не привели к значимому улучшению точности восстановления. В то же время увеличение числа тренировочных примеров в 3 раза привело к росту доли объяснённой дисперсии (EV) примерно на 10% как у MLP, так и у МоЕ.

Дальнейшая работа будет направлена, во-первых, на расширение имеющихся наборов данных для обучения моделей, что предполагает сбор и предобработку бóльшего объёма сеансов радиозондирования, а также использование архивов с реанализами для моделирования яркостных температур. Во-вторых, имеет смысл рассмотреть возможность включения расчётных значений яркостной температуры в функцию ошибки на этапе обучения ИНС. Такое включение означает, что рельеф поверхности оптимизации, ранее определяемый только отклонениями между целевыми и прогнозируемыми нейросетью высотными профилями (или их фрагментами), теперь также зависит от расхождения между входными спектрами яркостной температуры и спектрами, рассчитанными посредством прямого моделирования излучения атмосферы на базе прогнозируемых профилей. Первым шагом на этом пути может стать реализация специальных регуляризационных поправок на веса модели типа L1, L2 или Elastic Net, зависящих от фактической разницы между входными и «прогнозируемыми» яркостными температурами.

### **Литература**

1. Qiurui He, Zhenzhan Wang, Jiaoyang Li. Application of the Deep Neural Network in Retrieving the Atmospheric Temperature and Humidity Profiles from the Microwave Humidity and Temperature Sounder Onboard the Feng-Yun-3 Satellite // MDPI Sensors. 2021. Vol. 21. Iss. 14. P. 1-20.
2. Rohit Chakraborty, Animesh Maitra. Retrieval of Atmospheric Properties with Radiometric Measurements using Neural Network // Atmospheric Research. 2016. Vol. 181. P. 124-132.
3. Yan X., Liang C., Jiang Y., Luo N., Zang Z., Li Z. A Deep Learning Approach to Improve the Retrieval of Temperature and Humidity Profiles from a Ground-Based Microwave Radiometer // IEEE Transactions on Geoscience and Remote Sensing. 2020. Vol. 58. No. 12. P. 8427-8437.

4. Рекомендация МСЭ-R P.676-13 (08/2022). Затухание в атмосферных газах и связанное с ним воздействие. – Серия Р. Распространение радиоволн. 31 с.
5. Программный инструмент AtmRad и его интеграция с PyTorch // Репозиторий GitHub, URL: <https://github.com/dobribobri/atmrad> (дата обращения 20.04.2026).
6. Adam Paszke и др. PyTorch: An Imperative Style, High-Performance Deep Learning Library // arXiv:1912.01703, 2019. P. 1-12.
7. University of Wyoming Atmospheric Science Radiosonde Archive. URL: <https://weather.uwyo.edu/upperair/sounding.shtml> (дата обращения 20.04.2026).
8. Egorov D.P., Ilyushin Ya.A., Kutuza B.G. The Influence of Cumuli Distribution in Satellite Microwave Radiometer FOV on the Accuracy of Atmospheric Moisture Content Retrieval // IEEE Transactions on Geoscience and Remote Sensing. 2024. Vol. 62. P. 1.
9. Егоров Д.П., Кутуза Б.Г. Нейросетевой подход к решению обратной задачи восстановления высотного профиля влажности по нисходящему радиоизлучению облачной атмосферы // Материалы VII Всероссийской научной конференции «Проблемы военно-прикладной геофизики и контроля состояния природной среды». ВКА им. А.Ф. Можайского, Санкт-Петербург, 2022. С. 206-211.
10. Лаборатория 325 Радиофизических методов в аэрокосмических исследованиях природно-техногенной среды. URL: <https://lab329.ru> (дата обращения 20.04.2026).
11. Xiangyang Tan, Kaixue Ma, Fangli Dou. A Convolutional Neural Network and Attention-Based Retrieval of Temperature Profile for a Satellite Hyperspectral Microwave Sensor // MDPI Atmosphere. 2024. Vol. 15. N 2. P. 235.
12. Diederik P. Kingma, Jimmy Lei Ba. Adam: A Method for Stochastic Optimization // arXiv:1412.6980v9, 2017. P. 1-15.
13. Minhyeok Lee. GELU Activation Function in Deep Learning: A Comprehensive Mathematical Analysis and Performance // arXiv:2305.12073v2, 2023. P. 1-19.
14. PyTorchLightning et al. PyTorch-Metrics Documentation, Release 0.2.0 // Apr. 06, 2021.
15. Пашинов Е.В. Космический эксперимент «Конвергенция»: восстановление профиля водяного пара атмосферы с помощью искусственных нейронных сетей // Исследование Земли из космоса. 2019. № 6. С. 13-25.
16. Пашинов Е.В., Стерлядкин В.В., Кузьмин А.В., Шарков Е.А., Садовский И.Н. Нейросетевой алгоритм восстановления профилей влажности атмосферы по данным МТВЗА-ГЯ МЕТЕОР-М №2 // Труды XIV Международной научной конференции с научной молодёжной школой им. И.Н. Спиридонова. 2020. Т. 2. С. 251-256.
17. Селунский А.Б., Кузьмин А.В., Пашинов Е.В., Стерлядкин В.В., Хохлова А.В. Восстановление профилей температуры и влажности тропосферы методом нейронных сетей // Материалы XV Всероссийской открытой конференции «Современные проблемы дистанционного зондирования Земли из космоса». 2017. С. 466.