


Нейронные сети с механизмом внимания в задаче реконструкции температурно-влажностного профиля атмосферы по данным СВЧ радиометрии

Козлова А.А.^{1,2}, Егоров Д.П.¹

¹Институт радиотехники и электроники им. В.А. Котельникова РАН


²Московский физико-технический институт



Модельные спектры яркостной температуры
излучения атмосферы в диапазоне 1-300 ГГц

Наиболее информативными для радиометрического восстановления высотного профиля водяного пара нижней атмосферы, ее влагосодержания и водозапаса облаков при наблюдениях из приповерхностного слоя являются К- (18–26.5 ГГц) и Ка- (26.5–40 ГГц) диапазоны. Частотные каналы при этом стараются выбирать таким образом, чтобы часть из них располагалась непосредственно вблизи линии поглощения водяного пара, а остальные – на склоне этой линии. Так, в К-диапазоне обнаруживаются первая резонансная вращательная линия поглощения водяного пара 22.235 ГГц. Использование Ка-диапазона повышает точность восстановления профиля влажности в условиях развитой облачности. Это объясняется тем, что на более высоких частотах более ярко проявляется влияние влажности облаков.

При наблюдениях из космоса используют диапазон частот вблизи резонансной линии 183.3 ГГц (G-).




Предельные чувствительности СВЧ
радиометрической системы, обеспечивающие
восстановление термодинамической
температуры, безоблачная атмосфера [1]

Наиболее перспективным для восстановления профилей термодинамической температуры на высотах 0.5–5 км является диапазон 165–180 ГГц (или 185–200 ГГц), а альтернативой представляется диапазон 50–55 ГГц (или 65–70 ГГц), поскольку весовые функции в этих диапазонах слабо зависят от излучения подстилающей поверхности, имеют приемлемую частотную избирательность по высоте и приемлемые показатели предельной чувствительности [1].

[1]. Саворский В.П., Кибардина И.Н., Турыгин С.Ю., Смирнов М.Г. СВЧ радиометрические комплексы для восстановления температурновлажностных профилей атмосферы с высоким пространственным разрешением // VI Всероссийские Армандовские чтения. 2016. С. 223–229.

Одним из наиболее известных, широко используемых и физически обоснованных алгоритмов для решения обратной задачи восстановления профилей температуры и влажности в атмосфере по спектрам ее собственного излучения является алгоритм вариационной ассимиляции данных, см., например, 1D-Var [2, 3], объединяющий данные проведенных радиометрических измерений, модель решения прямой задачи (модельный расчет спектров яркостной температуры по заданным высотным распределениям метеорологических параметров) и фоновые исторические сведения по температурно-влажностному профилю для некоторой местности, времени года и суток (априорная информация).



[2]. Саворский В.П., Кутуза Б.Г., Аквилонова А.Б., Кибардина И.Н., Панова О.Ю., Данилычев М.В., Широков С.В. Повышение эффективности восстановления температурно-влажностных профилей облачной атмосферы по данным спутниковых сверхвысокочастотных спектрометров // Радиотехника и электроника. 2020. Т. 65. № 7. С. 658-666.

Алгоритм вариационной ассимиляции заключается в построении функционала ошибки вида (1) и дальнейшем использовании ньютоновских последовательных приближений или квази-ньютоновских методов для минимизации этого функционала [3, 4]. Несмотря на высокую точность при определенных условиях, этот алгоритм обладает рядом недостатков, к числу которых относятся его вычислительная сложность, низкая скорость работы, сильная зависимость от качества априорной информации. Линеаризация функционала (1), необходимая для традиционных методов оптимизации, может привести к ошибкам в условиях сильной нелинейности взаимосвязи яркостных температур и геофизических параметров наблюдаемой атмосферы, например, при наличии развитой кучевой облачности или осадков.

$$J(\mathbf{x}) = [\mathbf{x} - \mathbf{x}^b]^T \mathbf{B}^{-1} [\mathbf{x} - \mathbf{x}^b] + [\mathbf{y} - H(\mathbf{x})]^T \mathbf{R}^{-1} [\mathbf{y} - H(\mathbf{x})] \quad (1)$$

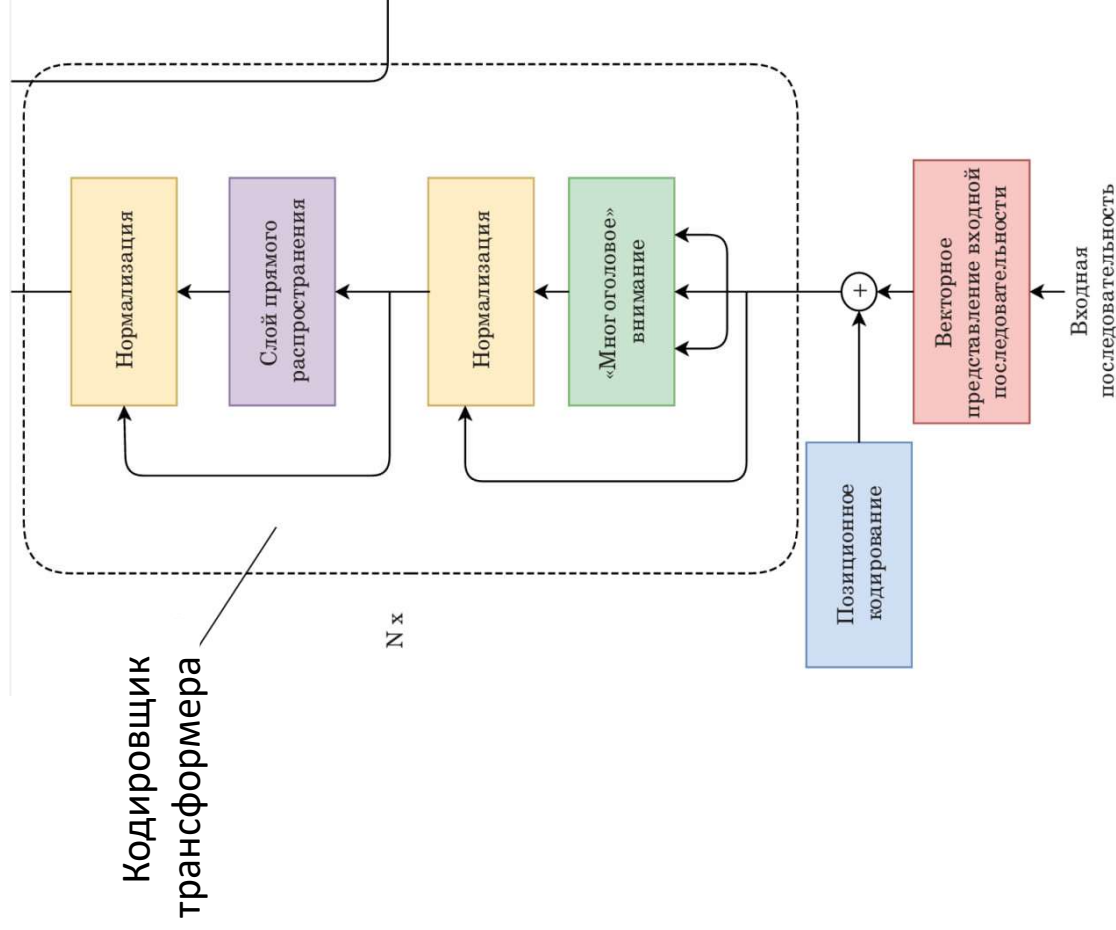
вектор состояния атмосферы
(восстанавливаемый профиль) априорный профиль вектор измерений

ковариационная матрица
фооновых ошибок оператор решения
прямой задачи ковариационная матрица
ошибок измерений

- [3]. Hewison T. 1D-VAR Retrieval of Temperature and Humidity Profiles From a Ground-Based Microwave Radiometer // IEEE Transactions on Geoscience and Remote Sensing. 2007. Vol. 45. No. 7. P. 2163-2168.
- [4]. Hualong Y., Zhao Y., Chen S. An Improved 1D-VAR Retrieval Algorithm of Temperature Profiles from an Ocean-Based Microwave Radiometer // Journal of Marine Science and Engineering. 2022, 10, 641. P. 1-14.

Перечисленные проблемы способны частично решить альтернативный нейросетевой подход. Обзор современных алгоритмов, использующих искусственные нейронные сети (ИНС) для восстановления температурно-влажностных профилей атмосферы, представлен, например, в работах [5-7]. Хотя определенные попытки были предприняты [8], в литературе пока мало сведений о применении в рассматриваемой задаче ИНС со встроенными механизмами самовнимания (self-attention) или перекрестного внимания (cross-attention).

- [5]. 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.
- [6]. Rohit Chakraborty, Animesh Maitra. Retrieval of Atmospheric Properties with Radiometric Measurements using Neural Network // Atmospheric Research. 2016. Vol. 181. P. 124-132.
- [7]. 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.
- [8]. 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.



Механизмы внимания позволили бы нейросетевым моделям лучше фокусироваться на наиболее значимых спектральных особенностях данных, учитывая при этом весь контекст измерений. Тем временем, ИНС с архитектурой «трансформер», ключевой особенностью которых является использование слоев внимания, демонстрируют способность выявлять долгосрочные пространственные и временные зависимости во входных потоках, видео и аудио сигналах [9]. Это открывает перспективы для создания алгоритмов быстрой обработки радиометрических данных принципиально нового уровня.

[9]. Zhaoyang Niu, Guoqiang Zhong, Hui Yu. A review on the attention mechanism of deep learning // Neurocomputing. 2021. Vol. 452. P. 48-62.

Ещё одним перспективным решением представляется использование PINN-моделей – ИНС с физически обоснованными ограничениями [10, 11]. Эти модели демонстрируют прорывные результаты в области вычислительной гидродинамики [12], представляя альтернативу традиционным подходам вроде 4D-Var, показывают эффективность в обработке медицинских изображений [13], в том числе в сложных случаях, когда необходимо реконструировать поля целевых параметров на основании весьма ограниченного объема исходных данных. Однако в контексте обратных задач атмосферной радиометрии модели PINN еще не рассматривались.

- [10]. Raissi M., Perdikaris P., Karniadakis G.E. Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations // *Journal of Computational Physics*. 2019. Vol. 378. P. 686–707.
- [11]. Pang G., Lu Lu, Karniadakis G.E. fPINNs: Fractional Physics-Informed Neural Networks // *SIAM J. Sci. Comput.* 2018. Vol. 41. P. A2603–A2626.
- [12]. Costabal F.S., Pezzuto S., Perdikaris P. Δ -PINNs: Physics-informed neural networks on complex geometries // *Engineering Applications of Artificial Intelligence*. 2024. Vol. 127. P. 107324.
- [13]. Raissi M., Yazdani A., Karniadakis G.E. Hidden fluid mechanics: Learning velocity and pressure fields from flow visualizations // *Science*. 2020. Vol. 367. N 6481, P. 1026–1030.

Преодоление существующих ограничений при восстановлении температурно-влажностных профилей представляется возможным при условии совершенствования радиофизических моделей решения прямой задачи и включения расчетных излучательных характеристик атмосфер (яркостных температур) в функцию ошибки на этапе обучения ИНС. Также 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. Таким образом, положение глобального минимума ошибки оказывается физически обоснованным. В этом и состоит суть подхода PINN в применении к атмосферной радиометрии [14].

[14]. Xuyang Bai, Shurun Tan. Layered Soil Remote Sensing with Multi-Channel Passive Microwave Observations and Physics Driven Artificial Intelligence: A Theoretical Study // TechRxiv. May 31, 2023.

В последующих работах авторы планируют реализовать предложенные подходы и интегрировать механизмы внимания в нейронные сети с физически обоснованными ограничениями.

