

Нейронно-сетевое восстановление метеопараметров из профилей индекса рефракции: статистический анализ

М.Е. Горбунов^{1,2}

¹ Институт физики атмосферы им. А.М. Обухова Российской Академии Наук
119017, Москва, Пыжевский пер. 3

E-mail: gorbunov@ifaran.ru

² Гидрометцентр России
123376, Москва, Б. Предтеченский пер. 13-1

Радиозатменное зондирование атмосферы Земли (РЗЗА) на частотах глобальных навигационных спутниковых систем (1.2–1.6 ГГц) чувствительно к атмосферному показателю преломления, зависящему от трех термодинамических переменных: температуры, давления и удельной влажности. Для сухой атмосферы восстановленный профиль индекса рефракции, дополненный уравнением гидростатики, позволяет восстановить две термодинамические переменные: температуру и давление. В данной работе мы анализируем подход к независимому восстановлению полного набора термодинамических переменных, основанный на искусственной нейронной сети (ИНС) и уравнении гидростатики. Мы приводим статистические оценки точности нашего алгоритма восстановления термодинамических переменных для разных сезонов и широтных поясов.

Ключевые слова: радиозатменное зондирование, восстановление термодинамических переменных, уравнение гидростатики, искусственная нейронная сеть

Neural-network retrieval of thermodynamic state variables from refractivity: a statistical analysis

М.Е. Gorbunov^{1,2}

¹ A.M. Obukhov Institute of Atmospheric Physics, Russian Academy of Sciences

² Hydrometcenter of Russia

Radio occultation sounding of the Earth's atmosphere on the frequencies of the Global Navigation Satellite Systems (1.2–1.6 GHz) is sensitive the atmospheric refractivity, which is a function of three thermodynamic variables: temperature, pressure, and specific humidity. For the dry atmosphere, the retrieved refractivity complemented with the hydrostatic equation makes it possible to retrieve two thermodynamic variables: temperature and pressure. In this study, we analyze the approach to the independent retrieval of the full set of the thermodynamic variables, based on the Artificial Neural Network (ANN) and the hydrostatic equation. We provide the statistical estimates of the accuracy of our retrieval algorithm of the thermodynamic variables' retrieval for different seasons and latitude bands. Keywords: radio occultation, thermodynamic variables retrieval, hydrostatic equation, artificial neural network

Введение

Термодинамические переменные, включающие температуру, давление и влажность являются важными прогностическими параметрами. Радиозатменное зондирование атмосферы Земли (РЗЗА) на частотах глобальных навигационных спутниковых систем (1.2–1.6 ГГц) чувствительно к атмосферному показателю преломления, зависящему от трех термодинамических переменных. Для сухой атмосферы восстановленный профиль

индекса рефракции, дополненный уравнением гидростатики, позволяет восстановить две термодинамические переменные: температуру и давление. Высота, на которой вклад влажности становится малым, меняется от 8 км в полярных областях до 12 км в тропиках. На этих высотах среднеквадратичная ошибка восстановления температур в предположении сухой атмосферы составляет около 0.5 К, а ошибка удельной влажности около 0.1 г/кг. В нижней тропосфере максимальная ошибка восстановления температуры меняется от 15 К в полярных областях до 40 К в тропиках. Профиль индекса рефракции и уравнение гидростатики недостаточны для восстановления трех термодинамических переменных.

В [1] было рассмотрено восстановление влажности с использованием априорных профилей давления и температуры. В [2] были предложены итеративные алгоритмы восстановления гибридного профиля удельной влажности из профилей восстановленного индекса рефракции и априорной температуры. Недостаток гибридных алгоритмов состоит в том, что они комбинируют разнородные типы данных с разными характеристиками ошибок и пространственного разрешения: 1) индекса рефракции из наблюдений РЗЗА и 2) априорные профили температуры или влажности.

В данной работе мы рассматриваем методы независимого восстановления термодинамических переменных из индекса рефракции. Независимость восстановления означает, что оно основано только на уравнении гидростатики и дополнительных физических и/или эмпирических ограничениях, без привлечения априорных профилей термодинамических переменных.

В [3] было использовано эмпирическое соотношение между температурой и давлением. В [4] рассматривалось более сложное условие: отклонения профилей плотности и индекса рефракции от экспоненциальной зависимости на масштабах до 1 км связаны с влажностью. В [5] использовалась политропная модель Хопфилда для сухой компоненты индекса рефракции. В [6] этот подход был обобщен на углы рефракции. В [7] была предложена комбинация метода наименьших квадратов с дополнительными ограничениями.

Подход к восстановлению термодинамических переменных, основанный на искусственных нейронных сетях (ИНС), разрабатывался в серии работ [8,9,10,11,12]. ИНС использовали профиль индекса рефракции (или угла рефракции) и выдавали на выходе профиль удельной влажности.

В данной работе мы рассматриваем подход, основанный на ИНС и уравнении гидростатики. ИНС вычисляет правую часть уравнения гидростатики. Для этого достаточно вычислять температуру из давления, индекса рефракции и дополнительных переменных, таких как широта, высота и т.д. Удельная влажность в свою очередь является известной функцией от давления, температуры и индекса рефракции; плотность, в свою очередь, является известной функцией от термодинамических переменных. Это позволяет интегрировать уравнение гидростатики, в котором давление является динамической переменной. В этой схеме мы можем поменять местами температуру и удельную влажность.

Мы проводим статистический анализ точности нашего алгоритма на глобальных полях реанализов Global Forecast System (GFS). Статистика вычислена для разных сезонов и широтных поясов.

Метод

Для практических целей используется формула для индекса рефракции:

$$N = C_1 \frac{P_d}{T} + C_2 \frac{P_w}{T} + C_3 \frac{P_w}{T^2} \approx C_1 \frac{P}{T} + C_3 \frac{P_w}{T^2}, \quad (1)$$

где $C_1 = 77.6 \times 10^{-6} \text{ K/hPa} \approx C_2, C_3 = 0.373 \text{ K}^2/\text{hPa}$, $P = P_d + P_w$ – полное атмосферное давление, P_d – парциальное давление сухой компоненты воздуха, P_w – парциальное давление водяного пара и T – абсолютная температура.

Давление и высота связаны уравнение гидростатики:

$$\frac{dP}{dz} = -\rho(z)g(z), \quad (2)$$

где z – высота над уровнем моря, $g(z)$ – профиль ускорения силы тяжести, зависящий от географической широты и долготы. Оно дополняется уравнением состояния. Обозначая через q удельную влажность, равную массе водяного пара на единицу массы влажного воздуха и измеряемой в кг/кг, мы можем выразить плотности компонент через плотность влажного воздуха ρ и записать уравнение состояния:

$$\begin{aligned} \rho_d &= \rho(1 - q), \quad \rho_w = \rho q, \quad a_q = \frac{R_d}{R_w}, \\ P &= (\rho_d R_d + \rho_w R_w)T = (1 + (a_q^{-1} - 1)q)\rho R_d T, \end{aligned} \quad (3)$$

где $\rho_{d,w}$ – плотности сухого воздуха и водяного пара, и $R_{d,w}$ – их газовые постоянные.

Наш подход основан на интегрировании уравнения гидростатики

$$dP(z)/dz = - \frac{g(z)P(z)}{R_d[1 + (a_q^{-1} - 1)q_{\text{ANN}}(\mathbf{X}(z))]T_{\text{ANN}}(\mathbf{X}(z))}. \quad (4)$$

где зависимости $q_{\text{ANN}}(\mathbf{X}(z))$ и $T_{\text{ANN}}(\mathbf{X}(z))$ от набора переменных $\mathbf{X}(z)$ вычисляются при помощи ИНС как средство нелинейной аппроксимации. Вектор \mathbf{X} включает следующие переменные: 1) месяц года, 2) широта ϕ , 3) высота z , 4) локальный профиль индекса рефракции $N(z_i)$, 5) локальный профиль давлений $P(z_i)$. Сетка для коротких локальных профилей определена как $z_i = z + i \Delta z$, $i = 0, 1, 2$, и $\Delta z = 1$ км. Сухое давление $P_{\text{dry}}(z)$ определяется как результат интегрирования уравнения гидростатики с $q(z) \equiv 0$. Это обобщает подход, обсуждавшийся в [3, 4, 5, 6, 7].

Для создания тренировочных, тестовых и валидационных наборов данных мы использовали сеточные поля термодинамических переменных GFS, находящиеся в открытом доступе. GFS предоставляет поля температуры T , давления P и относительной влажности r на неравномерной сетке геопотенциальных высот H_{ijk} и равномерных сетках географических широт ϕ_j и долгот λ_k . Мы преобразуем геопотенциальные высоты в геометрические z_{ijk} над уровнем моря и вычисляем давление водяного пара P_w и удельную влажность q . Таким образом, мы получаем давление P , температуру T , удельную влажность q и индекс рефракции N по формуле (1) как сеточные функции от $(z_{ijk}, \phi_i, \lambda_k)$, которые можно интерполировать в любую точку (z, ϕ, λ) .

Тренировочная стратегия была основана на рандомизации. Мы проводили множество итераций тренировок и тестов. На каждой итерации мы случайным образом задавали архитектуру ИНС, определяемую следующими параметрами: 1) количество перцептронных слоев (от 3 до 5), 2) количество нейронов в каждом слое (от 8 до 20), 3) активационные функции для каждого слоя. По результатам выбиралась лучшая ИНС.

Результаты

На рисунках 1–18 приведены вертикальные профили систематической и среднеквадратичной разницы между восстановленными и реперными профилями удельной влажности и температуры для января и июля и разных широтных зон.




Рис. 1. Ошибки удельной влажности и температуры. Январь, широты от $10^{\circ}S$ до $10^{\circ}N$.




Рис. 2. То же. Январь, широты от $20^{\circ}N$ до $30^{\circ}N$.




Рис. 3. То же. Январь, широты от $20^{\circ}S$ до $30^{\circ}S$.




Рис. 4. То же. Январь, широты от $40^{\circ}N$ до $50^{\circ}N$.




Рис. 5. То же. Январь, широты от $40^{\circ}S$ до $50^{\circ}S$.




Рис. 6. То же. Январь, широты от $70^{\circ}N$ до $80^{\circ}N$.




Рис. 7. То же. Январь, широты от $70^{\circ}S$ до $80^{\circ}S$.




Рис. 8. То же. Январь, широты от $80^{\circ}N$ до $90^{\circ}N$.




Рис. 9. То же. Январь, широты от $20^{\circ}N$ до $30^{\circ}N$.




Рис. 10. То же. Июль, широты от $10^{\circ}S$ до $10^{\circ}N$.




Рис. 11. То же. Июль, широты от $20^{\circ}N$ до $30^{\circ}N$.




Рис. 12. То же. Июль, широты от $20^{\circ}S$ до $30^{\circ}S$.

Month = 07. Lat = 40,50.




Рис. 13. То же. Июль, широты от $40^{\circ}N$ до $50^{\circ}N$.

Month = 07. Lat = -50,-40.




Рис. 14. То же. Июль, широты от $40^{\circ}S$ до $50^{\circ}S$.

Month = 07. Lat = 70,80.




Рис. 15. То же. Июль, широты от $70^{\circ}S$ до $80^{\circ}S$.

Month = 07. Lat = -80,-70.




Рис. 16. То же. Июль, широты от $70^{\circ}S$ до $80^{\circ}S$.

Month = 07. Lat = 80,90.




Рис. 17. То же. Июль, широты от $80^{\circ}N$ до $90^{\circ}N$.

Month = 07. Lat = -90,-80.




Рис. 18. То же. Июль, широты от $80^{\circ}S$ до $90^{\circ}S$.

Выводы

Лучшая точность восстановления достигается в экваториальной зоне, где влажность максимальна и в полярной зоне, где влажность минимальна. Так в экваториальной зоне точность восстановления удельной влажности у поверхности Земли составляет 0.5 г/кг, а температуры – 2 К. Наихудшая точность восстановления наблюдается в средних широтах 40 – 50°, где у поверхности Земли точность восстановления влажности составляет около 1.5 г/кг, а температуры – 6 К. Ошибка восстановления температуры падает с высотой.

Разделы «Введение» и «Метод» работы выполнена при поддержке госзадания Института физики атмосферы им. А.М. Обухова РАН (FMWR-2025-00026 рег. № 1022041300352-9-1.5.2, рег. карта 125020601652-8). Разделы «Результаты» и «Выводы» работы выполнены при поддержке госзадания Института физики атмосферы им. А.М. Обухова РАН (тема 17.1).

Литература

1. Kursinski E.R., Hajj G.A., Hardy K.R., Romans L. J., and Schofield J.T. Observing Tropospheric Water-Vapor by Radio Occultation Using the Global Positioning System. // Geophys. Res. Lett. 1995. 22 (17). 2365–2368.
2. Kursinski E.R., and Hajj G.A. A Comparison of Water Vapor Derived from GPS Occultations and Global Weather Analyses // J. Geophys. Res. 2001. 106 (D1). 1113–1138.
3. O’Sullivan D. B., Herman B.M., Feng D., Flittner D.E., and Ward D.M. Retrieval of Water Vapor Profiles from GPS/MET Radio Occultations // Bull. Amer. Meteor. Soc. 2000. 81 (5): 1031–1040.
4. Torre J.M. de la, and Nilsson M. On the Detection of Water Vapor Profiles and Thin Moisture Layers from Atmospheric Radio Occultations // J. Geophys. Res. 2003 108 (D9). 4276.
5. Vespe F., Benedetto C., and Pacione R. The Use of Refractivity Retrieved by Radio Occultation Technique for the Derivation of Atmospheric Water Vapor Content // Phys. Chem. Earth. 2004. 29 (2–3): 257–265.
6. Vespe F., and Persia T. Derivation of the Water Vapor Content from the GNSS Radio Occultations Observations // J. Atmos. Ocean. Technol. 2006. 23 (7): 936–43.
7. Andrisani A. and Vespe F. Humidity Profiles Retrieved from GNSS Radio Occultations by a Non-Negative Residual Constrained Least Square Error Method // Front. Earth Sci. 2020. 8.
8. Bonafoni S., Pelliccia F., and Anniballe R. Comparison of Different Neural Network Approaches for the Tropospheric Profiling over the Inter-Tropical Lands Using GPS Radio Occultation Data // Algorithms 2009. 2. 31–45.
9. Pelliccia F., Bonafoni S., Basili P., Anniballe R., Pierdicca N., and Ciotti P. Estimation of Tropospheric Profiles Using COSMIC GPS Radio Occultation Data with Neural Networks // It. J. Remote Sens., 2009. October. 23–38.
10. Pelliccia F., Pacifici F., Bonafoni S., Basili P., Pierdicca N., Ciotti P., and Emery W.J. Neural Networks for Arctic Atmosphere Sounding from Radio Occultation Data // IEEE Trans. Geosci. Remote Sens. 2011. 49 (12). 4846–4855.
11. Shyam A., Gohil B.S., and Basu S. Retrieval of Water Vapour Profiles from Radio Occultation Refractivity Using Artificial Neural Network // Indian J. Radio Space Phys. 2016. 42 (6). 411–419.
12. Lasota, E. Comparison of Different Machine Learning Approaches for Tropospheric Profiling Based on COSMIC-2 Data // Earth Planets Space. 2021. 73 (1).