

М.Ю. Катаев, А.Я. Суханов

Возможности метода нейронных сетей для восстановления профиля концентрации озона из лидарных данных

Институт оптики атмосферы СО РАН, г. Томск
Томский государственный университет систем управления и радиоэлектроники

Поступила в редакцию 2.10.2003 г.

Приводится описание подхода к обращению лидарных данных на основе метода нейронных сетей для восстановления профиля концентрации озона. Рассматриваются алгоритм поиска решения и возможности метода по восстановлению профиля при различных схемах обучения нейронных сетей. Приводятся результаты моделирования задачи восстановления профиля концентрации озона по данным лидарного зондирования.

Введение

В лидарном зондировании для восстановления вертикального распределения концентрации газа из УФ лидарных данных обычно применяют следующие методы – разностных схем, сплайн-функций, регуляризации Тихонова, оптимальной параметризации и др. [1–6]. Каждый из этих методов имеет ограничения (не позволяют восстанавливать профиль концентрации в тропосфере либо не достаточно точны) при обработке данных в автоматическом режиме (рутинный режим измерений).

Обзор методов обработки данных лидарного зондирования показал, что метод нейронных сетей (НС) ранее для решения обратных задач лазерного зондирования не использовался. Применение метода НС в настоящее время стало возможным благодаря росту вычислительной скорости компьютеров, обилию данных измерений профилей концентрации озона как при помощи лидаров, так и радиозондов.

Постановка задачи

Определение вертикального профиля содержания газа из лидарных эхосигналов, полученных с помощью двухволнового лидара, сводится к задаче дифференцирования функции $v(z)$ [6]:

$$v(z) = \frac{1}{2} \ln \left(\frac{N_{off}(z)}{N_{on}(z)} \right) + \Psi(z); \quad (1)$$

$$\Psi(z) = \frac{1}{2} \ln \left(\frac{\beta_{on}(z)}{\beta_{off}(z)} \right) - [\tau_{on}(z) - \tau_{off}(z)],$$

где N_{on} , N_{off} – зарегистрированные с высоты z эхосигналы на длинах волн λ_{on} и λ_{off} ; β_{on} , β_{off} – коэффициенты обратного рассеяния; τ_{on} , τ_{off} – суммарные оптические толщи молекулярного рассеяния и аэрозольного ослабления на соответствующих длинах волн.

В выражении (1) предполагается, что величины N_{on} , N_{off} очищены от сигналов фонового излучения атмосферы. Функция $\Psi(z)$ задается из модельных представлений либо определяется из независимого эксперимента. При посылке импульсов излучения в узкой спектральной области, занимаемой отдельной колебательно-вращательной линией, функцию $\Psi(z)$ можно положить равной нулю.

Концентрация газа определяется из выражения

$$\rho(z) = \frac{1}{2\Delta K(z)} \phi(z), \quad (2)$$

где $\phi(z)$ – регуляризованный аналог производной $v'(z)$ функции $v(z)$; $\Delta K = K_{on} - K_{off}$ – дифференциальное сечение поглощения исследуемого газа.

Известно [7], что задача дифференцирования экспериментальной информации относится к классу некорректно поставленных задач. Некорректность проявляется в нарушении устойчивости решения [8, 9], а именно: небольшие погрешности в исходных данных могут приводить к большим ошибкам в решении (решение «разбалтывается»), а в ряде случаев к появлению отрицательных значений концентрации газа.

Именно такая ситуация возникает при применении часто используемого метода конечных разностей при дифференцировании функции $v(z)$. Перед процедурой дифференцирования принимаемые сигналы (или логарифм отношения сигналов) сглаживаются при помощи различных фильтров скользящего среднего, полиномами и др. [10]. Однако, хотя эти подходы и быстры в вычислениях, имеют несколько серьезных недостатков. Во-первых, эти подходы работают «на глаз», так как не позволяют однозначно ответить на вопрос о том, с какой эффективностью прошло сглаживание (выбор между недоглаживанием и переглаживанием). Во-вторых, каждый лидарный сигнал, являясь уникальным, требует подгонки параметров сглаживания, что не позволяет однозначно потом интерпретировать профили, полученные в разные периоды времени. В-третьих,

не позволяют оценить точность восстановления профиля концентрации исследуемого газа (лишь только приближенно).

Метод нейронных сетей

Опишем решение данной задачи с помощью метода нейронных сетей. Нейронная сеть представляет собой совокупность взаимосвязанных простых элементов нейронов и способна выдавать на входное возмущение определенную выходную информацию. Математическую модель нейрона можно представить в следующем виде [11]:

$$y(w) = f(\sum_{i=1}^n w_i x_i + w_0) = f(g), \quad (3)$$

где y — выходной сигнал нейрона; $f(g)$ — функция активации нейрона; w_i — весовой коэффициент i -го входа; w_0 — начальное состояние (возбуждение) нейрона; x_i — входные сигналы, $i = 1, 2, \dots, n$ — номера входов нейрона.

Нейрон можно также представить в виде схемы, приведенной на рис. 1.

Рис. 1. Модель формального нейрона

В качестве функции активации служит сигмоидная функция:

$$f(g) = \frac{1}{1 + \exp(-ag)}. \quad (4)$$

Параметр a определяет наклон сигмоидной функции, график которой представлен на рис. 2.

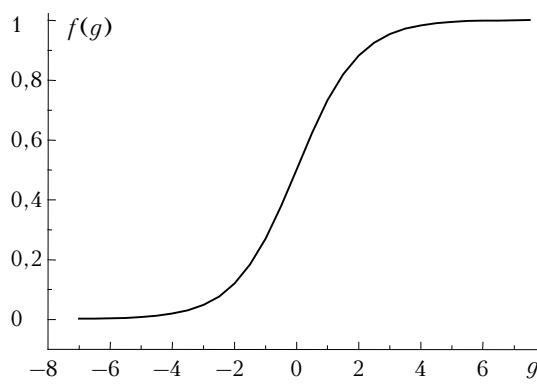


Рис. 2. Активационная функция

Наклон сигмоидной функции определяет возможности нейрона по различению входных воздействий. Чем круче наклон функции, тем меньше нейрон различает входных воздействий.

Существуют различные виды нейронных сетей. Использование конкретного вида зависит от поставленной задачи. Например, в задачах распознавания образов используют сети Хэмминга, Хопфилда. В задачах классификации используется сеть Коханена. Для решения обратной задачи лидарного зондирования наиболее подходящей является полносвязная многослойная нейронная сеть. Пример трехслойной нейронной сети представлен на рис. 3.

Рис. 3. Полносвязная трехслойная нейронная сеть

Для решения поставленной задачи в качестве входа для данной сети используется значение профиля оптической толщины (1), в качестве выхода — профиль концентрации. Профили приведены к одной и той же высотной сетке.

Для того чтобы сеть решала поставленную задачу, необходимо провести ее обучение. Существуют самообучающиеся нейронные сети и сети с учителем. Обучение с учителем предполагает, что для каждого входного вектора существует целевой вектор, представляющий собой требуемый выход. Вместе они называются обучающей парой. Обычно сеть обучается на некотором числе таких обучающих пар. Предъявляется входной вектор, вычисляется выход сети и сравнивается с соответствующим целевым вектором, разность (ошибка) с помощью обратной связи подается в сеть, и веса изменяются в соответствии с алгоритмом, стремящимся минимизировать ошибку. Векторы обучающего множества предъявляются последовательно, вычисляются ошибки, и веса подстраиваются для каждого вектора до тех пор, пока ошибка по всему обучающему массиву не достигнет приемлемого низкого уровня.

Существует несколько методов обучения нейронной сети [11]:

- *детерминированный метод обучения*, шаг за шагом осуществляющий процедуру коррекции весов сети, основанную на использовании их текущих значений, а также фактических выходов;

- *стохастический метод обучения*, выполняющий псевдослучайные изменения величин весов, сохраняя те изменения, которые ведут к улучшению результатов работы сети;

- *эвристические алгоритмы обучения*, к которым относится генетический алгоритм поиска, моделирующий процессы природной эволюции и позволяющий из множества решений (популяций) выбрать наилучшее решение.

К детерминированным методам относится алгоритм обратного распространения ошибки, к стохастическим методам относятся машина Больцмана и машина Коши.

Для решения нашей задачи в качестве алгоритма обучения был выбран алгоритм обратного распространения ошибки, который позволяет достаточно быстро обучить нейронную сеть. Скорость обучения в данной задаче существенна, так как возникает необходимость в переобучении сети при изменении условий моделирования обучающей пары, например при решении обратной задачи для другого газа. Стохастические алгоритмы хотя и позволяют обходить проблему локальных минимумов при решении задачи оптимизации решения и всегда сходятся к глобальному минимуму, но обладают при этом слишком медленной сходимостью.

Алгоритм обратного распространения ошибки [11] – это итеративный градиентный алгоритм. При обучении ставится задача минимизации ошибки нейронной сети, которая определяется методом наименьших квадратов:

$$E(w) = \frac{1}{2} \sum_{j=1}^p (y_j(w) - d_j)^2, \quad (5)$$

где p – число нейронов в выходном слое; y – текущий выход j -го нейрона; d – желаемый выход j -го нейрона (последний слой (см. рис. 3) – значение концентрации озона на высоте z); w – весовые коэффициенты.

Обучение нейронной сети осуществляется методом градиентного спуска, т.е. на каждой итерации изменение веса производится по формуле

$$w_{ij}(t+1) = w_{ij}(t) - h \frac{\partial E}{\partial w_{ij}}, \quad (6)$$

где h – параметр, определяющий скорость обучения.

В качестве нейронной сети была взята полносвязная нейронная сеть, состоящая из двух слоев. Входами для данной сети служат вертикальные профили оптической толщи, а выходами – вертикальные профили концентрации газа, приведенные к одной и той же высотной сетке. Число входов каждого нейрона сети равно числу элементов в высотной сетке (высотный диапазон зондирования 0–35 км, строб 500 м, 70 точек).

В качестве примеров для обучения были взяты вертикальные профили концентрации озона и профили температуры, построенные путем искажения модельного профиля [12] при помощи датчика случайных чисел. Коэффициенты поглощения озона для каждой высоты при длине волны $\lambda_{on} = 308$ нм рассчитывались по формуле [13]:

$$K_{oz}(T) = A + BT + CT^2 \text{ [см}^{-1} \cdot \text{атм}^{-1}], \quad (7)$$

где T – температура в слое z ; коэффициенты модели $A = 1,32$, $B = 3,45 \cdot 10^{-3}$, $C = 2,18 \cdot 10^{-5}$.

Значения молекулярной и аэрозольной составляющих оптической толщи рассчитывались по модельным представлениям о состоянии атмосферы и при расчете для различных профилей концентрации озона не изменялись.

Для того чтобы нейронная сеть могла восстанавливать концентрацию газа в тропосфере по страто-

сферным оптическим данным (на основе созданных обучающих пар «оптическая толща – профиль концентрации»), создавались дополнительные обучающие пары, в которых профиль концентрации оставался прежним, а оптические толщи для тропосферных высот приравнивались минус 1, последовательно для высот $[z_1]$, $[z_1, z_2], \dots, [z_1, z_m]$. Всего m пар для каждого профиля концентрации, где z_m – начало стратосферных высот (нами принято 12 км). Все обучающие выборки приводились к интервалу $[0,1]$.

Была реализована программа, позволяющая обучать нейронную сеть методом обратного распространения ошибки и проверять ее работу на данных, не входящих в выборку обучения. Для этого берется профиль концентрации озона, затем моделируется оптическая толща, нейронной сетью восстанавливается профиль концентрации озона. Значения, полученные сетью, сравниваются с исходными значениями, и вычисляется относительная ошибка.

Результаты моделирования

Моделирование проводилось в два этапа. На первом этапе на вход НС подавались все 70 точек профиля оптической толщи (диапазон высот 0–35 км) при 5%-м зашумлении и рассматривался профиль концентрации озона в сравнении с модельным (рис. 4).

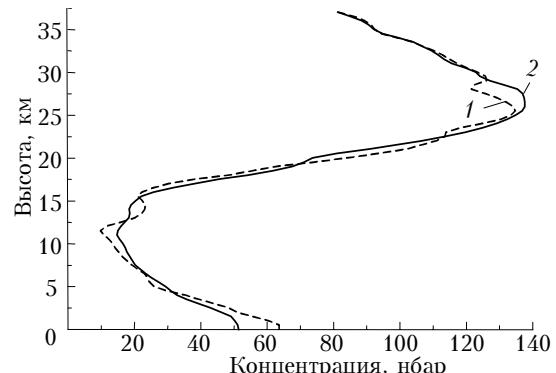


Рис. 4. Пример восстановления профиля концентрации озона (1 – модельный профиль, 2 – восстановленный)

На рис. 5 приведена относительная погрешность восстановления профиля концентрации озона при 5%-м шуме.

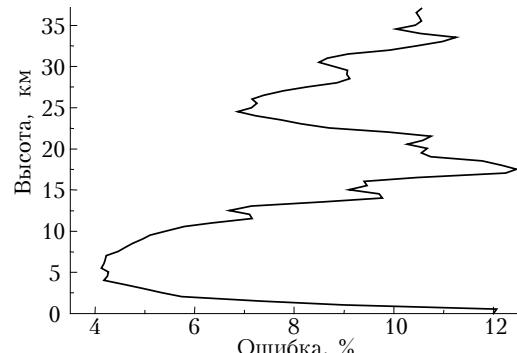


Рис. 5. Относительная ошибка восстановления профиля концентрации озона

На рис. 6 приведена относительная погрешность восстановления профиля озона при 15%-м шуме и при тех же условиях измерений. Сравнение рис. 5 и 6 показывает, что увеличение погрешности измерений в 3 раза (с 5 до 15%) не привело к значительному росту погрешности восстановления профиля концентрации озона. Это, на наш взгляд, связано с тем, что найденные коэффициенты НС слабо реагируют на случайные изменения оптической толщины (не присутствуют в обучении).

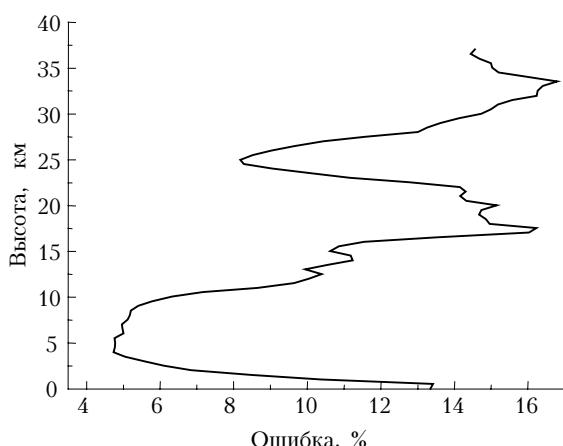


Рис. 6. Относительная ошибка восстановления профиля концентрации озона при 15%-м зашумлении толщи и диапазоне измерений 0–35 км

Второй этап моделирования связан с использованием для обработки только стратосферных измерений (12–35 км) и последующим восстановлением по всей высотной сетке от 0 до 35 км. Это приближенный к реальным стратосферным условиям модельный эксперимент. Результаты моделирования второго этапа представлены на рис. 7 и 8. На рис. 7 показано сравнение восстановленного и модельного профилей концентрации озона, а на рис. 8 – относительная погрешность восстановления.

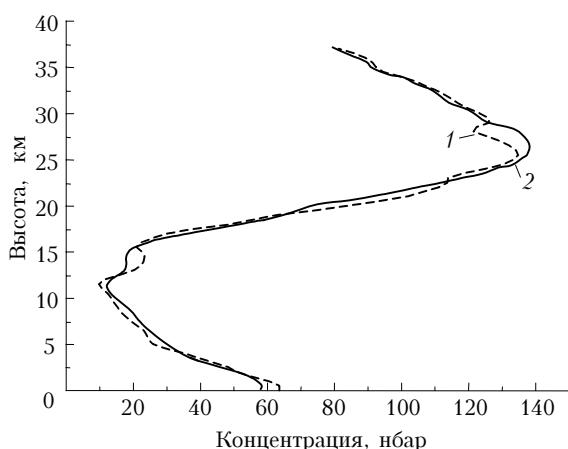


Рис. 7. Пример восстановления профиля концентрации озона при 5%-м зашумлении оптической толщи для диапазона измерений 12–35 км (1 – модельный профиль, 2 – восстановленный)

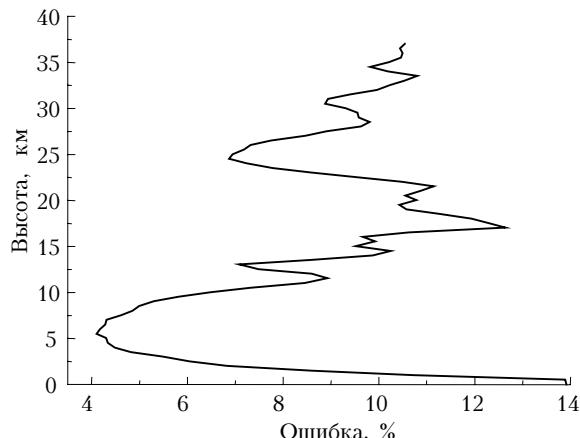


Рис. 8. Относительная ошибка восстановления профиля концентрации озона при 5%-м зашумлении оптической толщи и диапазоне измерений 12–35 км

Можно заметить, что погрешность восстановления первого и второго этапов практически не отличается. Это свойство методов, основанных на использовании статистической информации, которая в данном методе аккумулируется в виде коэффициентов модели.

Заключение

Рассмотренный в статье метод нейронных сетей позволяет проводить восстановление профиля концентрации озона из лидарных данных. Погрешность восстановления профиля концентрации озона слабо чувствительна к погрешности эксперимента вплоть до 30%, составляет в среднем около 10% и зависит от количества и качества обучаемой выборки. Представленный в статье материал является основой для дальнейших исследований возможностей метода нейронных сетей применительно к задачам лидарного зондирования.

1. Лазерный контроль атмосферы / Под ред. Э.Д. Хинкли. М.: Мир, 1979. 416 с.
2. Межерис Р. Лазерное дистанционное зондирование. М.: Мир, 1987. 550 с.
3. Применение лазеров для определения состава атмосферы / Под ред. В.М. Захарова. Л.: Гидрометеиздат, 1983. 216 с.
4. Захаров В.М., Костко О.К. Лазеры и метеорология. Л.: Гидрометеиздат, 1972. 175 с.
5. Зуев В.В., Катаев М.Ю., Макогон М.М., Мицель А.А. Лидарный метод дифференциального поглощения: современное состояние // Оптика атмосф. и океана. 1995. Т. 8. № 8. С. 1136–1164.
6. Ельников А.В., Зуев В.В., Катаев М.Ю., Мицель А.А., Маричев В.Н. Зондирование стратосферного озона двухволновым УФ-ДП-лидаром: методы решения обратной задачи и результаты натурного эксперимента // Оптика атмосф. и океана. 1992. Т. 5. № 3. С. 576–587.
7. Демидович В.Б. Восстановление функций и ее производных по экспериментальной информации // Вычислительные методы и программирование. М.: МГУ, 1967. № 8. С. 96–102.

8. Тихонов А.Н., Арсенин В.Я. Методы решения некорректных задач. М.: Наука, 1979. 238 с.
9. Морозов В.А. Регулярные методы решения некорректно поставленных задач. М.: Наука, 1987. 240 с.
10. Zuev V.E., Zuev V.V., Marichev V.N., Makushkin Yu.S., Mitzel A.A. Lidar differential absorbtion and scattering technique: experiment // Appl. Opt. 1983. V. 22. N 23. P. 3733–3741.
11. Коларцова Л.Г., Максимов А.В. Нейрокомпьютеры: Уч. пособие для вузов. М.: Изд-во МГТУ им. Н.Э. Баумана, 2002. 320 с.
12. Зуев В.Е., Комаров В.С. Статистические модели температуры и газовых компонент. Л.: Гидрометеоиздат, 1985. 199 с.
13. Зуев В.В., Катаев М.Ю., Маричев В.Н. Методика восстановления профилей озона из данных УФ-лидара: коррекция на аэрозольную и температурную стратификацию // Оптика атмосф. и океана. 1997. Т. 10. № 9. С. 1103–1111.

M.Yu. Kataev, A.Ya. Sukhanov. Capabilities of the neuron network method for retrieval of the ozone profile from lidar data.

The paper describes the approach to using lidar data for reconstruction of the ozone concentration profile based on the neuron network method. The capabilities of this method for profile retrieval at different schemes of neuron network learning, as well as the solution algorithm are considered. The problem of retrieving the ozone concentration profile from lidar sensing data is simulated on the computer.