

# Использование метода искусственных нейронных сетей при восстановлении вертикальных профилей атмосферных параметров

А.В. Поляков\*

Санкт-Петербургский государственный университет  
198504, г. Санкт-Петербург, Петродворец, ул. Ульяновская, 1

Поступила в редакцию 25.03.2013 г.

Рассматривается совместное применение метода искусственных нейронных сетей (ИНС) и метода главных компонент для зондирования вертикальных профилей температуры и состава атмосферы. Предлагается модификация метода ИНС, основанная на минимизации среднеквадратической погрешности конечного определяемого параметра атмосферы. На примере определения вертикального профиля температуры по измерениям прибора МТВЗА показано существенное (в сотни раз) преимущество предлагаемой методики в отношении скорости обучения ИНС и небольшое преимущество в точности определения профиля.

**Ключевые слова:** решение обратных задач атмосферной оптики, метеорологическое зондирование атмосферы, метод главных компонент, метод искусственных нейронных сетей; solution of atmospheric optic inverse problems, meteorological sounding of atmosphere, principal components, artifical neural network.

## Введение

Численное решение обратных задач атмосферной оптики, в том числе классической обратной задачи спутниковой метеорологии — температурного зондирования атмосферы, может осуществляться на основе различных алгоритмов [1]. В настоящее время температурно-влажностное зондирование выполняется с помощью спектральных приборов в ИК- и МКБ-областях спектра (приборы AIRS, TES, IASI, Crisl, AMSU и т.д.), измеряющих уходящее ИК-излучение в десятках, сотнях и тысячах спектральных каналов [2]. При этом возникает проблема быстродействия программ оперативной обработки спутниковых измерений, прежде всего в связи с потребностями оперативной обработки и численного прогноза погоды [3].

Одним из способов решения проблемы быстродействия является использование для решения обратной задачи алгоритмов, основанных на регрессионных подходах, а не непосредственно на физической модели переноса излучения. В частности, такие алгоритмы основываются на методах множественной линейной регрессии (МЛР) или искусственных нейронных сетей (ИНС) [4–12]. Преимущество последнего подхода состоит в том, что он позволяет решать нелинейные обратные задачи.

Для уменьшения размерности задачи может использоваться метод главных компонент как по отношению к представлению измеренных спектров, так

и по отношению к восстанавливаемым профилям метеопараметров [13]. Последнее оказывается, в частности, существенным при интерпретации микроволновых измерений, содержащих относительно немного информации о восстанавливаемых профилях, с учетом требований к характеристикам получаемых атмосферных параметров.

В настоящей статье предлагается методика использования подхода на основе ИНС в сочетании с методом главных компонент в задаче температурно-влажностного зондирования и приводится пример ее использования для МКБ-спектрометра МТВЗА, установленного на борту спутников «Метеор-3».

## Постановка задачи

Уходящее в зенит монохроматическое излучение земной атмосферы может быть описано [14] выражением

$$\begin{aligned} J^{out}(v) = & \epsilon(v)B(v, T_s)P(v, 0, p_0) + \\ & + \int_{p_0}^0 B(v, T(p)) \frac{dP(v, 0, p)}{dp} dp + (1 - \epsilon(v))P(v, 0, p_0) \times \\ & \times \int_0^{p_0} B(v, T(p)) \frac{dP(v, p, p_0)}{dp} dp, \end{aligned} \quad (1)$$

где  $\epsilon(v)$  — излучательная способность поверхности при волновом числе  $v$ ;  $B(v, T)$  — функция Планка при температуре  $T$ ;  $P(v, p_1, p_2)$  — функция пропускания атмосферы между уровнями с давлениями  $p_1$  и  $p_2$ .

\* Александр Викторович Поляков (polyakov@troll.phys.spbu.ru).

Уходящее излучение  $J^{out}$  включает три компоненты, соответствующие слагаемым в выражении (1): излучение поверхности, восходящее излучение атмосферы и отраженное поверхностью нисходящее излучение атмосферы. Функция пропускания атмосферы  $P(v, p_1, p_2)$ , в частности, зависит от ее газового состава.

Дистанционное температурно-влажностное зондирование атмосферы с использованием уходящего теплового излучения основано на решении обратной выражению (1) задачи – определению профилей температуры и содержания водяного пара в атмосфере по измеренным с космического аппарата значениям уходящего излучения. При этом, разумеется, аппаратура выполняет измерения с конечным спектральным разрешением и в конечном количестве спектральных каналов. Подробная постановка различных задач термического зондирования атмосферы неоднократно рассматривалась в литературе, например в [1, 14, 15].

Существенную роль при разработке, отладке и тестировании систем интерпретации дистанционных измерений играет выбор набора модельных состояний атмосферы, называемого также статистической моделью состояния атмосферы. Особенно важны свойства этого набора при построении решающего оператора обратной задачи дистанционного зондирования на основе метода ИНС. За основу ансамблей состояний атмосферы был взят банк данных TIGR, который содержит вертикальные профили температуры, содержания водяного пара и озона до высоты около 72 км [16] и дополнен необходимыми для моделирования параметрами поверхности. Для каждого состояния атмосферы из этого набора были рассчитаны яркостные температуры в каналах прибора и промоделированы ошибки их измерений.

## Описание методики

Следуя за подавляющим большинством публикаций по применению ИНС в обратных задачах атмосферной оптики [4–11], для решения рассматриваемой обратной задачи мы выбрали трехслойный перцептрон. На рис. 1 приведено графическое представление выбранной сети.

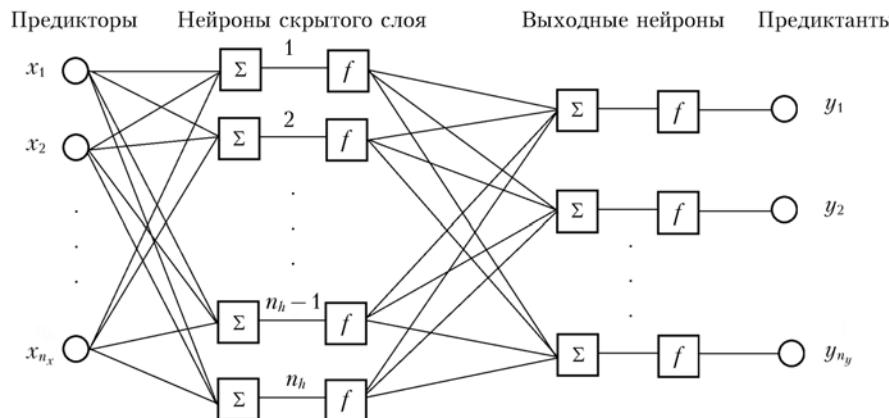


Рис. 1. Схема трехслойного перцептрана

В левой части рис. 1 представлены предикторы  $x_1, x_2, \dots, x_{n_x}$  – «входные» сигналы нашей нейронной сети. В первую очередь это величины, связанные с измеряемыми оптическими сигналами: интенсивности или яркостные температуры излучения в каналах (реальных или «виртуальных» для приборов типа Фурье-интерферометров), либо коэффициенты, полученные при разложении измеренного спектра по эмпирическим ортогональным функциям (ЭОФ) (метод главных компонент) [13]. Кроме того, в число предикторов могут входить параметры, несущие дополнительную информацию, например о геометрии наблюдений, типе подстилающей поверхности, балльности облачности, высоте ее верхней границы и т.д.

С формальной точки зрения гипотетические «датчики», поставляющие эти сигналы нейронной сети, представляют собой первый слой нейронов. Сигналы поступают на входы нейронов скрытого слоя. Каждый нейрон на рис. 1 представляет собой последовательно соединенные сумматор  $\Sigma$  и нелинейный преобразователь сигнала  $f$ . Сумматор суммирует все входные сигналы с весовыми коэффициентами, добавляет постоянную величину и получившуюся сумму передает нелинейному элементу. Сигналы с выходов нейронов скрытого слоя поступают на входы нейронов выходного слоя, устроенного аналогично. Выходы последних предоставляют «выходные» сигналы ИНС, определяющие в нашем случае результат восстановления параметров атмосферы.

За счет возможности индивидуального для каждого нейрона подбора коэффициентов нейронная сеть с нелинейным преобразованием сигнала может моделировать достаточно сложные зависимости предиктантов  $y_{i_y}$  от предикторов  $x_{i_x}$ .

Как ясно из вышеизложенного и рис. 1, количество входных  $n_x$  и выходных  $n_y$  сигналов определяется наборами предикторов и предиктантов, но количество нейронов скрытого слоя  $n_h$  является величиной произвольной.

При использовании нейронно-сетевых алгоритмов важным фактором является оптимальный выбор входных и выходных параметров сети. Необходимо оптимизировать задачу так, чтобы минимизировать число и тех, и других, в противном случае количество

коэффициентов, определяемых в процессе обучения сети, может оказаться чрезмерно велико. В самом деле, легко оценить на основе структуры сети на рис. 1, что общее количество коэффициентов  $N$ , определяемых в процессе обучения ИНС, находится по формуле

$$N = (n_x + 1)n_h + (n_h + 1)n_y. \quad (2)$$

То есть, например, для  $n_x = 40$ ,  $n_h = 30$  и  $n_y = 20$  число определяемых при обучении коэффициентов равно 1850.

Большое количество коэффициентов может приводить к избыточному определению сети, т.е. аппроксимация, реализуемая такой сетью, соответствует не физическим закономерностям задачи, а особенностям конкретной выборки, так как количество переменных настройки (обучения) сети может оказаться излишним по отношению к информационной обусловленности задачи. Как следствие, вместо аппроксимации может быть получено приближение к точному решению соответствующей системы уравнений, включающее шум. С другой стороны, малое число нейронов скрытого слоя ограничивает возможности нейронной сети в отношении аппроксимации сложных нелинейных зависимостей, что также может приводить к росту погрешности аппроксимации.

Таким образом, рассматривая каждую конкретную задачу (например, определение профиля температуры), необходимо найти оптимальное количество входных и выходных параметров, а также количество нейронов скрытого слоя.

В работах [4–11] выходные параметры сети представляют собой непосредственно значения метеопараметра, и приведенные выше соображения ограничивают высотный диапазон и количество уровней восстанавливаемых профилей. Это приводит к ряду неудобств и сложностей, связанных в первую очередь с тем, что требования к вертикальному разрешению и высотному диапазону измерений обычно пре-восходят информационные возможности рассматриваемых методов дистанционного зондирования.

По указанным причинам для представления многокомпонентных результатов, например профилей температуры и газового состава, оптимальным является метод главных компонент (представление искомых профилей в форме разложения по базису эмпирических ортогональных функций). Подобный подход находим в работе [12], однако использование методик на основе модели ИНС для определения главных компонент как предиктантов (показано ниже) приводит к вычислительным сложностям. В настоящей статье предлагается методика, которая позволяет эффективно сочетать методы ИНС и главных компонент.

Чтобы иметь возможность пояснить особенности предлагаемой методики, приведем основные соотношения, применяемые при использовании метода ИНС.

Участвующие в рассмотрении физические величины: предикторы  $\tilde{x}_{i_x}$ ,  $i_x = 1, n_x$  и предиктанты  $\tilde{y}_{i_y}$ ,  $i_y = 1, n_y$ , нормируются линейным преобразованием так, чтобы диапазон их изменения был ограничен ин-

тервалом  $[-1, +1]$ . Это можно записать следующим образом:

$$\begin{aligned} x_{i_x} &= 2(\tilde{x}_{i_x} - x_{i_x}^{\min})/(x_{i_x}^{\max} - x_{i_x}^{\min}) - 1; \\ y_{i_y} &= 2(\tilde{y}_{i_y} - y_{i_y}^{\min})/(y_{i_y}^{\max} - y_{i_y}^{\min}) - 1. \end{aligned} \quad (3)$$

Здесь  $x_{i_x}$  — нормированное безразмерное значение предиктора с индексом  $i_x$ ;  $x_{i_x}^{\max}$ ,  $x_{i_x}^{\min}$  — границы изменчивости физической величины  $\tilde{x}_{i_x}$ , аналогичные обозначения использованы для предиктантов  $\tilde{y}_{i_y}$ .

Математическая модель ИНС описывается формулой

$$y_{i_y}(\mathbf{x}) = f\left(b2_{i_y} + \sum_{i_h=1}^{n_h} w2_{i_y, i_h} f\left(b1_{i_h} + \sum_{i_x=1}^{n_x} w1_{i_h, i_x} x_{i_x}\right)\right), \quad (4)$$

где  $b2_{i_y}$ ,  $w2_{i_y, i_h}$ ,  $b1_{i_h}$ ,  $w1_{i_h, i_x}$  ( $i_y = 1, \dots, n_y$ ,  $i_h = 1, \dots, n_h$ ) — коэффициенты, в левой части предикторы объединены в вектор  $\mathbf{x} = (x_1, \dots, x_{n_x})$ ;  $f$  — функция активации нейрона, в нашем случае гиперболический тангенс. Ниже рассматриваются выборки пар векторов предикторов и предиктантов  $\tilde{X} = \{\tilde{\mathbf{x}}_{i_s}, \tilde{y}_{i_s}\}_{i_s=1, \dots, n_s}$ ,  $n_s$  — объем выборки. Обозначая отдельные элементы векторов, компонент выборки будем указывать верхним индексом  $i_s$ :  $\tilde{\mathbf{x}}_{i_s} = (\tilde{x}_1^{i_s}, \tilde{x}_2^{i_s}, \dots, \tilde{x}_{n_x}^{i_s})$ ,  $\tilde{y}_{i_s} = (\tilde{y}_1^{i_s}, \tilde{y}_2^{i_s}, \dots, \tilde{y}_{n_y}^{i_s})$ . Как и ранее, тильда над вектором обозначает ненормированную физическую величину, ее отсутствие — нормировку компонентов вектора к интервалу  $[-1, 1]$ .

Обучение сети в традиционной модели ИНС представляет собой подбор коэффициентов  $b2_{i_y}$ ,  $w2_{i_y, i_h}$ ,  $b1_{i_h}$ ,  $w1_{i_h, i_x}$ , минимизирующих среднеквадратическую (осредненную по выборке и вектору) разность выборочных и вычисленных методом ИНС значений нормированных предиктантов на выборке, называемой учебником:

$$L(\mathbf{b1}, \mathbf{b2}, \mathbf{w1}, \mathbf{w2}) = \sum_{i_s=1}^{n_s} \sum_{i_y=1}^{n_y} (y_{i_y}(\mathbf{x}_{i_s}) - y_{i_y}^{i_s})^2 \rightarrow \min. \quad (5)$$

Для решения подобных экстремальных задач развиты различные методы, подавляющее большинство которых представляет собой метод наискорейшего спуска с различными модификациями, позволяющими ускорить сходимость, избежать попадания алгоритма в «овраг» и т.д. В любом случае для работы этих алгоритмов требуется вычисление градиента функции цены (5) по всем искомым коэффициентам.

Продифференцировав выражение (5), получим формулу для расчета градиента:

$$\frac{\partial L}{\partial a_i} = 2 \sum_{i_s=1}^{n_s} \sum_{i_y=1}^{n_y} (y_{i_y}(\mathbf{x}_{i_s}) - y_{i_y}^{i_s}) \frac{\partial y_{i_y}}{\partial a_i}(\mathbf{x}_{i_s}). \quad (6)$$

Здесь для упрощения записи введен единый вектор параметров  $\mathbf{a} = \{a_i\}$ , составленный из коэффициентов

$(b2_{i_y}, w2_{i_y, i_h}, b1_{i_h}, w1_{h, i_x})$ , где  $i_y = 1, n_y, i_h = 1, n_h, i_x = 1, n_x$ . Производные  $\partial y_{i_y} / \partial a_i$  при этом вычисляются при «обратном проходе» — организации вычислений, обратной относительно расчета по формуле (4). Алгоритм их расчета не содержит принципиальных сложностей. Располагая методикой (компьютерной программой) расчета градиента, можно воспользоваться для обучения ИНС любым из многочисленных алгоритмов многопараметрической нелинейной минимизации, доступных в виде компьютерных программ в различных математических библиотеках.

Такой подход не вызывает никаких возражений, если модель ИНС используется для определения одного параметра, например скорости приводного ветра или температуры поверхности. Если же предиктантов  $\tilde{y}_{i_y}$  несколько, возникает вопрос о соотношении погрешностей их определения с помощью модели ИНС. Как видно из формул (3) и (5), погрешность аппроксимации каждого предиктанта (ненормированного) пропорциональна диапазону его изменчивости.

Такое распределение погрешностей хотя и имеет ясный физический смысл, но может отличаться от желаемого, например, при постоянном по высоте требовании к погрешности восстановления профиля температуры и использовании в роли предиктантов самих значений температуры в различных атмосферных слоях. В таком случае можно вместо выражения (5) рассмотреть минимизацию выражения

$$L(\mathbf{b}1, \mathbf{b}2, \mathbf{w}1, \mathbf{w}2) = \sum_{i_s=1}^{n_s} \sum_{i_y=1}^{n_y} (\tilde{y}_{i_y}(\mathbf{x}_{i_s}) - \tilde{y}_{i_y}^{i_s})^2 \rightarrow \min \quad (7)$$

или ввести вес и рассмотреть эквивалентную (7) задачу

$$\begin{aligned} L(\mathbf{b}1, \mathbf{b}2, \mathbf{w}1, \mathbf{w}2) &= \\ &= \sum_{i_s=1}^{n_s} \sum_{i_y=1}^{n_y} ((y_{i_y}(\mathbf{x}_{i_s}) - y_{i_y}^{i_s}) w_{i_y})^2 \rightarrow \min, \quad (8) \\ w_{i_y} &= (y_{i_y}^{\max} - y_{i_y}^{\min}) / 2. \quad (9) \end{aligned}$$

Градиент и в этом случае рассчитывается тем же способом, но введя в выражение (6) множитель  $w_{i_y}$ , получим следующее соотношение для расчета градиента:

$$\frac{\partial L}{\partial a_i} = 2 \sum_{i_s=1}^{n_s} \sum_{i_y=1}^{n_y} (y_{i_y}(\mathbf{x}_{i_s}) - y_{i_y}^{i_s}) w_{i_y} \frac{\partial y_{i_y}}{\partial a_i}(\mathbf{x}_{i_s}). \quad (10)$$

Заметим, что вес  $w_{i_y}$  можно выбирать и любым другим желаемым способом.

Однако если предиктанами с точки зрения ИНС являются не сами физические величины, а коэффициенты их разложения по базису ЭОФ, то распределение погрешностей в профиле определяется видом базисных векторов и диапазонами изменчивости коэффициентов разложения. Мы предлагаем в этом случае для достижения равновзвешенных по высоте погрешностей аппроксимации рассмотреть задачу минимизации:

$$L(\mathbf{b}1, \mathbf{b}2, \mathbf{w}1, \mathbf{w}2) =$$

Использование метода искусственных нейронных сетей при восстановлении вертикальных профилей...

$$= \sum_{i_s=1}^{n_s} \sum_{i_y=1}^{n_y} ((\mathbf{T}(\mathbf{x}_{i_s}) - \mathbf{T}_{i_s})(y_{i_y}^{\max} - y_{i_y}^{\min}) / 2)^2 \rightarrow \min, \quad (11)$$

$$\mathbf{T}(\mathbf{x}_{i_s}) = \bar{\mathbf{T}} + \mathbf{V}\tilde{\mathbf{y}}(\mathbf{x}_{i_s}), \quad (12)$$

где  $\mathbf{T}_{i_s}$  — вектор, представляющий собой профиль физической величины, например температуры  $T$ , соответствующий элементу выборки с индексом  $i_s$ ;  $\bar{\mathbf{T}}$  — вектор среднего профиля физической величины;  $\mathbf{V}$  — матрица, составленная из базисных векторов — ЭОФ. Предиктанты  $\tilde{y}_{i_y}$  в этом случае представляют собой коэффициенты разложения по усеченному базису ЭОФ, т.е. главные компоненты. Тогда расчет градиента для задачи (11), (12) выполняется по формуле

$$\frac{\partial L}{\partial a_i} = \sum_{i_s=1}^{n_s} \sum_{i_y=1}^{n_y} (\mathbf{T}(\mathbf{x}_{i_s}) - \mathbf{T}_{i_s}) \mathbf{V} (y_{\max} - y_{\min}) \frac{\partial y_{i_y}}{\partial a_i}(\mathbf{x}_{i_s}). \quad (13)$$

## Пример применения методики

Сравним результаты применения подходов, определяемых соотношениями (5), (6) I, (7)–(10) II и (11)–(13) III, на примере восстановления профиля температуры прибором МТВЗА с использованием метода главных компонент. При этом все параметры расчетов для трех методик полностью совпадали, различались лишь алгоритмы и программы расчета функции цены (5), (7) и (11) и градиента (6), (10), (13). Число измерительных каналов прибора МТВЗА достаточно невелико, и в качестве сигналов, подаваемых на вход сети, использовались непосредственно измеряемые яркостные температуры излучения. Выходными сигналами, как уже говорилось выше, являются главные компоненты решения — коэффициенты разложения профиля температуры по собственным векторам ковариационной матрицы. Специально для сравнения методик различных подходов были выполнены расчеты для всех трех подходов. Результаты обсуждаются ниже.

Прежде всего, отметим, что время обучения ИНС при использовании различных подходов существенно различалось (указанные далее продолжительности расчета получены при использовании компьютера на основе 4-ядерного процессора Intel Core2 Quad Q9400 2,66 ГГц). Так, «классический» подход ИНС I, при котором минимизируется погрешность аппроксимации коэффициентов разложения, нормированных на их изменчивость, требует максимального времени для обучения. Шаг процесса обучения, содержащий 3000 итераций метода минимизации, выполняется в среднем от 3 до 15 мин. Для метода II — минимизации погрешности коэффициентов разложения без нормировки — это время составляет около 1 мин, для метода III — минимизации погрешности профиля температуры — около 30 с. Кроме того, для метода I оптимум обучения не достигнут за 100 циклов (под циклом подразумевается выполнение шага минимизации для 50 различных случайных начальных приближений), для метода II достигнут на 8-м цикле, для метода III — на 5-м. В итоге

полное время обучения сети, включающее 50-кратный повтор описанных шагов при 50 попытках случайно моделируемого начального приближения, составило соответственно 18 сут, 1 сут и около 12 ч соответственно, а фактическое время — более 18 сут для метода I, 7 ч для метода II и 2 ч для метода III. Полученные на тестовом ансамбле профили средних и среднеквадратических погрешностей определения профиля температуры для трех методов представлены на рис. 2.

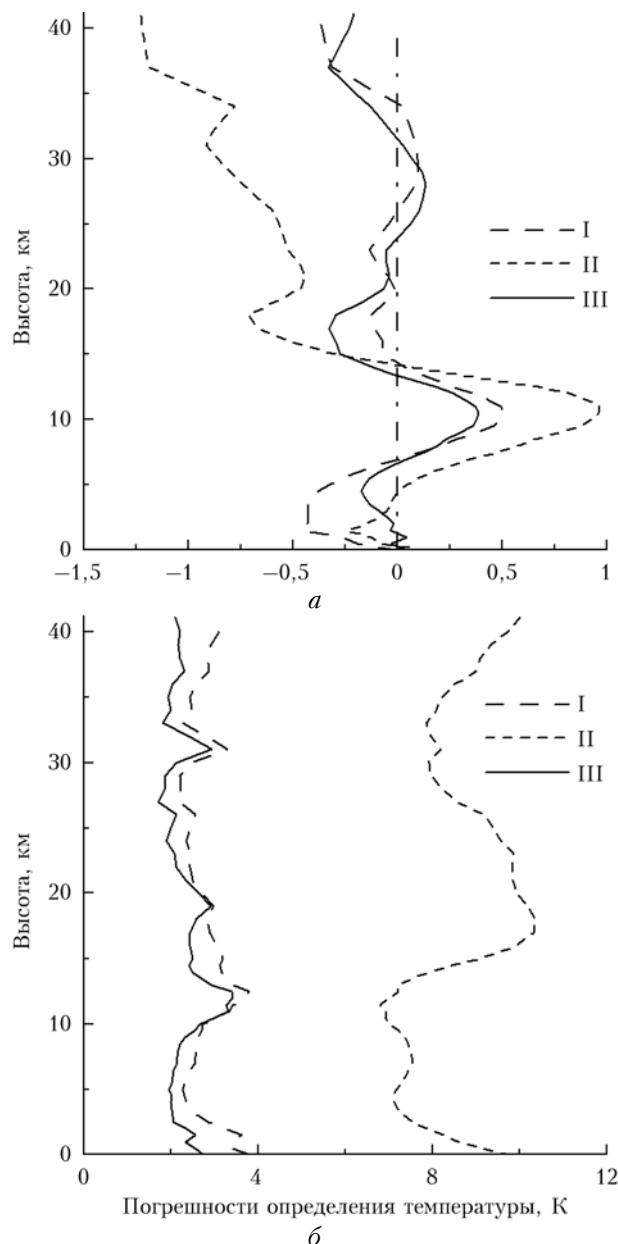


Рис. 2. Средние (а) и среднеквадратические (б) погрешности определения профиля температуры тремя методиками, основанными на методе ИНС

Прежде всего видно, что в рассмотренном случае минимизация коэффициентов разложения по ЭОФ с равновзвешенной абсолютной погрешностью (II) дает заметно худшие результаты, чем оба других

рассмотренных подхода. Подход III дает наилучшие результаты как по средней, так и по среднеквадратической погрешностям на большинстве уровней. С учетом существенно более быстрого метода обучения ИНС по сравнению с близким по точности подходом I безусловно следует использовать именно подход III.

Заметим, что необходимость многократного повторного обучения ИНС в процессе методических проработок делает практически нереализуемым подход I без привлечения мощных вычислительных систем.

Укажем, что предлагаемый подход III с успехом использовался также при методе обучения ИНС для восстановления профиля относительной влажности для прибора МТВЗА и для восстановления профилей температуры и относительной влажности по измерениям прибора ИКФС-2 [17], планируемого к установке на том же носителе. Для ИКФС-2 в качестве входных сигналов сети использовались главные компоненты измеренного спектра, так как количество спектральных измерений слишком велико для непосредственного использования в методе ИНС. При этом методические сравнения, подобные рассмотренным в настоящей статье, не проводились, так как они требуют большого объема непродуктивных вычислений.

## Заключение

При совместном использовании методов ИНС и главных компонент для восстановления профиля метеопараметров предложенный метод обучения ИНС, основанный на минимизации среднеквадратической погрешности восстанавливаемого атмосферного параметра, характеризуется принципиально (в нашем примере около 200 крат) более высокой скоростью обучения ИНС и несколько лучшими показателями как средней, так и среднеквадратической погрешности восстановления профиля по сравнению с минимизацией погрешности коэффициентов разложения по усеченному базису ЭОФ. Предложенный метод может быть рекомендован для использования в методиках интерпретации спектральных спутниковых измерений профилей атмосферных параметров.

Автор благодарит Ю.М. Тимофеева за полезные обсуждения в ходе работы над статьей.

Работа выполнена при поддержке гранта РФФИ № 12-05-00445-а.

1. Кондратьев К.Я., Тимофеев Ю.М. Метеорологическое зондирование атмосферы из космоса. Л.: Гидрометеоиздат, 1978. 280 с.
2. Успенский А.Б. Современное состояние и перспективы дистанционного температурно-влажностного зондирования земной атмосферы // Исслед. Земли из космоса. 2010. № 2. С. 26–36.
3. Успенский А.Б., Троценко А.Н., Рублев А.Н. Проблемы и перспективы анализа и использования данных спутниковых ИК-зондировщиков высокого спектрального разрешения // Исслед. Земли из космоса. 2005. № 5. С. 18–33.
4. Lei Shi. Retrieval of Atmospheric Temperature Profiles from AMSU-A Measurement Using a Neural Network Approach // J. Atmos. and Ocean. Technol. 2001. V. 18, N 3. P. 340–347.

5. Karbou F., Aires F., Prigent C., Eymard L. Potential of Advanced Microwave Sounding Unit-A (AMSU-A) and AMSU-B measurements for atmospheric temperature and humidity profiling over land // *J. Geophys. Res.* 2005. V. 110. D07109. DOI: 10.1029/2004JD005318.
6. Gribanov K.G., Zakharov V.I. Neural network solution for temperature profile retrieval from infrared spectra with high spectral resolution // *Atmos. Sci. Lett.* 2004. V. 5, iss. 1–4. P. 1–11.
7. Aires F., Prigent C., Rossow W.B., Rothstein M. A new neural network approach including first-guess for retrieval of atmospheric water vapor, cloud liquid water path, surface temperature and emissivities over land from satellite microwave observations // *J. Geophys. Res. D*. 2001. V. 106, iss. 14. P. 14887–14907.
8. Aires F., Chédin A., Scott N.A., Rossow W.B. A Regularized Neural Net Approach for Retrieval of Atmospheric and Surface Temperatures with the IASI Instrument // *J. Appl. Meteorol.* 2002. V. 41, N 2. P. 144–159.
9. Aires F., Prigent C., Rossow W.B. Neural Network uncertainty assessment using Bayesian statistics: a remote sensing application // *J. Neural Computation.* 2004. V. 16, N 11. P. 2415–2458.
10. Aires F., Rossow W.B., Scott N.A., Chédin A. Remote sensing from the infrared atmospheric sounding interferometer instrument 2. Simultaneous retrieval of temperature, water vapor, and ozone atmospheric profiles // *Geophys. Res. D*. 2002. V. 107, N 22. P. 4620–4622. DOI: 10.1029/2001JD001591.
11. Churnside J.H., Sternitz T.A., Schroeder J.A. Temperature profiling with neural network inversion of microwave radiometer data // *J. Atmos. and Ocean. Technol.* 1994. V. 11, N 1. P. 105–109.
12. Ning Wang, Zhao-Liang Li, Bo-Hui Tang, Funian Zeng, Chuanrong Li. Retrieval of atmospheric and land surface parameters from satellite-based thermal infrared hyperspectral data using a neural network technique // *Int. J. Remote Sens.* 2013. V. 34, N 9–10. P. 3485–3502.
13. Успенский А.Б., Романов С.В., Троценко А.Н. Применение метода главных компонент для анализа ИК-спектров высокого разрешения, измеренных со спутников // Исслед. Земли из космоса. 2003. № 3. С. 26–33.
14. Тимофеев Ю.М., Васильев А.В. Теоретические основы атмосферной оптики. СПб.: Наука, 2003. 474 с.
15. Кондратьев К.Я., Тимофеев Ю.М. Термическое зондирование атмосферы со спутников. Л.: Гидрометеоиздат, 1970. 410 с.
16. TIGR. Thermodynamic Initial Guess Retrieval (Электронный ресурс). URL: <http://ara.lmd.polytechnique.fr>
17. Завелевич Ф.С., Головин Ю.М., Десятов А.В., Козлов Д.А., Маццикий Ю.П., Никулин А.Г., Травников Р.И., Романовский А.С., Архипов С.А., Целиков В.А. Технологический образец бортового инфракрасного Фурье-спектрометра ИКФС-2 для температурного и влажностного зондирования атмосферы Земли // Современные проблемы дистанционного зондирования Земли из космоса. 2009. Т. 6, № 1. С. 259–266.

**A.V. Polyakov. Application of the artificial neural network method to the retrieval of vertical profiles of atmospheric parameters.**

A simultaneous use of artifical neural networks (ANN) and principal components has considered for remote sensing of temperature and composition profiles of the atmosphere. Some modification of ANN method has been offered based on minimisation of final product errors. An example of applications of the modification is adduced. An important advantage of the new approach has shown in speed of training of ANN and in profile precision.