

АППАРАТУРА И МЕТОДЫ ОПТИЧЕСКОЙ ДИАГНОСТИКИ ОКРУЖАЮЩЕЙ СРЕДЫ

УДК 528.813; 551.501

Оценка эффективности использования перспективных лидаров белого света для зондирования микрофизических параметров слоистой облачности: 3. Решение обратной задачи

Г.М. Креков, М.М. Крекова, А.Я. Суханов

Институт оптики атмосферы им. В.Е. Зуева СО РАН
634021, г. Томск, пл. Академика Зуева, 1

Поступила в редакцию 24.11.2008 г.

Продолжены исследования, связанные с оценкой эффективности использования перспективных широкополосных лидаров для зондирования микрофизических параметров облачного аэрозоля в ближней ИК-области спектра. Выполнено обобщение предложенного ранее итерационного метода на случай многоволнового лазерного зондирования. В рамках замкнутого численного моделирования проведена валидация нового оптимизационного алгоритма, основанная на сочетании идеологии метода искусственных нейронных сетей с генетическим поиском. Показана возможность восстановления высотных профилей спектра облачных частиц до значительных оптических глубин в условиях помехи многократного рассеяния.

Ключевые слова: лидар, уравнение переноса, генетические алгоритмы, нейронные сети.

Введение

Источником информации о микроструктурных и микрофизических свойствах облачного аэрозоля при лазерном зондировании атмосферы являются, как известно, оптические характеристики светорассеяния. В то же время сами оптические характеристики на протяженных атмосферных трассах нельзя измерить непосредственно. В реальном эксперименте измеряются, как правило, некие функционалы от сигнала обратного рассеяния, а для нахождения непосредственных профилей коэффициентов оптического взаимодействия необходимо решать соответствующую обратную задачу. При этом характер и сложность обратных оптических задач определяются, естественно, структурой функциональных зависимостей между измеряемыми и искомыми величинами в данном оптическом эксперименте.

Очевидно, что постановка обратных задач теории широкополосного светорассеяния должна начинаться с анализа исходных функциональных соотношений, определяющих информативность и взаимосвязь измеряемых и оцениваемых параметров в данном конкретном эксперименте. В реальной ситуации лазерного зондирования атмосферного аэрозоля извлечение информации о характеристиках рассеяния усложняется тем обстоятельством, что принимаемые оптические сигналы зависят как минимум от двух оптических параметров. Например, при лазерном моностатическом зондировании аэрозольного слоя в условиях однократного рассеяния

функциональное соотношение между пространственно разрешенным профилем сигнала обратного рассеяния $P(z, \lambda)$ на заданной длине волны λ и оптическими характеристиками β_{sct} , β_π (соответственно коэффициенты рассеяния и обратного рассеяния) может быть записано в неявном виде как $F(P, \beta_{sct}, \beta_\pi, z, \lambda) = 0$.

Очевидно, что это уравнение вообще не определено для того, чтобы найти характеристики светорассеяния. Для простейшей количественной интерпретации лидарных измерений необходимо дополнить указанное уравнение, задав, например, параметр взаимосвязи между коэффициентами полного и обратного рассеяния, так называемое лидарное отношение $b(z\lambda) = \beta_\pi(z\lambda) / \beta_{sct}(z\lambda)$. Это приводит к проблеме априорной оценки $b(z, \lambda)$ из дополнительных измерений или модельных оценок. Для преодоления возникшей неопределенности существует следующая альтернатива: можно, с одной стороны, увеличить объем измерительной информации в эксперименте, а с другой стороны, для ее обращения использовать более тонкие математические методы. Это привело к известной методологии мультиволнового лазерного зондирования [1–5], дальнейшее развитие которой составляет содержание данной статьи.

1. Оптические уравнения теории мультиволнового лазерного зондирования

Теория мультиволнового (или многочастотного) лазерного зондирования как оптического метода

* Георгий Михайлович Креков (gm@iao.ru); Маргарита Матвеевна Крекова; Александр Яковлевич Суханов.

дистанционного определения оптических и микрофизических параметров земной атмосферы и гидросфера основывается на нестационарном уравнении переноса излучения и операторах полидисперсного светорассеяния системами частиц, установленных в фундаментальных исследованиях И.Э. Наада [1–3]. При многочастотном зондировании уравнение переноса, записанное в приближении однократного рассеяния для набора спектральных интервалов, редуцируется в систему лидарных уравнений вида [1, 5]:

$$P(\lambda_i, z) = P_0(\lambda_i) \beta_\pi(\lambda_i, z) G(\lambda_i) z^{-2} \exp \left[-2 \int_0^z \beta_{ext}(\lambda_i, z') dz' \right], \quad (1)$$

где $P_0(\lambda_i)$ — мощность посылаемого сигнала на длине волны λ_i ; $G(\lambda_i)$ — аппаратурная постоянная, определяемая площадью приемной системы лидара и пропусканием оптических элементов на рабочих длинах волн лидара λ_i ; $\beta_{ext}(\lambda_i, z)$ — коэффициент ослабления.

Ниже в целях упрощения будем полагать, что в условиях облачности молекулярным рассеянием в ближнем ИК-диапазоне можно пренебречь. Для решения задачи о восстановлении микрофизических параметров облачности, в первую очередь функции распределения капель по размерам $f(r)$ (r — радиус капли), систему уравнений (1) необходимо дополнить известными интегральными соотношениями

$$\beta_{ext}(\lambda_i, z) = \int_{r_1}^{r_2} K_{ext}(\lambda_i, z, r) s(z, r) dr, \quad (2)$$

$$\beta_\pi(\lambda_i, z) = \int_{r_1}^{r_2} K_\pi(\lambda_i, z, r) s(z, r) dr, \quad (3)$$

где $s(r) = \pi r^2 f(r)$; r_1, r_2 — границы спектра размеров $f(r)$; K_{ext} , K_π — факторы эффективности ослабления и обратного рассеяния.

Поскольку оптические измерения в пределах выбранного спектрального интервала Λ проводятся для дискретного набора длин волн $\lambda_i \in \Lambda$, часто используют [2] операторную форму записи интегральных соотношений (2), (3):

$$\beta_\pi(\lambda_i) = (K_\pi s)(\lambda_i), \quad \beta_{ext}(\lambda_i) = (K_{ext}s)(\lambda_i). \quad (4)$$

С учетом (4) исходную систему уравнений (1)–(3) можно переписать в следующем виде:

$$\begin{aligned} F(P_i \beta_{\pi,i} \beta_{ext,i}, z, \lambda_i) &= 0; \\ K_\pi s = \beta_\pi K_{ext} s = \beta_{ext}, \end{aligned} \quad (5)$$

где значения компонент векторов β_π и β_{ext} определяются соотношениями

$$\beta_{\pi,i} = \beta_\pi(\lambda_i), \quad \beta_{ext,i} = \beta_{ext}(\lambda_i), \quad i = 1, 2, \dots, n.$$

Очевидно, эта система вполне определена относительно вектора s , который отражает искомое распределение $s(z, r)$ для всех z по трассе зондирования. Действительно, для определения вектора s имеются два уравнения, правые части которых, β_π и β_{ext} , хотя и не известны непосредственно, но связаны покомпонентно между собой локационными уравнениями. Это доказывает в конечном итоге состоятельность многочастотной лазерной локации как оптического метода определения микроструктуры аэрозолей.

2. Итерационный метод решения системы лидарных уравнений

Остановимся кратко на вопросах, связанных с построением алгоритма численного решения системы уравнений (5). Воспользуемся формальным оператором взаимного перехода, введенного в [1, 2] как $W = K_{ext} K_\pi^{-1}$ или $\tilde{W} = K_\pi K_{ext}^{-1}$. В этом случае систему (5) можно переписать

$$\begin{aligned} F(P_i \beta_{\pi,i} \beta_{ext,i}, z, \lambda_i) &= 0, \\ \beta_{ext} &= W \beta_\pi, \quad i = 1, 2, \dots, n. \end{aligned} \quad (6)$$

Далее преобразуем (6) в дискретную форму, считая, что в процессе оцифровки лидарного сигнала на каждой длине волны $\lambda_i \in \Lambda$ мы имеем массив равноотстоящих отсчетов $P_{k,i} = P(z_k, \lambda_i)$ с шагом $\Delta z = z_{k+1} - z_k$ ($k = 1, 2, \dots, N_z$). Тогда для каждого k имеем систему лидарных уравнений

$$S_{k,i} = \beta_{\pi,k,i} \exp \left\{ -2 \Delta z \sum_{j=1}^k \omega_j \beta_{ext,j,i} \right\}, \quad (7)$$

где $S_{k,i} = P_{k,i} z_k^2 / P_0 G_i$ — квадратично усиленный сигнал обратного рассеяния; ω_j — квадратурные коэффициенты.

Если решение системы (7) выполнять последовательно, начиная с $k = 1$, то для точки z_k все предыдущие значения оптических характеристик вплоть до $\beta_{\pi,k-1,i}$ и $\beta_{ext,k-1,i}$ будут известны. В этом случае (7) удобнее представить в виде [1, 6]:

$$\beta_{\pi,k,i} \exp(-2\tau_{k,i}) = S_{k,i} / T_{k-1,i}, \quad (8)$$

где

$$T_{k-1,i} = \exp \left[-2 \Delta z \sum_{j=1}^{k-1} \omega_j \beta_{ext,j,i} \right], \quad k \geq 2, \quad T_{1,i} = 1;$$

$$\tau_{k,i} = \Delta z (\beta_{ext,k-1,i} + \beta_{ext,k,i}) / 2$$

— оптическая толщина k -го слоя зондируемого облака.

Для решения системы (7) совместно с векторным уравнением (6) относительно векторов β_π и β_{ext} в работе [6] был предложен и математически

обоснован итерационный алгоритм, схема которого может быть представлена в следующем аналитическом виде:

$$\beta_{\pi k,i}^{(m)} = \frac{S_{k,i}}{T_{k-1,i}} e^{-2\tau_{k,i}^{(m-1)}}, \quad (9)$$

$$\beta_{ext,k}^{(m-1)} = W \beta_{\pi k}^{(m-1)}, \quad i=1,2,\dots,n; \quad k=1,2,\dots,$$

где m — номер итерации; оператор W — матричный аналог оператора $K_{ext} K_{\pi}^{-1}$.

В случае зондирования оптически плотных рассеивающих сред, к категории которых можно отнести слоистые облака нижнего яруса, требуется повышенная устойчивость алгоритмов обращения к помехе многократного рассеяния. Исходя из этих требований, в предыдущей части работы [7] предложена параметрическая модификация итерационной схемы (9), которая и использовалась в дальнейших расчетах векторов $\beta_{\pi}(\lambda_i)$ и $\beta_{ext}(\lambda_i)$ для выбранных длин волн лазерного зондирования λ_i .

3. Выбор информативных длин волн лазерного зондирования

Очевидно, что число длин волн зондирования n в данном спектральном интервале Λ зависит от того, как близко могут быть выбраны две соседние волны, например λ_i и λ_{i+1} , при данной точности измерительной аппаратуры. Обозначим через ε наименьшую относительную ошибку измерений в спектральном интервале Λ и рассмотрим задачу о допустимой близости двух длин волн при зондировании атмосферного аэрозоля. Предположим, что в эксперименте измеряются значения оптической характеристики $\beta(\lambda)$ в интервале Λ . Если обозначить через $\Delta\beta = \beta(\lambda_{i+1}) - \beta(\lambda_i)$ приращение оптической характеристики β в окрестности точки λ_i , то наименьшее расстояние между λ_i и λ_{i+1} должно удовлетворять очевидному соотношению $|\Delta\beta| \geq \varepsilon \beta(\lambda_i)$. В работах [1, 2] на основании анализа полидисперсных интегралов показана справедливость следующего неравенства:

$$m \ln |1 - \lambda_i / \lambda_{i+1}| \geq \varepsilon A, \quad i=1,2,\dots,n, \quad (10)$$

где минимум берется по парам соседних λ_i и λ_{i+1} при всевозможных разбиениях интервала зондирования Λ ; A — постоянная, зависящая только от свойств аэрозольного распределения ($0 < A < 1$). Таким образом, если λ — некоторая длина волны зондирования, то следующая длина волны должна быть выбрана на расстоянии, превышающем величину $|\Delta\lambda| \geq \varepsilon \lambda A$. Тогда нетрудно оценить допустимое число длин волн в целом по интервалу Λ . Обозначим через λ_{min} и λ_{max} соответственно левую и правую границы Λ . Тогда имеют место соотношения

$$\begin{aligned} \lambda_i &= (1 + \varepsilon A)^{i-1} \lambda_{min}, \quad i=1,2,\dots,n, \\ n &= 1 + \lg(\lambda_{max} / \lambda_{min}) / \lg(1 + A\varepsilon), \end{aligned} \quad (11)$$

из которых первое определяет порядок следования значений λ_i , а второе — максимально допустимое число отсчетов. Эти соотношения показывают, что независимо от свойств микроструктуры по мере увеличения λ отсчеты должны идти все реже и реже, причем величина соответствующего интервала $\Delta\lambda$ прямо пропорциональна λ . Для того чтобы воспользоваться этими соотношениями, необходимо знать величину A . Формально величина A есть функционал от распределения $s(r)$ и определяется выражением

$$A = S \left\{ \int_R (rs') |dr| \right\}^{-1}, \quad (12)$$

которое может быть использовано для численных оценок. В случае гамма-распределения частиц по размерам [8]:

$$f(r) = ar^{\alpha} \exp(-br^{\gamma}), \quad (13)$$

можно показать справедливость приближенного равенства $A \approx 1 / (\alpha + 3)$, где α — параметр распределения. Заметим, что приведенные соотношения имеют приближенный характер, однако они достаточны в случае, когда допустимо предположение о мономодальной форме искомого распределения $s(r)$, например спектр капель в слоистой облачности нижнего яруса. В отсутствие априорной информации о характере $s(r)$ оценку числа независимых измерений более строго можно выполнить, следуя [9] в рамках анализа Фурье непрерывных измерений.

4. Аналитические методы обращения интегрального уравнения

Формально распределение частиц по размерам $f(r)$ или сечениям $s(r)$ может определяться из спектрального поведения любых оптических характеристик, т.е. коэффициентов оптического взаимодействия (ослабления, рассеяния, поглощения, обратного рассеяния) или компонент матрицы рассеяния. В данной статье, имея в виду локационную схему измерения, отдается предпочтение коэффициентам обратного рассеяния $\beta_{\pi}(\lambda_i, z_k)$, которые помимо всего прочего обладают более глубоким информационным содержанием [4]. Восстановленные значения коэффициентов обратного рассеяния $\beta_{\pi}(\lambda_i, z_k)$ формально удовлетворяют интегральному уравнению Фредгольма 1-го рода (3), ядро которого содержит подлежащую оценке функцию $s(r)$.

Предположим, что функция $s(r)$ описывает распределение геометрического сечения аэрозольных частиц по размерам в единичном объеме рассеивающей среды. В задачах лазерного зондирования вид функции $s(r)$ может меняться в зависимо-

сти от пространственных координат. Фактор эффективности обратного рассеяния $K_\pi(\lambda, r)$ для отдельной частицы радиуса r на длине волны λ зависит от комплексного показателя преломления вещества аэрозольных частиц $m - ik$. Комплексный показатель преломления и граница размеров частиц в (3) в общем случае также могут быть неизвестны. При этих условиях обращение интегрального уравнения (3) является некорректно поставленной задачей [1, 2].

Построение приближенных решений некорректных обратных задач, устойчивых к малым изменениям в исходных данных, требует использования специальных математических методов [1, 3, 10]. К настоящему времени создана развитая теория и разработаны эффективные методы решения задач этого класса. Сравнительный анализ аналитических методов обращения интегрального уравнению Фредгольма 1-го рода в приложении к задачам атмосферной оптики выполнен в работах [4, 11, 12].

Успешную практическую апробацию на протяжении длительного времени прошли методы и алгоритмы решения обратных задач лазерного зондирования атмосферного аэрозоля, созданные в ИОА СО РАН [1–3]. В основном эти методы основаны на строгом математическом подходе теории регуляризации [10]. Для унимодальных спектров распределения, характерных для облачного аэрозоля, хорошо зарекомендовал себя более простой в алгоритмическом плане метод оптимальной параметризации [1, 6, 13]. Упрощение связано с априорным заданием аналитического вида функции распределения, например, в форме обобщенного γ -распределения [8, 14].

Решение обратной задачи находится вариационным методом в виде оптимальных оценок параметров $\{a, b, \alpha, \gamma\}$, характеризующих микроструктуру в среднем на заданном интервале решений $(r_1, r_2) \in R$. Численный алгоритм определения искомых параметров основан, как правило, на минимизации квадратичной формы

$$F(P) = \sum_{i=1}^{NI} [\beta(\lambda_i) - \beta_m(\lambda_i, a_1, a_2, \dots, a_m)]^2, \quad (14)$$

где β_m – множество модельных оптических характеристик, образуемых оператором K и модельной функцией $s_m(r, a_1, a_2, \dots, a_m)$ в некоторой ограниченной области Ω пространства решений

Следует отметить, что модельные функции распределения частиц, как правило, нелинейно зависят от искомых параметров и, вследствие этого, минимизируемая функция (14) может иметь в области Ω не один экстремум, что при оценке большого числа параметров часто приводит к неоднозначности решения.

С учетом этого обстоятельства важное значение имеет предварительный численный анализ обратной задачи аэрозольного светорассеяния

Он необходим для выбора наименьшего количества независимых оцениваемых параметров, от-

носительно которых измеряемые в конкретном оптическом эксперименте данные наиболее информативны.

5. Статистические и интеллектуальные методы решения обратных задач

Следует заметить, что метод регуляризации требует подбора коэффициента регуляризации, от которого существенно зависит точность восстановления искомых параметров микроструктуры аэрозольных частиц. Существуют различные методики автоматического подбора данного коэффициента, но это снижает скорость работы алгоритма в связи с необходимостью многократного перемножения матриц больших размерностей. Кроме того, метод регуляризации быстро теряет свою устойчивость с увеличением помехи в принимаемом сигнале за счет фона многократного рассеяния.

Эта проблема становится определяющей при зондировании оптически плотных атмосферных гидрометеоров. К ним относится, в первую очередь, слоистая облачность нижнего яруса, контроль которой весьма актуален с точки зрения безопасности авиаперевозок. В связи с возникающими трудностями количественной интерпретации данных оптического зондирования в последнее время повысился интерес к статистическим методам решения некорректных обратных задач [15–20] и методам, использующим технологию искусственного компьютерного интеллекта [21–25].

5.1. Метод Монте-Карло

Один из способов решения задачи основан на использовании стохастического алгоритма, или алгоритма случайного поиска [15, 19, 20]. Метод заключается в том, что ожидаемый диапазон размеров $[r_1, r_2]$ разбивается на равные интервалы, после чего осуществляется итерационный поиск значений плотности распределения в каждом интервале с минимизацией функционала (14), т.е. значение плотности распределения в интервалах на каждом шаге итерации корректируется на некоторую случайную величину, распределенную по равномерному закону с нулевым средним. Если это приводит к уменьшению функционала, то скорректированное значение сохраняется, иначе возвращается предыдущее значение на данном интервале:

$$\sum_{i=1}^{NI} \left[\beta_\pi(\lambda_i) - \int_{r_1}^{r_2} f(r) K_\pi(\lambda_i, r) dr \right]^2 \rightarrow \min. \quad (15)$$

Другой способ восстановления основан на применении метода Монте-Карло. В этом случае генерируется выборка значений радиусов заданной размерности, распределенных в интервале $[r_1, r_2]$. Далее начинается итерационная процедура, где одно из значений, выбранное случайным образом,

заменяется новым случайнм значением, если это приводит к уменьшению функционала

$$\sum_{i=1}^{Nl} \left(K_\pi(\lambda_i) - \frac{S \sum_{j=1}^{Nv} K_\pi(\lambda_j) r_j}{Nv} \right)^2 \rightarrow \min, \quad (16)$$

где $K_\pi(\lambda_j)$ – коэффициент обратного рассеяния на j -й длине волны; Nv – размерность выборки; S – масштабирующий коэффициент; Nl – число длин волн, на которых осуществляется зондирование; r_i – радиус i -й частицы в выборке. Данная процедура повторяется до тех пор, пока не будет достигнута заданная точность либо не будет достигнуто заданное число итераций. Масштабирующий коэффициент S изменяется также случайно. Решение об изменении данного коэффициента принимается на каждом этапе итеративного процесса в соответствии с заранее заданной вероятностью.

После процедуры минимизации строится нормированная гистограмма по массиву радиусов. Особенность данного метода в том, что он не использует априорной информации о виде функции распределения.

Проведенные численные эксперименты [23] показали, что при использовании метода Монте-Карло для корректного восстановления функции распределения требуется большое число длин волн (от 10 и более), при этом вторая реализация метода имеет тот недостаток, что резко увеличивается количество возможных решений уравнения (14) в связи с подстройкой «отдельно каждой частицы». По этой причине в дальнейшем выбор был сделан в пользу генетического алгоритма и метода нейронных сетей.

5.2. Генетический алгоритм

Генетический алгоритм [26–30] используется для минимизации функционалов вида (15), при этом функция распределения $f(r)$ может быть задана в любом виде, в частности в виде (13). Поиск осуществляется по пространству параметров функции распределения. Генетический алгоритм поиска минимума основан на моделировании процесса природной эволюции и относится к так называемым эволюционным методам поиска, поэтому при его описании используются термины, заимствованные из биологии. При практической реализации данного метода используют операции, аналогами из живого мира которым служат мутация и скрещивание. Операции производятся над множеством решений (популяцией), и их результатом являются потомки (новые решения), которые также включаются в популяцию. Наряду с созданием потомков из популяции удаляются неприспособленные особи (худшие решения). В результате многократного повторения данных операций в популяции остаются самые приспособленные особи, т.е. таким образом можно достичь оптимума.

Более строго, генетическим алгоритмом называется следующий объект $GA(P^0, Ns, Fit, sl, cr, m, sc)$, где P^0 – начальная популяция; Ns – количество элементов в популяции; Fit – функция фитнеса (функция полезности), определяющая «пригодность» решения; sl – селекция решений для создания нового решения; cr – оператор кроссинговера, определяющий возможность получения нового решения; m – оператор мутации; sc – оператор отбора. Блок-структура нашего алгоритма приведена на рис. 1.

Начальная популяция P^0 – это множество начальных решений, принадлежащих пространству решений $X \in D$. P^0 генерируется случайным образом



Рис. 1. Блок-структура генетического алгоритма

либо на основе априорных данных об искомом решении. Функция фитнеса определяется минимизируемым функционалом. Селекция решений необходима для создания нового решения. Наиболее выгодно выбирать решения, соответствующие наиболее оптимальным решениям и наиболее различающимся между собой.

Другими словами, стратегия алгоритма заключается в равновероятном выборе тех решений, для которых $Fit(X_k) < Fit_{cp}$, где Fit_{cp} – среднее значение функции фитнеса.

После выбора образующих решений (предков) над ними проводится операция кроссинговера для создания нового решения (потомка). Кроссинговер может проводиться либо с помощью перекомбинаций элементов векторов решений предков [30], либо по следующей формуле:

$$x_i^n = x_{k1,i}q + x_{k2,i}(1-q),$$

где x_i^n – i -й элемент нового вектора решения; q – равномерно распределенная величина от 0 до 1; $x_{k1,i}, x_{k2,i}$ – образующие решения.

После того как новое решение создано, над ним проводится операция мутации, которая осуществляется следующим образом:

$$x_i = x_i + \delta, \quad i \in [1, Np],$$

где Np – размерность вектора решения; δ – случайное малое значение; i выбираются из указанного диапазона $[1, Np]$, при этом вероятность изменения большего числа элементов мала. Решение после этой операции добавляется в популяцию. Далее осуществляется отбор хороших решений или отбрасывание худших из популяции. Этот процесс может происходить над одним или сразу несколькими решениями, например, по условию $Fit(X_k) > Fit_{cp}$ все решения отбрасываются, после чего воссоздается с помощью кроссинговера и мутации новое множество решений.

В задаче лидарного зондирования микроструктуры облачного слоя в предположении, что спектр капель удовлетворяет обобщенному γ -распределению вида (13), функцию фитнеса можно представить в следующем виде:

$$Fit(\mathbf{p}) = \sum_i \left(\beta_\pi(\lambda_i) - \int_0^{\infty} \sum_{j=0}^{Nq} A_j \exp\left(-\frac{(r-r_j)^2}{2\mu_j^2}\right) \times \right. \\ \left. \times K_\pi(\lambda_i, r, m, \lambda_i) dr \right)^2, \quad (17)$$

где $\mathbf{p} = (Ng, A_0, \mu_0, A_1, \mu_1, \dots, A_{x-1}, \mu_{x-1})$.

Число функций также является неизвестным параметром поиска, значение которого при операции мутации выбирается всякий раз по экспоненциальному закону распределения

$$F(x) = \begin{cases} q \exp(-qx), & x > 0 \\ 0, & x \leq 0 \end{cases}. \quad (18)$$

Датчик случайных чисел распределения реализуется по формуле

$$Ng = \left[-\ln\left(\frac{1-F}{q}\right) + 1 \right],$$

где квадратные скобки показывают округление до целых. Также в качестве неизвестных параметров вводятся амплитуда и центр каждой γ -функции. Их полуширины μ являются варьируемыми параметрами при $\mu \ll \max(r)$.

Реализованный нами алгоритм в целом можно описать следующим образом. Для каждого искомого параметра устанавливается диапазон поиска. Диапазон может быть задан исходя из наших знаний о функции $f(r)$.

На первом этапе определяется начальный массив решений, значениям параметров каждого возможного решения присваиваются случайные значения из соответствующего диапазона. Для каждого решения (вектор искомых параметров $[a_1, a_2, \dots, a_n]$ для произвольной функции или $[a, \alpha, b, \gamma]$ для функции γ -распределения) рассчитывается функция фитнеса (17). Чем меньше значение функционала (17) (более высокая точность определения параметров), тем лучше решение. В массиве решений выбираются два или более решения, производится операция кроссинговера (скрещивания). Затем осуществляется операция мутации: изменения одного или более параметров потомка на малую величину либо полное изменение нескольких из параметров. После того как образован потомок, определяется, лучше ли он самой неприспособленной в популяции особи, и если это так, то неприспособленная особь удаляется из популяции и заменяется потомком. Операции повторяются до тех пор, пока не будет получено приемлемое решение.

5.3. Метод искусственных нейронных сетей

Другой предлагаемый метод основан на применении искусственных нейронных сетей [25, 31–34]. Нейронные сети можно считать неким устройством, позволяющим построить необходимую функциональную зависимость по предлагаемым ей примерам обучения. В нашем случае при реализации метода нейронных сетей важно выбрать метод обучения, число слоев, тип нейронов, а также создать обучающую выборку. Создание обучающей выборки – отдельная и сложная задача, необходимо, чтобы выборка была полной, наиболее информативной и не очень большой по объему. При ее создании необходимо моделировать процесс лидарного зондирования для различных атмосферных условий.

Для решения задачи лидарного зондирования можно применить несколько конструкций нейронных сетей, отличающихся видом активационных функций, числом слоев, комбинацией входных параметров, количеством отдельных нейронных сетей, предназначенных для восстановления общего профиля концентрации.

Как показано в наших работах [33, 34], для задач оптического зондирования наиболее эффективной сетью является трехслойная нейронная сеть типа многослойного персептрона (рис. 2).

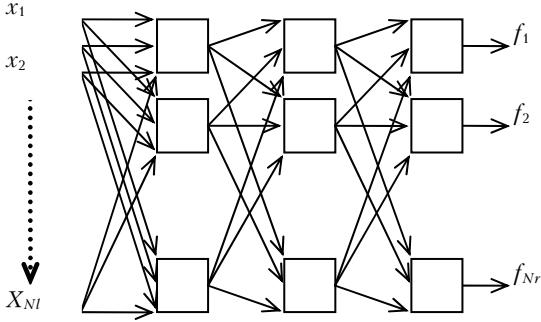


Рис. 2. Структурная схема трехслойной нейронной сети

Математически функционирование трехслойной нейронной сети можно описать следующим выражением:

$$f_i = \Phi_{3,i} \left\{ \sum_{j_1=0}^{Nr-1} w_{i,j_1}^3 \Phi_{2,j_1} \left[\sum_{j_2=0}^{Nin-1} w_{j_1,j_2}^2 \Phi_{1,j_2} \left(\sum_{j_3=0}^{Nl-1} w_{j_2,j_3}^1 x_{j_3} \right) \right] \right\}, \quad (19)$$

где $\Phi_{i,j}$ – активационная функция j -го нейрона i -го слоя; $w_{i,j}^n$ – j -й весовой коэффициент i -го нейрона n -го слоя; f_i – выходные значения нейронной сети, соответствующие выходу i -го нейрона последнего слоя; x_i – входные значения нейронной сети (НС), их число равно числу входов каждого входного нейрона нейронной сети; Nr – количество дискретных значений функции $f(r)$.

Для придания необходимой функциональности НС предварительно обучают на примерах. В нашем случае в качестве входных данных для НС могут служить и сигналы, полученные на различных длинах волн, и значения оптических характеристик, в частности значения обратного рассеяния на нескольких длинах волн $\beta_\pi(\lambda_i)$ ($i=1,2,\dots,n$). В качестве выходных данных НС использовались значения функции распределения $f(r, z_j)$ ($j=1,2,\dots$). Для создания примеров методом Монте-Карло решалась имитационная прямая задача зондирования облачного слоя. Расчет подгоночных значений факторов обратного рассеяния проводился по теории Ми с коэффициентами преломления для воды при их модификации до 5%. Функции распределения в приведенном ниже примере, как и ранее, рассчитывались на основе γ -распределения (13) с различными параметрами; параметры выбирались следующим стохастическим образом:

$$\begin{aligned} \alpha &= [5 - 1,5(\xi - 0,5)], \\ b &= 2 + (\xi - 0,8), \\ \gamma &= 1 + 0,5(\xi - 0,1), \\ a &= \left(1 + \frac{0,1\xi}{(\alpha / (\gamma b))^{2\gamma}} \right) b^3, \end{aligned} \quad (20)$$

где $\xi \in (0,1)$ – равномерно распределенная случайная величина; квадратные скобки [] – выделение целой части числа.

Реализованная в настоящей задаче схема обучения кратко состоит в следующем. Пусть в начальный момент времени весовые коэффициенты $w_{i,j}^n$ всех синаптических связей трехслойного персептрона, однозначно связанные с искомыми значениями параметров (20), приобретают некоторые случайные значения. Для тренировки НС используется некоторое количество учебных примеров, состоящих из входных сигналов x_1, x_2, \dots, x_n и соответствующих желаемых откликов на выходе сети d_1, d_2, \dots, d_n . Последовательное обучение предполагает предъявление НС один за одним входных векторов и коррекцию весов в соответствии с выбранным правилом. Сигнал ошибки выходного j -го нейрона на итерации m (соответствующей m -й учебной паре x_m и d_m) очевидно определяется как $e_j(m) = d_j(m) - y_j(m)$. Иногда [25] вводят такую термодинамическую аналогию, как энергия ошибки j -го нейрона, определенную как $e_j^2(m)/2$, тогда общая энергия ошибки сети определяется как

$$E(m) = \sum_{j=1}^n e_j^2(m) / 2. \quad (21)$$

Это выражение можно трактовать как целевую функцию для минимизации (или функцию стоимости), зависящую от всех весовых коэффициентов НС. Можно ввести «энергию» среднеквадратической ошибки, т.е. усредненную энергию (21) по всем образцам учебного набора

$$\bar{E} = \frac{1}{N} \sum_{m=1}^N E(m) = \frac{1}{N} \sum_{m=1}^N \sum_{j=1}^n e_j^2(m) / 2, \quad (22)$$

которая имеет смысл меры эффективности обучения НС.

Рассмотрим j -й нейрон во втором слое сети на итерации m (т.е. при подаче на входы сети m -го образца из учебного набора). Аргумент функции активации данного нейрона равен

$$g(m) = \sum_{i=0}^{N_i} w_{i,j}(m) y_i(m),$$

где $y_i(m)$ – сигналы с выходов нейронов предыдущего слоя. Тогда функциональный сигнал на выходе рассматриваемого j -го нейрона определяется как $y_j(m) = \Phi_j[g(m)]$.

В качестве эффективной схемы обучения выбран алгоритм обратного распространения ошибки (ОРО) [25], хорошо зарекомендовавшей себя в задачах флуоресцентной спектроскопии. Сущность этого алгоритма состоит в применении к весу $w_{i,j}(m)$ коррекции $\Delta w_{i,j}(m) = -\eta \frac{\partial E(m)}{\partial w_{i,j}}$, пропорциональной градиенту ошибки. Обучение осуществляется мето-

дом градиентного спуска, т.е. на каждой итерации изменение веса производится по формуле

$$w_{i,j}(m+1) = w_{i,j}(m) - \eta \frac{\partial E}{\partial w_{i,j}}, \quad (23)$$

где η — параметр, определяющий скорость обучения. Функция ошибки в явном виде не содержит зависимости от веса $w_{i,j}$, поэтому воспользуемся формулами неявного дифференцирования сложной функции:

$$\frac{\partial E}{\partial w_{i,j}} = \frac{\partial E}{\partial y_j} \frac{\partial y_j}{\partial S_j} \frac{\partial S_j}{\partial w_{i,j}}, \quad (24)$$

где S_j — взвешенная сумма входных сигналов. При этом множитель $\frac{\partial S_j}{\partial w_{i,j}} = x_i$, где x_i — значение i -го входа. Определим первый множитель формулы (24):

$$\frac{\partial E}{\partial y_j} = \sum_k \frac{\partial E}{\partial y_k} \frac{\partial y_k}{\partial S_k} \frac{\partial S_k}{\partial y_j} = \sum_k \frac{\partial E}{\partial y_k} \frac{\partial y_k}{\partial S_k} w_{k,j}^{(n+1)}, \quad (25)$$

где k — число нейронов в слое $n+1$. Введем вспомогательную переменную $\delta_j^{(n)} = \frac{\partial E}{\partial y_j} \frac{\partial y_j}{\partial S_j}$, тогда можно определить рекурсивную формулу для определения $\delta_j^{(n)}$ n -го слоя, если известно значение этой переменной следующего $n+1$ -го слоя:

$$\delta_j^{(n)} = \frac{\partial y_j}{\partial S_j} \sum_k \delta_k^{(n+1)} w_{k,j}^{(n+1)}. \quad (26)$$

Нахождение $\delta_j^{(n)}$ для последнего слоя нейронной сети не представляет трудностей, так как априорно известен вектор тех значений, который должна выдавать сеть при заданном входном векторе:

$$\delta_j^{(n)} = (y_j^n - d_j) \frac{\partial y_j}{\partial S_j}. \quad (27)$$

В результате всех преобразований получим следующее выражение для вычисления приращения весов связи в нейронной сети:

$$\Delta w_{i,j} = -\eta \delta_j^{(n)} x_i^n; \quad (28)$$

$$w_{i,j}(m+1) = w_{i,j}(m) + \Delta w_{i,j}. \quad (29)$$

Таким образом, можно сформулировать полный алгоритм обучения методом ОРО (структурная схема алгоритма приведена на рис. 3):

1. Подать на вход нейронной сети очередной входной вектор из обучающей выборки и определить значения выходов нейронов в выходном слое.
2. Рассчитать $\Delta w_{i,j}$, используя формулы (27), (28) для выходного слоя НС.
3. Рассчитать $\Delta w_{i,j}$, используя формулы (26), (28) для остальных слоев.
4. Скорректировать все веса НС по формуле (29).

5. Если ошибка существенна, вернуться к шагу 1, если нет, то завершить процедуру обучения.

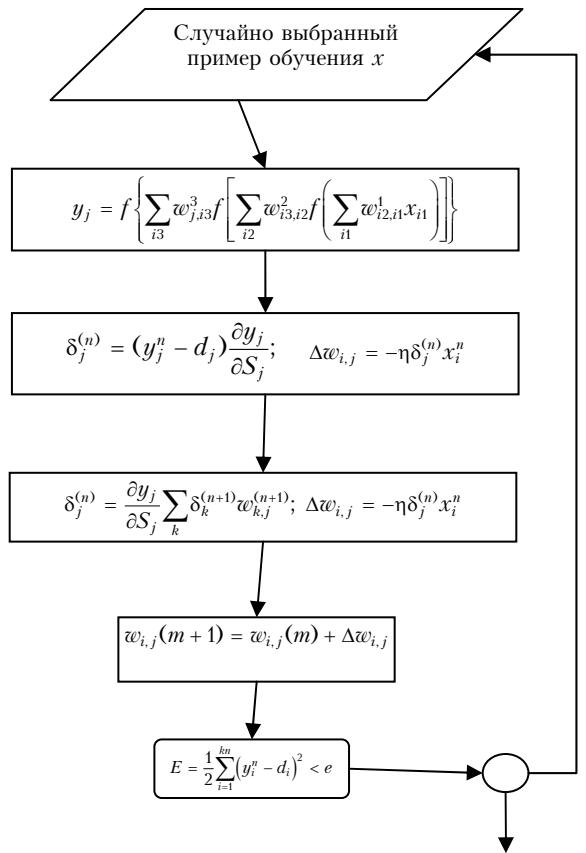


Рис. 3. Структурная схема алгоритма обратного распространения ошибки

Изложенный алгоритм ОРО в его канонической форме [25] недостаточно эффективен в случае, когда производные по различным весам сильно отличаются, что нередко имеет место в рассматриваемом классе задач ввиду осциллирующего характера амплитудных коэффициентов Ми. Поэтому для повышения сходимости метода в данной работе реализована гибридная схема, основанная на включении в алгоритм обратного распространения ошибки элементов изложенного выше генетического поиска. Сам генетический алгоритм имеет тот недостаток, что необходимо рассчитывать функцию ошибки сети для всех примеров в выборке, и это очень снижает скорость работы данного алгоритма. Рационально использовать данный алгоритм для малой части выборки, содержащей примеры, имеющие наиболее сильный разброс, тогда скорость алгоритма существенно повышается. В итоге результирующий алгоритм состоит в том, что поочередно используются генетический алгоритм и метод ОРО. При этом, когда метод ОРО снижает ошибку на очень малую величину, управление передается на генетический алгоритм, который в свою очередь через определенное число циклов возвращает управление методу ОРО.

6. Численный эксперимент по зондированию микроструктурных параметров слоистой облачности с помощью лидара белого света

Для решения обратной задачи восстановления микрофизических характеристик облаков использовалось прямое моделирование процесса зондирования методом Монте-Карло. Как и ранее, начальные и граничные условия решения интегрального уравнения переноса соответствуют схеме моностатического лазерного локатора наземного базирования. Предполагается, что источник излучает δ -импульс по времени в конусе направлений $2\pi(1-\cos\varphi_s)$, где $\varphi_s = 0,1$ мрад — полный угол расходимости источника. Эхосигнал регистрируется приемником в угловых конусах $2\pi(1-\cos\varphi_d^k)$, где φ_d^i — набор полных углов приема, $k = 1, 2, \dots$. Традиционные оптические характеристики атмосферы, как правило, задаются кусочно-постоянными функциями высоты z .

В качестве примера выбрана модель слоисто-неоднородного облака со спектром частиц, удовлетворяющим обобщенному γ -распределению (вариант C1 по Deirmendjan [8]). Облачный слой толщиной 100 м задавался на высоте 200 м. Для решения прямой задачи был выполнен предварительный расчет по формулам Ми оптических параметров выбранной модели облака, включая коэффициенты рассеяния, ослабления, обратного рассеяния, вероятности выживания кванта и индикаторы рассеяния, для длин волн оптического зондирования 1,28; 1,56; 1,61 и 2,13 мкм. Подобный набор длин волн обусловлен в первую очередь необходимостью работы лидара в генеральных окнах прозрачности атмосферы [7, 14] и информативностью принятого набора волн относительно искомых параметров облачного аэрозоля. На рис. 4 показаны гистограммы, отражающие вертикальные профили модельных значений коэффициентов обратного рассеяния слоисто-неоднородного облака для указанных длин волн.

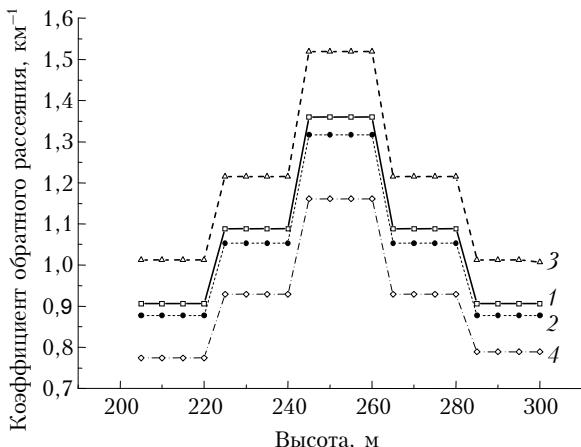


Рис. 4. Оптическая модель облака C1. Высотный профиль коэффициента обратного рассеяния на четырех длинах волн (1 – 1,28; 2 – 1,56; 3 – 1,61; 4 – 2,13 мкм)

870

Креков Г.М., Крекова М.М., Суханов А.Я.

Рассчитанные методом Монте-Карло сигналы обратного рассеяния для выбранной оптической модели численного эксперимента представлены на рис. 5.

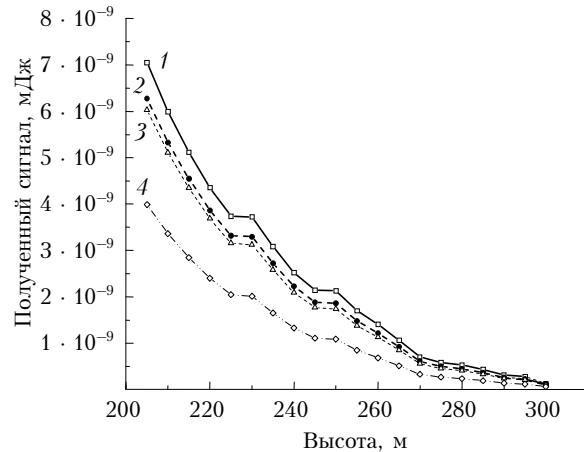


Рис. 5. Сигналы на четырех длинах волн (1 – 1,28; 2 – 1,56; 3 – 1,61; 4 – 2,13 мкм) от облака типа C1, полученные путем Монте-Карло-моделирования

Эти сигналы, включающие в себя помеху многократного рассеяния, используются далее в качестве входных параметров первого этапа решения обратной задачи, т.е. восстановления дискретных вертикальных профилей априори заданных оптических характеристик на основе изложенного ранее [7] алгоритма. Восстановленные значения коэффициентов обратного рассеяния для исходного примера приведены на рис. 6.

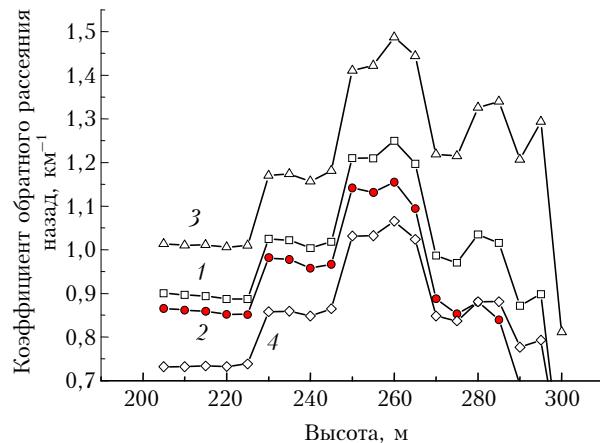


Рис. 6. Профили коэффициентов обратного рассеяния на четырех длинах волн (1 – 1,28; 2 – 1,56; 3 – 1,61; 4 – 2,13 мкм), полученные на основе итерационного алгоритма решения системы лидарных уравнений

Очевидно, что на конце трассы коэффициенты обратного рассеяния сильно искажены, что вызвано расхождением итерационного процесса из-за вклада помехи многократного рассеяния в сигнал. В начале трассы коэффициенты имеют явную корреляционную зависимость, что позволяет использовать их для восстановления функций распределения, при этом

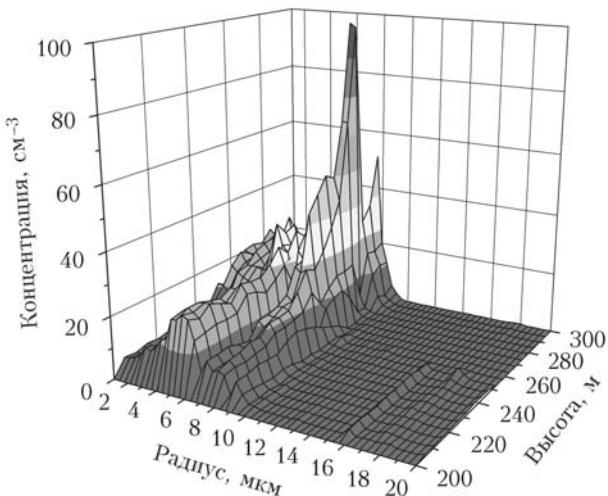


Рис. 7. Высотный профиль функции распределения счетной концентрации частиц $f(r)$ по размерам, восстановленный методом Монте-Карло

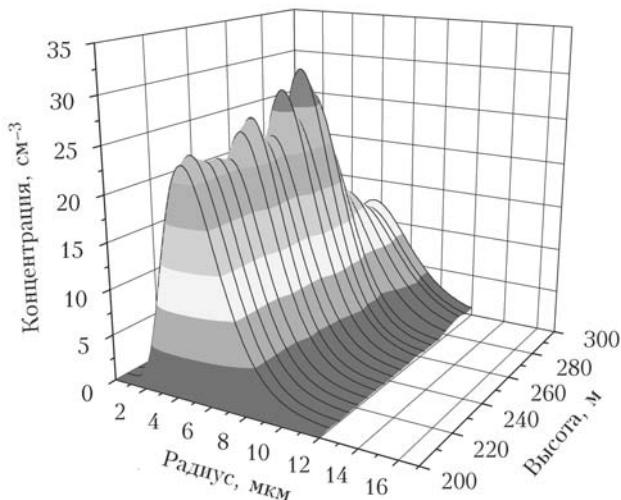


Рис. 8. Высотный профиль функции распределения счетной концентрации частиц $f(r)$ по размерам, восстановленный с помощью генетического алгоритма

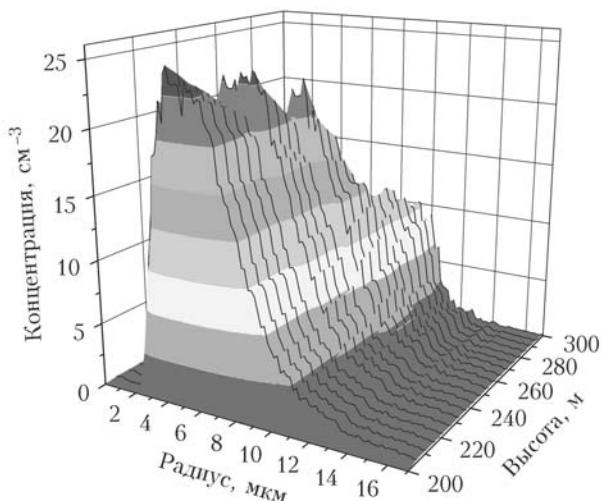


Рис. 9. Высотный профиль функции распределения счетной концентрации частиц $f(r)$ по размерам, полученный на основе метода нейронных сетей

можно утверждать, что основная ошибка восстановления будет приходиться на масштабирующий коэффициент функции распределения, по сути, на точность восстановления концентрации частиц в облаке.

На рис. 7 приведен высотный разрез функций распределения счетной концентрации облачных капель по размерам $f(r)$, восстановленных с применением обратного метода Монте-Карло. Данный метод не использует априорной информации о виде функции распределения. Следовательно, возможно получение множества решений, поскольку они априорно не ограничены каким-либо классом функций. Для того чтобы ограничить количество возможных решений, начальная выборка радиусов создается случайным образом в соответствии с некоторой плотностью вероятностей, имеющей заранее заданный модальный радиус. Результаты, полученные с помощью метода Монте-Карло, показывают, что данный метод при больших погрешностях в коэффициентах обратного рассеяния начинает давать сильное расхождение. Кроме того, в реальных экспериментах модальный радиус известен лишь приблизительно и для повышения точности метода требуется использование большего числа длин волн.

Далее для решения задачи был применен генетический алгоритм, полученные результаты восстановления функции распределения $f(r)$ представлены на рис. 8.

Данный алгоритм позволил повысить точность восстановления функции распределения. Однако следует заметить, что при сильном искажении восстановленных профилей коэффициента обратного рассеяния будет достаточно сложно выбрать надлежащий критерий прекращения итераций генетического алгоритма, поскольку получаемые решения ограничены классом гамма-функций. Также определенным недостатком генетического алгоритма является его довольно медленная сходимость, что затрудняет его использование в режиме реального времени. Тем не менее точность восстановления достаточно высока в связи с тем, что модельная функция зависимости коэффициента обратного рассеяния от длины волн ограничена некоторым классом функций.

Данный метод может успешно применяться и при обработке реальных данных, поскольку мономодальные функции распределения $f(r)$ в большинстве случаев аппроксимируются обобщенным γ -распределением. В случае сложных композитных распределений $f(r)$ необходимо привлечение большего количества длин волн зондирования. Однако, как показали численные эксперименты, даже при использовании многих длин волн в ограниченном классе функций $f(r)$ возможно получение нескольких решений задачи (15). При этом остается неясным, какое из решений соответствует действительности, часто предлагается [1, 2] получать усредненное решение или уточнить решение с помощью имеющихся априорных представлений о функции распределения.

Высотные профили функции распределения $f(r)$ для аналогичной модели эксперимента, восстановленные с помощью метода искусственных нейронных сетей, представлены на рис. 9.

Можно сказать, что метод нейронных сетей оказался несколько более чувствителен к погрешностям входных значений профилей коэффициента обратного рассеяния по сравнению с генетическим алгоритмом, что во многом вызвано переобучением НС на конкретных примерах, а также сильным искажением коэффициента обратного рассеяния. Кроме того, возможности нейронной сети ограничены областью обучающих примеров: если реальные или тестовые значения выйдут за пределы обучающей выборки, сеть может давать неадекватные решения или несоответствующие реальности, но во многом это решается путем создания наиболее полной информативной обучающей выборки. При этом НС способна решать задачу восстановления в режиме реального времени, а также автоматически решает проблему множества решений задачи (15), усредняя их. Отметим, что эта проблема также может решаться на этапе конструирования путем добавления дополнительного входа НС для ввода априорной информации (например, указание примерного значения модального радиуса или полуширины распределения).

Заключение

Выполнен краткий обзор аналитических методов решения некорректных обратных задач в приложении к проблеме многочастотного лазерного зондирования аэрозольной атмосферы. Показано, что в условиях значительных помех многократного рассеяния, имеющих место при оптическом зондировании облачного аэрозоля, предпочтительно использование более гибких, так называемых интеллектуальных алгоритмов восстановления микрофизических параметров аэрозоля. Наиболее эффективной оказывается гибридная схема, в которой процедура обучения в методе искусственных нейронных сетей оптимизируется на базе генетического поиска. Результаты замкнутого численного моделирования, приведенные на рис. 8, 9, демонстрируют весьма удовлетворительное качество воспроизведения априори заданных спектров распределения облачных капель по размерам до оптических глубин, в 1,5–2 раза превышающих известные до сих пор оценки.

Работа выполнена при финансовой поддержке РФФИ (гранты № 07-01-00509, 09-01-00698, 09-05-00738, 09-07-00477).

1. Зуев В.Е., Наац И.Э. Обратные задачи лазерного зондирования. Новосибирск: Наука, 1982. 242 с.
2. Наац И.Э. Теория многочастотного лазерного зондирования атмосферы. Новосибирск: Наука, 1980. 157 с.
3. Zuev V.E., Naats I.E. Inverse Problems of Lidar Sensing of the Atmosphere. Berlin: Springer-Verlag, 1983. 260 p.
4. Bockmann C., Mironova I., Muller D., Schneidenbach L., Nessler R. Microphysical aerosol parameters

- from multiwavelength lidar // J. Opt. Soc. Amer. 2005. V. 22. N 3. P. 518–528.
5. Матвиенко Г.Г., Веретенников В.В., Креков Г.М., Крекова М.М. Дистанционное зондирование атмосферных аэрозолей с использованием фемтосекундного лидара белого света. I. Численное моделирование // Оптика атмосф. и океана. 2003. Т. 16. № 12. С. 1107–1114.
6. Зуев В.Е., Креков Г.М., Крекова М.М., Макиенко Э.В., Наац И.Э. Теория и численный эксперимент по дистанционному зондированию облачного аэрозоля // Радиофизические исследования атмосферы. Л.: Гидрометеоиздат, 1977. С. 6–15.
7. Креков Г.М., Крекова М.М., Суханов А.Я. Оценка эффективности использования перспективных лидаров белого света для зондирования микрофизических параметров слоистой облачности: 2. Параметрическая модификация итерационного метода решения лидарного уравнения // Оптика атмосф. и океана. 2009. Т. 22. № 8. С. 795–802.
8. Deirmendjan D. Electromagnetic scattering of spherical polydispersions. N.Y.: American Elsevier Publ. Co, 1969. 166 p.
9. Веретенников В.В., Костин Б.С., Наац И.Э. К выбору числа измерений при оптическом зондировании атмосферного аэрозоля // Вопросы лазерного зондирования атмосферы. Новосибирск: Наука, 1976. С. 92–104.
10. Тихонов А.Н., Арсенин В.Я. Методы решения некорректных задач. М.: Наука, 1979. 286 с.
11. Veselovski I., Kolgotin A., Muller D., Whiteman D.N. Information content of multiwavelength lidar data with respect to microphysical particle properties derived from eigenvalue analysis // Appl. Opt. 2005. V. 44. N 25. P. 5292–5303.
12. Porsnavad P., Bockmann C., Ritter C., Rafler M. Ill-posed retrieval of aerosol coefficient profiles from Raman lidar data by regularization // Appl. Opt. 2008. V. 47. N 10. P. 1649–1661.
13. Krekov G.M., Krekova M.M., Makienko E.V., Naats I.E. Optical location of the microphysical characteristics of scattering media // Radiophys. and Quantum Electron. 1980. V. 20. N 4. P. 358–365.
14. Зуев В.Е., Креков Г.М. Оптические модели атмосферы. Л.: Гидрометеоиздат, 1986. 256 с.
15. Voutilainen A. Statistical inversion methods for the reconstruction of aerosol size distributions // Report Ser. in Aerosol Sci. 2001. N 52. 137 p.
16. Gillespie J.B., Ligon D.A., Pellegrino P.M., Fel N.N., Wood N.J. Development of a broadband lidar system for remote determination of aerosol size distributions // Measure Sci. Technol. 2002. V. 13. N 3. P. 383–390.
17. Ligon D., Chen T.W., Gillespie J.B. Determination of aerosol parameters from light-scattering data using an inverse Monte Carlo technique // Appl. Opt. 1996. V. 35. N 21. P. 4297–4304.
18. Ligon D., Gillespie J.B., Pellegrino P.M. Aerosol properties from spectral extinction and backscatter estimated by inverse Monte Carlo method // Appl. Opt. 2000. V. 39. N 24. P. 4402–4410.
19. Ramachandran G., Leith D. Extraction of aerosol-size distribution from multispectral light extinction data // Aerosol Sci. Technol. 1992. V. 17. N 4. P. 303–325.
20. Voutilainen A., Kaipio J.P. Statistical inversion of aerosol size distribution data // J. Aerosol Sci. 2000. V. 31 (Suppl.1). P. 767–768.
21. Trahan M.W., Wagner J.S., Shokair I.R., Tisone G.C., Gray P.C. The use of intelligent algorithms in multispectral UV analysis // CALIOPE Techn. Review Proc. 1998. V. 1. P. 358–375.
22. Madkour A.A., Hossain M.A., Dahal K.P., Yu H. Real-time system identification using intelligent algorithm // IEEE SMC UK_RI Confer. Proc. Londonderry. 2004. P. 236–241.
23. Krekov G.M., Sukhanov A.Ya. Application of artificial intelligence methods in remote sensing problems // XV Int. Sympos. «Atmospheric and Ocean Optics, Atmospheric physics». June 22–29, 2008. Krasnoyarsk, 2008. C. 100. CO-05.
24. Ressom H., Miller R.L., Natarajan P., Slade W.H. Computation intelligence and its application in remote sensing // Remote Sensing of Coastal Aquatic Environments / Ed. by R.L. Miller. Berlin: Springer, 2005. P. 205–227.
25. Galushkin A.I. Neural Network Theory. Berlin: Springer, 2007. 402 p.
26. Goldberg D., Sastry K. Genetic Algorithms. Berlin: Springer, 2007. 350 p.
27. Lienert B.R., Porter J.N., Sharma S.K. Repetitive genetic inversion of optical extinction data // Appl. Opt. 2001. V. 40. N 21. P. 3476–3482.
28. Lienert B.R., Porter J.N., Sharma S.K. Aerosol size distributions from genetic inversion of polar nephelometer data // J. Atmos. Sci. 2003. V. 20. N 10. P. 1403–1410.
29. Mera N.S., Elliott L., Ingham D.B. A multi-population genetic algorithm approach for solving ill-posed problems // Comput. Mechanics. 2004. V. 33. N 4. P. 254–262.
30. Креков Г.М., Крекова М.М., Лисенко А.А., Суханов А.Я. Радиационные характеристики растительного листа // Оптика атмосф. и океана. 2009. Т. 22. № 4. С. 397–410.
31. Доленко С.А., Гердова И.В., Доленко Т.А., Фадеев В.Б. Лазерная флуориметрия смесей сложных органических соединений с использованием искусственных нейронных сетей // Квант. электрон. 2001. Т. 31. № 9. С. 834–838.
32. Ye M., Wang S., Lu Y., Hu T., Zhu Z., Xu Y. Inversion of particle-size distribution from angular light-scattering data with genetic algorithms // Appl. Opt. 1999. V. 38. N 12. P. 2667–2685.
33. Суханов А.Я., Камаев М.Ю. Возможности метода нейронных сетей для восстановления профиля концентрации озона из лидарных данных // Оптика атмосф. и океана. 2003. Т. 16. № 12. С. 1115–1119.
34. Гришин А.И., Креков Г.М., Крекова М.М., Матвиенко Г.Г., Суханов А.Я., Тимофеев В.И., Фамеева Н.Л., Лисенко А.А. Исследование органического аэрозоля растительного происхождения с помощью флуоресцентного лидара // Оптика атмосф. и океана. 2007. Т. 20. № 4. С. 328–337.

G.M. Krekov, [M.M. Krekova], A.Ya. Sukhanov. Estimate of perspective white-light lidar efficiency for sensing the stratus cloud microphysical parameters: 3. Inverse problem solution.

The investigations are in progress associated with estimating the efficiency of the use of promising wide-band lidars for sensing of microphysical parameters of cloud aerosol in the near-infrared spectral region. The iteration method proposed before has been generalized for the case of the multiwave laser sensing. In the framework of a closed numerical simulation the validation has been made of a new optimization algorithm, based on the combination of the ideology of the method of artificial neuron nets with a genetic search. The reconstruction of altitude profiles of the cloud particle spectrum was made possible up to considerable optical depths under conditions of the multiple scattering noise.