

Применение нейронных сетей для определения оптических параметров сильно рассеивающих сред по профилю интенсивности рассеянного назад излучения

С.П.Котова, И.В.Майоров, А.М.Майорова

Анализируются возможности одновременного определения трех оптических параметров рассеивающих сред, а именно коэффициента рассеяния, коэффициента поглощения и параметра анизотропии рассеяния по профилю интенсивности рассеянного назад излучения с использованием метода обращения нейронной сети, а также метода гибридной нечеткой системы с последующим ее обращением. Погрешность определения коэффициента поглощения составила 20 %, а коэффициента рассеяния и параметра анизотропии рассеяния – 5 % – 10 %.

Ключевые слова: оптические параметры рассеивающих сред, профили интенсивности рассеянного назад излучения, метод Монте-Карло, нейронные сети, гибридные системы.

1. Введение

Задача определения коэффициента рассеяния μ_s , коэффициента поглощения μ_a и параметра анизотропии рассеяния (среднего косинуса угла рассеяния) g сред с сильным рассеянием актуальна в связи с тем, что именно эти параметры, наряду с показателем преломления n , позволяют полностью описать распределение интенсивности оптического (лазерного) излучения, как рассеянного, так и поглощенного средой. Интерес к этой проблеме в значительной степени связан с развитием оптики биологических сред и тканей [1–5] и широким применением низкоинтенсивного лазерного излучения в медицине как для диагностики, так и для терапии. С точки зрения медицины особый интерес представляет разработка неинвазивных (неразрушающих) методов диагностики состояния биологических систем, позволяющих определять оптические параметры *in vivo*. Такую возможность дают методы определения этих параметров по пространственным характеристикам рассеянного назад излучения.

В работах [6–8] нами был предложен, теоретически обоснован и экспериментально подтвержден метод одновременного определения трех оптических параметров, а именно коэффициента рассеяния, коэффициента поглощения и параметра анизотропии по профилю интенсивности рассеянного назад излучения. Оптические параметры определяются в реальном времени на основе сравнения экспериментальных профилей интенсивности рассеянного назад излучения с модельными профилями, полученными методом Монте-Карло в широком диапазоне оптических параметров. При построении экспериментального профиля для доставки и приема излучения использовались оптические волокна, источником излу-

чения служил He–Ne-лазер. Применение источников непрерывного излучения привлекательно тем, что диагностические устройства на их основе просты в реализации и не требуют использования быстродействующих приемников излучения и высокочастотных устройств обработки сигнала. Для определения оптических параметров по профилю интенсивности рассеянного назад излучения применялись два независимых метода: метод полного перебора и метод регуляризации (подробнее см. в [8]). В результате удалось с высокой точностью (погрешность около 10 %) определить оптические параметры сред с альбедо $\mu_s/(\mu_a + \mu_s) \leq 0.98$. Однако для сред с более высоким альбедо приемлемой точности достичь не удалось. По данным, приведенным в [1, 2], некоторые биоткани (например, кровь, матка, дерма кожи, серое и белое вещество мозга и др.) характеризуются высокими альбедо (более 0.98) на длинах волн видимого и ближнего ИК диапазонов.

В настоящей статье анализируется возможность определения оптических параметров по профилю интенсивности рассеянного назад излучения методом обращения нейронной сети, а также методом гибридной нечеткой системы с последующим ее обращением ANFIS (adaptive-network-based fuzzy inference system). При этом основной задачей было повысить точность определения оптических параметров (в частности, для альбедо, превышающих 0.98), а также выбрать наиболее подходящий математический алгоритм с точки зрения его простоты и удобства реализации. Заметим, что, хотя в настоящее время нейронные сети широко используются в оптике биологических сред, например для определения коэффициента поглощения и транспортного коэффициента рассеяния [9, 10] или характеристик (среднего радиуса, показателей преломления) одиночных частиц [11], целью нашего исследования было показать возможность применения методов обращения нейронной сети и гибридной нечеткой системы для одновременного определения всех трех оптических параметров: коэффициента рассеяния, коэффициента поглощения и параметра анизотропии рассеяния. Знание этих параметров важно с точки зрения

С.П.Котова, И.В.Майоров, А.М.Майорова. Самарский филиал Физического института им. П.Н.Лебедева РАН, Россия, 443011 Самара, Ново-Садовая ул., 221; e-mail: kotova@fian.smr.ru

Поступила в редакцию 20 июня 2006 г., после доработки – 10 октября 2006 г.

дозиметрии (когда необходима информация о распределении светового поля вблизи поверхности биологических тканей) и при использовании для диагностики медицинских приборов, в которых расстояние между подающим и приемным волокнами составляет одну-две длины свободного пробега фотонов $l_{fr} = 1/(\mu_a + \mu_s)$ [12], а также приборов с ограниченной апертурой приема излучения [8].

2. Создание модельного массива методом Монте-Карло

Как уже отмечалось, определение оптических параметров проводилось на основе сравнения экспериментального профиля интенсивности рассеянного назад излучения с модельными профилями, построенными для широкого диапазона оптических параметров. Для построения модельных профилей использовался метод Монте-Карло, основанный на численном моделировании распространения фотонов в среде. Случайное блуждание фотонов внутри образца биоткани моделируется компьютером с использованием генератора случайных чисел и прослеживается от точки влета фотона в образец до его поглощения в нем или выхода из образца через границы биоткани. При этом внутри образца фотон испытывает случайные столкновения с неоднородностями среды, на которых в зависимости от коэффициентов поглощения и рассеяния он либо поглощается, либо меняет случайным образом (в соответствии с фазовой функцией рассеяния) направление своего полета [1]. В нашем случае моделирование выполнялось для конкретной экспериментальной установки, схема которой представлена на рис.1 [6].

Рассеивающая среда с коэффициентом рассеяния μ_s , коэффициентом поглощения μ_a , параметром анизотропии (средним косинусом угла рассеяния) g и показателем преломления $n = 1.4$ была ограничена размерами кюветы ($49 \times 77 \times 26.5$ мм). Среда освещалась пучком He-Ne-лазера ГН-4П (длина волны излучения 0.63 мкм, мощность 4 мВт) через подводящее волокно с диаметром сердцевины 400 мкм и апертурным углом 35° . Профиль интенсивности рассеянного назад излучения $R(\rho)$ (где ρ – расстояние от центра подводящего волокна до центра приемного волокна) измерялся с помощью приемного волокна, закрепленного на платформе шагового двигателя. Приемное волокно имело те же параметры, что и подводящее. Четырехмерный массив $R(\rho, \mu_a, \mu_s, g)$ моделировался в широком диапазоне оптических параметров,




Рис.1. Схема экспериментальной установки:
1 – лазер; 2 – объектив; 3 – подающее волокно; 4 – приемное волокно; 5 – фотодиод; 6 – преобразователь фототока в напряжение; 7 – шаговый двигатель; 8 – вольтметр; 9 – кювета с модельной средой; 10 – компьютер.

соответствующих оптическим параметрам биотканей: $0.01 \text{ мм}^{-1} \leq \mu_a \leq 0.15 \text{ мм}^{-1}$ с шагом $\Delta\mu_a = 0.014 \text{ мм}^{-1}$; $2 \text{ мм}^{-1} \leq \mu_s \leq 20 \text{ мм}^{-1}$ с шагом $\Delta\mu_s = 1.8 \text{ мм}^{-1}$; $0.8 \leq g \leq 0.98$ с шагом $\Delta g = 0.018$; $0 \leq \rho \leq 5.6$ мм с шагом $\Delta\rho = 0.4$ мм. В качестве фазовой функции рассеяния использовалась функция Хеньи – Гринштейна

$$p(\theta) = \frac{1}{4\pi} \frac{1 - g^2}{(1 + g^2 - 2g \cos \theta)^{3/2}},$$

где θ – угол рассеяния. Для построения каждой зависимости использовалось 10^5 фотонов. Отметим, что функция $R(\rho, \mu_a, \mu_s, g)$ не имеет локальных экстремумов в рассматриваемой области значений ρ, μ_a, μ_s и g ; профили $R(\rho)$ резко спадают при малых расстояниях между волокнами (~ 1 мм), а затем зависимость от ρ имеет экспоненциальный характер.

3. Определение оптических параметров методом обращения нейронной сети

Задачу определения оптических параметров по характеристиками рассеянного (как вперед, так и назад) излучения часто называют обратной задачей [1 – 3]. При этом метод нейронных сетей является одним из универсальных методов, пригодных для решения обратных задач. Это связано с возможностью с помощью нейронной сети моделировать сложные нелинейные соотношения между входными и выходными параметрами аналогично модели «черного ящика», т. е. внутренняя структура задачи не описывается набором математических уравнений, а создается в процессе обучения. Существует большое число нейросетей, обладающих различными свойствами [13 – 15]. Мы выбрали однослойный перцептрон (рис.2) – «сеть прямого распространения». Нейроны в такой сети располагаются в нескольких слоях. Сигналы передаются только в одном направлении: от входного слоя к выходному. В рассматриваемой задаче сеть состоит из входного слоя из трех нейронов (оптические параметры μ_a, μ_s, g), скрытого слоя из 20 нейронов и выходного слоя из 15 нейронов (значения интенсивности $R(\rho)$ в 15 точках). Входной и выходной слою являются линейными, а нейроны скрытого слоя осуществляют нелинейные преобразования с помощью функции активации (гиперболический тангенс). Выбор нелинейной функции этого типа был обусловлен простотой вычислений при ее использовании.

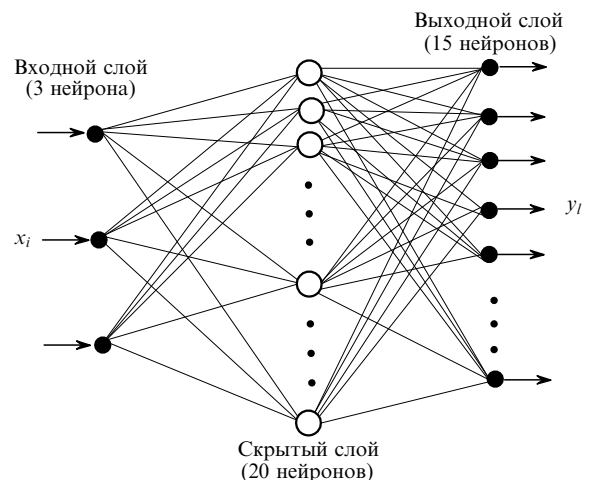


Рис.2. Схема однослойного перцептрона.

Заметим, что конфигурация сети, ее тип, число слоев и число нейронов в скрытых слоях определяются экспериментально. Чем сложнее сеть, тем большими возможностями она обладает, но при этом значительно возрастает время обучения. К тому же однослойный перцептрон применяется для решения не очень сложных задач.

Процесс обучения нейросети заключался в следующем. Пусть входной сигнал x_i – набор оптических параметров (μ_a, μ_s, g) , выходной сигнал $y_l = R(\rho_l)$ – набор значений интенсивности в 15 точках, N – число нейронов в скрытом слое, $\sigma(z) = \tanh z$ – нелинейная функция активации нейрона. Обозначим веса нейронных связей скрытого слоя w_{ij}^h (i – номер компоненты входного сигнала, j – номер нейрона в скрытом слое), веса выходных соединений – w_{jl}^{out} (j – номер нейрона, l – номер компоненты выходного сигнала, т. е. интенсивности в l -й точке). Тогда, если на вход перцептрона подан сигнал x_i , то на нейронах скрытого слоя появится «активационный» сигнал

$$z_j = \sum_{i=1}^p w_{ij}^h$$

(где $p = 3$ – число компонент входного сигнала, $j = 1, \dots, N$), который преобразуется нейроном в функцию $\sigma(z_j)$. Компонента выходного сигнала y_l формируется путем сложения вкладов всех нейронов скрытого слоя:

$$y_l = \sum_{j=1}^N w_{jl}^{\text{out}} \sigma(z_j),$$

где $l = 1, \dots, 15$.

Таким образом, на выходе получаем значения интенсивности в 15 точках. Далее находилась погрешность определения интенсивности путем сравнения с модельными данными, т. е. значениями интенсивности, полученными методом Монте-Карло. Затем с помощью обратного распространения ошибки корректировались веса нейронов выходного и скрытого слоев:

$$w_{jl}^{\text{out}} \leftarrow w_{jl}^{\text{out}} + \alpha \sigma(z_j) e_l,$$

$$w_{ij}^h \leftarrow w_{ij}^h + \alpha x_i \sigma'(z_j) \sum_l w_{jl}^{\text{out}} e_l,$$

где α – константа скорости обучения; e_l – разность между истинным и полученными l -ми компонентами выходного сигнала; $\sigma'(z)$ – производная функции активации.

Такое однократное вычисление называется «эпохой». После некоторого числа эпох (обычно 500–1000) погрешность становится приемлемой. Обычно она составляет 2.5%–10%, поскольку при меньших погрешностях существует опасность «переобучения» сети, когда сеть хорошо обучается на одном наборе данных и плохо воспроизводит другой. Заметим, что кроме среднеквадратичной погрешности после каждого цикла итераций (эпохи) программная реализация позволяла выбирать число нейронов в скрытом слое (от 20 до 30), скорость обучения, число итераций (от 100 до 1000), а также различные алгоритмы поиска минимума функции ошибок: градиентные 1-го порядка и Левенберга – Маркварда (Levenberg – Marquardt) 2-го порядка [16]. Чтобы не перевести нейроны в состояния насыщения, описываемые хвостами функции $\tanh x$, все данные были нормированы в диапазон $[-1, 1]$.

В результате обученная нейросеть «хранит» модель в числовых коэффициентах, называемых весами нейронов. Теперь, если подать входной сигнал, сеть выдает выходной, который отличается от модельного на величину, не

превышающую ошибку обучения. Кроме того, обученная сеть обладает аппроксимирующими и предсказывающими свойствами: она позволяет получать значения интенсивности для любых оптических параметров в рассматриваемом диапазоне. Таким образом, сеть строит нелинейное отображение $R(\rho, x_i)$. Отметим, что в данном случае с помощью нейросети фактически решалась задача аппроксимации многомерной нелинейной функции. На втором этапе задачи с помощью обученной нейросети определялись входные оптические параметры по известным значениям $R(\rho)$. Теперь сеть должна работать в обратном порядке: полагаем, что веса нейронов фиксированы, входным сигналом будут 15 значений интенсивности, а подгоночными параметрами – «входные» параметры, т. е. μ_a, μ_s, g . Такой способ решения называется обращением нейронной сети [17]. Можно обучать сеть сразу на решение обратной задачи, т. е. задавать $R(\rho)$, а получать μ_a, μ_s, g , но при этом результаты будут гораздо хуже. Это объясняется «плохими» свойствами обратного преобразования (поскольку это некорректно поставленная задача).

Итак, порядок расчета с использованием нейросети включал в себя следующие этапы:

1. Ввод данных, нормировка в диапазон $[-1, 1]$.
2. Выбор числа нейронов в скрытом слое (20–30).
3. Выбор скорости обучения (0.1, 0.01, 0.001).
4. Выбор числа итераций (100–1000).
5. Выбор метода обучения.

6. Получение среднеквадратичной погрешности после каждого цикла итераций (эпохи). Если погрешность полагается приемлемой, то прекращают процесс обучения, если нет – то продолжают.

7. Проверка нескольких тестовых наборов, чтобы убедиться, что сеть «не переобучена».

8. Фиксирование весов нейронов.

9. Ввод данных для решения обратной задачи (из файла или из массива Монте-Карло).

10. Обращение нейронной сети.

В табл. 1 представлены некоторые результаты наших численных экспериментов по определению оптических параметров. Обучение нейронной сети при этом проходило на всем массиве данных. Скорость обучения задавалась равной 0.001, число скрытых нейронов составило 30, число эпох – 500. Обучение сети было прекращено, когда среднеквадратичная погрешность была меньше 10% (9.3%). Оптические параметры определялись по профилю $R(\rho)$.

Анализ численных экспериментов показал, что метод обращения нейронной сети позволяет определить коэффициент рассеяния μ_s и параметр анизотропии рассеяния g с погрешностью $\sim 10\%$ даже при высоких альбедо (более 0.99), однако погрешность определения коэффициента поглощения составляет при этом 20%–60%. Такая большая погрешность связана с тем, что профили интенсивности (особенно при высоких альбедо) малочувствительны к изменению этого оптического коэффициента. Кроме того, погрешность определения параметров существенно возрастает, когда истинные значения μ_s, μ_a и g совпадают с границами диапазона оптических параметров, для которых построен модельный массив (третья строка – $\mu_s = 20 \text{ мм}^{-1}$, восьмая – $\mu_s = 2 \text{ мм}^{-1}$, $\mu_a = 0.15 \text{ мм}^{-1}$).

Нельзя не отметить, что, так же как и в методах полного перебора с усреднением и регуляризацией, точность определения оптических параметров методом обраче-

Табл.1. Точность определения оптических параметров в модельном эксперименте.

$\mu_s/(\mu_s + \mu_a)$	Истинные значения			Полученные значения			Погрешность определения параметров (%)		
	μ_s (мм ⁻¹)	μ_a (мм ⁻¹)	g	μ_s (мм ⁻¹)	μ_a (мм ⁻¹)	g	$\Delta\mu_s/\mu_s$	$\Delta\mu_a/\mu_a$	$\Delta g/g$
0.996	9.0	0.04	0.91	8.5	0.03	0.87	5.5	25	4
0.996	11	0.04	0.91	9.7	0.03	0.87	13	25	4
0.995	20.0	0.10	0.80	17.1	0.04	0.92	14.5	60	15
0.993	11.0	0.08	0.89	10.2	0.05	0.91	7	50	2
0.993	9.0	0.06	0.91	8.1	0.04	0.90	10	33	1
0.992	9.2	0.07	0.89	9.23	0.04	0.91	< 1	43	2
0.98	5.0	0.10	0.85	5.8	0.06	0.91	16	40	7
0.93	2.0	0.15	0.80	1.2	0.12	0.85	40	20	6

ния нейронной сети существенно зависит от шага задания параметров в модельной сетке. Нами был дополнительно построен модельный массив $R(\rho, \mu_a, \mu_s, g)$, для которого коэффициент рассеяния μ_s изменялся от 1.5 до 6.5 мм⁻¹ с шагом $\Delta\mu_s = 0.5$ мм⁻¹, параметр анизотропии g – от 0.7 до 0.9 с шагом $\Delta g = 0.02$, а коэффициент поглощения μ_a и координата ρ изменялись в том же диапазоне и с тем же шагом, что и для основного модельного массива. Было проведено обучение нейронной сети на данном модельном массиве. При этом скорость обучения задавалась равной 0.01, число скрытых нейронов составило 20, число эпох – 100. Обучение сети было прекращено, когда среднеквадратичная погрешность составила 5%. Затем по профилю $R(\rho)$ находились оптические параметры. Точность их определения значительно возросла. Например, для профиля с истинными значениями оптических параметров $\mu_a = 0.1$ мм⁻¹, $\mu_s = 5$ мм⁻¹ и $g = 0.85$ (седьмая строка табл.1) погрешность уменьшилась до 1% для μ_s , до 5% для μ_a и до 3% для g . Для профиля с $\mu_a = 0.15$ мм⁻¹, $\mu_s = 2$ мм⁻¹, $g = 0.8$ (восьмая строка) погрешности составили 14% для μ_a , 6% для μ_s и 12.5% для g .

Тем не менее можно считать, что метод обращения нейронной сети практически не дал увеличения точности определения оптических параметров по сравнению с методами полного перебора и регуляризации [8]. При этом к существенным недостаткам нейросетевого подхода можно отнести трудоемкость его реализации на этапе обучения: большие затраты машинного времени и памяти, значительный произвол в выборе геометрии системы (необходимость экспериментировать с разнообразными сетями и даже в одной сети с разным числом слоев и числом нейронов в них), а также возможность эффекта «переобучения» нейросети.

4. Решение обратной задачи с помощью гибридной нечеткой нейросети

В связи со значительным прогрессом в теории нечетких множеств и экспериментах по совмещению преимуществ нечеткой логики и нейросетей с середины 90-х годов получили распространение гибридные системы, в которых геометрия нейросети зависит от количества так называемых правил. Гибридные системы, а именно ANFIS [18], работают следующим образом: на вход подаются данные, внутри происходит замена их нечеткими распределениями (фузификация), строится система правил. Затем выполняется преобразование нечеткого распределения значений выходного параметра в область действительных чисел (дефузификация), после чего нейросеть «подправляет» параметры правил в процессе обу-

чения. Обученная ANFIS внешне работает точно так же, как нейросеть, однако ее внутренний механизм связан с настройкой системы нечетких правил, а не с подгонкой весов нейросети. Подчеркнем, что нечеткие множества используются внутри системы, а входные и выходные данные – это обычные величины. Для упрощения алгоритмов нечеткие множества мы моделировали гауссовыми функциями. Обычно используют широкий набор функций – от линейных до колоколообразных, но это приводит к более сложным алгоритмам обработки.

Типичное фуззи-правило имеет вид

if x_1 in A_{1k} , x_2 in A_{2k} , ..., x_n in A_{nk} ,

then $y_k = a_{k1}x_1 + \dots + a_{kn}x_n$,

где x_1, x_2, \dots, x_n – входные параметры; y_k – выходной параметр; A_{nk} – нечеткие множества; a_{kn} – коэффициенты модели Такаги–Сугено [19]; k – номер правила. Процедура дефузификации осуществляется с помощью одно-временного учета действия всех правил:

$$y(x_i) = \sum_k \gamma_k(x_i) \sum_i a_{ki}x_i,$$

где $\gamma_k(x_i)$ – так называемая степень активации k -го правила; K – число правил; M – число компонентов входного сигнала.

На практике в ANFIS рассматривают обычно модель Такаги–Сугено [19]. Описываемая модель – это модель MISO (multiple inputs – single output). Нам же требуется модель MIMO (multiple inputs (три оптических параметра) – multiple outputs (значения интенсивности в 15 точках)). Модель MIMO может быть получена из нескольких независимых моделей MISO. Входным сигналом для каждой модели MISO являются три оптических параметра, а выходным – интенсивность в одной точке. После обучения 15 MISO-моделей для решения обратной задачи использовался метод обращения нейронной сети, рассмотренный ранее.

Перечислим последовательно все шаги, используемые в ANFIS-системе при решении обратной задачи:

1. Ввод массива, его нормировка в диапазон $[-1, 1]$ и прореживание до $\sim 1/15$ всего объема.
2. Выбор числа фуззи-правил (3, 5, 7, ...).
3. Выбор числа итераций (100 – 500) и скорости обучения (0.1 – 0.01).
4. Контроль среднеквадратичной погрешности ($\sim 5\%$).
5. Ввод данных для решения обратной задачи (из массива Монте-Карло задается входной сигнал (интенсивности)).

6. Решение обратной задачи путем обращения сети.

Укажем только, что из-за большого количества данных в массиве $R(\rho, \mu_a, \mu_s, g)$ ($15 \times 10 \times 10 \times 10$), полученном при моделировании методом Монте-Карло, у нас не было возможности обучать ANFIS на всех данных или на произвольной их части, как это обычно делается. В отличие от нейросети, в которой мы использовали последовательное задание каждой пары (x_i, y_i) , где x_i – входной сигнал, y_i – выходной сигнал, и подгоняли веса нейронов на каждом шаге, в ANFIS использовали так называемую пакетную коррекцию, т. е. большой набор пар (x_i, y_i) . Пакетная коррекция менее чувствительна к локальным минимумам функции ошибок и приводит к лучшим результатам, однако требует значительно больших ресурсов памяти для хранения матриц. Из-за более жестких требований к вычислительным ресурсам пришлось ограничиться алгоритмами оптимизации 1-го порядка (градиентным методом), тогда как в предыдущей задаче можно было экспериментировать и с алгоритмами Левенберга – Маркварда.

Что касается массива данных, то, учитывая ограничения ресурсов памяти и обеспечивая приемлемое время обучения (не более 1 ч на компьютере Pentium IV (1600 МГц, 512 Мб)), из этого массива выбирались все элементы по ρ (15) и по четыре элемента для μ_a, μ_s, g (вместо 10). Этот редуцированный массив примерно в 15 раз меньше всего модельного массива.

В результате численных экспериментов оказалось, что с помощью гибридной нейронной фuzzi-системы обратная задача решается с несколько большей точностью, чем с помощью однослойного перцептрона. Получены следующие результаты: μ_a определяется с погрешностью 15%–20%, μ_s и g – с погрешностью менее 10%. Отметим, что часто встречаются случаи неоднозначного определения μ_a и μ_s (т. е. задаваемые профили $R(\rho)$ хорошо совпадают, а истинные и полученные значения μ_s и μ_a различаются). Это объясняется некорректностью обратной задачи, а также использованием малого количества (менее 10%) исходных данных для численного эксперимента.

5. Заключение

Таким образом, задача одновременного определения трех оптических параметров сильно рассеивающих сред по профилю интенсивности рассеянного назад излучения решалась нами с использованием четырех математических алгоритмов: методом полного перебора с усреднением, методом регуляризации [6–8], а также методами обращения нейронной сети (однослойного перцептрона) и гибридной нечеткой нейросистемы Такаги – Сугено с последующим ее обращением, рассмотренными в настоящей статье. Обучение нейросетей проходило на модельном массиве данных $R(\rho, \mu_a, \mu_s, g)$, полученном методом Монте-Карло в широком диапазоне оптических пара-

метров. Особенностью нейросистем и нечетких нейросистем является то, что процесс обучения требует значительных ресурсов памяти и процессора, а получение результатов с помощью обученной системы происходит быстро и не требует больших вычислительных ресурсов. Погрешность определения коэффициента поглощения составила 20%, коэффициента рассеяния и параметра анизотропии рассеяния – 5%–10% (в том числе и для сред с высоким альбедо (более 0.98)). Сравнительно большая погрешность определения коэффициента поглощения связана, в первую очередь, с тем, что профили интенсивности рассеянного света (особенно при высоких альбедо) малочувствительны к изменению этого параметра.

Сравнительный анализ алгоритмов показал, что расчет методом обращения нейросети дает практически ту же точность, что и расчет методом полного перебора с усреднением, однако является очень трудоемким. Методы регуляризации и нечеткой нейросистемы схожи по результатам. Привлекательной в использовании нейросетей для задач определения оптических параметров является возможность их обучения на массиве экспериментальных данных без использования модельного массива Монте-Карло. Отметим, что метод нечеткой логики очень перспективен, обладает большой общностью и поэтому может быть применен для решения аналогичных задач.

1. Тучин В.В. *Лазеры и волоконная оптика в биомедицинских исследованиях* (Саратов: Изд-во Саратовского гос. ун-та, 1998).
2. Tuchin V. *Tissue Optics* (Bellingham: SPIE Press, 2000).
3. Wilson B., Jacques S. *IEEE J. Quantum Electron.*, **26**, 2186 (1990).
4. Gosh N., Mohanty S., Majumder S., Gupta P. *Appl. Opt.*, **40**, 176 (2001).
5. Mourant J., Fuselier T., Boyer J., et al. *Appl. Opt.*, **36**, 949 (1997).
6. Котова С.П., Майорова А.М., Якуткин В.В. *Оптика и спектроскопия*, **95** (3), 452 (2003).
7. Майорова А.М., Котова С.П., Якуткин В.В. *Препринт ФИАН № 35* (М., 2002).
8. Mayorova A.M., Kotova S.P., Rakhmatulin M.A., Jakutkin V.V. *J. Russian Laser Research*, **24** (1), 1 (2003).
9. Farrell T., Wilson B., Patterson M. *Phys. Med. Biol.*, **37** (12), 2281 (1992).
10. Kienle A., Ligte L., Patterson M., et al. *Appl. Opt.*, **35**, 2304 (1996).
11. Бердник В.В., Мухамедьяров Р.Д., Лойко В.А. *Оптика и спектроскопия*, **96** (2), 323 (2004).
12. Bevilacqua F., Piguat D., et al. *Appl. Opt.*, **38**, 4939 (1999).
13. Braspenning P.J., Thuijsman F., Weijters A.J. *Artificial Neural Networks* (Berlin: Springer-Verlag, 1995).
14. Bishop C.M. *Neural Networks for Pattern Recognition* (Oxford University Press, 1995).
15. Горбань А.Н., Россиев Д.А. *Нейронные сети для персональных компьютеров* (Новосибирск: Наука, 1999).
16. Hagan M.T., Menhaj M. *IEEE Trans. Neural Networks*, **5** (6), 989 (1994).
17. Jensen C.A., Reed R.D., et al. *Proc. IEEE*, **87** (9), 1536 (1999).
18. Jang J.-S.R. *IEEE Trans. Systems, Man, and Cybernetics*, **23** (3), 665 (1993).
19. Takagi T., Sugeno M. *IEEE Trans. Systems, Man, and Cybernetics*, **15** (1), 116 (1985).