

НЕЙРОСЕТЕВОЕ И АЛГЕБРАИЧЕСКОЕ МОДЕЛИРОВАНИЕ ПАРАЛЛЕЛЬНОГО 2D ПРОЕЦИРОВАНИЯ В ВОЛОКОННО-ОПТИЧЕСКОЙ ТОМОГРАФИИ ПРИ ОГРАНИЧЕННОМ ЧИСЛЕ НАПРАВЛЕНИЙ СКАНИРОВАНИЯ

Юрий Николаевич Кульчин¹ (директор ИАПУ ДВО РАН, director@iacp.dvo.ru),
Елена Владимировна Закасовская² (доцент ИФИТ ДВГУ, zakasovskaya@inbox.ru)

¹Институт автоматизации и процессов управления ДВО РАН,
²Дальневосточный государственный университет

Аннотация

В работе рассмотрена задача восстановления функций распределения физических полей с использованием распределенных волоконно-оптических измерительных систем [1] для случаев неполных схем укладки измерительных линий. Представлен подход, позволяющий использовать нейронные сети радиально-базисного типа [2] для предобработки проекционных данных с целью дальнейшего применения к ним методов аппроксимации для нерегулярных схем укладки измерительных линий более простого вида.

Ключевые слова: распределенные волоконно-оптические измерительные системы, схемы укладки измерительных линий, параллельно-лучевая томография, нейронные RBF-сети.

Введение

Для исследования, контроля и восстановления параметров физических полей (ФП), распределенных на протяженных поверхностях, все большее применение получают распределенные волоконно-оптические измерительные сети (ВОИС). Такие сети представляют собой набор волоконно-оптических измерительных линий, уложенных в соответствии с определенной схемой на исследуемой поверхности. Задача восстановления параметров распределенных физических полей по характеристикам оптического излучения, проходящего по ВОИС, является томографической [3]. При решении томографической задачи одним из определяющих факторов является выбор схемы укладки измерительных линий.

Ранее для восстановления функций распределения ФП с помощью ВОИС измерительные линии (ИЛ) укладывались по четырем направлениям – горизонтальному, вертикальному и двум диагональным (рис. 1а).

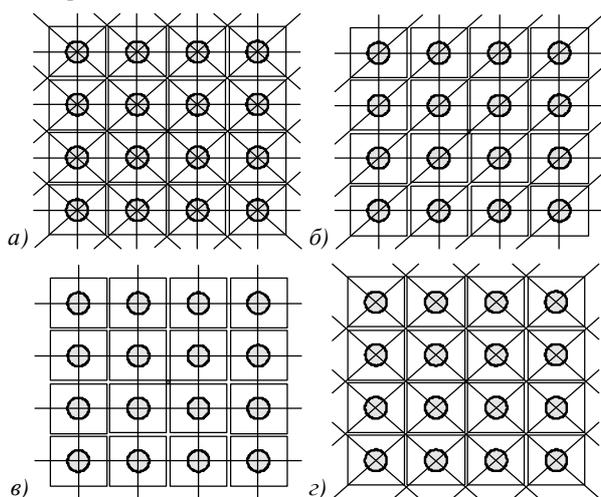


Рис. 1. Параллельные схемы укладки измерительных линий в ВОИС

Однако применение подобной схемы укладки линий при практическом изготовлении ВОИС

большой размерности приводит к усложнению конструкции и методов обработки всей информационно-измерительной системы. Поэтому весьма актуальной является задача разработки эффективных конструкций ВОИС, позволяющих уменьшить число используемых ИЛ.

Целью настоящей работы является исследование конструкции распределенной ВОИС повышенной размерности, имеющей схему укладки ИЛ в трех направлениях (рис. 1б).

Задачу восстановления функций физических полей с использованием ВОИС можно разбить на несколько этапов: дискретизацию, получение и обработку проекционных данных, обратное проецирование (рис. 2).

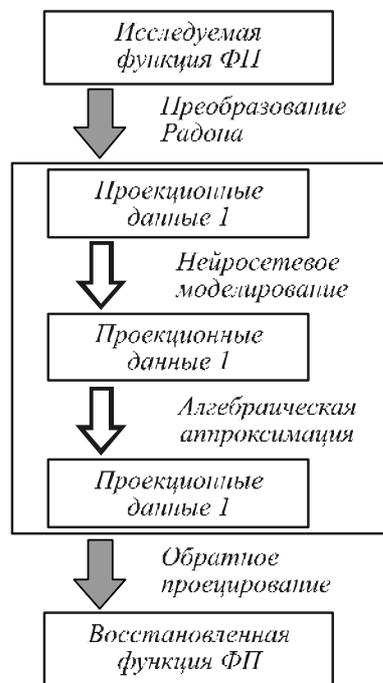


Рис. 2. Схема восстановления функции ФП

Основное внимание в этой работе уделено процессу обработки проекционных данных, который,

в свою очередь, заключается в последовательном выполнении двух процессов:

1. нейросетевой предобработки с помощью нейронной сети радиально-базисного типа,
2. аппроксимации на множестве дискретизации специального вида, а именно: на объединении двух классов смежности.

1. Основные определения и обозначения

Пусть через Z, R, C обозначены множества целых, вещественных и комплексных чисел соответственно. Далее будем предполагать, что $f \in C_0^\infty(R^2)$, то есть функция f бесконечно дифференцируема и имеет компактный носитель, $L^2(R^2)$ – пространство функций, интегрируемых с квадратом над $R^2, S(R^2)$ – пространство Шварца быстро убывающих функций.

Пусть $f(x_1, x_2)$ – функция двух переменных, описывающая исследуемый объект.

Двумерное (2D) преобразование Радона отображает функцию f во множество ее линейных интегралов.

Пусть индекс i определяет направление сканирования φ_i , индекс j определяет отсчет s_{ij} в выбранном i – м направлении. В этом случае паре индексов (i, j) соответствует прямая линия L_{ij} , вдоль которой сканируется область. Тогда значение проекции вдоль прямой L_{ij} можно записать как

$$g_{ij} = \mathfrak{R}_{ij} f = \int_{L_{ij}} f(x_1, x_2) dl, \tag{1}$$

где \mathfrak{R} – преобразование Радона функции f , а dl – приращение вдоль прямой L_{ij} .

Пары чисел (φ_i, s_{ij}) , определяющие параллельную схему сканирования на плоскости, могут быть рассмотрены как элементы группы $G = \mathbb{T} \times R$, где интервал $\mathbb{T} = [0, 2\pi)$ – циклическая группа относительно сложения по модулю 2π , а R – аддитивная группа поля вещественных чисел [4].

2. Дискретная модель задачи восстановления функции распределения ФП

ВОИС могут быть использованы для исследования различных свойств объектов окружающего пространства. Этой цели в наибольшей степени удовлетворяют сети матричного типа. Каждая ячейка матрицы представляет собой датчик (силы, деформации, момента) и дает конкретную информацию, а все ячейки вместе позволяют сформировать целостное представление о свойствах исследуемого объекта (рис. 1).

Разобьем исследуемую область $S \subset R^2$ на малые элементарные ячейки (элементы изображения) так, чтобы $S = \bigcup_{k=1}^N S_k$.

Считаем функцию f постоянной в каждой ячейке S_k и равной f_k . Для любого $k(1 \leq k \leq N)$ сформируем набор функций вида $e_k(x) = \begin{cases} 1, & x \in S_k \\ 0, & x \notin S_k \end{cases}$.

Тогда функцию f можно представить в виде

$$f(x) = \sum_{k=1}^N f_k e_k(x).$$

Величина $a_{ij}^k = \mathfrak{R}_{ij}(e_k(x)) = \int_{L_{ij}} e_k(x) dl$ геомет-

рически представляет собой длину пересечения измерительной линии L_{ij} с k -м элементом изображения S_k . Пусть p – число направлений сканирования, M – общее число измерительных линий и $g_{i1}, g_{i2}, \dots, g_{i\gamma(i)}$ значения всех $\gamma(i)$ проекций для i – го направления сканирования. В этом случае очевидно, что $M = \sum_{i=1}^p \gamma(i)$.

Интегральные уравнения (1) преобразуются в систему M линейных уравнений $\sum_{j=1}^N a_{ij}^k f_k = g_{ij}$ с N неизвестными f_1, \dots, f_N , которая в матричной форме имеет вид:

$$AF = G, \tag{2}$$

где $A = (a_{ij}^k)_{1 \leq i \leq M, 1 \leq j \leq N}$ – матрица размера $M \times N$,

$F = (f_1, \dots, f_N)^T$ – столбец неизвестных высоты N ,

$G = (g_{11}, g_{12}, \dots, g_{1\gamma(1)}; \dots; g_{i1}, g_{i2}, \dots, g_{i\gamma(i)}; \dots; g_{p1}, g_{p2}, \dots, g_{p\gamma(p)})^T$ –

столбец проекционных данных высоты M .

3. Алгебраическая аппроксимация функции проекции

Спецификой задач волоконно-оптической томографии является наличие ультрамалоракурсной схемы сбора данных. Как правило, в таких ВОИС число измерительных линий меньше числа элементов контролируемых областей. Имеет место недоопределенность системы линейных алгебраических уравнений (2). Таким образом, возникает проблема решения некорректной задачи [3], связанной с поиском решения по интегральным данным, получаемым по ВОИЛ, уложенным определенным образом на сканируемом поле. На практике часто встречаются схемы укладки измерительных линий, которым, с алгебраической точки зрения, не соответствуют решетки. К ним неприменимы обычные условия корректности. Примерами таких схем являются схемы, представленные на рис. 1а, б.

Рассмотрим, например, схему укладки измерительных линий в четырех направлениях, при которой имеет место равномерное распределение углов $k \frac{\pi}{p}, k = 0, \dots, p-1$ (рис. 1а). Особенностью этой

укладки является неравномерность отсчетов вдоль прямых: в вертикальном и горизонтальном направлениях шаг сканирования – h_1 , а в диагональных направлениях другой – $h_2 = \sqrt{2}/2 h_1$.

Эту схему можно рассматривать как объединение двух стандартных подсхем с двумя направлениями сканирования (рис. 1а, з), т.е. $\Delta\phi = \pi/2$. При этом в плоскости $O\phi z$ каждой из подсхем соответствует своё множество дискретизации. Первой соответствует множество дискретизации M_1 , а второй – M_2 . С алгебраической точки зрения, эти множества дискретизации имеют различные структуры. Так, множество M_1 является решеткой, $M_1 = \mathbb{H}_1$, где \mathbb{H}_1 – подгруппа, порожденная над Z^2 матрицей $\mathbb{W}_1 = \begin{pmatrix} \pi/2 & 0 \\ 0 & h_1 \end{pmatrix}$, т.е.

$\mathbb{H}_1 = \mathbb{W}_1 Z^2$. Множество M_2 решеткой не является, но его можно представить как смежный класс дискретной группы \mathbb{G} по подгруппе

$$\mathbb{H}_2 = \mathbb{W}_2 Z^2, \mathbb{W}_2 = \begin{pmatrix} \pi/2 & 0 \\ 0 & h_2 \end{pmatrix}.$$

Таким образом, множество вида

$$M = M_1 \cup M_2 = \mathbb{H}_1 \cup \left\{ \mathbb{H}_2 + \begin{pmatrix} \pi/4 \\ 0 \end{pmatrix} \right\} \quad (3)$$

представляет собой множество дискретизации для всей исследуемой схемы сканирования (рис. 1а) в четырех направлениях.

Очевидно, что множество дискретизации M не удовлетворяет обычным условиям дискретизации, поэтому невозможно непосредственно использовать стандартные алгоритмы без опасности получить серьезные артефакты.

Если R_1 и R_2 – фундаментальные области решеток \mathbb{H}_1^\perp и \mathbb{H}_2^\perp соответственно, то имеет место очевидное включение $R_1 \subset R_2$.

Это говорит о том, что решетка \mathbb{H}_2 является более плотной и множество дискретизации M_2 целесообразно взять в качестве основного для восстановления функции проекции по формуле

$$g(z) = S_{\mathbb{H}_2+x_2} g(z) + \left(1 - e^{2\pi i(z-x_2, v)}\right) C_1 \times \sum_{y \in \mathbb{H}_1} \frac{g(y) - S_{\mathbb{H}_2+x_2} g(y)}{1 - e^{2\pi i(y-x_2, v)}} \tilde{\chi}_{R_1}(z-y) \quad (4)$$

для любого $z \in \mathbb{G}$ и $C_i = (2\pi)^{-1} |\mathbb{W}_i|$, $i=1,2$.

В формуле (4) $\tilde{\chi}_{R_i}$ – обратное преобразование Фурье характеристической функции χ_{R_i} фундаментальной области R_i ([5-7]).

Первое слагаемое в (4) представляет собой аппроксимацию на множестве M_2 и вычисляется по формуле

$$S_{\mathbb{H}_2+x_2} g(z) = C_2 \sum_{y \in \mathbb{H}_2} g(x_2+y) \tilde{\chi}_{R_2}(z-x_2-y).$$

В случае трех направлений (рис. 1з) в разных направлениях – разные отсчеты, неравномерное распределение углов и эту схему нельзя представить в

виде объединения двух однотипных двумерных решеток (3) и затем применить формулу (4).

Для того, чтобы это стало возможным, не хватает значений четвертого направления сканирования и их предполагается получить, применив RBFNN.

На рис. 2 представлена схема восстановления функций физических полей с помощью распределенной ВОИС. В соответствии с этой схемой неполные проекционные данные 1 преобразуются нейросетевым методом в более полный набор проекционных данных 2.

4. Использование нейронных сетей RBFNN

Ранее в работе [8] авторами была исследована возможность применения RBFNN для схемы укладки в трех направлениях (рис. 1б).

Формируемый сетью информационный массив, представленный вектором G , являлся набором томографических данных, по которым нейронная сеть должна реконструировать вектор F . Таким образом, нейросеть должна выполнить преобразование вида $F = \tilde{A}(G)$, предварительно пройдя обучение на множестве обучающих пар $\{(G, F)\}$.

Для создания обучающей страницы использовался способ выбора обучающих пар «с подкреплением», при котором рассматривались пары вида (G_i, F_i) , где $AF_i = G_i$.

При создании обучающих пар RBFNN в [8] использовались функции гауссовского типа $Z(x, y) = e^{-a_i((x-c_i)^2 + (y-b_i)^2)}$, причем параметры b_i, c_i , являющиеся центрами данных RBFNN, подбирались как узлы решетки соответствующей схемы сканирования.

Были использованы эталонные распределения: одиночные Гауссианы и пары Гауссиан.

Для поля 5×5 была составлена обучающая страница, состоящая из 3325 обучающих пар, на которой была обучена сеть RBFNN. Экспериментально было показано, что построенная сеть позволяет осуществлять восстановление функций пространственного распределения исследуемой физической величины с погрешностью в отдельной точке не более 2%, обладает хорошими прогнозирующими возможностями. Однако было отмечено, что при этом способе восстановления в задачах с применением ВОИС повышенных размерностей возникают серьезные трудности при обучении сети ввиду слишком большого объема обучающих страниц. Поэтому возникла необходимость поиска оптимальных путей при применении нейронных сетей.

5. Использование нейронных сетей RBFNN для предобработки проекционных данных

Опишем теперь более подробно нейросетевой метод предобработки проекционных данных. Обозначим через \mathfrak{X}_i набор томографических данных по i -му направлению сканирования:

$$\mathfrak{R}_i = (g_{i1}, g_{i2}, \dots, g_{i\gamma(i)})^T, 1 \leq i \leq p.$$

Предположим, что практически возможно получить значения данных только для $p-1$ направления сканирования $\mathfrak{R}_1, \mathfrak{R}_2, \dots, \mathfrak{R}_{p-1}$, а для корректного восстановления функции $f(x_1, x_2)$ классическими или специальными методами (например, ART, FBP [9], UQC 1 или UQC 2 [6, 7]) необходимо иметь значения проекционных данных в p направлениях $\mathfrak{R}_1, \mathfrak{R}_2, \dots, \mathfrak{R}_{p-1}, \mathfrak{R}_p$.

Следовательно, в первую очередь, необходимо получить значения проекционных данных с недостающего p -го направления сканирования.

Для решения этой задачи предлагается использовать нейронную сеть радиально-базисного типа, которая должна выполнить преобразование вида

$$\mathfrak{R}_1, \mathfrak{R}_2, \dots, \mathfrak{R}_{p-1} \rightarrow \mathfrak{R}_p.$$

Выбор эталонных функций должен находиться в зависимости от ширины спектра b исследуемой функции $f(x, y)$. Функции гауссовского типа

$$Z(x, y) = e^{-a_i((x-g_i)^2 + (y-b_i)^2)} \tag{5}$$

могут быть использованы в качестве таковых, так как они принимают ненулевые значения только в зоне вокруг определённого центра.

Для проведения анализа нейросетевого метода решения задачи с помощью RBFNN в этой работе была рассмотрена томографическая задача восстановления информации с информационно-измерительного поля размерности 10×10 и выше. Предполагалось, что эталонное воздействие на поле имеет вид гладкой функции с ограниченной эффективной шириной спектра b , равной условной спектральной единице π . Можно также считать, что все значения функции неотрицательны и нормированы на единицу.

В данной работе использованы те же три типа эталонных распределений физической величины, что и в [8]. Первый и второй типы относятся к регулярному способу, а третий – к случайному. Опишем их подробнее.

Тун I. Эталонные распределения поля в этом случае представляют собой одиночные Гауссианы вида (5), центры которых расположены в узлах измерительной сети.

Параметр a_i отвечает за ширину носителя функции $Z(x, y)$. Если исследуемая функция f имеет ширину спектра $b = \pi$, то по теореме Найквиста правильное восстановление функции возможно, если шаг сканирования $h \leq 1$. Тогда ширина носителя функции $Z(x, y)$ должна быть порядка $2h$. Следовательно, и ширина носителя функции должна быть того же порядка. Было установлено, что оптимальными для обучения являются параметры a_i , принимающие значения $0 < a_i \leq 5$.

Для обучения рассматривались одиночные Гауссианы:

- а) Узкие одиночные Гауссианы $a_i = 1, 2, \dots, 5$.
- б) Широкие одиночные Гауссианы $a_i = 0, 1; 0, 2; \dots; 0, 9$.

Тун II. Аналитически эти функции могут быть представлены в виде

$$Z(x, y) = e^{-a_1((x-c_1)^2 + (y-b_1)^2)} + e^{-a_2((x-c_2)^2 + (y-b_2)^2)} \tag{6}$$

при условии, что носители находятся на расстоянии не менее $2\pi/b$, т.е.

$$\sqrt{(b_1 - b_2)^2 + (c_1 - c_2)^2} - \frac{1}{2\sqrt{2a_1}} - \frac{1}{2\sqrt{2a_2}} \geq 2 \frac{\pi}{b}.$$

Это пары Гауссиан с непересекающимися носителями.

Тун III. Эталонные распределения этого типа были получены с помощью процесса рандомизации с нормированием. Каждому целочисленному случайному набору $a_1, a_2, b_1, c_1, b_2, c_2 = \overline{1, N}$ ставилась в соответствие функция вида (6). Каждый вектор перед включением в обучающую страницу был нормирован.

6. Создание обучающей страницы

Качество обучения RBFNN зависит от правильного подбора обучающих пар, которые составляют обучающую страницу.

Для каждой эталонной функции $Z(x, y)$ находим проекции по всем p направлениям сканирования и строим вектор-столбец

$$G = (g_{11}, g_{12}, \dots, g_{1\gamma(1)}; \dots; g_{i1}, g_{i2}, \dots, g_{i\gamma(i)}; \dots; g_{p,1}, g_{p,2}, \dots, g_{p,\gamma(p)})^T = (\mathfrak{R}_1 \dots \mathfrak{R}_i \dots \mathfrak{R}_p)^T.$$

Повторяем эту процедуру для всех эталонных функций.

Пусть M – количество функций в обучающей странице, а Q – матрица, состоящая из столбцов проекционных данных для всех M функций обучающей страницы:

$$Q = \left(\begin{array}{cccc} \mathfrak{R}_1^{(1)} & \mathfrak{R}_1^{(2)} & \dots & \mathfrak{R}_1^{(M)} \\ \dots & \dots & \dots & \dots \\ \mathfrak{R}_i^{(1)} & \mathfrak{R}_i^{(2)} & \dots & \mathfrak{R}_i^{(M)} \\ \dots & \dots & \dots & \dots \\ \mathfrak{R}_{p-1}^{(1)} & \mathfrak{R}_{p-1}^{(2)} & \dots & \mathfrak{R}_{p-1}^{(M)} \\ \mathfrak{R}_p^{(1)} & \mathfrak{R}_p^{(2)} & \dots & \mathfrak{R}_p^{(M)} \end{array} \right) \left. \vphantom{\begin{array}{c} \mathfrak{R}_1^{(1)} \\ \dots \\ \mathfrak{R}_i^{(1)} \\ \dots \\ \mathfrak{R}_{p-1}^{(1)} \\ \mathfrak{R}_p^{(1)} \end{array}} \right\} Q_1.$$

Матрицу, состоящую из первых $\gamma(1) + \dots + \gamma(p-1)$ строк матрицы Q , обозначим через Q_1 , а из последних $\gamma(p)$ – через Q_2 .

Таким образом, созданы два массива для обучения нейронной сети: Q_1 – массив входных данных из M

векторов длины $\gamma(1)+\dots+\gamma(p-1)$, а Q_2 – массив соответствующих выходов из M векторов длины $\gamma(p)$.

7. Восстановление функции проекции на объединении двух множеств дискретизации

После того, как проекционные данные были обработаны с помощью нейросетевых методов, они приобрели корректный вид для применения к ним алгебраических методов, кратко изложенных в п. 2.

Далее восстановим функцию проекций $g = \mathfrak{R} f$ алгебраическим методом, подробно изложенным авторами в работах [6, 7], основанным на применении формулы (4).

Алгоритм:

1. Создание массивов проекционных данных.
2. Создание массива измерительных данных по наиболее плотному множеству дискретизации. Массив формируется из проекционных данных по наиболее плотному множеству дискретизации $M_2 = \mathbb{H}_2 + x_2$.
3. Аппроксимация и коррекция проекционных данных по менее плотному множеству дискретизации M_1 .
4. Комбинация измерительных и проекционных данных.
Следующие два шага при необходимости можно применить с целью дальнейшего увеличения числа проекционных данных.
5. Создание массива дополнительных данных, используя сдвиги данных из п. 2 и п. 3 на половинные углы.
6. Комбинация данных из п. 4 и п. 5.

Далее выполняется стандартная процедура обратного проецирования в соответствии со схемой, представленной на рис. 2.

8. Численное моделирование

Для проведения анализа нейросетевого метода решения задачи с помощью радиально-базисной нейронной сети было рассмотрено информационно-измерительное поле 10×10 ($n=10$).

Эталонные распределения (п. 3.3) для поля 10×10 имеют следующий вид:

- 1) узкие и широкие одиночные Гауссианы представлены в 500 и 900 вариантах соответственно;
- 2) пары Гауссиан с непересекающимися носителями были найдены в среде Matlab в количестве 2688 функций ($a_i = 3, 5; b_i, c_i = \overline{2,9}$);
- 3) эталонные распределения, полученные рандомизацией с нормированием, выбирались в количестве L функций по случайному набору параметров $a_1, a_2 = \overline{1,5}, b_1, c_1, b_2, c_2 = \overline{1,10}$.

По этим наборам эталонных распределений составлялись матрицы проекционных данных, из которых далее формировались вход и выход нейронной сети. Сеть обучали несколько раз для различных значений рандомизированных распределений $L: 0 \leq L \leq 1100$.

На рис. 3 представлены зависимости нормированной среднеквадратичной ошибки (mse) от L для восстановления недостающей четвертой проекции для четырех типов распределений, не принадлежащих обучающей странице.

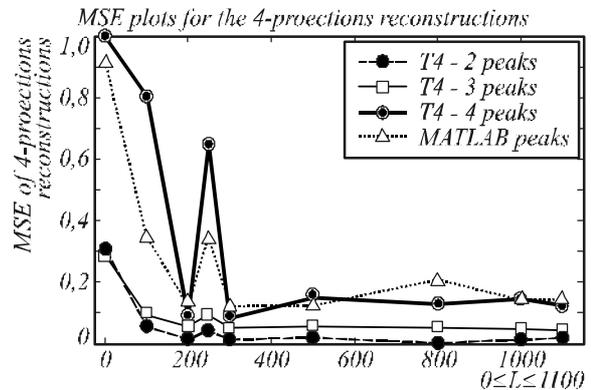


Рис.3. Зависимости нормированных среднеквадратичных ошибок для восстановления функций проекций от числа рандомизированных функций в обучающих страницах

На рис. 4 изображены зависимости mse восстановления функции распределения физического поля от объема обучающей страницы. Пунктирная и сплошная тонкая линии соответствуют функциям из обучающей страницы, а остальные – двойным, тройным и четверным комбинациям Гауссиан.

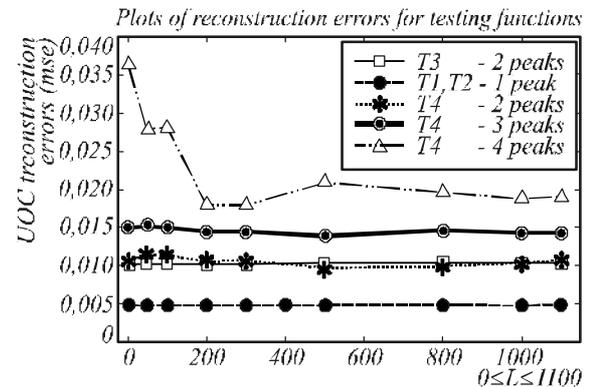


Рис.4. Зависимости нормированных среднеквадратичных ошибок для восстановления функции распределения физического поля от объема обучающих страниц

На основании проведенных численных экспериментов был сделан вывод о том, что оптимальным является параметр $L = 500$.

На рис. 5 для $L = 500$ изображен контур проекционных данных, использованных для обучения.

Для сети, обученной на 4588 обучающих парах, величина mse по обучающей странице не превысила величины $6,7 \times 10^{-16}$.

На рис. 6 приводится исследование для эталонной функции вида: $Z(x, y) = e^{-0.1((x-4)^2 + (y-6)^2)}$.

Как следствие, мала и ошибка восстановления исследуемой функции $Z(x, y) = e^{-0.1((x-4)^2 + (y-6)^2)}$.

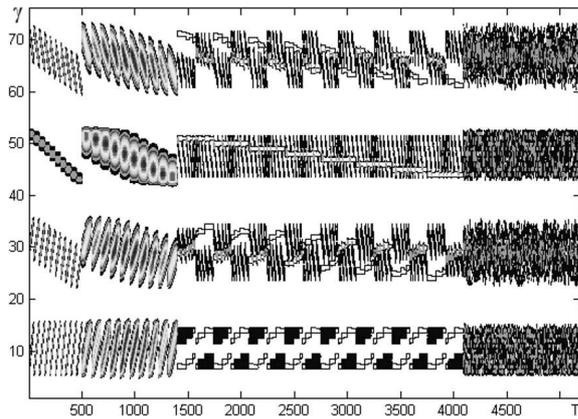


Рис.5. Контур множества проекционных данных для создания обучающей страницы

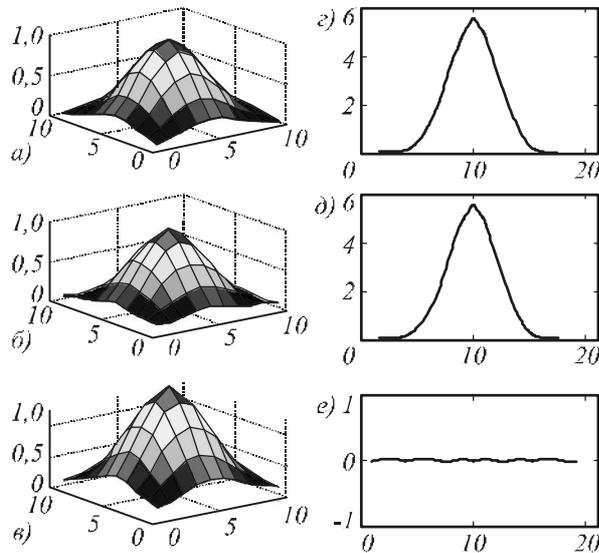


Рис. 6. Эталон (а), восстановление с помощью классического метода фильтрации обратных проекций (FBP) (б), оригинал проекции № 4 (под углом 135°) (з), восстановление проекции № 4 с помощью нейронной RBFNN (д), ошибка (mse) восстановления функции проекции четвертого направления (е)

Проекционные данные этой функции используются при создании обучающей страницы.

Для функции в левом столбце рис. 6 приведены результаты восстановления с помощью последовательно применения нейросетевого и алгебраического методов с последующим обратным проецированием.

В правом столбце на рис. 6 представлены результаты нейросетевой предобработки функции проекции: показаны результаты восстановления значений с недостающего направления сканирования.

При RBF-восстановлении 4-го направления сканирования ошибка близка к нулю и равна $3,7484 \times 10^{-24}$.

Аналогичная ситуация для других функций из обучающей страницы.

Для функций, не принадлежащих обучающей странице, значения mse при восстановлении функции проекции уже не нулевые (рис. 7е).

Так, для функции

$$Z(x, y) = e^{-5((x-2)^2 + (y-2)^2)} + e^{-5((x-4)^2 + (y-7)^2)} + e^{-5((x-8)^2 + (y-4)^2)},$$

которая соответствует воздействию на исследуемое поле в трех различных местах, при RBF-восстановлении 4-го направления сканирования mse равна 0,0568, а итоговая ошибка восстановления самой функции – 0,0145.

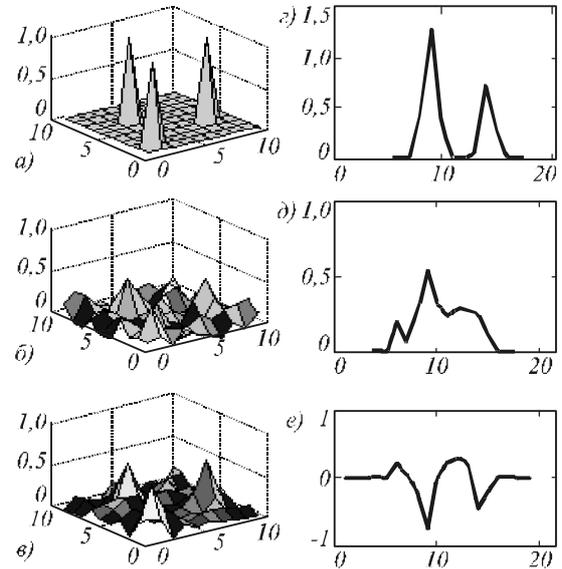


Рис. 7. Восстановление функции, не принадлежащей обучающей странице (обозначения а-е соответствуют обозначениям, использованным на рис. 6)

Однако, следует заметить, что функция проекции, построенная с помощью нейронной сети (рис. 7д), похожа на исходную проекцию (рис. 7з), но имеет более сглаженный вид. Это вполне соответствует общей концепции обучаемости нейронной сети.

Заключение

В статье представлены основные принципы решения нелинейных задач реконструктивной томографии для восстановления информации, поступающей с волоконно-оптических измерительных линий распределенной ВОИС. Предложен новый комбинированный алгоритм обработки проекционных данных для реконструкции функций распределения физических полей.

Этот алгоритм заключается в последовательном выполнении двух процессов: нейросетевой предобработки измерительной информации с помощью RBFNN и дальнейшей аппроксимации полученных данных на множестве дискретизации специального вида.

При реализации RBFNN предложен новый способ создания функций для обучения нейронной сети, которые строятся на основе тех функций, которые моделируют конкретный физический процесс. Построенная сеть обладает хорошими прогнозирующими возможностями и может с успехом использоваться для распределенных вычислений в задачах с применением ВОИС больших размерностей. В результате применения нейронной сети происходит восстановление проекционных данных с недостающих направлений сканирования, что предоставляет возможность примене-

ния методов аппроксимации данных на нерегулярной сетке специального вида.

Применение комбинированного алгоритма позволяет восстанавливать информацию с полей вдвое более высоких размерностей по сравнению с ранее использованными методами [8].

Литература

1. **Кульчин, Ю.Н.** Распределенные волоконно-оптические измерительные системы / Ю. Н. Кульчин – М.: Физматлит, 2001. – 272 стр.
2. **Haykin, S.** Neural Networks: a Comprehensive Foundation / S. Haykin – New Jersey, Prentice Hall, 1999. – 842 p.
3. **Тихонов, А. Н.** Методы решения некорректных задач / А. Н.Тихонов, В. Я. Арсенин – М.: Наука, 1988. – 288 стр.
4. **Faridani, A.** A Generalized Sampling Theorem for Locally Compact Abelian Groups / A. Faridani // Math. of Comp. – 1994. – Vol. 63. – P. 307-327.
5. **Behmard, H.** Sampling of Bandlimited Functions on Unions of Shifted Lattices / H. Behmard, A.Faridani // J. Fourier Anal. Appl. – 2002. – V. 8. – P. 43-58.
6. **Кульчин, Ю.Н.** Неравномерные схемы укладки измерительных линий в распределенных волоконно-оптических системах / Ю.Н. Кульчин, Е.В. Закасовская // Информатика и системы управления – 2009. – № 3(21). – С. 61-71. – ISSN 1814-2400.
7. **Kulchin, Yu.N.** Artifacts suppression in limited data problem for parallel fiber optical measuring systems / Yu.N. Kulchin, E.V. Zakasovskaya // Optical Memory & Neural Networks (Information Optics). – 2009. – V.18, N 3, P.171-180. – ISSN 1060-992X.
8. **Kulchin, Yu.N.** Artifacts suppression in limited data problem for parallel fiber optical measuring systems / Yu.N. Kulchin, E.V. Zakasovskaya // Optical Memory & Neural Networks (Information Optics). – 2008, vol.17, № 4, P. 317-327. – ISSN 1060-992X.
9. **Наттерер, Ф.** Математические аспекты компьютерной томографии / Ф. Наттерер; пер. с англ. – М.: Мир. 1990. – 280 с (F. Natterer. Mathematics of Computerized Tomography / John Wiley & Sons Ltd., N. Y., 1986.).

References

1. **Kul'chin, Yu.N.** Distributed Optical Fiber Measuring Systems / Yu.N. Kul'chin – Moscow: Fizmatlit, 2001. – 272 p. – (in Russian).
2. **Haykin, S.** Neural Networks: a Comprehensive Foundation / S. Haykin – New Jersey, Prentice Hall, 1999. – 842 p.
3. **Tikhonov, A.N.** Methods of solving ill-posed problems / A.N. Tikhonov and V.Ya. Arsenin – Moscow: "Nauka", 1988. – 288 p. – (in Russian).
4. **Faridani, A.** A Generalized Sampling Theorem for Locally Compact Abelian Groups / A. Faridani // Math. of Comp. – 1994. – Vol. 63. – P. 307-327.
5. **Behmard, H.** Sampling of Bandlimited Functions on Unions of Shifted Lattices / H. Behmard, A.Faridani // J. Fourier Anal. Appl. – 2002. – V. 8. – P. 43-58.
6. **Kulchin, Yu. N.** Nonuniform schemes of measuring lines stacking in distributed fibre-optic systems/ Yu. N. Kulchin, E.V. Zakasovskaya // Informatics and control systems – 2009. – № 3(21). – P. 61-71. – ISSN 1814-2400 – (in Russian).
7. **Kulchin, Yu.N.** Artifacts suppression in limited data problem for parallel fiber optical measuring systems / Yu.N. Kulchin, E.V. Zakasovskaya // Optical Memory & Neural Networks (Information Optics). – 2009. – V.18, N 3, P.171-180. – ISSN 1060-992X.
8. **Kulchin, Yu.N.** Artifacts suppression in limited data problem for parallel fiber optical measuring systems / Yu.N. Kulchin, E.V. Zakasovskaya // Optical Memory & Neural Networks (Information Optics). – 2008, vol.17, № 4, P. 317-327. – ISSN 1060-992X.
9. **Natterer, F.** Mathematics of Computerized Tomography/ Natterer F.– John Wiley & Sons Ltd., N. Y., 1986. –288 p.

NEURAL-LIKE AND ALGEBRAIC MODELING OF PROJECTION DATA IN PARALLEL FIBER OPTICAL TOMOGRAPHY IN LIMITED-ANGLE CONDITIONS

Yury Nikolaevich Kulchin^a (director IACP FEB RAS, director@iacp.dvo.ru),

Elena Vladimirovna Zakasovskaya^b (ass. professor, zakasovskaya@inbox.ru)

^aInstitute of Automation and Control Processes, FEB RAS,

^bFar Eastern National University

Abstract

The paper discusses tomography reconstruction of distributed physical fields by means of distributed fiber optical measuring systems (FOMN) for incomplete parallel schemes of measuring lines (ML) stacking. The approach is presented, allowing to use Radial Basis Function Neural Network (RBFNN) for preprocessing of projection data for the purpose of further application to them of methods of approximating for the nonregular schemes of stacking of ML of more simple form.

Key words: distributed fibre-optic measuring system, schemes of scanning, parallel beam tomography, radial basis function neural network (RBFNN).

Поступила в редакцию 27.08.2009 г.