

УДК 004.032.2

СРАВНЕНИЕ НЕЙРОСЕТЕВЫХ МЕТОДОВ ПРЕДОБРАБОТКИ ДАННЫХ ПРИ РЕШЕНИИ ЗАДАЧ АНАЛИЗА, ДИАГНОСТИКИ И КЛАССИФИКАЦИИ ДЕФЕКТОВ РАДИОЭЛЕКТРОННОЙ АППАРАТУРЫ

© Б. П. Иваненко, С. А. Клестов, В. И. Сырямкин

*Томский государственный университет,
634050, Томск, просп. Ленина, 36
E-mail: ivanenko_boris@mail.ru*

Рассматриваются вопросы предобработки данных, полученных с рентгеновского 3D-микротомографа, при решении задач анализа, диагностики и классификации дефектов радиоэлектронной аппаратуры. Предлагается при решении поставленной задачи использовать нейросетевые методы и регуляризирующие сплайны. Проводится сравнительный анализ нейросетевых и сплайн-методов при решении задач восстановления сильно зашумлённых сигналов. Эффективность предложенного подхода исследована методами численного моделирования и при обработке реальных данных.

Ключевые слова: дефектоскопия, нейронные сети, сплайны, регуляризация.

DOI: 10.15372/AUT20230202

Введение. Современным эффективным средством исследования внешней формы и внутренней структуры деталей сложных технических систем (СТС) является рентгеновская компьютерная томография, которая позволяет достичь высокой точности бесконтактного неразрушающего измерения размеров внутренних структурных элементов и их локальных дефектов [1–5]. Отметим, что при решении задач анализа, диагностики и классификации дефектов радиоэлектронной аппаратуры в нейросетевом базисе от грамотного построения обучающих выборок существенно зависит результат решения поставленной задачи. Однако обработка результатов измерений, полученных с помощью рентгеновского 3D-микротомографа, осуществляется в условиях случайных помех, также при наличии пробелов в соответствующих базах данных. В связи с чем при обработке экспериментальных данных необходимо использовать те или иные методы фильтрации.

Различные методы фильтрации экспериментальных данных подробно описаны в [6, 7].

Целью данной работы является создание и реализация на ЭВМ различных методов восстановления сигналов на фоне случайных помех на этапе предобработки эмпирических данных, получаемых 3D-микротомографом, а также исследование и сравнительный анализ их точностных характеристик методами численного моделирования.

В предлагаемой работе для решения поставленной задачи предлагается использовать искусственные нейронные сети (ИНС) и сплайны, основанные на их представлении через функцию Грина и ядро некоторого энергетического оператора [8]. Приводятся результаты исследования точностных характеристик данных методов и их сравнительный анализ.

В работе [9] предложена концептуальная основа создания информационной математической модели, реализуемой в нейросетевом базисе, и программного обеспечения для дефектоскопии снимков рентгеновского 3D-микротомографа, предназначенного для анализа, диагностики классификации дефектов радиоэлектронной аппаратуры.

Основы информационного моделирования. Согласно [10–12] в основе информационного кибернетического подхода лежит создание моделей не путём анализа, а с использованием синтеза компонент. При этом моделируется внешнее функционирование системы, которое описывается информационно исходя из данных эксперимента или наблюдений над реальной системой.

Искусственные нейронные сети являются удобным и естественным базисом для представления информационных моделей. В укрупнённом виде ИНС выполняет функциональное соответствие между входом и выходом и может служить информационной моделью G системы F . Согласно [10] определяемая нейросетью функция может быть произвольной при легко выполнимых требованиях к структурной сложности сети и наличию нелинейности в переходных функциях нейронов.

Отметим, что при информационном подходе требуемая модель G системы F не может быть полностью основана на явных правилах и формальных законах. Процесс получения G из имеющихся отрывочных экспериментальных сведений о системе F может рассматриваться как обучение модели G поведению F в соответствии с заданным критерием. Алгоритмически обучение означает подстройку внутренних параметров модели (весов синаптических связей в случае нейронной сети) в целях минимизации ошибки модели.

При использовании базы данных наблюдений за системой для обучения может отводиться некоторая её часть, называемая в этом случае обучающей выборкой. Для обучающих примеров X отклики системы Y известны. Норма невязки модельной функции G и системной функции Y на множестве X играет важную роль в информационном моделировании и называется ошибкой обучения модели E_L . В приложениях пользователя обычно интересуют предсказательные свойства модели. При этом главным является вопрос, каковым будет отклик системы на новое воздействие, пример которого отсутствует в базе данных наблюдений. Наиболее общий ответ на этот вопрос даёт (по-прежнему недоступная) ошибка модели E_G . Неизвестная ошибка, допускаемая моделью G на данных, не использовавшихся при обучении, называется ошибкой обобщения модели E_G . При построении информационной модели основной целью является уменьшение именно ошибки обобщения, поскольку малая ошибка обучения гарантирует адекватность модели лишь в заранее выбранных точках. Проводя аналогии с обучением в биологии, можно сказать, что малая ошибка обучения соответствует прямому запоминанию обучающей информации, а малая ошибка обобщения — формированию понятий и навыков, позволяющих распространить ограниченный опыт обучения на новые условия [7]. Важно отметить, что малость ошибки обучения не гарантирует малости ошибки обобщения.

На практике при оценке ошибки обобщения (прогноза) поступают следующим образом. Из обучающей выборки случайным образом исключают некоторое количество примеров и формируют из них так называемое верификационное множество, которое подаётся на вход обученной нейросети. В результате мы можем оценить ошибку верификации E_v , на основании которой можно сделать определённые выводы о прогностических свойствах, т. е. об ошибке обобщения E_G [12–14].

Согласно [11] наименее исследованным является определение рациональной структуры нейросетевой модели, в том числе количества слоёв и нейронов. Наблюдается тесная связь между количеством весов сети и количеством обучающих векторов. Если бы целью обучения было только запоминание обучающих векторов, то их количество могло быть равным числу весов. В этом случае каждый вес соответствовал единственному обучающему вектору.

Такая сеть может только восстанавливать данные и не будет обладать свойством обобщения. Для обретения способности обобщения сеть должна тренироваться на избыточном обучающем множестве, тогда веса будут адаптироваться не к уникальным векторам,

а к их статистически усреднённым совокупностям. В научной литературе данная проблема известна как проблема пластичности — стабильности (biase-variance trade-off). Часто такие характеристики считают сложностью нейросетевой модели. Нейросетевая модель со сложностью меньше рациональной не обладает достаточными ресурсами для получения результатов с заданной точностью, а у нейросети с избыточной сложностью значительно ухудшаются возможности аппроксимации выборочных данных (феномен переобучения — overfitting) [11].

На практике для оценки числа нейронов в скрытых слоях для однородных нейронных сетей можно воспользоваться формулой оценки необходимого числа синаптических весов N_w в многослойной сети с сигмоидальными передаточными функциями [10]:

$$\frac{N_y N_p}{1 + \log_2(N_p)} \leq N_{yy} \leq N_y \left(\frac{N_p}{N_x} + 1 \right) (N_x + N_y + 1) + N_y, \quad (1)$$

где N_y — размерность выходного сигнала, N_p — число элементов обучающей выборки, N_x — размерность входного сигнала. Оценив необходимое число весов, можно рассчитать число нейронов в скрытых слоях. Например, число нейронов в двухслойной сети составит

$$N = N_{yy} / (N_x + N_y). \quad (2)$$

Аналогично можно рассчитать число нейронов в сетях с бóльшим числом слоёв.

Однако, как показывает опыт, применение формул (1), (2) далеко не всегда позволяет оптимальным образом построить нейронную сеть.

Согласно [6, 13, 14] решение задач с использованием нейросетевых методов следует проводить по следующей схеме:

1) физическая постановка задачи в целях построения обучающих выборок, основой для создания которых могут быть результаты численного моделирования и соответствующие базы экспериментальных данных;

2) выбор архитектуры, топологии сети, а также алгоритма её обучения;

3) предварительная обработка данных;

4) построение обучающих выборок;

5) обучение, тестирование и возможное дообучение сети;

6) анализ результатов.

Нейросетевые методы предобработки данных. На первом этапе следует обращать внимание, прежде всего, на значительные случайные выбросы сигналов, обусловленные сбоями в регистрирующей аппаратуре либо ошибками при передаче данных. Сигналы следует удалить из обучающей выборки.

Очевидно, что простейшая предобработка результатов измерений может быть основана на их статистической обработке, расчёте среднего и дисперсии, что позволяет уменьшить погрешность измерений. При этом данные о среднем значении могут быть внесены в обучающую выборку, что, как показывает опыт, существенно повышает их информативность [13, 14].

Ещё одна возможность борьбы со случайными погрешностями измерений заложена в самих нейросетях [6, 15], т. е. в их регуляризирующих свойствах.

В приложении к нейросетевым моделям регуляризирующие методы сводятся к оптимизации функционала ошибки (в простейшем случае — суммы квадратов отклонений модели от экспериментальных значений) с аддитивной добавкой, исчезающей по мере улучшения свойств гладкости функции:

$$E[G] = \sum_{\alpha=1}^{N_\alpha} (G(\mathbf{x}^\alpha) - \mathbf{y}^{(\alpha)})^2 + \lambda \varphi[G].$$

Здесь φ — регуляризирующий функционал, λ — параметр регуляризации.

Полезность регуляризирующих свойств нейронных сетей проявляется в ситуациях, когда экспериментальные данные о системе содержат внутреннюю избыточность, которая позволяет представить совокупность данных моделью, содержащей меньшее число параметров, чем имеется данных. Таким образом, нейросетевая модель сжимает экспериментальную информацию, устраняя шумовые компоненты и подчёркивая непрерывные гладкие зависимости. Однако при этом возникает проблема выбора структуры нейросети, которая заключается в том, что на основании имеющихся данных необходимо построить нейросеть, решающую поставленную задачу с требуемой точностью и при этом обладающую минимальной структурой. Требование минимальности структуры связано с известным фактом, что модель с меньшим числом настраиваемых параметров обладает лучшими аппроксимационными способностями и поэтому является более предпочтительной. Как известно [6], выделяют три различных подхода к автоматизированному определению структуры:

1. Прореживание избыточной сети (pruning), заключающееся в удалении несущественных связей и элементов нейросети в процессе обучения — процесс контрастирования.

2. Нарастивание нейросети в процессе обучения (constructive algorithms). Суть данного подхода состоит в последовательном добавлении новых элементов в структуру сети.

3. Использование проверочного множества V для раннего останова сети или так называемая кроссвалидация, иначе верификация. Как уже отмечалось ранее, проверочное множество V непосредственно в процессе обучения не участвует, но используется для оперативной проверки фактически набранного уровня обобщения. Процесс обучения нейронной сети периодически останавливается, и вычисляется ошибка сети на множестве V . Обучение прекращается, когда погрешность обобщения на этом подмножестве достигнет минимального значения (или начнёт возрастать).

Сплайн-методы предобработки данных. Ещё одним эффективным способом предобработки является построение интерполяционного или сглаживающего сплайна функций N переменных на хаотических сетках в областях произвольной конфигурации, основанного на представлении сплайна через функцию Грина и ядро некоторого энергетического оператора [12].

В простейшем двумерном случае, когда сплайн-функция удовлетворяет условию минимума функционала энергии вида

$$\int [\sigma_{x,x}^2 + 2\sigma_{x,y} + \sigma_{y,y}^2] d\Omega = \min \Omega,$$

сплайн-функция двух переменных определяется формулой

$$\sigma(x, y) = \frac{1}{2} \sum \lambda_i [(x - x_i)^2 + (y - y_i)^2] \ln [(x - x_i)^2 + (y - y_i)^2] + \nu_{00} + \nu_{10}x - \nu_{01}y,$$

а коэффициенты λ_i являются решением системы линейных алгоритмических уравнений вида

$$\begin{vmatrix} 0 & a_{1,2} & \dots & a_{1n} & 1 & x_1 & y_1 \\ a_{2,1} & 0 & \dots & a_{nn} & 1 & x_2 & y_2 \\ \vdots & \vdots & \ddots & \vdots & \vdots & \vdots & \vdots \\ a_{n,1} & a_{n,2} & \dots & 0 & 1 & x_n & y_n \\ 1 & 1 & \dots & 1 & 0 & 0 & 0 \\ x_1 & x_2 & \dots & x_n & 0 & 0 & 0 \\ y_1 & y_2 & \dots & y_n & 0 & 0 & 0 \end{vmatrix} \begin{vmatrix} \lambda_1 \\ \lambda_2 \\ \vdots \\ \lambda_n \\ \lambda_{00} \\ \lambda_{10} \\ \lambda_{01} \end{vmatrix} = \begin{vmatrix} r_i \\ r_i \\ \vdots \\ r_i \\ r_i \\ r_i \\ r_i \end{vmatrix},$$

$$a_{ii} = G_{22}(0) = 0, \quad a_{i,j} = \|P_i - P_j\|^2 \ln \|P_i - P_j\|.$$

В данном случае функция $G_{m,s}(x, p)$ с точностью до постоянного положительного множителя совпадает с функцией Грина для полигармонического оператора, $(-1)^m \Delta^m = (D^m)^* D^m$, $P_{i,j}$ — узлы интерполяции, r_i — значения функции, а при переходе в режим сглаживания к диагональным элементам матрицы добавляются значения $\alpha \geq 0$ параметра сглаживания. Применительно к задачам рентгеновской томографии этот метод можно успешно использовать для предварительной обработки данных при построении обучающих выборок, поскольку такой алгоритм позволяет учитывать специфику решения поставленной задачи, например, в виде ограничений на саму функцию либо на её производные по направлениям. Отметим, что представляет определённый интерес сравнить методы N -мерной сплайн-интерполяции и нейросетевые, а также их точностные характеристики.

В качестве простейшего примера построения карты изолиний зададим на единичном квадрате $[0, 1] \times [0, 1]$ аналитическую функцию вида $F(x, y) = 100 + 3x^2 \sin(5y + x) + 4(y - x) \cos(3x + 2y)$. С использованием датчика случайных чисел нанесём на этот квадрат нерегулярно расположенные интерполяционные узлы и рассчитаем в них значения искомой функции. Количество узлов интерполяции положим равным 80. Подготовим обучающую выборку, входами которой будут узлы интерполяции, а параметром обучения — значения функции. Построим простейшую нейронную сеть — многослойный персептрон и обучим сеть на нерегулярной сетке, а затем на вход подадим координаты узлов, рассчитанных на регулярной сетке размером 11×11 . Аналогичные расчёты проведём с использованием методов сплайн-интерполяции и построим карты изолиний.

На рис. 1 приведены результаты расчётов. На рисунке точками нанесены узлы интерполяции, сплошные толстые линии получены с помощью методов сплайн-интерполяции, а тонкие линии построены на основе нейросетевых расчётов. Легко заметить, что результаты расчётов практически совпали, что служит хорошим аргументом в пользу нейросетевых методов. Аналогичные результаты можно получить и при решении трёхмерной задачи.

Особо отметим, что при выборе примера построения карт изолиний предполагается, что такой подход к визуализации данных, полученных с рентгеновского $3D$ -




Рис. 1. Построение карт изолиний




Рис. 2. Пример сигнала, полученного на томографе




Рис. 3. Графическая иллюстрация способности сети к обобщению

микротомографа, в отличие от обычной визуализации, основанной на представлении данных в виде цветовой градации, позволит более наглядно представить в числовом формате.

Практические результаты. Апробация предложенных методов предобработки (фильтрации сигналов) была проведена на примере обработки реальных данных, полученных на томографе.

На рис. 2 $s(x)$ можно рассматривать как срез изображения, восстановленного в томографе, кривая $Sd(x)$ представляет собой сумму полезного сигнала и шума [10].

На рис. 3 приведены результаты восстановления сигнала $Sd(x)$ с использованием нейросети. Как было отмечено выше, одной из сложных задач при использовании нейросетевых методов является определение рациональной структуры нейросетевой модели, в том числе количества слоёв и нейронов. Проиллюстрируем это на конкретном примере, проводя аналогию между полиномиальной аппроксимацией и нейросетью. На рис. 3 кривая $s(x)$ — точные значения сигнала; $S1(x)$ — восстановленные нейросетью значения, когда исполь-




Рис. 4. Сравнительный анализ методов предобработки данных

зовалось слишком большое количество нейронов (степень полинома завышена); $S2(x)$ — правильное количество нейронов (степень полинома подобрана верно); $S3(x)$ слишком малое количество нейронов (степень полинома занижена — линейная аппроксимация).

Далее приведём результаты решения этой задачи с использованием некоторой модификации вышеописанной интерполяции (сплайны нечётной степени на отрезке [12]) и проведём сравнительный анализ методов сплайн-интерполяции и нейросетевых. Соответствующие результаты представлены на рис. 4, где кривая $s(x)$ — точные значения сигнала, $S_n(x)$ — восстановленные нейросетью значения, $S_s(x)$ — восстановленные значения с использованием сплайна.

Анализируя графический материал, отметим, что сравнение методов восстановления сильно зашумлённых эмпирических данных с использованием регуляризирующих сплайнов и нейронных сетей позволяет сделать вывод об их высокой эффективности.

Заключение. В представленной работе приведены результаты исследования точностных характеристик и эффективности разработанных и реализованных на ЭВМ методов предобработки экспериментальных данных, полученных с рентгеновского 3D-микротомографа, основанных на применении регуляризирующих сплайнов и нейросетевых методов.

При решении задачи в нейросетевом базисе использовался многослойный перцептрон с обучением по методу обратного распространения ошибки.

В случае использования регуляризированных сплайнов параметр регуляризации определялся по невязке.

Анализируя полученные результаты, можно сделать вывод, что точностные характеристики разработанных нейросетевых и сплайн-методов восстановления сильно зашумлённых эмпирических данных практически совпадают и могут успешно применяться при решении поставленной задачи.

Разработанные методы в настоящее время применяются авторами при решении задач анализа, диагностики и классификации поверхностных дефектов печатных плат на основе данных, получаемых рентгеновским 3D-микротомографом.

Финансирование. Работа выполнена при поддержке Российского научного фонда (грант № 22-19-00389, <https://rscf.ru/project/22-19-00389/>).

СПИСОК ЛИТЕРАТУРЫ

1. **Сырямкин В. И.** Цифровой рентгеновский 3D-микротомограф для диагностики материалов и элементов радиоэлектронной аппаратуры // Дефектоскопия. 2016. № 9. С. 29–38.
2. **Клестов С. А., Сунцов С. Б., Сырямкин В. И.** Интеллектуальная цифровая рентгеновская 3D-микротомография на основе нейросетевых методов анализа данных // Решетневские чтения: Матер. XXIV Междунар. научно-практ. конф., посвящённой памяти генерального конструктора ракетно-космических систем академика М. Ф. Решетнева. Красноярск, 10–13 ноября 2020 г. С. 175–176.
3. **Klestov S. A., Syryamkin V. I., Suntsov S. B.** Digital 3d X-ray microtomographic scanners for electronic equipment testing // Journ. Physics: Conf. Ser.: International Conference «Actual Trends in Radiophysics». 2020. Vol. 1499. 012045. DOI: 10.1088/1742-6596/1499/1/012045.
4. **Syryamkin V. I., Klestov S. A., Suntsov S. B.** Digital X-ray Tomography. Tomsk State University. 2nd edition. London: Red Square Scientific, Ltd., 2020. 200 p.
5. **Борзов С. М., Карпов А. В., Потатуркин О. И., Хадзиев А. О.** Применение нейронных сетей для дифференциальной диагностики лёгочных патологий по рентгенологическим изображениям // Автометрия. 2022. 58, № 3. С. 61–71. DOI: 10.15372/AUT20220307.
6. **Назаренко С. Ю., Удод В. А.** Применение искусственных нейронных сетей в радиационном неразрушающем контроле // Дефектоскопия. 2019. № 6. С. 53–64. DOI: 10.1134/S013030821906006X.
7. **Калинин П. В., Сирота А. А.** Статистические, нейросетевые и комбинированные алгоритмы фильтрации аппликативных помех на изображениях // Автометрия. 2012. 48, № 6. С. 18–28.
8. **Василенко В. А.** Сплайн-функции: теория, алгоритмы, программы / Отв. ред. Г. И. Марчук. Новосибирск: Наука, Сиб. отд-ние, 1983. 214 с.
9. **Иваненко Б. П.** Сравнительный анализ нейросетевых и сплайн методов при решении задач предобработки экспериментальных данных при построении обучающих выборок // Сб. матер. V Междунар. форума «Интеллектуальные системы 4-й промышленной революции» / Под ред. В. И. Сырямкина. Томск: Общество с ограниченной ответственностью «СТТ», 2023. С. 28–30.
10. **Горбань А. Н., Россиев Д. А.** Нейронные сети на персональном компьютере. Новосибирск: Новосибирский филиал ФГУП «Академический научно-издательский и книгораспространительский центр Наука», 1996. 276 с.
11. **Горбань А. Н.** Обучение нейронных сетей. М.: Изд. СССР-США СП "ParaGraph", 1990. 160 с.
12. **Горбань А. Н., Дунин-Барковский В. Л., Кирдин А. Н. и др.** Нейроинформатика. Новосибирск: Наука, Сибирское предприятие РАН, 1998. 296 с.
13. **Иваненко Б. П.** Нейросетевое имитационное моделирование нефтяных месторождений и гидрогеологических объектов. Томск: Издательский Дом Томского Государственного университета, 2014. 186 с.
14. **Иваненко Б. П., Клестов С. А., Сырямкин В. И.** Нейросетевой прогноз природных ресурсов. На примере реальных нефтяных месторождений, полигонов захоронения ЖРО, прогнозе паводковых вод. Beau Bassin: LAP LAMBERT, 2019 г., 200 с.
15. **Терехов С. А.** Прямые, обратные и смешанные задачи в нейросетевом моделировании сложных инженерных систем // Тез. IV Всеросс. рабоч. семинара «Нейроинформатика и её приложения» / Под ред. А. Н. Горбаня. Красноярск: КГТУ, 1996. С. 122.

Поступила в редакцию 27.07.2022

После доработки 13.09.2022

Принята к публикации 19.09.2022