

## **О ВЫБОРЕ АРХИТЕКТУРЫ НЕЙРОННОЙ СЕТИ ПРИ РЕШЕНИИ НЕКОТОРЫХ ЗАДАЧ МАТЕМАТИЧЕСКОЙ ДЕФЕКТОСКОПИИ**

### **Введение**

Одна из основных проблем, которая возникает при решении той или иной математической задачи с использованием нейросетевого подхода, - выбор архитектуры нейронной сети. Интенсивное развитие нейрокompьютерной науки привело к появлению большого количества сетевых архитектур, имеющих минимальное отличие в своей структуре, но обладающих при этом разными спектрами применимости и вычислительными возможностями. Невозможность нейросетевого решения данной задачи, или же получение результатов менее точных, чем при применении традиционного математического аппарата, зачастую говорит о некорректном выборе сетевой модели. Нейросетевой подход в решении некоторых математических задач дефектоскопии может значительно сократить сам процесс решения, так как позволяет избежать громоздких математических преобразований, связанных с поиском закономерностей между входными и выходными данными, часто осложненный необходимостью восстановления законов и функций распределения вероятностей. Устойчивость решения, предоставляемого нейронной сетью при наличии шумовой компоненты в исходных данных, делает нейронные сети достаточно ценным инструментом в арсенале исследователя.

В свете сказанного представляется достаточно важным рассмотреть возможности применения нейронных сетей различных архитектур для решения таких задач как распознавание и классификация, восстановление и реконструкция данных, сжатие и извлечение признаков, аппроксимация и регуляризация, оптимизация. В качестве примера рассмотрен вопрос о выборе архитектуры нейронной сети при решении задач распознавания и классификации двумерных объектов, а также при решении обратной задачи электроимпедансной томографии (ЭИТ). В статье не обсуждаются особенности реализации той или иной модели нейронной сети, а также их преимущества или недостатки ввиду наличия значительного количества специальной литературы по данному вопросу, например [1].

### **Обработка экспериментальных данных и нейросетевые алгоритмы**

Формально последовательность действий над экспериментальными данными можно разделить на следующие этапы:

1. Предварительная обработка данных и фильтрация.

---

© А.Н. Петренко, А.Е. Кучеренко, 2008

2. Анализ главных компонентов и извлечение ключевых признаков, в результате чего происходит значительное сжатие данных, что упрощает их анализ. Выбор ключевых признаков часто осуществляется при помощи разложений по системе ортогональных функций (разложение в ряд Фурье, разложение Карунена-Лоэва) либо посредством аппроксимации функциями [2].
3. Анализ и обработка сжатых данных.
4. Анализ результата.
5. Оптимизация – обычно не рассматривается как отдельный шаг решения задачи, а непосредственно внедряется в каждый этап ее решения.

В последние два десятилетия для решения перечисленных задач все более широко используются искусственные нейронные сети. Непараметрические нейронные сети являются мощным инструментом для решения широкого круга задач. Ниже рассмотрены этапы решения задачи в смысле нейросетевого подхода.

**Предварительная обработка данных и фильтрация.** Один из ключевых моментов предварительной обработки данных — фильтрация, для выполнения которой возможно применение нейронных сетей различных типов: линейные нейронный фильтры, сети с обратным распространением ошибки, динамические сети, сети на основе радиальных базисных функций. Одна из интересных нейронных архитектур, примененная для фильтрации и подавления шумов, - обобщенный адаптивный нейронный фильтр [3,4], который представляет собой набор нейронов, построенных на основе функций, реализующих фильтр Винера. В [5] описана гибридная система, состоящая из фильтра, использующего статистический подход для шумовой фильтрации, и сети Хопфилда, которая используется для устранения негативных последствий работы фильтра. Данная работа являет собой пример удачного сочетания различным технологий обработки данных, существенно дополняющих друг друга. В [6] представлена система фильтрации, представляющая собой “сеть сетей” — каждый модуль представляет собой отдельную нейронную сеть с обратным распространением ошибки. Такая комплексная система позволила реализовать множество разнородных фильтров.

**Анализ главных компонентов и извлечение ключевых признаков.** В упрощенном виде этот этап можно представить в виде пары кодирование-декодирование. Для выполнения такой задачи подходят нейронные сети с обратным распространением ошибки, самоорганизующиеся карты признаков, машины опорных векторов, сети на основе теории адаптивного резонанса. В [7-9] описаны случаи применения сетей с обратным распространением ошибки и машин опорных векторов для уменьшения размерности исходных данных. Сети были обучены восстанавливать исходные данные. В [10] используется самоорганизующаяся карта признаков для выполнения процедуры сжатия. Более сложные

методы сжатия основаны на комбинированном подходе. В [11] описана модульная система, в которой специализированная нейронная сеть определяла, какой нейронный модуль, реализующий тот или иной алгоритм сжатия, использовать. В [12] представлена реализация хорошо известного метода одномерного анализа главных компонент на основе нейросетевого подхода. Позже он был распространен на случай многомерных данных [13]. Дальнейшее развитие нейросетевого подхода в решении задачи анализа главных компонент состояла в применении многослойных нейронных сетей. В частности, применение нейронных сетей с пятью слоями позволяет выполнять нелинейное сокращение размерности, в том числе поиск “поверхностей главных компонент” [14,15]. Один из подходов в выявлении ключевых признаков состоит в предварительной кластеризации многомерных данных (например, с помощью самоорганизующейся карты признаков) с последующим использованием центра кластера в качестве прототипа для всего кластера. Из анализа приведенных публикаций, а также [16-19] следует, что для анализа главных компонент и извлечения ключевых признаков наиболее широко использовались многослойные сети с обратным распространением ошибки. Достаточно часто использовались сети на основе самоорганизующихся карт и сети Хопфилда. Как отмечают авторы публикаций, использование нейронных сетей вместо традиционного статистического анализа компонентов имеет определенные преимущества. Использование многослойной нейронной сети с обратным распространением ошибки позволяет выполнять нелинейное извлечение ключевых признаков, однако такой подход нуждается в дальнейшем исследовании.

**Анализ и обработка сжатых данных.** Собственно, на данном этапе выполняется основное решение задачи, определение модели, описывающей наблюдаемые процессы. Соответственно, в зависимости от поставленной задачи возможно применение определенной нейросетевой структуры. Наиболее универсальные сетевые архитектуры - многослойные сети с обратным распространением ошибки и сети на основе радиальных базисных функций – подходят для построения практически сколь угодно сложных моделей [20,21].

**Анализ результата.** Смысловая интерпретация полученных результатов обычно находится в компетенции человека. В то же время практически любая нейронная сеть обладает некоторыми способностями к обобщению, которые усиливаются при рациональном обучении сети. Существует особая группа нейронных сетей под обобщенным названием семантические нейронные сети. Основная решаемая ими задача - морфологический, синтаксический и смысловой разбор естественного языка. Одно из направлений использования семантических нейронных сетей - экспертные системы [22]. Соответственно комбинация тематической базы знаний экспертной системы и семантической нейронной сети позволяет в некоторой степени осуществить анализ результата. Нейронные деревья решений [23], семантические нейронные сети [24, 25] могут быть использованы для репрезентации знаний в контексте полученно-

го результата. Эти знания могут быть использованы для ограничения количества возможных вариантов интерпретации решения. Так, в [24] авторы последовательно описывают построение комплексной нейронной сети, в состав которой входит семантическая нейронная сеть, которая используется для определения опухолей костей и постановки предварительного диагноза. Основная проблема, возникающая при нейросетевом подходе в решении данного этапа - это представление о нейронной сети как о “черном ящике”, что фактически создает значительные трудности в объяснении решения, принятого нейронной сетью. Частный подход в преодолении этого вопроса - “извлечение правил” [26] из обученной нейронной сети.

**Оптимизация.** Некоторые подзадачи могут быть сформулированы в виде задач оптимизации, решаемых с помощью сети Хопфилда [27-35]. Одно из направлений в применении сетей Хопфилда - решение комбинаторных задач оптимизации, если они могут быть сформулированы как задачи минимизации энергии. Нейронная сеть Хопфилда представляет собой слой адаптивных сумматоров с обратными связями, выходные сигналы которых, подвергаясь нелинейной обработке по заданному закону, поступают с некоторой временной задержкой на входы нейронов, в результате чего выходной сигнал нейронной сети формируется лишь после того, как сеть достигнет динамического равновесия. Поведение нейронной сети моделирует, таким образом, некоторый стохастический процесс, конечное состояние которого определяется входным вектором нейросети, являющимся, по сути, вектором внешних смещений. Поведение нейронной сети Хопфилда можно анализировать, используя графовую модель либо решая задачу о собственных векторах и собственных значениях рассматриваемой системы. Но непосредственное применение сети Хопфилда связано с определенными трудностями, в связи с чем исходную задачу часто необходимо модифицировать. Следует также учесть, что вычислительная сложность, связанная с применением сети Хопфилда, практически эквивалентна таковой традиционных алгоритмов, которые применяются при решении оптимизационных задач.

### **Классификация нейронных сетей в контексте решаемых задач**

Нейронные сети интенсивно используются в различных областях науки. Анализ работ, связанных с использованием нейронных сетей для решения некоторых вычислительных задач, показывает, что нейросетевой подход имеет преимущества перед традиционными математическими методами в следующих случаях:

1. Когда рассматриваемая задача в силу конкретных особенностей не поддается адекватной формализации, поскольку содержит элементы неопределенности, не формализуемые традиционными математическими методами.
2. Когда рассматриваемая задача формализуема, но на настоящее время отсутствует аппарат для ее решения.

3. Когда для рассматриваемой, хорошо формализуемой задачи существует соответствующий математический аппарат, но реализация вычислений с его помощью на базе имеющихся вычислительных систем не удовлетворяет требованиям получения решений по времени, размеру, весу, энергопотреблению и др.; в такой ситуации приходится либо производить упрощение алгоритмов, что снижает качество решений, либо применять соответствующий нейросетевой подход при условии, что он обеспечит нужное качество выполнения задачи [36].

В таблице 1 приведена классификация различных нейронных архитектур в связи с возможной областью их применения.

### **Выбор архитектуры нейронной сети при решении задачи локализации и классификации дефектов**

Одна из главных задач дефектоскопии - задача локализации и классификации дефектов. Проблема состоит в определении дефекта в контролируемом изделии, выявлении его положения и соотнесении этого дефекта к определенному классу, что в свою очередь позволяет принять решение о годности контролируемого изделия [37]. В статье [38] предложен метод автоматической локализации и классификации дефектов на цифровых рентгенограммах с использованием двух нейронных сетей.

Соответственно первая нейронная сеть использовалась для выполнения предварительно обработки изображений, а именно - фильтрации, преобразования из полутонового в бинарное, сегментации. В соответствии с таблицей 1 для выполнения поставленных задач наиболее подходят многослойный персептрон (МП), сети на основе радиальных базисных функций (РБФ), динамические нейронные сети. Качество выполнения каждой задачи после соответствующего обучения сети на 30 рентгенограммах дефектных объектов оценивалось визуально с присвоением оценки от 1 (очень плохо) до 5(отлично). В таблице 2 приведены средние оценки выполнения каждой из трех задач соответствующей нейронной сетью. Таким образом, по общей сумме баллов в качестве сети № 1 была выбрана сеть Элмана.

Для решения задачи классификации возможно использование многослойного персептрона, самоорганизующихся карт признаков (СКП), динамических сетей. В таблице 3 представлены данные правильной классификации дефектов сетью после обучения ее на 30 рентгенограммах дефектных объектов. При оценке качества классификации были использованы 30 изображений из обучающей выборки и 10 незнакомых сети изображений. Многослойный персептрон с 4 скрытыми слоями (сеть свертки) показал наилучший результат при классификации дефектов на рентгенограммах.

Табл. 1 – Классификация нейронных архитектур

Архитектура	Восстановление данных	Фильтрация данных	Сжатие данных	Извлечение ключевых признаков	Анализ данных	Анализ результата	Оптимизационные задачи
Персептрон				+	+		
Многослойный персептрон	+	+	+	+	+		+
Сети на основе РБФ	+	+		+	+		+
Вероятностные НС				+	+	+	
Регрессионные сети	+	+			+		
Самоорганизующиеся карты признаков			+	+	+		
Квантование векторов обучения	+	+		+	+		+
Сеть Хопфилда	+	+		+	+		+
Ячейстые сети	+	+	+	+	+		
Адаптивные нейронные фильтры	+	+					
Адаптивная резонансная теория	+				+		
Неокогнитрон		+		+	+		
Динамические НС	+	+	+	+	+		
Семантические НС							
Экспертные системы							+

### Выбор архитектуры нейронной сети при решении обратной задачи ЭИТ

Электроимпедансная томография - методика, позволяющая визуализировать пространственное распределение электрического импеданса внутри объекта, в частности, внутри тела человека по результатам неинвазивных электрических измерений. Цель решения обратной задачи ЭИТ состоит в определении внутренней структуры исследуемого объекта путем измерения разницы потенциалов на поверхности объекта. Другими словами, необходимо определить границы участков с разли-

Табл. 2 – Оценки качества работы сетей

Архитектура	Фильтрация	Бинарное преобразование	Сегментация	Сумма баллов
МП с 1 скрытым слоем	5	4	3	12
МП с 2 скрытыми слоями	4	2	4	10
Сеть на основе РБФ	1	4	3	8
Сеть Элмана	5	3	5	13

Табл. 3 – Оценки качества классификации дефектов

Архитектура	% правильной классиф. изученных изобр.	% правильной классиф. неизвестных сети изобр.
МП с 4 скрыт. сл.	96,6	90
МП с 3 скрыт. сл.	93,3	70
МП с 2 скрыт. сл.	93,3	70
МП с 1 скрыт. сл.	90	60
СКП	86,7	60
Сеть Элмана	96,6	80

чной проводимостью внутри объекта. В статье [39] предложен метод решения обратной задачи ЭИТ с использованием нейронной сети на основе РБФ. Проблема реконструирования изображений ЭИТ рассмотрена для шестнадцатиелектродной измерительной системы с полярной инъекцией тока. Геометрия исследуемого объекта - цилиндрическая, при этом исследуемый срез разделен на 576 элементов для повышения точности реконструирования изображения.

Для решения обратной задачи ЭИТ подходят МП, динамические сети, сети на основе РБФ. Выбор архитектуры нейронной сети в данном случае был осуществлен, основываясь на том факте, что за приемлемое время для восстановления изображения ЭИТ удалось обучить только сеть на основе РБФ. Сети иных архитектур либо не могли закончить обучение с заданной точностью, либо их обучение затягивалось на неопределенно долгий срок.

### Заключение

Искусственные нейронные сети возможно использовать для решения задач математической дефектоскопии. Применение подобных механи-

змов позволяет избежать построения громоздких, трудноформализуемых решений. Способность сети к самостоятельному принятию решения на основе имеющегося опыта делает этот аппарат ценным при поиске невыраженных закономерностей, которые трудно выявить обычными методами. В тоже время применение нейронных сетей должно быть тщательно продумано и обосновано, т.к. вполне рационально при выборе метода решения следовать принципу Оккама. Классификация же сетей по области применения ставит своей целью облегчить выбор архитектуры при решении конкретной задачи.

### Литература

1. Осовский С. Нейронные сети для обработки информации / Пер. с польского И.Д. Рудинского. - М.: Финансы и статистика, 2002.
2. Ту Дж., Гонсалес Р. Принципы распознавания образов. - М.: Издательство "Мир", 1978.
3. Hanek H., Ansari N. Speeding up the generalized adaptive neural filters. *IEEE Trans. Image Process.* 5(5), 1996, pp. 705-712.
4. Zhang Z.Z., Ansari N. Structure and properties of generalized adaptive neural filters for signal enhancement. *IEEE Trans. Neural Networks* 7(4), 1996, pp.857-868.
5. Qian W., Kallergi M., Clarke L.P. Order static-neural network hybrid filters for gamma-camera-bremsstrahlung image restoration. *IEEE Trans. Med. Imaging* 12(1), 1993, pp. 58-64.
6. Guan L., Anderson J.A., Sutton J.P. A network of networks processing model for data regularization. *IEEE Trans. Neural Networks* 8(1), 1997, pp. 169-174.
7. Rizvi S.A., Wang L.C., Nasrabadi N.M. Nonlinear vector prediction using feed-forward neural networks. *IEEE Trans. Image Process.* 6(10), 1997, pp. 1431-1436.
8. Tzovaras D., Strintzis M.G. Use of nonlinear principal component analysis and vector quantization for data coding. *IEEE Trans. Image Process.* 7(8), 1998, pp. 1218-1223.
9. Weingessel A., Biscof H., Hornik K. Adaptive combination of PCA and VQ networks. *IEEE Trans. Neural Networks* 8(5), 1997, 1208-1211.
10. Amerijckx C., Verleysen M., Thissen P. Image compression by self-organized Kohonen map. *IEEE Trans. Neural Networks* 9(3), 1998, pp. 503-507.
11. Dony R.D., Haykin S. Optimally adaptive transform coding. *IEEE Trans. Image Process.* 4(10), 1995, pp.1358-1370.
12. Oja E. A simplified neuron model as a principal component analyzer. *J. Math. Biol.* 15(3), 1982, pp. 267-273.

13. Oja E. Neural networks, principal components, and subspaces. *Int. J. Neural Systems*. 1 (1), 1989, pp. 61-68.
14. Kramer M. Nonlinear principal component analysis using autoassociative neural networks. *Am. Ins. Chem. Eng. J.* 37(2), 1991, pp. 223-243.
15. Usui S., Nakauchi S., Nakano M. Internal color representation acquired by five-layer neural network. *Proceedings of the International Conference on Artificial Neural Networks, Helsinki, Finland, 1991*, pp. 867-872.
16. Abbas H.M., Fahmy M.M. Neural networks for maximum likelihood clustering. *Signal Processing*, 36(1), 1994, pp. 111-126.
17. Shustorovich A. A subspace projection approach to feature extraction - the 2D Gabor transform for character recognition. *Neural Networks*, 7(8), 1994, pp. 1295-1301.
18. Lampinen J., Oja E. Distortion tolerant pattern recognition based on self-organizing feature extraction. *IEEE Trans. Neural Networks* 6(3), 1995, pp. 539- 547.
19. Ahmed M.N., Farag A.A. Two-stage neural network for volume segmentation of medical images. *Pattern Recognition Lett.*(11-13), 1997, pp. 1143-1151.
20. Hall L.O., Bensaid C., Clarke L.P. A comparison of neural network and fuzzy clustering techniques in segmentation magnetic resonance images of the brain. *IEEE Trans. Neural Networks*, 3(5), 1992, pp.672-682.
21. Le D.X., Thoma G.R., Wechsler H. Classification of binary document images into textual or nontextual data blocks using neural network models. *Mach. Vision Appl.* 8(5), 1995, pp.289-304.
22. Дударь З.В., Шуклин Д.Е. Семантическая нейронная сеть, как формальный язык описания и обработки смысла текстов на естественном языке. *Радиоэлектроника и информатика. - X.: Изд-во ХТУРЭ, 2000. - № 3. С. 72-76.*
23. Foresti G.L., Pieroni G. Exploiting neural trees in range image understanding. *Pattern Recognition Lett.* 19 (9) (1998) 869-878.
24. Reinus W.R., Wilson A.J., Kalman B. Diagnosis of focal bone lesions using neural networks, *Invest. Radiol.* 29 (6) (1994) 606-611.
25. Stassopoulou A., Petrou M., Kittler J., Bayesian and neural networks for geographic information processing, *Pattern Recognition Lett.* 17 (13) (1996) 1325-1330.
26. Tickle A.B., Andrews R., Golea M. The truth will come to light: directions and challenges in extracting the knowledge embedded within trained artificial neural networks, *IEEE Trans. Neural Networks* 9 (6) (1998) 1057-1068.

27. Bertin E., Bischof H., Bertolino P. Voronoi pyramids controlled by Hopfield neural networks, *Comput. Vision Image Understand.* 63 (3) (1996) 462-475.
28. Chen T.W., Lin W.C. A neural network approach to CSG-based 3-D object recognition, *IEEE Trans. Pattern Anal. Mach. Intell.* 16 (7) (1994) 719-726.
29. Chung P.C., Tsai C.T., Chen E.L. Polygonal approximation using a competitive Hopfield neural network, *Pattern Recognition* 27 (11) (1994) 1505-1512.
30. Nasrabadi N.M., Choo C.Y., Hopfield network for stereo correspondence, *IEEE Trans. Neural Networks* 3 (1) (1992) 5-13.
31. Ruichek Y., Postaire J.-G. A neural matching algorithm for 3-D reconstruction from stereo pairs of linear images, *Pattern Recognition Lett.* 17 (4) (1996) 387-398.
32. Shen D., Ip H.H.S. A Hopfield neural network for adaptive image segmentation: an active surface paradigm, *Pattern Recognition Lett.* 18 (1) (1997) 37-48.
33. Suganthan P.N., Teoh E.K., Mital D.P. Pattern recognition by graph matching using the Potts MFT neural networks, *Pattern Recognition* 28 (7) (1995) 997-1009.
34. Suganthan P.N., Teoh E.K., Mital D.P. Optimal mapping of graph homomorphism onto self organising hopfield network, *Image Vision Comput.* 15 (9) (1997) 679-694.
35. Yu S.-S., Tsai W.-H. Relaxation by the Hopfield neural network, *Pattern Recognition* 25 (2) (1992) 197-210.
36. Рычагов М.Н. Нейронные сети: многослойный перцептрон и сети Хопфилда // *Exponenta Pro. Математика в приложениях.* - 2003. - № 1(1). - С. 29-37.
37. Малайчук В.П., Мозговой А.В. Математическая дефектоскопия: Монография.—Днепропетровск: Системные технологии, 2005.
38. Петренко А.Н., Кучеренко А.Е. Метод автоматической локализации и классификации дефектов // *Системні технології. Регіональний міжвузівський збірник наукових праць.*—Випуск 5(52).—Дніпропетровськ, 2007. С. 59-64.
39. Петренко А.Н., Кучеренко А.Е. нейросетевой метод решения обратной задачи электроимпедансной томографии // *Системні технології. Регіональний міжвузівський збірник наукових праць.*—Випуск 1(54).—Дніпропетровськ, 2008. С. 58-65.

*Получено 21.04.2008*