

УДК 004

***ПРИМЕНЕНИЕ НЕЙРОННЫХ СЕТЕЙ ДЛЯ РЕШЕНИЯ
ПРАКТИЧЕСКИХ ЗАДАЧ В ЭКОНОМИКЕ***

Науменко В.А.

Магистр

Национальный Исследовательский Ядерный Университет «МИФИ»,

Москва, Россия

Аннотация: в данной статье приводится краткий обзор искусственных нейронных сетей, принципы построения различных классических архитектур, их особенности, их актуальность на сегодняшний день и области применения. В том числе рассматриваются важные практические задачи экономики, решения которых были реализованы на основе логики нейросетей.

Ключевые слова: искусственные нейронные сети, аппроксимация, прогнозирование, оптимизация, персептрон, самоорганизующиеся карты.

***THE APPLICATION OF NEURAL NETWORKS FOR SOLVING PRACTICAL
PROBLEMS IN ECONOMICS***

Naumenko V.A.

Master

National Research Nuclear University “MEPhI”

Moscow, Russia

Abstract: This article provides a brief overview of artificial neural networks, the principles of construction of various classical architectures, their features, their relevance to date and applications. In particular, we consider important practical problems of the economy, the solutions of which were implemented on the basis of the logic of neural networks.

Keywords: artificial neural networks, approximation, prediction, optimization, perceptron, self-organising maps.

При решении реальных задач часто возникает ситуация, когда задачу трудно формализовать и решать её аналитически. С этой проблемой столкнулись еще в середине прошлого века. Однако выход был найден. Как раз в то же время и появились искусственные нейронные сети, которые способствовали решению данной проблемы, и использующиеся по сей день в самых различных областях человеческой деятельности. На название "Нейронные сети" сейчас претендуют все вычислительные структуры, которые в той или иной степени моделируют работу мозга. То есть они в какой-то степени соблюдают те же принципы и методы функционирования, которые заложены в нервных клетках живого организма [11]. Но такое моделирование, в основном, является очень фрагментарным, и говорить о создании в ближайшем будущем искусственного мозга или даже некоторой его модели, которая дублировала бы работу мозга самых примитивных живых существ, еще рано.

В настоящее время известно довольно обширное число областей применения искусственных нейронных сетей, в которых человеческий интеллект малоэффективен, а аналитические вычисления достаточно трудоемки и физически неадекватны. Приведем наиболее распространенные из них: финансы, экономика, производство, медицина, военная промышленность и авиация, энергетика, научные исследования, информационные технологии, искусственный интеллект и т.д.

На сегодняшний день существует огромное количество программного обеспечения, использующего возможности технологии искусственных нейронных сетей (ИНС). Существуют универсальные программы, решающие при помощи ИНС задачи от распознавания речи, лиц до решения задач прогнозирования [2,4,15].

Известны следующие типы программного обеспечения: универсальные и прикладные программные продукты для моделирования ИНС (Neural Network Simulators).

Универсальные или как еще называют объектно – инвариантные программные среды предоставляют возможность проводить синтез оптимальных нейронных сетей, которые нашли свое применение в решении большого класса задач. Приведем некоторые примеры универсального ПО: Matlab Neural Network Toolbox, Trajan, Delta, X-Sim, Brain Wave, VieNet2, NeuroWindows, Aspirin/MIGRAINES, Atree, Cnaps, ICSIM, Neural Shell, Senkom, SOMPAK, Xerion, Nets.

Прикладные же среды программного моделирования в большинстве своем предназначены для синтезирования ИНС в различных специфических и узкоспециализированных задачах.

Важнейшим свойством нейросетевых симуляторов ПО является способность синтезировать код программы результирующей нейронной сети на алгоритмическом языке высокого уровня. В дальнейшем такой код проще интегрировать в любую пользовательскую программу.

Искусственная нейронная сеть - математическая модель, а также ее программная или аппаратная реализация, построенная по принципу организации и функционирования биологических нейронных сетей - сетей нервных клеток живого организма. Это понятие возникло в ходе изучения процессов, протекающих в мозге, в частности при попытке моделирования этих процессов [17]. С математической точки зрения обучение нейронных сетей - это многопараметрическая задача нелинейной оптимизации. Возможность обучения – одна с основных положительных сторон нейронных сетей перед классическими алгоритмами. Технически обучение заключается в определении коэффициентов связей среди нейронов. В ходе обучения нейронная сеть может

Вектор экономики | www.vectoreconomy.ru | СМИ Эл № ФС 77-66790, ISSN 2500-3666

обнаруживать сложные связи между входными и выходными данными и помимо этого осуществлять синтез. Возможности нейронной сети к моделированию непосредственно вытекают из ее возможности к обобщению и выделению скрытых связей среди входных и выходных данных. После обучения сеть может прогнозировать предстоящее значение определенной последовательности на основе некоторых предшествующих значений и/или каких-то имеющихся в данный период условий. Необходимо выделить, то что моделирование возможно только лишь в тех случаях, когда предшествующие изменение на самом деле в той или иной степени предопределяют будущее.

Проблема обучения многослойных нейронных сетей была решена в середине 1980-х годов методом обратного распространения ошибки (Backpropagation) [12,13]. Это итеративный градиентный алгоритм, который используется с целью минимизации ошибки работы нейронной сети, обеспечивает получение желаемого результат. Для определения качества работы нейронной сети используют функцию потерь (loss function). Обычно за такую функцию выбирают евклидово расстояние, среднеквадратичную погрешность или функцию кросс-энтропии [14].

В качестве основных ИНС можно выделить следующие:

- Сети прямого распространения;
- Сеть радиально-базисных функций;
- Самоорганизующиеся карты или Сети Кохонена;

В сетях с прямым типом распространения все связи от входных нейронов направлены строго к выходным. К этим сетям можно отнести простейший персептрон и многослойный персептрон. Персептрон - одна из первых моделей нейронных сетей. Несмотря на свою простоту, персептрон способен учиться и решать достаточно сложные задачи. Основная математическая задача, с которой он справляется - это линейное разделение любых нелинейных

Вектор экономики | www.vectoreconomy.ru | СМЭ Эл № ФС 77-66790, ISSN 2500-3666

множеств, так называемое обеспечение линейной сепарабельности. Стоит отметить, что персептрон Розенблатта является одной из имплементаций персептрона. Типичная архитектура многослойного персептрона схематически изображена на рис. 1.




Рис. 1 - Архитектура многослойного персептрона

Персептрон состоит из трех типов элементов, а именно: сигналов, поступающих от датчиков, которые передаются в ассоциативные элементы, а затем в реагирующие. Таким образом, персептроны позволяют создать набор «ассоциаций» между входными стимулами и необходимой реакцией на выходе [7]. В биологическом плане это соответствует превращению, например, зрительной информации в физиологический ответ двигательных нейронов.

Персептрон применяется для решения классических задач машинного (классификация, регрессия) обучения как отдельная модель, так и в составе более сложных моделей.

Сеть радиально - базисных функций – это вид нейросети, которая имеет скрытый слой, состоящий из радиальных элементов, и выходной слой из линейных элементов. На рис. 2 изображена сама нейросеть. Сети, принадлежащие к этому типу, являются компактными и быстро обучаются [16]. Впервые упоминаются в работах Broomhead and Lowe 1988 г. и Moody and

Darkin 1989 г. Сети этого типа обладают следующими особенностями: присутствует один скрытый слой, нелинейная активационная функция есть лишь у нейронов скрытого слоя и синаптические веса, относящиеся к входному и скрытому слоям, равны единице.




Рис. 2 - Сеть радиально - базисных функций

Самоорганизующиеся карты или Сети Кохонена – это класс сетей, которые обучаются без учителя и успешно применяется в задачах распознавания, прогнозирования и аппроксимации. Структура сети изображена на рис. 3. Сети такого класса могут выявлять новизну во входных данных: если после обучения сети встретится набор данных, непохожий ни на один из известных образцов, то у неё не получится классифицировать данный набор и таким образом выявит его новизну. Сеть Кохонена состоят только из двух слоев: входного и выходного, состоящего из радиальных элементов [1,6,10]. Сети Кохонена используются для визуализации и первичного анализа данных.




Рис. 3 - Сеть Кохонена

В Таблице 1 приведено сопоставление ИНС и решаемых ими экономических задач.

Таблица 1 – Сопоставление типов задач и применяемых для их решения ИНС

Тип задачи	Применяемые ИНС
Задача прогнозирования	Персептрон
	Сеть радиально-базисных функций
Задача аппроксимации	Персептрон
	Сеть радиально-базисных функций
Задача оптимизации	Сеть Кохонена

Решение описанных в таблице задач возможно именно благодаря способности нейронной сетей определять функциональные зависимости между величинами исключительно на основе входных и соответствующих выходных значений. Вынесение аппроксимации функции в отдельную задачу обусловлено широким применением нейронных сетей для аппроксимации явно и неявно выраженных функциональных зависимостей в широком кругу прикладных

задач, таких как: прогнозирование, фильтрация, сглаживание, оптимизация, управление объектами в условиях структурной и параметрической неопределенности, проектирование материальных объектов и тому подобное [3,8,9].

Практическое применение нейронных сетей, особенно в задачах проектирования, в том числе синтеза, материальных объектов, связано с решением проблем, вызванных особенностями, характерными именно для этой области, поэтому и подходы к их решению должны отличаться от классических.

Для аппроксимации функции традиционно применяют многослойную нейронную сеть с нелинейной функцией активации, которая учится с помощью алгоритма обратного распространения. Доказано, что уже двухслойной нейронной сети достаточно для аппроксимации любой непрерывной функции, хотя оптимальным является использование трех слоев. Существует две основные проблемы при применении такой архитектуры и метода обучения: паралич сети и попадание алгоритма обучения к локальному минимуму.

Паралич сети вызывает значительный рост весовых коэффициентов синаптических связей в результате чего растут исходные значения нейрона (которые соответствуют участкам с низкой крутизной функции активации). Это в свою очередь приводит к уменьшению значения производной функции активации и, соответственно, уменьшается величина погрешности при обратном ходе, обучение замедляется почти до полной остановки. Попадание сети во время обучения к локальному минимуму обусловлено особенностями расчетного процесса (часто проявляется при использовании, например, метода градиентного спуска). В точке локального минимума движение во всех направлениях будет приводить к росту погрешности обучения и сеть не способна будет самостоятельно из него выйти.

Нейронные сети прекрасно себя проявляют в задачах оптимизации. Например, оптимизация товарно-денежных потоков, процессов производства, логистике, оценках риска. Сегодняшнее проведение каких-либо маркетинговых исследований сопровождается использованием нейросетей, и это дает значительное улучшение результатов. Кроме того, появилась возможность хоть и частичной оценки социально-экономических систем, которые ранее поддавались анализу только методом экспертной оценки.

Менее чем за полувековую историю существования теории искусственных нейронных сетей было доказана эффективность их применения для решения многих реальных задач. ИНС довольно успешно нашли свое применение в анализе и прогнозировании на финансовом рынке, при построении медицинской диагностики:

- Прогнозирование уровня спроса на новый продукт/услугу;
- Оценка платежеспособности банковских клиентов;
- Оценка эффективности проектов на основе большого количества показателей;
- Оценка рисков;
- Прогнозирование объема продаж.

Достаточно широко нейронные сети нашли свое отражение в таких отраслях науки как робототехника и системы управления. Как явный и самый очевидный пример этому – целые разновидности электронных домашних игрушек, которые ведут себя как «живые» существа, могут приобретать индивидуальные черты характера и могут обучаться [5].

В любой области, где только можно построить четкий алгоритм решения задачи заложен принцип построения нейронной сети: распознавание текста, при выделении отдельного элемента изображения, сочинение музыки, предсказание погоды и др.

Чрезвычайно эффективен принцип построения нейронных сетей: распределенная обработка информации независимыми друг от друга простейшими вычислителями.

В основе ИНС лежит принцип объединения простых вычислителей, что делает их способными создавать мощные программные, вычислительные комплексы с высокой степенью надежности и выполнением условий параллелизма.

Таким образом, нейронные сети, благодаря своей гибкости и универсальности, является эффективным инструментом решения широкого круга прикладных задач. Однако их использование обычно связано с решением вопросов, специфических для конкретного практического применения.

Архитектура и правила обучения нейронных сетей, как правило, носят ситуационный характер - разрабатываются для решения определенных (или группы родственных) задач, поэтому важно понимание принципов и особенностей их работы, что позволит профессионально подходить к вопросу выбора готовых или создания новых алгоритмов обучения.

Библиографический список

1. Бодянский Е.В. Искусственные нейронные сети: архитектуры, обучение, применения / Е.В. Бодянский, О.Г. Руденко — Харьков: ТЕЛЕТЕХ, 2004. — 369с.
2. Гайнуллин Р. Н. и др. Прогнозирование бизнес-процессов на основе нейронных сетей //Вестник Казанского технологического университета. – 2017. – Т. 20. – №. 3.
3. Гусева, Анна Ивановна. Вычислительные системы, сети и телекоммуникации: учебник для студентов вузов / А. И. Гусева, В. С. Киреев. - М.: Академия, 2014. - 288 с.

4. Катасёв А. С., Катасёва Д. В., Кирпичников А. П. Нейросетевая биометрическая система распознавания изображений человеческого лица // Вестник Казанского технологического университета. – 2016. – Т. 19. – №. 18.
5. Климанов С.Г. Долгосрочное прогнозирование объемов продаж продукции компании на международных рынках обогащенного урана в условиях ограничений и квот/С. Г. Климанов и [др.] // Вестник национального исследовательского ядерного университета "МИФИ". - 2016. - т. 5, N № 3.- С.254-261.
6. Круглов В.В. Искусственные нейронные сети. Теория и практика / В.В. Круглов, В.В. Борисов. — М.: Горячая линия — Телком, 2002. — 382с. — ISBN 5- 93517-031-0.
7. Посмаков Н.П., Емельяненко А.С. Архитектура нейронной сети // ТПИ Наука. – 2017. – №6(18) – С.34-43.
8. Сидоренко Е.В. Средства визуализации и отображения взаимосвязей финансовых показателей в системах поддержки принятия управленческих решений / Е. В. Сидоренко, А. Н. Тихомирова; рец. А. И. Гусевой // Аудит и финансовый анализ. - 2010. - N 2. - С. 354-357
9. Тихомирова А.Н., Сидоренко Е.В. Математические модели и методы в логистике: Учебное пособие. - М.: НИЯУ МИФИ, 2010. – 320с.
10. Хайкин С. Нейронные сети. Полный курс / С. Хайкин — М.: Вильямс, 2006 — 1104 с.
11. Червяков Н. и др. Применение искусственных нейронных сетей и системы остаточных классов в криптографии. – Litres, 2018.
12. Amari S.I. Statistical theory of learning curves under entropic loss criterion / S.I. Amari, N. Murata // Neural Computation. — Vol. 5, N 1. — 1993. — P. 140–153.
13. Goodfellow I. Deep Learning / Goodfellow I., Bengio Y. and Courville A.; Cambridge MA: MIT Press [2017] – 777 pages.
14. LeCun Y. Deep learning / Y. LeCun, B. Yoshua, H. Geoffrey // Nature. — Vol. 521, N 7553. — 2015. — P. 436–444.

15. McCulloch W.S. A logical calculus of the ideas immanent in nervous activity / W.S. McCulloch, W. Pitts // The bulletin of mathematical biophysics. — Vol. 5, N 4. — 1943. — P. 115–133.
16. Rosenblatt F. The Perceptron: a probabilistic model for information storage and organization in the brain/ F. Rosenblatt // Cornell Aeronautical Laboratory, Psychological Review — 1958 — vol.65, No. 6 — P. 386—408.
17. Rumelhart D.E. Learning representations by back-propagating errors / D.E. Rumelhart, G.E. Hinton, R.J. Williams // Cognitive modeling. — Vol. 5, N 3. — 1988. — P. 213–220.

Оригинальность 81%