

## АППРОКСИМАЦИЯ С ПОМОЩЬЮ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ

Реимбаев Хушнудбек ,

магистрант Ташкентский университет

информационных технологий имени Мухаммада аль-Хоразмий

### Аннотация:

В этой работе описываются основные принципы функционирования и обучения искусственных нейронных сетей (ИНС), акцентируя внимание на их способности к адаптации и оптимизации для решения разнообразных задач. Рассматривается структура ИНС, вдохновленная человеческим мозгом, и как это влияет на их вычислительные возможности, включая способность аппроксимировать функции с заданной точностью. Особое внимание уделено процессу обучения, в ходе которого ИНС корректируют свои веса на основе обучающих данных для минимизации ошибок, используя методы, такие как обратное распространение ошибки. Обсуждается важность выбора структуры сети и метода обучения для успешной адаптации сети к конкретным задачам. Тексты подчеркивают сложность процесса обучения ИНС и его зависимость от множества факторов, включая качество обучающих данных и архитектуру сети.

**Ключевые слова:** Искусственные нейронные сети (ИНС), Обучение, Адаптация, Минимизация ошибки, Обратное распространение ошибки, Архитектура сети, Вычислительные возможности, Аппроксимация функций, Оптимизация весов, Выбор метода обучения

### Введение

Система искусственных нейронных сетей (ИНС) вдохновлена научными работами о биологических системах, в частности, о человеческом мозге. В техническом смысле ИНС представляет собой параллельный распределенный процессор, который сконструирован из базовых вычислительных единиц — нейронов, задачей которых является хранение эмпирических знаний и обеспечение их доступности для последующего использования. Этот процессор обладает двумя характеристиками, сходными с функциями



человеческого мозга: во-первых, сеть извлекает знания из своего окружения через процесс обучения, и во-вторых, использует силу связей между нейронами, известных как веса, для хранения этих знаний [1].

### Основная часть

Каждый искусственный нейрон определяется соотношением между его входами и выходами и выполняет определенную локальную операцию. Результат работы нейрона полностью зависит от его входных и выходных данных, взаимосвязей с другими нейронами и, возможно, от внешних сигналов. Структура нейронной сети, используемый метод обучения и спецификации нейронов задают её функциональность. В этом исследовании фокус сделан на нейронные сети с прямым распространением (НСПР). В таких сетях все связи между нейронами ориентированы в одном направлении, и нейроны упорядочиваются по слоям. Входные данные проходят через входной слой, а результаты представляются на выходном слое. Все остальные нейроны распределены по одному или нескольким скрытым слоям. Каждый нейрон одного слоя соединен со всеми нейронами следующего слоя. Скрытые слои значительно расширяют функциональные возможности нейронной сети, поскольку добавление таких слоев позволяет сети обрабатывать информацию более сложного порядка [1]. Этот вид сетей можно охарактеризовать последовательностью целых чисел, указывающих число нейронов в каждом из слоёв. Так, искусственная нейронная сеть с структурой 2-3-3-1 означает наличие двух нейронов в входном слое, трех нейронов в каждом из первого и второго скрытых слоев, и одного нейрона в выходном слое. Работа такой сети осуществляется через серию повторяющихся действий. Изначально входные сигналы подаются на нейроны входного слоя, в то время как скрытые и выходной слои остаются пассивными. Затем, на втором этапе, нейроны первого скрытого слоя агрегируют и суммируют поступающие к ним сигналы, после чего рассчитывают свои выходные данные для передачи в следующий слой. Этот процесс повторяется для каждого слоя, до тех пор пока не будут получены итоговые значения на выходе сети.

Вычислительные способности нейронных сетей обусловлены их способностью к параллельной обработке данных и адаптации к различным задачам через обучение и обобщение. Эти характеристики позволяют



нейронным сетям эффективно решать сложные задачи. Исследования [2, 3] показывают, что стандартная нейронная сеть с прямым распространением, имеющая всего один скрытый слой, может аппроксимировать любую непрерывную функцию в пределах определённого компактного пространства и любую измеримую функцию с определённой степенью точности. Дополнительно, в исследовании [4] было установлено, что нейронная сеть с прямым распространением, содержащая  $r$  нейронов в скрытом слое, обладает определённой минимальной степенью аппроксимации для любой функции, которая может быть улучшена за счёт добавления дополнительных скрытых слоёв. Майров и Пинкус в [4] продемонстрировали, что на единичном кубе в пространстве  $R^n$  любую непрерывную функцию можно аппроксимировать с любой заданной точностью при помощи нейронной сети с двумя скрытыми слоями, где первый слой содержит  $2n + 1$  нейрон, а второй —  $4n + 3$  нейрона. Отсюда следует, что эффективность использования нейронных сетей в определённых задачах может зависеть от качества обучения, количества скрытых слоёв или наличия связи между входными и выходными данными. Применение этого мощного вычислительного инструмента к задачам криптографии, основанным на дискретных алгебраических структурах, привело к аналогичным выводам.

В процессе обучения веса нейронной сети корректируются путем подачи на ее входы учебных примеров, известных как образы, у которых заранее известны результаты на выходе. Основная задача обучения заключается в подборе таких значений весов  $W$ , чтобы минимизировать различие между ожидаемым результатом и фактическим выходом сети. Адаптация начинается с представления сети всех учебных образов и расчета общей ошибки  $E$ , представляющей собой сумму ошибок для каждого учебного примера, обозначаемую как  $E = \sum_{k=1}^P E_k$ , где  $P$  обозначает общее число обучающих образов, а  $E_k$  — это ошибка сети для  $k$ -го обучающего примера, вычисленная как сумма квадратов разностей между актуальным выходом и ожидаемыми значениями для данного примера.

Обучающие образы могут быть представлены нейронной сети многократно, но в каждом случае в различной последовательности. Один цикл предъявления всего набора учебных данных  $T$  называется периодом обучения. Если процедура адаптации эффективно уменьшает общую ошибку, то достижение



цели обучения подтверждается. Такой процесс обучения представляет собой сложную задачу оптимизации. Метод обратного распространения ошибки является одним из самых распространенных подходов, который использует градиентный спуск для оптимизации [1]. Во время обучения с обратным распространением ошибки, в каждую эпоху  $t$  происходит корректировка весов, пропорциональная градиенту функции ошибки  $E(w)$ . Этот процесс продолжается до достижения сетью стабильного состояния, когда изменения весов становятся незначительными, или когда общая ошибка падает ниже заранее установленного порога. В таком случае предполагается, что сеть «удовлетворительно» освоила задачу. Общее количество необходимых эпох обучения может служить мерой эффективности используемого метода. Для более сложных методов обучения существуют дополнительные исследования [1, 5–10].

### Заключение

Из обсуждения искусственных нейронных сетей (ИНС) следует, что их способность к обучению и адаптации делает их мощным инструментом для решения широкого спектра задач. Архитектура ИНС, вдохновленная человеческим мозгом, позволяет им эффективно аппроксимировать различные функции и обрабатывать данные в параллельной манере. Ключевым аспектом успешного применения ИНС является их способность минимизировать ошибку через процесс обучения, при котором корректируются веса на основе предоставленных данных. Метод обратного распространения ошибки выделяется как основной способ оптимизации весов сети. Тем не менее, достижение оптимальной производительности ИНС зависит от множества факторов, включая структуру сети, качество обучающих данных и выбор метода обучения. Таким образом, хотя ИНС обладают значительным потенциалом, их успешное применение требует тщательного планирования и настройки.



## Литература

1. Haykin S. Neural Networks. — Macmillan College Publishing Company, 1999. — 842 p.
2. Hornik K. Multilayer feedforward networks are universal approximators // Neural Networks. 1989. V. 2. P. 359–366.
3. White H. Connectionist nonparametric regression: multilayer feedforward networks can learn arbitrary mappings // Neural Networks. 1989. V. 2. P. 359–366.
4. Pincus A. Approximation theory of the MLP model in neural networks // Acta Numerica. 1999. P. 143–195.
5. Kohonen T. Self-Organized Maps. — Berlin: Springer, 1997. — 501 p.
6. Magoulas G. D., Plagianakos V. P., Vrahatis M. N. Adaptive stepsize algorithms for on-line training of neural networks // Nonlinear Analysis T.M.A. 2001. V. 47, № 5. P. 3425–3430.
7. Magoulas G. D., Vrahatis M. N., Androulakis G. S. Effective backpropagation training with variable stepsize // Neural Networks. 1997. V. 10, № 1. P. 69–82.
8. Magoulas G. D., Vrahatis M. N., Androulakis G. S. Increasing the convergence rate of the error backpropagation algorithm by learning rate adaptation methods // Neural Computation. 1999. V. 11, № 7. P. 1769–1796.
9. Riedmiller M., Braun H. A direct adaptive method for faster backpropagation learning: The RPROP algorithm // IEEE International Conference on Neural Networks, San Francisco, CA. 1993. P. 586–591.
10. Vrahatis M. N., Androulakis G. S., Lambrinos J. N., Magoulas G. D. A class of gradient unconstrained minimization algorithms with adaptive stepsize // J. Comput. Appl. Math. 2000. V. 114, № 2. P. 367–386.

