

## **ОТЛАДКА И СОПОСТАВЛЕНИЕ НЕЙРОСЕТЕВЫХ АЛГОРИТМОВ САН И АДФ**

**Терешин С.В., Мокогон Д.А.**

**научный руководитель канд. техн. наук Ланкин Ю.П.**

**научный руководитель канд. техн. наук Каргушинский А.В.**

*Сибирский федеральный университет*

Понимание и прогнозирование поведения природных систем является одной из наиболее важных задач современной науки. Создание достаточно точных и подробных моделей Биосферы, ее экосистем, атмосферы и гидросферы позволяет надеяться найти способы преодоления глобального экологического кризиса, протекающего в настоящее время на нашей планете, повысить точность метеорологических и климатических прогнозов и т.д. Однако моделирование природных систем представляет собой весьма непростую задачу из-за сложности самих систем. Природные системы состоят из огромного числа элементов и подсистем. Связи между этими элементами имеют сложную структурную организацию, особенно между элементами Биосферы. На любую природную систему оказывается множество внешних влияний, а сама система, в свою очередь, оказывает воздействие на другие природные системы. Поэтому такие структуры Биосферы, атмосферы и гидросферы чрезвычайно сложны как для понимания, так и для описания существующими методами моделирования.

Нужно отметить, что современная наука добилась больших достижений в понимании и моделировании сложных природных систем.

Однако по-прежнему остается ряд нерешенных фундаментальных научных проблем. Среди них: проклятье размерности, потеря устойчивости моделей природных систем с ростом их сложности (что противоречит свойствам реальных природных систем), не стационарность, нелинейность свойств природных систем и другие особенности, порождающие трудности моделирования.

Одним из наиболее эффективных средств для решения задач моделирования систем и большой размерности с квазистационарным поведением, являются искусственные нейронные сети. Во многих случаях нейронные сети проще для понимания, чем традиционные методы. В нейронных сетях используются универсальные алгоритмы обработки информации в самых разных задачах с различными данными. Сети высокоэффективны в задачах нахождения зависимостей, закономерностей и взаимосвязей внутри системы и между системами. Нейросетевые методы обладают большим преимуществом при необходимости оперативной обработки данных и дают возможность решать очень сложные многомерные задачи путем обучения сети без необходимости построения аналитических или численных моделей вручную.

Нейронная сеть представляет собой совокупность вычислительных блоков, называемых нейронами, соединённых между собой каналами связи, называемыми синапсами. На рисунке 1.б представлен пример организации нейронов в сети.

Формальный нейрон представляет собой нелинейный преобразователь, на вход которого, через синапсы подаются возмущающие сигналы, а с выхода снимается результат функционирования. Структурная схема нейрона представлена на рисунке 1.а.

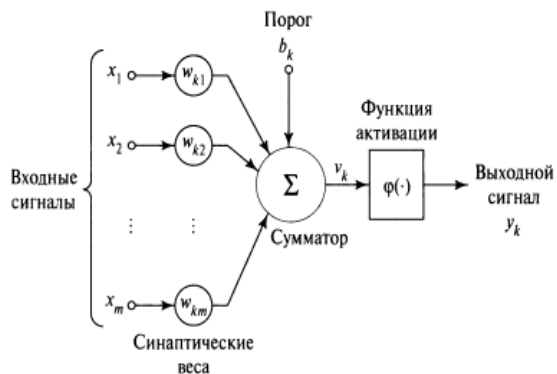


Рисунок 1.а – Схема нейрона

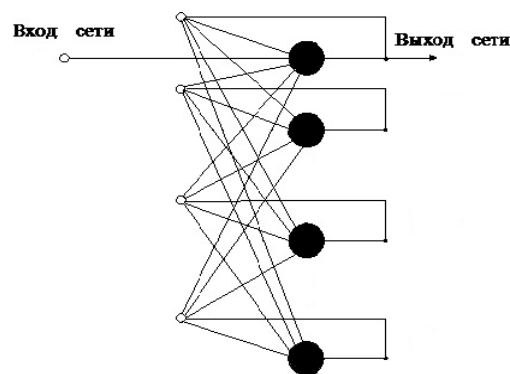


Рисунок 1.б - Архитектура ИНС

В зависимости от решаемой задачи, архитектура и количество нейронов в сети могут меняться. На рисунке 1.б представлена архитектура одного из вариантов полносвязной сети все нейроны которой соединены друг с другом.

Работа нейронной сети описывается взаимодействием ее нейронов, включающим две процедуры – функционирование и обучение.

Обучение это процесс работы нейронной сети, при котором синаптические веса нейронов модифицируются, с целью уменьшить ошибку между получаемым выходом сети и желаемым результатом.

Функционирование это процесс работы обученной нейронной сети.

Для правильной настройки нейронной сети для решения требуемых задач, необходимо иметь хороший алгоритм обучения. Существует ряд базовых и множество разновидностей алгоритмов обучения нейронных сетей.

Новый алгоритм обучения нейросетей САН разработан Ю. П. Ланкиным (канд. техн. наук, научный сотрудник ИБФ СО РАН) в рамках предложенной им теории «самоорганизующихся адаптивных систем». Особенность данного алгоритма состоит в том, что его использование дает возможность моделировать длинные временные ряды данных, сложные адаптивные структуры и взаимодействие сложных адаптивных систем. Это необходимо для моделирования и прогнозирования поведения сложных природных систем и процессов, которые взаимодействуют между собой. Возможность работы с большими объемами данных делает алгоритм САН очень полезным для обработки спутниковых наблюдений Земли за большой период времени.

Основная идея алгоритма заключается в том, что помимо обычного функционирования сети производится параллельное функционирование этой же сети, так называемое эталонное. При втором функционировании значение сигналов, полученное на выходных нейронах (результат функционирования) заменяется на желаемое значение, после чего вычисляется ошибка. Далее производится корректировка весов в нужную сторону для получения желаемого результата при первом (обычном) функционировании.

Для сопоставления обучения нейронной сети новым алгоритмом был выбран алгоритм обучения нейронных сетей АДФ.

Алгоритм АДФ имеет хорошее математическое обоснование и многократно применялся для решения широкого спектра задач. Однако он имеет ряд недостатков, что делает его использование затруднительным для моделирования природных процессов.

Впервые метод был описан в 1974 г. А.И. Галушкиным, а также независимо и одновременно Полом Дж. Вербосом. Далее существенно развит в 1986 г. Дэвидом И.

Румельхартом, Дж. Е. Хинтоном и Рональдом Дж. Вильямсом и независимо и одновременно В.А. Охониным и С.И. Барцевым (ИБФ СО РАН, Красноярск). В дальнейшем на его основе возникла красноярская школа нейроинформатики под руководством А. Н Горбаня. Это итеративный градиентный алгоритм, который используется с целью минимизации ошибки работы многослойного перцептрона и получения желаемого выхода. А с 1986 года появилась возможность обучения динамических сетей для работы на коротких интервалах времени.

Основная идея этого метода состоит в распространении сигналов ошибки от выходов сети к её входам, в направлении, обратном прямому распространению сигналов в обычном режиме работы.

Несмотря на многочисленные успешные применения алгоритма обратного распространения, он не является универсальным. Алгоритм АДФ обладает рядом ограничений не позволяющих ему работать с длинными рядами данных, что сильно осложняет или делает его непригодным при моделировании и прогнозировании сложных природных процессов. Это обусловлено рядом причин:

- 1) При усложнении архитектуры сети быстро растет сложность понимания и реализации;
- 2) Быстрое затухание ошибки при обратном распространении, как уже было сказано, создает проблему для обучения сети на длинных рядах данных;
- 3) Необходимость остановки работы сети для выполнения обратного распространения ошибки

Однако, с учетом указанных ограничений, благодаря тому, что АДФ применялся для решения широкого спектра задач, таких как распознавание образов, классификация, кластирезация, сжатие данных и т.п., он может использоваться в качестве своеобразного эталона для сравнения.

В нашей работе алгоритм АДФ применялся как инструмент проверки успешного обучения конкретной задаче. Т.е. если алгоритм АДФ нашел решение для поставленной задачи то, следовательно, алгоритм САН должен обучаться не хуже, а в перспективе лучше.

Для сравнения обучения нейронной сети подготовлены векторы требуемых значений разной длины, приведенные в таблице 1.

Таблица 1 – тестовый набор сигналов

№ сигнала	Количество точек	Набор точек
1	3	0,1; 0,25; 0,05
2	6	0,1; -0,25; 0,15; -0,25; 0,14; 0,36
3	11	0,1; -0,25; 0,15; -0,25; 0,14; 0,36; 0,12; -0,34; 0,25; 0,43; 0,12

В обоих вариантах сети с алгоритмами обучения АДФ и САН начинают с одинаковых начальных значений весов синапсов, сгенерированных случайно. Для более детального сравнения наилучших вариантов работы алгоритмов параметры функционирования сети на данном этапе отладки настраиваются вручную. Количество нейронов и параметры сети, настроенные под решаемую задачу, предоставлены в таблице 2. Основным критерием для сравнения выступает оценка функционирования сети, а так же время, за которое сеть обучилась до заданного значения оценки. Ограничение по времени в данном случае берется в 1000 циклов переобучения.

Таблица 2 – результаты сравнения

№ группы эксп-тов	№ сигнала	Алгоритм обучения	Число нейронов	Шаг	Оценка	Время
1	1	АДФ	3	0.02	1.006956e-10	53
1	1	САН	3	0.02	1.035514e-10	64
2	2	АДФ	6	0.003	1.036610e-10	120
2	2	САН	6	0.002	5.517400e-09	150
3	3	АДФ	11	0.0006	3.226651e-07	1000
3	3	САН	11	0.003	1.274233e-05	1000

На основе проделанной работы можно сделать следующие выводы:

1) новый алгоритм демонстрирует результаты обучения близкие к контрольному алгоритму;

2) для реализации описанных преимуществ нового алгоритма требуются дальнейшие исследования, аналогичные тем, что были выполнены при доработке АДФ до его широкого использования при обработке данных.

После окончательной доработки алгоритма предполагается его использования в таких задачах, как моделирование, прогнозирование, восстановление данных, обработка длинных временных рядов, включая информацию со спутников о состоянии природных систем нашей планеты.