

# РАСПОЗНАВАНИЕ ИЗОБРАЖЕНИЙ ЗЁРЕН ПЫЛЬЦЫ, ПОЛУЧЕННЫХ С ПОМОЩЬЮ РАСТРОВОГО ЭЛЕКТРОННОГО МИКРОСКОПА В КОНТЕКСТЕ ПРИМЕНЕНИЯ НЕЙРОННЫХ СЕТЕЙ

**Камалова Юлия Борисовна**

Аспирант, Ижевский государственный технический университет имени М. Т. Калашникова  
pmkk@istu.ru

## THE RECOGNITION OF IMAGES OF POLLEN GRAINS OBTAINED USING A SCANNING ELECTRON MICROSCOPE IN THE CONTEXT OF USING NEURAL NETWORKS

*Yu. Kamalova*

*Summary.* Application of neural networks in tasks of images of pollen grains obtained using a scanning electron microscope, is a regular task that is traditionally solved with the use, and accordingly, it causes a number of problems associated with the choice of neural network architecture, preparation of input and output data, determination of optimal learning algorithms. The solution of these issues is hampered by the lack of standards in this area and a significant amount of anecdotal knowledge about the use of neural networks in various branches of science and industry. Therefore, before the formulation of the implementation of the recognition of images of pollen grains obtained using a scanning electron microscope, it is advisable to see the classic application of neural networks and their methods of training that will allow in the future to avoid problems related to their learning and functioning.

*Keywords:* neural network, function, structure, material object, recognition, training an artificial intelligence.

*Аннотация.* Применение нейронных сетей в задачах распознавания изображений зёрен пыльцы, полученных с помощью растрового электронного микроскопа, не относится к классическим задачам, которые традиционно решаются с их помощью, и соответственно, это приводит к возникновению ряда проблем, связанных с выбором архитектуры нейронной сети, подготовкой входных и выходных данных, определением оптимальных алгоритмов обучения. Решение этих вопросов затруднено отсутствием стандартов в данной области и значительным количеством несистематизированных знаний об использовании нейронных сетей в различных отраслях науки и хозяйства. Поэтому перед постановкой задачи реализации распознавания изображений зёрен пыльцы, полученных с помощью растрового электронного микроскопа, целесообразно ознакомиться с классическим применением нейронных сетей и методов их обучения, что позволит в дальнейшем избежать проблем, связанных с особенностями их обучения и функционирования.

*Ключевые слова:* нейронная сеть, функционирование, структура, материальный объект, распознавание, обучение искусственного интеллекта.

**П**роцедура распознавания зерен пыльцы энтомофильных растений используется в палинологии, апиологии, апимониторинге и аллергодиагностике. Определение принадлежности зерна к виду растения высококвалифицированным оператором — дорогостоящая процедура, но до сих пор являющаяся наиболее точной и эффективной. Впервые применение автоматической системы классификации зерен пыльцы предлагал ввести Джон Фленлей в 1968 году. Однако эта идея была трудноразрешимой в то время из-за технологических ограничений. На сегодняшний день, возможность создания данной системы реальна благодаря успехам компьютерных технологий (в частности, различных задач распознавания — формирования обучающей выборки, обучения системы распознавания, снижения размерности пространства признаков, контроля качества распознавания и др.).

Автоматическое распознавание пыльцы лежит в основе развития полностью автоматизированных систем,

которые сочетают отбор проб, осаждения частиц на поверхность, подходящую для оптического анализа, автоматическую подготовку, микроскопические методы визуализации, распознавание и численную концентрацию пыльцы в воздухе. Так как число образцов достаточно ограничено и процесс распознавания должен протекать с возрастающей постепенно точностью, что автоматизация процесса распознавания должна основываться на самообучающихся структурах, которыми являются нейронные сети.

Одной из особенностей нейронных сетей является их способность к обучению. В широком понимании процесс обучения — это адаптация параметров и архитектуры сети для решения поставленной задачи путем оптимизации выбранного критерия качества. Чаще всего к параметрам, которые адаптируются относятся весовые коэффициенты нейронов, реже — архитектура сети и параметры функции активации. Все алгоритмы обучения можно разделить на два больших класса: детерми-




Рис. 1. Схематическое представление парадигм обучения, где вектор состояния среды;  $y$  — фактический выход сети;  $d$  — ожидаемый выход;  $e$  — сигнал ошибки




Рис. 2. Взаимосвязь парадигм и правил обучения

нированные и стохастические. Для алгоритмов первого класса характерно наличие жестких правил действий при адаптации параметров, а для второго характерны действия, которые подчиняются некоторому случайному процессу [7, с. 144].

На сегодня известно три парадигмы обучения нейронных сетей, в основу которых положены особенности машинного обучения: обучение с учителем {supervised learning}, обучение без учителя (unsupervised) (или обучение на основе самоорганизации {self-organized}) и обучение с подкреплением {reinforcement learning} [1], на рис. 1 изображено их схематическое представление.

Обучение с учителем предполагает, что для каждого входного вектора ( $X_i$ ) существует вектор выходных значений. Вместе эти два вектора называют учебной парой ( $X_i, \phi$ ), а множественное число учебных пар — обучающей выборкой (рис. 1а). Процесс обучения сводится к поочередной подаче на вход нейронной сети учебных пар, вычисление погрешности между действительным и желаемым значением нейронной сети  $S=y-d$  и корректировка параметров сети в сторону уменьшения этой погрешности.

Особенностью обучения без учителя (самообучение) является отсутствие информации о правиль-

ной реакцию сети на входные сигналы (рис. 1б), а сама сеть находит взаимосвязи между элементами обучающей выборки. Обучение без учителя применяется в задачах классификации, кластеризации, факторного анализа, сжатия данных и тому подобное [4, с. 95].

Обучение с подкреплением является промежуточным вариантом двух предыдущих парадигм. Вместо «учителя» в схему обучения вводится блок «критика» (рис. 1в), который отслеживает реакцию среды на входной сигнал и опираясь на нее определяет эвристическую погрешность, которая положена в процесс обучения сети.

Указанные парадигмы базируются на соответствующих правилах обучения, которые определяют основные особенности их применения. Известно пять правил: обучение на основе коррекции ошибок (error learning), обучение на основе памяти (memory-based learning), обучение Гейбба (Hebb's learning), конкурентное обучение (competitive learning) и обучение Больцмана (Boltzmann learning). Парадигмы и правила обучения тесно связаны друг с другом (рис. 2), что обусловлено их относительной универсальностью. Кроме связи с парадигмами, правила обучения взаимосвязаны между собой.

Обучение на основе коррекции ошибок — является типичным обучением с учителем. На основе этого правила разработано много различных алгоритмов обучения. Так для обучения однослойных сетей часто применяют дельта-правило (следует из правил Хебба), согласно которого весовые коэффициенты каждого синапса корректируются на величину произведения значения входа для конкретного синапса и значение погрешности его выхода, что в результате приводит к ее уменьшению.

Дельта-правило не применяется для многослойных сетей, ведь выходные значения нейронов известны лишь для последнего слоя, поэтому погрешность в явном виде для остальных слоев определить невозможно. Известно несколько методов решения этой проблемы. Первый заключается в расчете выходных сигналов для каждого слоя, но при сложных конфигурациях данный метод трудоемкий и не всегда может быть реализован. Второй метод заключается в динамическом подборе весовых коэффициентов синапсов, с отслеживанием изменения погрешности. Реализуется с помощью изменения слабых связей в ту или иную сторону, причем сохраняются только те изменения, которые привели к уменьшению погрешности, этот метод требует значительных расчетных мощностей. Оптимальным является третий метод — распространение значения погрешности от выхода сети к ее входу, который получил название алгоритма обратного распространения ошибки (*error back-propagation algorithm*). Этот алгоритм применяется для обучения большинства многослойных нейронных сетей прямого распространения, иногда для рекуррентных нейронных сетей. Создано много разновидностей данного алгоритма, которые направлены на ускорение обучения сети и избегания локальных минимумов [3, с. 8].

Правила на основе памяти и обучения Хебба относятся к обучению без учителя. Они базируются на нейрофизиологическом постулате, который определяет взаимосвязь между нейронами и синаптическими связями, а именно: если нейроны с обеих сторон синапса находятся в возбужденном состоянии, то сила связи между ними возрастает, и наоборот, если в разных состояниях или не возбуждены, то ослабляется.

В основу конкурентного учения положено правило «победитель получает все», то есть возбуждается выход только одного нейрона, выходной сигнал которого наибольший. Этот принцип используется в сетях адаптивного резонанса (ART) и самоорганизационных картах (SOM).

Обучение Больцмана является стохастическим правилом, в основе которого лежат принципы теоретической термодинамики (отжиг металла). Наличие

рандомизации весовых коэффициентов во время их корректировки предотвращает попадание сети в локальные минимумы, но при этом, конечно, возрастает время обучения.

На основе правил обучения разрабатываются алгоритмы их практической реализации. Количество алгоритмов обучения постоянно растет, и все чаще они сочетают в себе не только несколько правил, но и несколько парадигм, что вызвано ростом сложности задач, которые решаются с помощью нейронных сетей.

Выбор той или иной парадигмы, правила и алгоритма обучения (или их сочетания) зависит от архитектуры сети, ее основных задач, желаний, опыта и интуиции разработчика, и имеет влияние на скорость обучения и способность достижения результата с заданной достоверностью.

Широкое применение нейронных сетей в различных областях науки и техники обусловлено тремя характерными задачами, которые решаются с их помощью: классификация, ассоциация и аппроксимация.

Исторически первым применением нейронной сети распознавания образов. Сеть училась распознавать печатные буквы английского алфавита, для этого на ее вход, который представляет собой прямоугольную матрицу синапсов, подаются разбитые на элементарные пиксели изображения букв, а каждый выход сети отвечает за конкретную букву, после нескольких этапов обучения сеть начинала «узнавать» представленное на входе изображение. Подобным образом можно обучить простейшую однослойную сеть, но она начинает ошибаться в большинстве случаев как только изображение тестовой буквы отличается от изображения учебной, то есть такая сеть способна распознать исключительно те изображения, которые подавались на вход во время обучения.

Дальнейшим развитием стало применение нейронных сетей в задачах классификации образов, когда ей необходимо за счет накопления классификационных признаков отнести до заданного класса изображение, которое было подано на вход во время обучения. В большинстве случаев для решения этой задачи нейронная сеть должна состоять из двух частей. Первая — реализует задачу селекции и выделение признаков и учится без учителя, а вторая — учится с помощью учителя и несет информацию о принадлежности образа к определенному классу.

Такие нейронные сети применяют для распознавания речи, печатного и рукописного текста, для обработки изображений, в медицине для обработки кардиограмм и томограмм, в других отраслях, где необходимо обраба-

тивать большое количество фотографий или различных диаграмм и графиков.

Ассоциативная память в нейронных сетях реализуется в двух формах: автоассоциация и гетероассоциация. В первом случае сеть обучается на основе входных образов, которые могут быть искажены. Происходит выделение и запоминание основных признаков, на основе которых и происходит в дальнейшем восстановление (упоминание) образа. Гетероассоциация отличается от автоассоциации только наличием учителя, то есть каждому поданному тестовому образу соответствует определенный заданный исходный образ. Задача кластеризации тесно связана с ассоциацией. Алгоритм кластеризации основан на размещении близких образов в одном кластере. Применяется для добычи знаний, сжатия данных [6, с. 367].

Решение предыдущих задач возможно за счет способности нейронной сети определять функциональные зависимости между величинами исключительно на основе входных и соответствующих выходных значений, поэтому она считается универсальным аппроксимирующим аппаратом. Вынесение аппроксимации функции в отдельную задачу обусловлено широким применением нейронных сетей для аппроксимации явно и не явно выраженных функциональных зависимостей в широком круге прикладных задач, таких как: прогнозирование, фильтрация, сглаживание, оптимизация, управление объектами в условиях структурной и параметрической неопределенности, распознавания зерен пыльцы и тому подобное.

Практическое применение нейронных сетей, особенно в задачах распознавания зерен пыльцы, 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 обучается с помощью алгоритма обратного распространения. Доказано, что уже двух слоев 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, которые могут помешать достижению нужного результата аппроксимации: паралич сети и попадание алгоритма обучения до локального минимума.

Паралич сети вызывает значительный рост весовых коэффициентов синаптических связей в результате чего возрастают выходные значения нейрона (которые отвечают 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, обучения замедляется почти до полной остановки.

Попадание в сети во время обучения до локального минимума обусловлено особенностями расчетного процесса (что часто проявляется во время использования, например, метода градиентного спуска). В точке локального минимума движение во всех направлениях будет приводить к росту погрешности обучения и сеть не способна самостоятельно из него выйти [5, с. 61].

Также значительной проблемой использования нейронных сетей, как аппроксимационных систем, является возникновение так называемого «проклятия размерности», т.е. экспоненциального роста необходимого количества входных данных из-за роста размерности пространства (в нейронных сетях размерность пространства напрямую зависит от количества слоев и нейронов в них). То есть для обеспечения требуемой гибкости сети, для аппроксимации сложной функции необходимо увеличивать количество нейронов, а это в свою очередь требует увеличения количества входных данных для удачного обучения сети.

Применение нейронных сетей для аппроксимации функции требует решения определенных задач еще на подготовительных этапах:

- ◆ выбор конфигурации сети: от количества слоев и нейронов в них зависит гибкость системы, а соответственно способность к аппроксимации сложных функций с заданной точностью, однако значительное увеличение количества нейронов приводит к переобучению сети и возникновению «проклятия размерности»;
- ◆ выбор алгоритма обучения: при неудачном выборе метода и алгоритма обучения время необходимое на аппроксимацию с заданной точностью может значительно возрасти, кроме того может возникнуть паралич сети или учебы остановится из-за попадания до локального минимума;
- ◆ формирование обучающей выборки: обучающая выборка должна содержать достаточное количество данных о всех экстремумах функции, при этом входные данные должны быть нормализованы и равномерно распределены в пространстве. Несоблюдение этого требования приводит к некорректному обучению сети, когда значение погрешности будет разным для разных участков характеристики.

На сегодня не существует универсальных методов решения поставленных проблем, особенно при применении сети в задачах проектирования, которые требуют аппроксимации функции многих переменных, поэтому

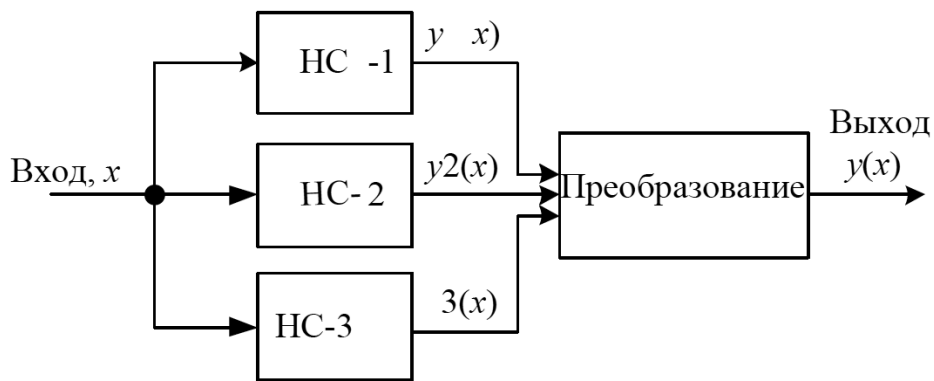


Рис. 3. Ансамбль нейронных сетей

в них часто возникают противоречия, связанные с получением достаточно гибкой системы в условиях ограниченного количества расчетных или экспериментальных входных данных [2, с. 34].

Так, для обеспечения требуемой гибкости сети можно увеличить количество слоев и нейронов в них, примером удачного применения могут быть работы, однако в таких сетях значительно возрастает возможность возникновения паралича сети, поэтому это решение нельзя считать универсальным. Также нейронную сеть можно использовать в качестве математической модели в алгоритмах распознавания зерен пыльцы. Предложено использование каскадных нейронных сетей (в которых количество нейронов скрытого слоя при необходимости увеличивается в процессе обучения) для аппроксимации функции, что позволяет построить оптимальную с точки зрения количества нейронов, архитектуру сети и избежать проблемы переобучения [1, с. 144].

Заслуживает особого внимания использование ансамбля нейронных сетей — объединение функционально независимых нейронных сетей в комплексы, что позволяет создавать гибкие системы направленные на решение конкретных задач и избежания проблем с учебой или эксплуатацией. Изоляция элементов ансамбля друг от друга позволяет создавать системы, которые не чувствительны к негативному воздействию слабосвязанных параметров друг на друга, а в сочетании с возможностью распределения входных и выходных значений способствует созданию нейронных сетей с более простой архитектурой. На рис. 3 изображен один из вариантов применения ансамбля нейронных сетей, в котором обработка данных происходит одновременно в нескольких сетях, которые могут отличаться как по архитектуре, так и по методу обучения. Объединяющий слой выполняет функцию выбора выхода в зависимости от того, какая сеть для текущих входных данных обеспечивает меньшую погрешность.

Применение ансамбля в задачах проектирования позволяет решить проблемы связанные с широким динамическим диапазоном входных и выходных значений и конструировать несложные по архитектуре сети, которые быстрее учатся и лучше подвергаются дополнительному обучению на этапе эксплуатации.

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

Алгоритмы и правила обучения нейронных сетей, как правило, носят ситуационный характер — разрабатываются для решения определенных (или группы родственных задач, поэтому важным является понимание принципов и особенностей их работы, что позволит профессионально подходить к вопросу выбора готовых или создание новых алгоритмов обучения.

Использование нейронных сетей в задачах распознавания зерен пыльцы является отдельным направлением их теоретического исследования и практического применения через значительное отличие от классических задач, которые решались на протяжении развития этого инструментария.

Для целей распознавания зерен пыльцы перспективными являются ансамбли нейронных сетей, развитие которых позволит построить математические модели объектов, характеризующихся широким диапазоном изменения величины параметров и выходных характеристик, при существенной зависимости большинства этих характеристик от одного из параметров (например, зависимость характеристик микроволнового устройства от геометрических параметров структуры и частоты).

ЛИТЕРАТУРА

1. Герасименко М. А. Метод управления узлом сенсорной сети на основе нейронных сетей // В книге: Межвузовская научно-техническая конференция студентов, аспирантов и молодых специалистов им. Е. В. Арменского Материалы конференции. Московский институт электроники и математики Национального исследовательского университета «Высшая школа экономики». 2016. С. 144–145.
2. Козлов П.В., Южаков А. А. Преобразование исходного изображения для распознавания нейронной сетью на основе неокогнитрона // Вопросы защиты информации. 2016. № 2 (113). С. 32–34.
3. Лабинский А.Ю., Уткин О. В. К вопросу аппроксимации функции нейронной сетью // Природные и техногенные риски (физико-математические и прикладные аспекты). 2016. № 1 (17). С. 5–10.
4. Ле М. Х. Свёрточная нейронная сеть для решения задачи классификации // Труды Московского физико-технического института. 2016. Т. 8. № 3 (31). С. 91–97.
5. Мазуров М. Е. Распознавание сложных объектов избирательными нейронными сетями // В книге: XIV Всероссийская научная конференция «Нейрокомпьютеры и их применение» Тезисы докладов. Под редакцией А. И. Галушкина, А. В. Чечкина, Л. С. Куравского, С. Л. Артеменкова, Г. А. Юрьева, П. А. Мармалюка, А. В. Горбатова, С. Д. Кулика. 2016. С. 60–61.
6. Ольшанский А.М., Игнатенков А. В. О решении задачи управления искусственной нейронной сетью при квазипериодическом характере поведения сигнала ошибки // В сборнике: Перспективные информационные технологии труды Международной научно-технической конференции. 2016. С. 635–638.
7. Павлова А.И., Бобрикова К. А. Сравнение алгоритмов распознавания образов нейронными сетями Хопфилда // В мире научных открытий. 2016. № 5 (77). С. 134–145.

© Камалова Юлия Борисовна ( pmkk@istu.ru ). Журнал «Современная наука: актуальные проблемы теории и практики»

