

Левицкий В.А.

Нейронные сети: алгоритм обратного распространения ошибок

История исследования искусственных нейронных сетей (ИНС) насчитывает уже около 50 лет. За это время интерес к ИНС то возрастал, то ослабевал. Однако число публикаций, посвященных ИНС, и сообщений о создании прикладных систем с использованием ИНС неуклонно растет. ИНС зарекомендовали себя в качестве полезного инструмента во многих приложениях, которые можно рассматривать как системы обработки информации

Искусственные нейронные сети (ИНС) - совокупность моделей биологических нейронных сетей. Представляют собой сеть элементов – искусственных нейронов – связанных между собой синаптическими соединениями. Сеть обрабатывает входную информацию и в процессе изменения своего состояния во времени формирует совокупность выходных сигналов.

Теория нейронных сетей (НС) включает широких круг вопросов из разных областей науки: биофизики, математики, информатики, схемотехники и технологии. Поэтому понятие “нейронные сети” детально определить сложно.

Существуют три парадигмы обучения: "с учителем", "без учителя" (самообучение) и смешанная. В первом случае нейронная сеть располагает правильными ответами (выходами сети) на каждый входной пример. Веса настраиваются так, чтобы сеть производила ответы как можно более близкие к известным правильным ответам. Усиленный вариант обучения с учителем предполагает, что известна только критическая оценка правильности выхода нейронной сети, но не сами правильные значения выхода. Обучение без учителя не требует знания правильных ответов на каждый пример обучающей выборки. В этом случае раскрывается внутренняя структура данных или корреляции между образцами в системе данных, что позволяет распределить образцы по категориям. При смешанном обучении часть весов определяется посредством обучения с учителем, в то время как остальная получается с помощью самообучения.

Метод обратного распространения ошибки является распространенным методом обучения ИНС для выполнения распознавание текстов, контекстная реклама в Интернете, игра на бирже, проверка проведения подозрительных операций по банковским картам, фильтрация спама, системы безопасности и видеонаблюдения — и это далеко не все.

Впервые метод был описан в 1974 г. А.И. Галушкиным [1], а также независимо и одновременно Полом Дж. Вербосом [2]. Далее существенно развит в 1986 г. Дэвидом И. Румельхартом, Дж. Е. Хинтоном и Рональдом Дж. Вильямсом [3] и независимо и одновременно С.И. Барцевым и В.А. Охониным (Красноярская группа) [4]. Это итеративный градиентный алгоритм, который используется с целью минимизации ошибки работы многослойного перцептрана и получения желаемого выхода.

Обучение алгоритмом обратного распространения ошибки предполагает два прохода по всем слоям сети: прямого и обратного. При прямом проходе входной вектор подается на входной слой нейронной сети, после чего распространяется по сети от слоя к слою. В результате генерируется набор выходных сигналов, который и является фактической реакцией сети на данный входной образ. Во время прямого прохода все синаптические веса сети фиксированы. Во время обратного прохода все синаптические веса настраиваются в соответствии с правилом коррекции ошибок, а именно: фактический выход сети вычитается из желаемого, в результате чего формируется сигнал ошибки. Этот сигнал впоследствии распространяется по сети в направлении, обратном направлению синаптических связей. Отсюда и название – алгоритм обратного распространения ошибки. Синаптические веса настраиваются с целью максимального приближения выходного сигнала сети к желаемому.

Целью обучения сети алгоритмом обратного распространения ошибки является такая подстройка ее весов, чтобы приложение некоторого множества входов приводило к требуемому множеству выходов. Для краткости эти множества входов и выходов будут называться векторами. При обучении предполагается, что для каждого входного вектора существует парный ему целевой вектор, задающий требуемый выход. Вместе они называются обучающей парой. Сеть обучается на многих парах.

Алгоритм обратного распространения ошибки следующий:

1. Инициализировать синаптические веса маленькими случайными значениями.
2. Выбрать очередную обучающую пару из обучающего множества; подать входной вектор на вход сети.
3. Вычислить выход сети.
4. Вычислить разность между выходом сети и требуемым выходом (целевым вектором обучающей пары).
5. Подкорректировать веса сети для минимизации ошибки (как см. ниже).
6. Повторять шаги с 2 по 5 для каждого вектора обучающего множества до тех пор, пока ошибка на всем множестве не достигнет приемлемого уровня.

Несмотря на многочисленные успешные применения обратного распространения, оно не является панацеей. Больше всего неприятностей приносит неопределённо долгий процесс обучения. В сложных задачах для обучения сети могут потребоваться дни или даже недели, она может и вообще не обучиться. Причиной может быть одна из описанных ниже.

Паралич сети. В процессе обучения сети значения весов могут в результате коррекции стать очень большими величинами. Это может привести к тому, что все или большинство нейронов будут функционировать при очень больших значениях OUT, в области, где производная сжимающей функции очень мала. Так как посылаемая обратно в процессе обучения ошибка пропорциональна этой производной, то процесс обучения может практически замереть. В теоретическом отношении эта проблема плохо изучена. Обычно этого избегают уменьшением размера шага η , но это увеличивает время обучения. Различные эвристики использовались для предохранения от паралича или для восстановления после него, но пока что они могут рассматриваться лишь как экспериментальные.

Локальные минимумы. Обратное распространение использует разновидность градиентного спуска, то есть осуществляет спуск вниз по поверхности ошибки, непрерывно подстраивая веса в направлении к минимуму. Поверхность ошибки сложной сети сильно изрезана и состоит из холмов, долин, складок и оврагов в пространстве высокой размерности. Сеть может попасть в локальный минимум (неглубокую долину), когда рядом имеется гораздо более глубокий минимум. В точке локального минимума все направления ведут вверх, и сеть неспособна из него выбраться. Основную трудность при обучении нейронных сетей составляют как раз методы выхода из локальных минимумов: каждый раз выходя из локального минимума снова ищется следующий локальный минимум тем же методом обратного распространения ошибки до тех пор, пока найти из него выход уже не удаётся.

Размер шага. Внимательный разбор доказательства сходимости показывает, что коррекции весов предполагаются бесконечно малыми. Ясно, что это неосуществимо на практике, так как ведёт к бесконечному времени обучения. Размер шага должен браться конечным. Если размер шага фиксирован и очень мал, то сходимость слишком медленная, если же он фиксирован и слишком велик, то может возникнуть паралич или постоянная неустойчивость. Эффективно увеличивать шаг до тех пор, пока не прекратится улучшение оценки в данном направлении антиградиента и уменьшать, если такого улучшения не происходит. П. Д. Вассерман [5] описал адаптивный алгоритм выбора шага, автоматически корректирующий размер шага в процессе обучения. В книге А. Н. Горбаня [6] предложена разветвлённая технология оптимизации обучения.

Следует также отметить возможность переобучения сети, что является скорее результатом ошибочного проектирования её топологии. При слишком большом количестве нейронов теряется свойство сети обобщать информацию. Весь набор образов, предоставленных к обучению, будет выучен сетью, но любые другие образы, даже очень похожие, могут быть классифицированы неверно.

Появление алгоритма обратного распространения ошибки стало знаковым событием в области развития нейронных сетей, так как он реализует вычислительно эффективный метод обучения многослойного персептрона. Будет неправильно утверждать, что алгоритм обратного распространения ошибки предлагает действительно оптимальное решение всех потенциально разрешимым проблем, однако он развеял пессимизм относительно обучения многослойных машин, воцарившийся в результате публикации Минского в 1969 году.

Литература:

1. Галушкин А. И. Синтез многослойных систем распознавания образов. — М.: «Энергия», 1974.
2. Werbos P. J., Beyond regression: New tools for prediction and analysis in the behavioral sciences. Ph.D. thesis, Harvard University, Cambridge, MA, 1974.

3. Rumelhart D.E., Hinton G.E., Williams R.J., Learning Internal Representations by Error Propagation. In: Parallel Distributed Processing, vol. 1, pp. 318—362. Cambridge, MA, MIT Press. 1986.
4. Барцев С. И., Охонин В. А. Адаптивные сети обработки информации. Красноярск : Ин-т физики СО АН СССР, 1986. Препринт N 59Б. — 20 с.
5. Wasserman P. D. Experiments in translating Chinese characters using backpropagation. Proceedings of the Thirty-Third IEEE Computer Society International Conference.. — Washington: D. C.: Computer Society Press of the IEEE, 1988.
6. Горбань А. Н. Обучение нейронных сетей.. — Москва: СП ПараГраф, 1990.

Е.В.Лук'янчук, М. В. Полякова

Интеллектуальная система обработки изображений на ангиограммах с использованием вейвлет-анализа

Для диагностики поражений сосудов в кардиологии активно применяется ангиографическое исследование коронарных сосудов, направленное на верификацию диагноза ишемической болезни сердца, уточнение локализации поражения сосудистого русла, на основе чего врачом определяется тактика лечения. Одной из базовых процедур ангиографического исследования является сегментация дерева сосуда на ангиограммах, которая проводится по признаку равной интенсивности. Цель сегментации — сокращение объема обрабатываемой информации и обеспечение инвариантности к преобразованиям интенсивности изображений. Данная проблема является актуальной. Ею занимались многие авторы, такие как Guo D., Richardson P., Wang Y., Toumoulin C., Shu H., Zhou Z., Coatrieux J.-L., Ильясова Н.Ю., Казанский Н.Л., Корепанов А.О., Куприянов А.В. и многие др.

Проведенный анализ существующих методов сегментации изображений сосудов на ангиограммах показал, что основным недостатком этих методов является высокое время обработки или, как альтернатива, высокий уровень аппаратных затрат. Однако необходимость принятия решения о хирургическом вмешательстве накладывает временные ограничения на метод сегментации ангиографических изображений. Поэтому для сокращения вычислительных затрат в методах сегментации ангиограмм используют многомасштабную обработку изображений [1]. Сокращение времени обработки ангиограмм за счет применения обобщенных вейвлет-функций с компактным носителем для локализации дерева сосудов было достигнуто в работе [2].

Целью работы является исследование помехоустойчивости метода с применением обобщенных вейвлет-функций с компактным носителем при сегментации ангиограмм коронарных сосудов.

Для достижения поставленной цели решаются следующие задачи:

— анализ метода с применением обобщенных вейвлет-функций для сегментации изображений сосудов на ангиограммах;