

Применение нейронных сетей для параллельных вычислений в сейсмоакустических системах наблюдения

Ю.Х. Зарипова

*Научно-технологический парк "Дубна", Московская область, Дубна
j.zaripova@ntpdubna.ru*

Использование нейронных сетей для параллельной обработки информации

Существуют два принципиально разных подхода к обработке информации: последовательная обработка символов и параллельное распознавание образов. Основное различие между ними заключается в размерности. Размер образа может быть на много порядков больше размера символа. Различия в размерах данных имеют принципиальное значение, так как сложность работы с образами возрастает нелинейно при увеличении их разрядности.

Для относительно коротких символов можно описать все возможные над ними операции, но реализовать то же самое для образов невозможно, поскольку подобное описание будет расти экспоненциально. А значит, любой процессор, предназначенный для обработки образов, содержит лишь часть возможных входных образцов и соответствующих им действий и должен обобщать известные ему примеры, чтобы его реакция была приемлемой с точки зрения решения задачи, для которой он предназначен. Таким образом, различие между последовательными и параллельными вычислениями заключается в принципиально разных методах постановки и решения задач, связанных с обработкой информации.

На принципе последовательных вычислений на ограниченных по длине символах основаны компьютеры, реализованные по традиционной архитектуре фон Неймана с алгоритмическими программами, а параллельные вычисления и распознавание образов лежат в основе нейрокомпьютеров.

Основная задача нейрокомпьютеров — обработка образов. При этом вычисления и обучение распределены по всем элементарным процессорам — нейронам, которые функционируют параллельно. За счет этого нейрокомпьютеры позволяют добиться высокой производительности, которая может в миллионы раз превышать производительность компьютеров с последовательной архитектурой. Нейронные сети (НС) превосходят последовательные машины в решении тех же задач, в которых машину превосходит человек.

Преимущества нейросетевого подхода заключаются в следующем:

- распределенное представление информации и параллельные вычисления;
- способность к обучению и обобщению;
- адаптивность;
- способность решать неформализованные задачи.

Искусственные НС являются вычислительной системой с огромным числом параллельно функционирующих простых процессоров с множеством связей. Они могут менять свое поведение в зависимости от состояния окружающей их среды. После анализа входных сигналов (возможно, вместе с требуемыми выходными сигналами) они самонастраиваются и обучаются, чтобы обеспечить правильную реакцию. Обучение НС — это задача многомерной оптимизации, и для ее решения существует множество алгоритмов [7].

Обученная сеть может быть устойчивой к некоторым отклонениям входных данных, что позволяет ей правильно распознавать образ, содержащий различные помехи и искажения. Работа НС состоит в преобразовании входных сигналов во времени, в ре-

зультате чего меняется внутреннее состояние сети и формируются выходные воздействия.

Параллельность обработки информации в НС означает, что каждый нейрон формирует свой выход только на основе своих входов и собственного внутреннего состояния под воздействием общих механизмов регуляции.

Существует большое число различных конфигураций НС с различными принципами функционирования, которые ориентированы на решение различных задач.

Области применения НС весьма разнообразны — это распознавание текста и речи, семантический поиск, экспертные системы и системы поддержки принятия решений, предсказание курсов акций, системы безопасности, анализ текстов, определение тематики текстовых сообщений, управление маршрутизацией потоков данных, распознавание речи [5, 6].

Технологии НС применимы практически в любой области, а в распознавании образов они стали широко используемым инструментом.

НС позволяют создать эффективное программное обеспечение для параллельных компьютеров. Для высокопараллельных машин существует проблема их эффективного использования. Создавая математическое обеспечение на базе НС, можно для широкого класса задач решить эту проблему.

Задача классификации в сейсмоакустических системах наблюдения

Периметровые средства обнаружения (СО), предназначенные для повышения эффективности охраны рубежей промышленных, военных и гражданских объектов, занимают особое место в отрасли специальной техники [4]. Сейсмоакустические системы наблюдения обладают по сравнению с остальными СО возможностями контролировать обстановку не только в узкой полосе рубежа вдоль охраняемого периметра, но и в широкой зоне на подступах к нему. Для повышения эффективности работы сейсмоакустических систем при решении подобных задач используют современные технологии с элементами искусственного интеллекта.

Работа сейсмоакустической системы основана на регистрации сейсмических волн, возбуждаемых в грунте различными физическими воздействиями. Сейсмоакустическая система выполняет функции по приему информации из внешней среды, обработке ее и принятию решения о вторжении в охраняемую зону нарушителя.

Одной из задач, решаемых сейсмоакустической системой наблюдения является идентификация объекта нарушения. Идентифицировать объект означает поставить в соответствие сигналу на входе системы какой-либо объект (человек, группа людей, автомобиль или другая техника). При этом решается задача классификации по сейсмограмме, связанная с определением принадлежности данного объекта к одному из заранее выделенных классов объектов, т.е. с определением принадлежности сигнала на входе системы к выделенному классу сигналов. Ее решение предусматривает разработку определенного метода (решающего правила), который с определенной вероятностью мог бы отнести записанное событие к одному из классов.

Пусть сигнал от объекта описан m -размерным вектором признаков $\mathbf{X} = \{x_1, \dots, x_m\}$. Множество реализаций сигналов от объекта, описанных с помощью такого вектора, образуют обучающее множество. По нему можно определить закономерности и связи между значениями признаков. Для каждого объекта, имея обучающую выборку, можно найти эталонный вектор (или несколько векторов) и поставить в соответствие номер класса z . Тогда, воспользовавшись некоторым правилом и задавшись мерой сходства, можно входной (контрольный) сигнал, описанный с помощью того же вектора признаков, отнести к одному из классов z .

Оптимальная по критерию минимума среднего риска классификация выполняется на основе условных вероятностей $P(z|\mathbf{x})$. При наличии априорной неопределенности синтез классификатора осуществляется с использованием обучающей выборки $\mathbf{D}$, которая состоит из пар значений $\mathbf{x}(n), z(n)$, $n=1, \overline{N}$. Задача классификации при наличии нескольких альтернатив может быть сведена к совокупности задач бинарной классификации. В этом случае $z \in \{0,1\}$. Решение $\hat{z}$ выносится на основе апостериорной вероятности $P(z=1|\mathbf{x})$, вычисляемой на основе теоремы Байеса:

$$P(z=1|\mathbf{x}) = \frac{p(\mathbf{x}|z=1)P(z=1)}{p(\mathbf{x}|z=1)P(z=1) + p(\mathbf{x}|z=0)P(z=0)}.$$

Несмотря на то, что для решения данной задачи в настоящее время успешно применяются методы статистического анализа, продолжается поиск более эффективных алгоритмов, которые бы позволили проводить классификацию точнее и с меньшими затратами. В качестве таких методов предлагается использовать аппарат нейронных сетей.

Поскольку исходные данные представлены в виде сейсмограмм – временных отобразений колебаний земной поверхности, то в таком виде анализировать информацию, оценивать различные физические характеристики зафиксированного события достаточно трудно. Существуют методы, специально предназначенные для обработки сигналов, которые позволяют выделять определенные признаки, и, в дальнейшем, по ним производить анализ записанного события.

Отбор наиболее информативных признаков для классификации

В сейсмограмме анализируемого события можно выделить достаточно много различных характеристик, но далеко не все из них могут действительно нести информацию, существенную для надежной идентификации объекта. Многочисленные исследования показали, что выделение малого числа наиболее информативных признаков исключительно важно для эффективной классификации. Несколько тщательно отобранных признаков могут обеспечить вероятность ошибочной классификации существенно меньшую, чем при использовании полного набора.

При необходимости использовать нейросетевые методы для решения конкретных задач первое, с чем приходится сталкиваться – это подготовка данных. Успех обучения нейросети может решающим образом зависеть от того, в каком виде представлена информация для ее обучения.

Общий принцип предобработки данных для обучения состоит в максимизации энтропии входов и выходов.

Сжатие входных данных, уменьшение степени их избыточности, использующее существующие в них закономерности, может существенно облегчить последующую работу, выделяя действительно независимые признаки.

Для того чтобы понять какие из входных переменных несут максимум информации, а какими можно пренебречь необходимо либо сравнить все признаки между собой и определить степень информативности каждого из них, либо пытаться найти определенные комбинации признаков, которые наиболее полно отражают основные характеристики исходных данных.

Основопологающий принцип предобработки данных - это снижение существующей избыточности всеми возможными способами. Это повышает информативность примеров и, тем самым, качество работы НС.

В результате предобработки данных было установлено, что наиболее информативными признаками сигнала, используемыми для его классификации являются:

- энергия выборки;

- скважность сигнала (если он имеет импульсный характер)
- коэффициент заполнения выборки;
- изрезанность сигнала;
- отношение энергии высокочастотной части спектра к низкочастотной.

Из исходных данных формируются две выборки – обучающая и тестовая. Обучающая выборка нужна для алгоритма настройки весовых коэффициентов, а наличие проверочной, тестовой выборки нужно для оценки эффективности обученной нейронной сети.

Реализация решения задачи нейросетевой классификации

Условное распределение $P(z|x, w, s)$ вероятности принадлежности вектора признаков x к классу z может быть задано с помощью НС с радиальными базисными функциями, характеризующейся вектором параметров w и структурой s . Синтез классификатора включает процедуры определения как параметров, так и структуры НС. На основе байесовской методологии разработано семейство алгоритмов синтеза нейросетевых классификаторов, которые были использованы для решения задачи идентификации объектов в сейсмоакустической системе. При этом все алгоритмы обеспечивали синтез классификаторов, характеризующихся достаточно близкими значениями коэффициентов ошибок. Алгоритмы реализованы в программном обеспечении в среде MatLab. В [1], [2] и [3] дается описание реализованных на основе байесовской методологии алгоритмов для синтеза нейросетевого классификатора, а также разработанного программного обеспечения нейросетевой классификации, включающего режимы распознавания образов и статистического моделирования. При помощи разработанного программного обеспечения выполнена нейросетевая классификация данных, полученных в результате работы сейсмоакустической системы рубежного контроля.

Проведенные исследования подтвердили эффективность применения нейросетевых технологий для идентификации типа источника сейсмоакустического сигнала. При определенных настройках нейронной сети можно добиться результатов, когда вероятность правильного распознавания составляет 95%.

Заключение

Основные результаты проведенных исследований:

- Нейронные сети позволяют успешно решать проблему определения типа источника сейсмического события.
- Нейросетевое решение не уступает по эффективности традиционным методам, использующимся для решения исследуемой задачи.
- Возможны улучшения технических характеристик нейросетевого решения.

В качестве дальнейших исследований, направленных на повышение эффективности нейросетевого решения, можно предложить накопление информации о результатах работы сейсмоакустической системы. Обработка и анализ данной информации позволят сделать выводы о влиянии на работу нейросетевого классификатора различных факторов, учет которых позволит понизить коэффициент ошибок.

Литература

1. Баранов, В.Г. Нейросетевые алгоритмы распознавания образов / В.Г. Баранов, В.В. Кондратьев, В.Р. Милов, Ю.Х. Зарипова // Нейрокомпьютеры: разработка, применение. – 2007. – № 11. – С. 20 – 27.
2. Баранов, В.Г. Байесовская методология синтеза нейросетевых классификаторов / В.Г. Баранов, В.Р. Милов, Ю.Х. Зарипова // Труды НГТУ: Системы обработки информации и управления / НГТУ. – Н.Новгород. – 2007. – Т. 65, Вып. 14. – С. 5 – 12.

3. Баранов, В.Г. Байесовские методы обучения нейронных сетей / В.Г. Баранов, В.Р. Милов, С.А. Шалюгин // Нейрокомпьютеры: разработка, применение. – 2007. – № 11. – С. 14 – 19.
4. Волчихин, В.И. Теория и техника построения сейсмических информационных систем: Учеб. пособие. / В. И. Волчихин, Г.К. Чистова. — Пенза: Изд-во Пенз. гос. ун-та. 1998. — 136 с.
5. Круглов, В.В. Искусственные нейронные сети. Теория и практика. / В.В. Круглов, В.В. Борисов. – М.: Горячая линия – Телеком, 2001. – 328 с.
6. Хайкин, С. Нейронные сети: полный курс. / С. Хайкин. – Издательский дом «Вильямс», 2006. – 1104 с.
7. Уоссермен, Ф. Нейрокомпьютерная техника. / Ф. Уоссермен. - М.: Мир, 1992 – С - 184.