



L.V. Stepanova, P.S. Roslyakov// International Journal of Solids and Structures. – 2016. – V. 100-101. – P. 11-28.

4. Степанова, Л.В., Яковлева, Е.М. Смешанное деформирование пластины с трещиной в условиях плоского напряженного состояния [Текст]/ Л.В. Степанова, Е.М. Яковлева// Вестник Пермского национального исследовательского политехнического университета. – 2014. – Т.3. – С. 129-162.

5. Степанова, Л.В. Влияние высших приближений в асимптотическом разложении М.Уильямса на описание поля напряжений в окрестности вершины трещины в изотропном линейно упругом материале [Текст]/ Л.В.Степанова // Материалы X Всероссийской конференции по механике деформируемого твердого тела. – Самара: Самарский государственный технический университет. – 2017. - Т.2. – С.222-225.

6. Котенко, М.В., Раздорский, В.В., Лелявин, А.Б. Поляризациино-оптический метод в исследовании напряженно-деформированного состояния моделей с дентальными имплантатами из нитинола [Текст]/ М.В. Котенко, В.В. Раздорский, А.Б. Лелявин // Сибирский медицинский журнал. – Иркутск. – 2016. – №8. – С.34-38.

7. Маковецкая-Абрамова, О.В., Хлопова, А.В., Маковецкий, В.А. Исследование напряженных состояний и износа в кривошипе подшипника двигателя М-62 методом фотоупругости [Текст]/ О.В. Маковецкая-Абрамова, А.В. Хлопова, В.А. Маковецкий // Техничко-технологические проблемы сервиса. – СПбГЭУ. – 2013. – № 1(23). – С.19-22.

8. Hello, G., Tahar, M.B., Roelandt, J.-M. Analytical determination of coefficients in crack-tip stress expansions for a finite crack in an infinite plane medium [Текст]/ G. Hello, M.B. Tahar, J.-M. Roelandt // International Journal of Solids and Structures. – 2012. - №49. С.556-566.

9. Tada, H. The Stress Analysis of Cracks Handbook Third Edition: учеб.-метод. пособие / H. Tada, C. P. Paris, G. R. Irwin. - New York: ASME Press, 2000 - 696 с.

А.А. Лякишев, И.В. Лёзина

АВТОМАТИЗИРОВАННАЯ СИСТЕМА АППРОКСИМАЦИИ ПЛОТНОСТИ ВЕРОЯТНОСТИ РАДИАЛЬНО-БАЗИСНОЙ НЕЙРОННОЙ СЕТЬЮ С ПРИМЕНЕНИЕМ АЛГОРИТМОВ ИНИЦИАЛИЗАЦИИ ВЕСОВ

(Самарский национальный исследовательский университет
имени академика С.П. Королева)

В современном мире мы часто сталкиваемся с большими объемами данных, полученных тем или иным образом. Визуальная или ручная обработка больших числовых массивов невозможна, когда количество полученных значений превышает несколько тысяч чисел. Поэтому для решения подобных задач пишут специальные программы, чтобы проанализировать и определить закон



распределения, которому принадлежат эти данные. Но зачастую вычислительной мощности обычных алгоритмов обработки становится недостаточно. В таком случае целесообразно использовать нейронные сети.

Нейронная сеть представляет собой систему соединённых и взаимодействующих между собой простых процессоров (искусственных нейронов). Каждый нейрон получает входные данные, обрабатывает их и передает результат последующим нейронам.

Аппроксимирующая нейронная сеть представляет собой универсальный аппроксиматор, реализующий нелинейную функцию $y = f(x)$, где x – входной вектор, а y – реализованная функция.

Одной из таких сетей является радиально-базисная сеть (RBF) [1]. Сеть состоит из одного скрытого слоя, выполняющего нелинейное преобразование входной последовательности, и выходного нейрона, суммирующего выходные значения нейронов скрытого слоя [2]. Особенностью этой сети является радиальная функция активации скрытых нейронов:

$$\phi(x) = \phi(\|x - c_i\|_{Q_i}) = e^{-(x-c_i)^T Q_i^T Q_i (x-c_i)} = e^{-\frac{(x-c_i)^T C_i (x-c_i)}{2}},$$

где матрица $\frac{C_i}{2} = Q_i^T Q_i$ играет роль коэффициента $\frac{1}{2\sigma_i^2}$ стандартной функции Гаусса, которая используется в RBF сетях, имеющей вид:

$$\phi(x) = \phi(\|x - C_i\|) = e^{-\frac{\|x - C_i\|^2}{2\sigma_i^2}},$$

где x – входной вектор, i – индекс нейрона в скрытом слое.

Матрица Q является матрицей весовых коэффициентов эвклидовой меры, которая имеет вид:

$$\|x\|_Q^2 = (Qx)^T (Qx) = x^T Q^T Q x$$

Масштабирующая матрица для N -мерного вектора имеет вид:

$$Q = \begin{bmatrix} Q_{11} & \cdots & Q_{1N} \\ \vdots & \ddots & \vdots \\ Q_{N1} & \cdots & Q_{NN} \end{bmatrix}$$

Задача аппроксимации состоит в подборе соответствующего количества радиальных функций $\phi(\|x - C_i\|)$ и их параметров, а так же подборе весов. Эту проблему можно свести к минимизации целевой функции:

$$E = \sum_{i=1}^p [\sum_{j=1}^k w_j \phi(\|x_i - c_j\|) - d_i]^2,$$

где k – количество радиальных нейронов, а p – количество обучающих пар (x_i, d_i) , где x_i – входной вектор, d_i – ожидаемая величина.

Процесс обучения сети сводится:

1. К подбору центров c_i и параметров σ_i формы базисных функций;
2. К подбору весов нейронов выходного слоя.

Веса нейронов могут инициализироваться различными способами. Самым простым способом является их случайная инициализация на основе равномерного распределения в интервале $[0;1]$.



Вторым способом инициализации весов нейронной сети является алгоритм имитации отжига. Этот алгоритм основывается на имитации физического процесса, который происходит при кристаллизации вещества, в том числе при отжиге металлов. Предполагается, что атомы уже выстроились в кристаллическую решетку, но еще допустимы переходы отдельных атомов из одной ячейки в другую. Предполагается, что процесс протекает при постепенно понижающейся температуре. Так же переход атома происходит с некоторой вероятностью, которая уменьшается вместе с уменьшением температуры.

Перед началом алгоритма веса инициализируются случайными значениями в интервале $[0;1]$. Далее выполняется имитация отжига по следующим шагам [3]:

1. Генерируется входной вектор – выбирается случайное решение x_0 из системы, которое должно быть оптимизировано.
2. Инициализируется температура T . Причем, если это значение будет слишком высоким, алгоритм будет длиться слишком долго, а если будет маленьким – процесс остановится до нахождения наилучшего решения.
3. Выбирается новое решение из соседних к текущему $x_0 + \Delta x$
4. Оценивается новое решение: если $f(x_0 + \Delta x) \leq f(x_0)$, то $x_0 + \Delta x$ принимается и заменяет текущее решение, после чего производится переход к пункту 6.
5. Периодически уменьшается температура, в результате чего уменьшается вероятность принятия худших решений.
6. Повторить пункты 2 – 6 до тех пор, пока не будет выполнен критерий остановки.

Цель данной работы – реализовать автоматизированную систему для аппроксимации плотности вероятности с использованием радиально-базисной нейронной сети и сравнить между собой два алгоритма инициализации весов нейронной сети: случайным образом и алгоритмом имитации отжига. В системе реализована генерация обучающих выборок, распределенных по различным законам. Также имеется возможность загрузить данные с внешнего носителя.

Исследование данных способов инициализации показало, что при 10000 эпохах обучения СКО для экспоненциального закона распределения со случайной инициализацией весов равняется 0,033, а после алгоритма имитации отжига – 0,027, что показывает незначительное увеличение точности работы сети.

По результатам эксперимента можно сделать вывод, что случайная инициализация весовых коэффициентов дает результаты хуже, чем алгоритм имитации отжига.

Литература

1. Латыш, С.К., Исследование аппроксимативных возможностей радиально-базисной сети с различными функциями активации [Текст] / С. А. Прохоров, И. А. Лёзин, И. В. Лёзина, С. К. Латыш, С. А. Саиян – Известия Самарского научного центра Российской академии наук, Механика, т.15, №4, 2013. – с. 271–274. – ISSN 1990-5378.



2. Осовский, С. Нейронные сети для обработки информации [Текст] / Пер. с польского И. Д. Рудинского. – М.: Финансы и статистика, 2002. – 344 с.: ил.

3. L.M. Rasdi Rere, Mohamad Ivan Fanany, Aniati Murni Arymurthy. Simulated Annealing Algorithm for Deep Learning [Электронный ресурс] – Электрон. Текстовые дан. – The Third Information Systems International Conference, 2015. – режим доступа к журн.: <https://www.sciencedirect.com/science/article/pii/S1877050915035759#bbib0065>, свободный

И.А. Лёзин, Е.С. Худобердина

КЛАСТЕРИЗАЦИЯ КРИСТАЛЛИЧЕСКИХ РЕШЕТОК ГИБРИДНОЙ НЕЙРОННОЙ СЕТЬЮ КОХОНЕНА

(Самарский университет)

В настоящее время искусственные нейронные сети часто используются для решения задач кластеризации. Кластеризация применяется для решения многих прикладных задач, например таких, как сегментация изображений, экономическое прогнозирование, анализ данных. Задачу кластеризации кристаллических решеток можно свести к установлению типов решеток.

Кристаллическая решётка – присущее веществу в кристаллическом состоянии правильное расположение атомов (ионов, молекул), характеризующееся периодической повторяемостью в трёх измерениях. Ввиду такой периодичности для описания кристаллической решетки достаточно знать размещение атомов в элементарной ячейке, повторением которой путём параллельных дискретных переносов (трансляций) образуется вся структура кристалла. Математической схемой кристаллической решетки, в которой остаются лишь геометрические параметры переносов, но не указывается конкретное размещение атомов в данной структуре, является пространственная решётка. В ней система трансляций, присущих данной кристаллической решетки, изображается в виде системы точек – узлов.

Существует 14 различающихся по симметрии пространственных трансляционных решеток, называемых Браве решетками.

По виду примитивной решетки Браве классифицируют семь типов так называемых кристаллических систем, или сингоний. В одну сингонию объединяются примитивная решетка Браве и сложные решетки, у которых одинаковы элементы точечной симметрии, так и кристаллографическая система координат [3].

Данные, подаваемые на вход сети, представлены в виде шести числовых признаков: длины трех сторон и величины углов между сторонами. Эти характеристики однозначно определяют тип кристаллической решетки.

Наиболее популярной архитектурой нейронной сети является многослойный персептрон, который успешно применяется для решения разнообразных