



<http://doi.org/10.35596/2522-9613-2022-28-1-20-26>

Оригинальная статья
Original paper

УДК 004.93

МЕТОДЫ ПОСТРОЕНИЯ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ ДЛЯ КЛАССИФИКАЦИИ ДАННЫХ

Л.В. СЕРЕБРЯНАЯ^{1,2}

¹БИП – Университет права и социально-информационных технологий (г. Минск, Республика Беларусь)

²Белорусский государственный университет информатики и радиоэлектроники
(г. Минск, Республика Беларусь)

Поступила в редакцию 13 января 2022

© Белорусский государственный университет информатики и радиоэлектроники, 2022

Аннотация. Рассмотрены особенности организации дистанционной формы обучения студентов в высшем учебном заведении, а также необходимые для этого информационно-образовательные технологии. Предложена система автоматического оценивания знаний студентов. В ее основу положена модель в виде искусственной нейронной сети. Приведены особенности такой модели. Реализовано два метода построения искусственных нейронных сетей, используемых в программном модуле тестирования знаний студентов. Обоснован выбор типа сети, ее структуры и параметров. Первый способ связан с построением искусственной нейронной сети в ручном режиме. Изложен алгоритм, отражающий итерационный процесс ее обучения. Во втором случае сеть строится автоматически путем применения генетического алгоритма. В начале работы на вход алгоритма поступает множество исходных данных, сформированное случайным образом. В ходе своей работы генетический алгоритм определяет архитектуру и параметры нейронной сети, обеспечивающие успешное решение поставленной прикладной задачи. Обученные сети используются для классификации данных. Обе сети показали приемлемую точность классификации результатов, полученных в ходе тестирования знаний студентов.

Ключевые слова: дистанционное обучение, искусственная нейронная сеть, многослойный персептрон, генетический алгоритм, классификация данных.

Конфликт интересов. Автор заявляет об отсутствии конфликта интересов.

Для цитирования. Серебряная Л.В. Методы построения искусственных нейронных сетей для классификации данных. Цифровая трансформация. 2022; 28(1): 20-26.

METHODS FOR CONSTRUCTING ARTIFICIAL NEURAL NETWORKS FOR DATA CLASSIFICATION

LIYA V. SEREBRYANAYA^{1,2}

¹*BIP – University of Law and Social Information Technologies (Minsk, Republic of Belarus)*

²*Belarusian State University of Informatics and Radioelectronics (Minsk, Republic of Belarus)*

Submitted 13 January 2022

© Belarusian State University of Informatics and Radioelectronics, 2022

Abstract. The features of the organization of distance learning of students in a higher educational institution, as well as the information and educational technologies necessary for this, are considered. A system of automatic assessment of students' knowledge is proposed. It is based on a model in the form of an artificial neural network. The features of such a model are given. The two implemented methods for constructing artificial neural networks have been used in the software module for testing students' knowledge. The choice of the type of network, its structure, and parameters has been substantiated. The first method is related to the construction of an artificial neural network in the manual mode. An algorithm is presented that reflects the iterative process of its training. In the second case, the network is built automatically by applying a genetic algorithm. At the beginning of the work, a set of randomly generated initial data arrives at the input of the algorithm. In the course of its work, the genetic algorithm determines the architecture and parameters of the neural network, which ensure the successful solution of the assigned applied problem. Trained networks are used to classify data. Both networks showed acceptable classification accuracy of the results obtained in the course of the students' knowledge testing.

Keywords: distance learning, artificial neural network, multilayer perceptron, genetic algorithm, data classification.

Conflict of interests. The author declares no conflict of interests.

For citation. Serebryanaya L.V. Methods for Constructing Artificial Neural Networks for Data Classification. Digital transformation. 2022; 28(1): 20-26.

Введение

В последнее время по известным причинам во всех сферах жизнедеятельности социума наравне с общением вживую, а часто и заменяя его, появляются различные формы виртуального взаимодействия людей. Эти формы не обошли стороной и образовательные процессы.

Поскольку уже имеется достаточно большой опыт дистанционной формы обучения, можно уверенно перечислить ее плюсы и минусы, понимая, что максимальных успехов удается достичь, сочетая традиционный и удаленный подходы к обучению. Отличием дистанционного обучения от традиционного является удаленность преподавателя от студента, отсутствие их непосредственного контакта в процессе обучения. В этом отношении традиционная форма обучения всегда будет иметь преимущество, какой бы совершенной ни была техническая основа передачи информации. Однако такие особенности удаленного обучения, как безопасность, доступность, гибкость, массовость, экономия ресурсов, постоянно повышают интерес к нему.

Для организации дистанционного обучения в высшем учебном заведении необходимы современные информационно-образовательные технологии, основу которых составляет математическое и программное обеспечение. Его созданию посвящена данная работа.

Особенности решения задач с помощью искусственной нейронной сети

Одним из основных этапов образовательного процесса является оценивание знаний студентов. При дистанционном обучении его стараются автоматизировать, освободив от технической работы преподавателей. Рассмотрим контрольно-оценочную систему знаний

студентов, которая может быть представлена в виде тестирования. В ходе него студенту предъявляются вопросы из различных разделов курса, соответствующие разным уровням сложности, после чего выставляется оценка его знаний. В статье в качестве модели, положенной в основу системы автоматического оценивания знаний студентов, предлагается использовать искусственную нейронную сеть (ИНС).

Постоянно расширяется круг задач, которые решаются с помощью машинного обучения. Работа ИНС также опирается на него, а результатом ее функционирования будут классификация и распознавание образов. ИНС в качестве модели выбрана вследствие ее универсальности, позволяющей использовать сеть для решения задач из любой прикладной области. Это обусловлено следующими свойствами данной модели.

1. *Обучение.* В ходе предъявления сети обучающих объектов, для которых известны выходные сигналы, происходит корректировка весовых коэффициентов ИНС, после чего она может распознавать тестовые образы.

2. *Обобщение.* Отклик сети после обучения может быть до некоторой степени нечувствителен к небольшим изменениям входных сигналов. Важно, что ИНС выполняет автоматически обобщение благодаря своей структуре.

3. *Абстрагирование.* Если на вход сети подать несколько искаженных вариантов входного образа, то благодаря свойствам 1 и 2 сеть сможет создать на выходе корректный образ, с которым она раньше никогда не встречалась.

Решение проблемы распознавания (классификации) образов с помощью ИНС состоит из двух процедур: обучения и непосредственно распознавания незнакомых образов [1–2].

Процесс поиска решения задачи с помощью сети, прошедшей обучение, оказывается более гибким, чем использование других вычислительных средств, поскольку ИНС может повышать точность результатов по мере накопления ею опыта и адаптироваться к происходящим изменениям.

Предложено два способа построения моделей ИНС.

Первый способ построения и обучения ИНС

Модуль тестирования знаний студентов реализован на основе одной из популярных архитектур ИНС – многослойного персептрона, его структура приведена на рис. 1.

Нейроны могут объединяться в сети различными способами, а количество слоев и нейронов в них может быть произвольным. Обычно во всех скрытых слоях одинаковое количество нейронов. В каждом слое выполняется нелинейное преобразование линейной комбинации сигналов предыдущего слоя.

Главная особенность работы с ИНС – это необходимость ее обучения, которое заключается в нахождении значений весовых коэффициентов связей между нейронами. Результат работы сети состоит в определении класса, которому принадлежит конкретный образ. Образец для обучения или обработки представляет собой вектор значений признаков объекта. При этом совокупность всех признаков объекта должна точно определять класс, к которому относится образ.

Топология сети строится так, чтобы количество нейронов в выходном слое соответствовало количеству классов, предусмотренных архитектурой ИНС. Для модуля тестирования количество классов определяется шкалой оценок, которые может получить студент. При этом должно быть установлено соответствие между значениями на выходном слое и номером определенного класса. Поэтому баллы, которые студенты набирают в ходе тестирования, попадают в определенный диапазон значений, а каждый диапазон связан с одним из классов в выходном слое ИНС и соответствует оценке студента.




Рис. 1. Модель ИНС в виде перцептрона
Fig. 1. ANN model in the form of a perceptron

Для построения перцептрона необходимо выбрать вид функции активации, число слоев в сети и количество нейронов в каждом слое, задать диапазоны изменений всех переменных, учитывая множество значений выбранной функции активации. Параметрами ИНС являются пороговые значения и весовые коэффициенты [3–4].

Поскольку перцептрон обучается с учителем, должно быть задано обучающее множество пар векторов $\{x, d\}$, где x – условие задачи, d – известное решение для этого условия. В нашем случае множество входных данных – это тесты, состоящие из вопросов, каждый из которых относится к одному из разделов учебной дисциплины и имеет определенный уровень сложности, влияющий на результирующую оценку студента. Количество элементов в обучающем множестве должно быть достаточным для обучения сети, чтобы под управлением алгоритма сформировать набор параметров сети, дающий нужное отображение входного множества X в выходное множество Y . При этом количество элементов в обучающей выборке не регламентируется. В ходе обучения выбирается один из векторов обучающей выборки и подается на вход сети. На выходе получится некоторый вектор y . Тогда ошибкой сети можно считать $E = |d - y|$ для каждой пары (x, d) . Для оценки качества обучения выбирают суммарную квадратическую ошибку или среднюю относительную ошибку. Алгоритм обучения перцептрона можно представить следующим образом:

1. Инициализировать веса и параметры функции активации в малые ненулевые значения.
2. Подать на вход сети один образ и рассчитать выходное значение.
3. Посчитать ошибку E , сравнив d и y .
4. Изменить веса и параметры функции активации так, чтобы ошибка E уменьшилась.
5. Повторять шаги 2–4 до тех пор, пока ошибка не перестанет убывать или не станет достаточно малой.

Алгоритм обучения перцептрона называют алгоритмом обратного распространения ошибки [5]. Предполагается два прохода по всем слоям сети: прямой и обратный. 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 реакцией сети на данный входной образ. Фактически решение задачи – это определение весовых коэффициентов вектора значений. Во время прямого прохода все веса сети фиксированы. В течение обратного прохода веса настраиваются в соответствии с правилом коррекции ошибок, а именно фактический выход сети вычитается из желаемого, в результате чего формируется сигнал ошибки (шаг 3 алгоритма). Этот сигнал впоследствии распространяется по сети в направлении, обратном направлению связей между нейронами. Весовые коэффициенты настраиваются с целью максимального приближения выходного сигнала сети к желаемому.

Достоинством алгоритма обратного распространения ошибки является его универсальность с точки зрения применения, т. к. обычно он используется для определения класса объекта, которому соответствует входной сигнал. Однако недостатком данного

алгоритма может оказаться неопределенно долгий процесс обучения и подбор всех параметров сети в ручном режиме.

Второй способ построения и обучения ИНС

В рамках второго способа фактически требуется построить ИНС, аналогичную полученной первым способом, только сеть строится автоматически путем применения генетического алгоритма [6]. Его цель – определить в ходе эволюции архитектуру и параметры ИНС, обеспечивающие успешное решение поставленной прикладной задачи. На рис. 2 показана схема работы генетического алгоритма, рассмотрим его этапы [7].

Генетический алгоритм работает с популяцией особей, в хромосоме каждой из которых закодировано возможное решение задачи. В начале работы алгоритма популяция формируется случайным образом, чему соответствует блок «Формирование начальной популяции». В блоке «Оценивание популяции» при помощи функции приспособленности, которая необходима для вычисления приспособленности каждой особи, оценивается качество закодированных решений. По результатам оценки особей наиболее приспособленные из них выбираются в блок «Селекция» для скрещивания. В блоке «Скрещивание» к выбранным особям применяется генетический оператор кроссинговера, и создается следующее поколение особей – потомство. Его генетическая информация формируется в результате обмена хромосомной информацией между родительскими особями. Созданные потомки формируют новую популяцию, причем часть потомков мутирует, что выражается в случайном изменении их генотипов в блоке «Мутация». Период, включающий в себя последовательность «Оценивание популяции» – «Селекция» – «Скрещивание» – «Мутация», называется поколением. Эволюция популяции состоит из последовательности таких поколений.

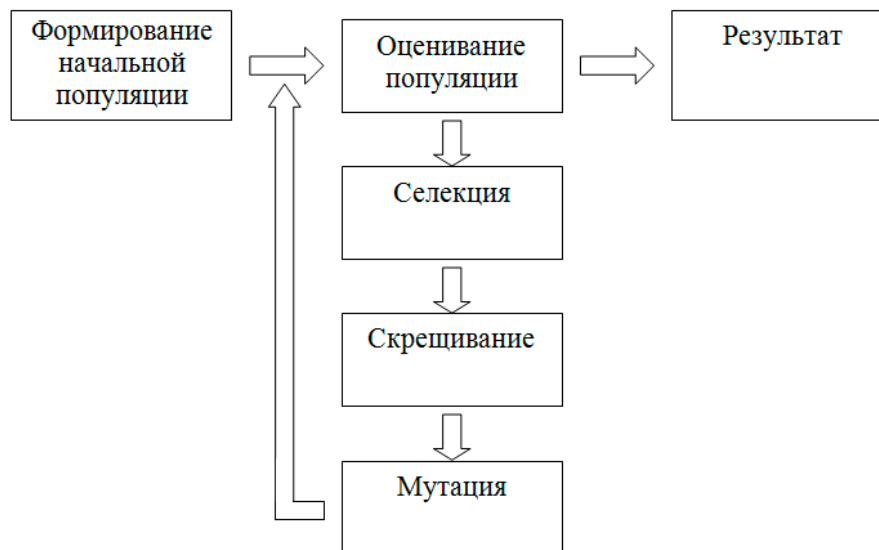


Рис. 2. Схема работы генетического алгоритма
Fig. 2. Scheme of the genetic algorithm

В большинстве случаев при решении какой-либо задачи с использованием ИНС ее параметры и архитектура подбираются экспериментальным путем. Это обусловлено тем, что каждая задача имеет свои уникальные особенности: данные, требуемый результат, желаемую обобщающую способность и т. д. Подбор оптимальных параметров сети является достаточно трудоемким процессом из-за ручного перебора и подгона. Для автоматизации построения сети может использоваться генетический алгоритм.

Для работы генетический алгоритм использует исходную выборку (популяцию), где гены каждой отдельной особи являются частным решением задачи отбора. Как правило, число генов у особи зависит от задачи и от желаемых параметров в реализуемой модели. В результате на основе генов каждой особи ставится в соответствие какая-то оценочная величина, которая показывает, насколько успешно данный элемент (особь) решает

поставленную задачу. Далее более приспособленные особи скрещиваются, полученные потомки формируют новую популяцию, которая впоследствии оценивается вышеприведенным образом. В ходе скрещивания двух особей за счет применения генетических операторов происходит обмен определенной частью генов, а получившиеся потомки обладают свойствами как одного, так и второго родителя.

Решение, найденное при помощи генетического алгоритма, может и не быть лучшим, но оно окажется близким к оптимальному. Указанная неточность окупается тем фактом, что вычислительная сложность алгоритма только косвенно зависит от сложности решаемой задачи. Для алгоритма нужны лишь начальная выборка, вид целевой функции, параметры для кодирования генотипа и ограничения, если они имеются. К основным особенностям таких алгоритмов можно отнести: возможность создания самообучающейся и самоорганизующейся системы, которая способна решать достаточно большой круг задач, а также широкие возможности адаптивного поведения в задачах классификации.

Поскольку количество слоев сети и нейронов в них будет определяться при помощи генетического алгоритма, необходимо уточнить последовательность и типы слоев в сети, а также создать начальную популяцию с заданными характеристиками.

Теоретический и практический опыт работы с архитектурами различных типов ИНС показал, что для сетей с небольшим количеством нейронов можно кодировать связи и веса нейронов, а для архитектур с большим числом элементов удобнее, чтобы кодировались отдельные слои и их конфигурации.

В работе были проверены оба способа кодирования. В случае скрещивания слоев двух родительских ИНС, состоящих из слоев разных типов, алгоритм может привести к генерированию сети, которая будет недействительна с точки зрения совместимости слоев между собой. Поэтому для предотвращения подобных ситуаций были введены ограничения на перемешивание слоев.

Под мутацией здесь понимается изменение структуры нейронной сети, т. е. добавление или удаление ее слоев и связей между нейронами. Как и в случае с алгоритмом скрещивания, алгоритм мутации также нуждается в определении правил изменения структуры сети, чтобы после мутации сеть сохраняла совместимость по всем связям между нейронами и слоями.

Для эксперимента была использована начальная популяция размером в 30 особей (сетей), а также 100 популяционных циклов для моделирования эволюционного процесса. Для каждой из особей вычислялась фитнес-функция. Она связана с построением нейронной сети из предложенных генов с последующим процессом обучения сети, после которого выводится значение метрики, оценивающей точность классификации.

Заключение

Результаты показали, что автоматически сгенерированная сеть уступает архитектуре, построенной вручную, на 17 % по точности классификации. Однако следует учитывать, что во втором случае построение выполнялось без участия экспертов предметной области. Поэтому подход автоматического построения сетей может применяться, например, для создания прототипов, где на первом месте стоит реализация работающей модели, а не ее качественные характеристики. Приемлемая точность классификации автоматически сгенерированной сети делает возможным использование генетических алгоритмов для решения большого круга задач распознавания образов.

Обе модели искусственных нейронных сетей, построенные как первым, так и вторым способом, могут использоваться в качестве программного обеспечения модуля автоматического тестирования знаний студентов.

Список литературы

1. Рутковская Д., Пилинский М., Рутковский Л. Нейронные сети, генетические алгоритмы и нечеткие системы. Москва: Горячая Линия-Телеком; 2007.
2. Николенко С.И., Кадурин А.А., Архангельская Е.О. Глубокое обучение. Санкт-Петербург: Питер; 2018.

3. Реза Б.З., Рамсундар Б. TensorFlow для глубокого обучения. Санкт-Петербург: BHV; 2019.
4. Серебряная Л.В., Третьяков Ф.И. Методы и алгоритмы принятия решений: учебно-методическое пособие по курсу «Методы и алгоритмы принятия решений» для студентов специальности «Программное обеспечение информационных технологий». Минск: БГУИР; 2016.
5. Метод обратного распространения ошибки [Электронный ресурс]. Режим доступа: https://www.wikiwand.com/ru/Метод_обратного_распространения_ошибки. Дата доступа: 08.01.2022.
6. Серебряная Л.В., Бочкарев К.Ю., Попитич А.Я. Модель автоматической классификации и локализации образов. Цифровая трансформация. 2019;1(6):43-48. <https://doi.org/10.38086/2522-9613-2019-1-43-48>
7. Генетический алгоритм [Электронный ресурс]. Режим доступа: http://www.machinelearning.ru/wiki/index.php?title=Генетический_алгоритм. Дата доступа: 08.01.2022.

References

1. Rutkovskaya D., Pilinsky M., Rutkovsky L. [Neural networks, genetic algorithms and fuzzy systems]. M.:Hot Line-Telecom, 2007. (In Russ.)
2. Nikolenko S.I., Kadurin A.A., Arkhangel'skaya Ye.O. [Deep Learning]. St. Petersburg: Piter, 2018. (In Russ.)
3. Reza B.Z., Ramsundar B. [TensorFlow for deep learning]. St. Petersburg: BHV; 2019. (In Russ.)
4. Serebryanaya L.V., Tretyakov F.I. [Methods and algorithms for decision making: study guide for the course «Methods and algorithms for decision making» for students of the specialty «information technology software»]. Minsk: BSUIR; 2016. (In Russ.)
5. [Method of back propagation of errors]. Available at: https://www.wikiwand.com/ru/Method_back_propagation_bugs. Accessed: 08.01.2022. (In Russ.)
6. Serebryanaya L.V., Bochkarev K.Yu., Popitich A.Ya. [Model of automatic classification and localization of images]. Tsifrovaya transformatsiya = Digital transformation. 2019;1(6):43-48. <https://doi.org/10.38086/2522-9613-2019-1-43-48> (In Russ.)
7. [Genetic algorithm]. Available at: http://www.machinelearning.ru/wiki/index.php?title=Genetic_algorithm. Accessed: 08.01.2022. (In Russ.)

Сведения об авторах

Серебряная Л.В., заведующая кафедрой информационных технологий и математики «БИП – Университет права и социально-информационных технологий», к.т.н., доцент; доцент кафедры программного обеспечения информационных технологий Белорусского государственного университета информатики и радиоэлектроники.

Information about the authors

Serebryanaya L.V., Head of the Department of Information Technologies and Mathematics «BIP – University of Law and Social Information Technologies», Cand. of Sci., Associate Professor; Associate Professor at the Information Technologies Software Department of the Belarusian State University of Informatics and Radioelectronics.

Адрес для корреспонденции

220004, Республика Беларусь,
г. Минск, ул. Короля, 3,
БИП – Университет права и социально-информационных технологий;
тел. +375-17-375-01-56;
220013, Республика Беларусь,
г. Минск, ул. П. Бровки, 6,
Белорусский государственный университет информатики и радиоэлектроники;
тел. +375-17-293-84-93;
e-mail: L_silver@mail.ru
Серебряная Лия Валентиновна

Address for correspondence

220013, Republic of Belarus,
Minsk, Korolya st., 3,
BIP – University of Law
and Social Information Technologies;
tel. +375-17-375-01-56;
220013, Republic of Belarus,
Minsk, P. Brovka st., 6,
Belarusian State University
of Informatics and Radioelectronics;
tel. +375-17-293-84-93;
e-mail: L_silver@mail.ru
Serebryanaya Liya Valentinovna