

В.С. Тормозов

аспирант

(Тихоокеанский государственный университет)

г. Хабаровск, Российская Федерация

А.Л. Золкин

канд. техн. наук

(Самарский филиал Волжского государственного

университета водного транспорта)

г. Самара, Российская Федерация

К.А. Василенко

(Колледж сервиса и дизайна при Владивостокском

университете экономики и сервиса)

г. Владивосток, Российская Федерация

Структурная оптимизация персептрона с помощью аппарата эволюционного моделирования для задачи прогнозирования значений временных рядов

В статье предлагается метод, позволяющий с помощью стохастической функции мутации с постоянным коэффициентом вариации решать сложную комбинаторную задачу структурной оптимизации искусственной нейронной сети при большой размерности пространства параметров оптимизации. Дано исследование по оценке применимости данного подхода для решения поставленной задачи. Указанный метод предлагается использовать для задачи прогнозирования значений временных рядов.

Ключевые слова: искусственная нейронная сеть; генетический алгоритм; прогнозирование; временной ряд; структурная оптимизация.

V.S. Tormozov

Postgraduate Student

(Pacific State University)

Khabarovsk, Russian Federation

A.L. Zolkin

Cand. of Techn. Sciences

(Samara branch of Volga State University of Water

Transport)

Samara, Russian Federation

K.A. Vasilenko

(College of Service and Design at the Vladivostok

University of Economics and Service)

Vladivostok, Russian Federation

Perceptron Structural Optimization Using the Apparatus of Evolutionary Modeling for the Task of Predicting the Values of Time Series

The article proposes a method that allows using the stochastic mutation function with a constant coefficient of variation to solve the complex combinatorial problem of structural optimization of an artificial neural network with a large dimension of the space of optimization parameters. A study is given to assess the applicability of this approach to solve the problem. This method is proposed to be used for the task of forecasting the values of time series.

Keywords: artificial neural network; genetic algorithm; forecasting; time series; structural optimization.

DOI: 10.25791/asu.8.2020.1210

Искусственные нейронные сети (ИНС) могут менять свое поведение в зависимости от внешней среды. Теория и математический аппарат ИНС хорошо зарекомендовали себя в области прогнозирования, там,

где необходимо применение человеческого интеллекта, в частности при прогнозировании временных рядов. Однако результативность решения задач ИНС во многом зависит от выбора множества параметров сети и

процедуры машинного обучения [1...3]. Задача поиска ИНС с оптимальными параметрами (количество скрытых слоев и нейронов в каждом из них, вид и коэффициенты функции активации, и другие) относится к задачам структурной оптимизации.

Генетический алгоритм (ГА) как метод оптимизации применительно к выбору значений параметров сложной сетевой математической модели позволяет эффективно выполнять поиск значения целевой функции, достаточно приближенного к оптимальному, многопараметрической комбинаторной задачи [4]. В основе подобных алгоритмов используется аналогия с природными эволюционными процессами. ГА находит приближенное решение комбинаторных задач и построен на основе математического аппарата эволюционного моделирования. Достоинством подобных методов, в сравнении с классическими методами, является возможность использования вероятностных, эвристических правил поиска максимума, что позволяет решать сложные, унимодальные задачи.

Применение стохастического аппарата ГА для настройки ИНС [5, 6] основано на исследовании пространства поиска с проработкой множества решений. Поиск среди множества решений вносит значительный вклад в нахождение глобальных оптимумов адаптивных рельефов. Вычислительная сложность ГА в меньшей степени зависит от объема множества оптимизации, чем переборный метод поиска оптимального решения.

Математическая постановка задачи

Имеется m временных рядов, представленных обучающей и тестовой выборками: $T_s^k = \{t_{k1}, t_{k2}, \dots, t_{kn}\}$, $T_t^k = \{t_{k1}, t_{k2}, \dots, t_{kn}\}$, k – объем прогнозирования, p – искусственная нейронная сеть (ИНС) Румельхарта.

На вход ИНС поступают данные временных рядов в заданном объеме прогнозирования: $p \cdot m$ нейронов на входном слое. ИНС прогнозирует последующие данные с единичным горизонтом прогнозирования: m нейронов на выходном слое. Функцией активации нейронов выбрана сигмоидальная функция:

$$S_{out} = \frac{1}{1 + e^{-\alpha S}},$$

где: S_{out} – выходной сигнал нейрона;

S – сигнал нейрона;

α – коэффициент функции активации сигмоидальной функции.

Каждую возможную ИНС характеризует ее конфигурация C_i : норма скорости обучения η , коэффициент функции активации нейронов α , структура ИНС, задаваемая количеством нейронов на каждом скрытом слое: $\{n_1, n_2, \dots, n_{nl}\}$, n_i – количество нейронов на i -м скрытом слое, $n_i \in \{0, 150\}$, nl – максимальное количество возможных скрытых слоев.

Если количество нейронов в каком-нибудь скрытом слое равно нулю, то количество нейронов в последующих скрытых слоях для осуществимой конфигурации также должно быть равно нулю.

Норма скорости обучения принимает различные значения с шагом 0.1 из диапазона $[0, 10]$. Десятичная степень коэффициента функции активации нейронов α принимает целые значения в диапазоне $[0, 10]$. Таким образом, коэффициент функции активации принимает значения степени десятки от 100 до 1010.

Архитектура возможных конфигураций нейронных сетей представлена на рисунке 1.




Рис. 1. Архитектура возможных конфигураций ИНС

Обучение нейронной сети производится по алгоритму обратного распространения ошибки. Данный алгоритм является одним из наиболее распространенных вариантов проведения корректировки весов.

Требуется найти такую конфигурацию ИНС, которая за приемлемое количество итераций обучения n_{it} даст наименьшую среди множества рассматриваемых конфигураций погрешность на представленной тестовой выборке T_t .

Таким образом, целевой функцией в работе является обратное значение достигнутой погрешности ИНС на тестовой выборке T_t после n_{it} итераций обучения для прогнозирования значений временных рядов с единичным горизонтом: $f(n_{it}, C_i, T_s, T_t)$ [7]:

$$f(n_{it}, C_i, T_s, T_t) = \frac{1}{e_{test}},$$

где $f(\cdot)$ – целевая функция ГА, e_{test} – достигнутая минимальная погрешность тестирования ИНС.

Каждый вариант решения – это конфигурация ИНС, определяемая набором параметров $C_i = \{n_1, n_2, \dots, n_{nl}, \alpha, \eta\}$.

Таким образом, в этой задаче $nl + 2$ параметров, причем не все конфигурации допустимы: если $n_i = 0$, то $n_k = 0$, $k > i$, $k \leq nl$.

Существующие методы решения задачи

Метод *Symbiotic* [8] основан на генетическом алгоритме двух популяций. В одной популяции происходит настройка отдельных нейронов, в

другой – настраиваются структуры ИНС. Количество нейронов в скрытых слоях предварительно задано.

Метод *ESP* является модификацией алгоритма *Symbiotic* [9]. Модификация заключается в том, что структура ИНС не изменяется и задается до начала работы ГА. Вся популяция состоит из групп особей. В каждой группе ГА работает независимо от остальных групп. Такое разбиение на независимые группы позволяет распараллелить поиск решения. Отсутствие процедуры оптимизации структуры ИНС позволяет ускорить поиск решения по сравнению с *Symbiotic*.

Алгоритм *NEAT* [10] работает с такими приемами, как специализация особей [11] и исторические метки, которые позволяют существенно увеличить эффективность работы ГА.

Алгоритм Гроу [12] для моделирования нейросетевых структур использует оригинальную грамматику. Каждая конфигурация ИНС представляет собой особь ГА, а нейрон – элемент этой особи. Наращивание элементов выполняется путем параллельного и последовательного раздвоения нейронов-элементов особи.

Использование ГА для оптимизации структуры ИНС

Метод градиентного спуска останавливается при достижении локального минимума и в данном случае не гарантирует оптимальности найденного решения, так как задача не является унимодальной. Метод полного перебора прост в реализации, однако вычислительно сложен: уже для $n! = 1$ требует обучения и тестирования $1,5 \cdot 10^5$ конфигураций ИНС.

Генетический метод сочетает в себе метод перебора и градиентного спуска: перебор осуществляется встроенными алгоритмами мутации и скрещивания, а градиентный спуск реализуется через отбор особей для размножения. ГА – это одно из направлений исследований в области искусственного интеллекта, занимающееся созданием упрощенных моделей эволюции живых организмов для решения задач оптимизации.

Очень важным понятием в ГА считается функция приспособленности, иначе называемая *функцией оценки*. Она представляет меру приспособленности данной особи в популяции. Эта функция играет важнейшую роль, поскольку позволяет оценить степень приспособленности конкретных особей в популяции и выбрать из них наиболее приспособленные (т. е. имеющие наибольшие значения функции приспособленности в соответствии с эволюционным принципом выживания лучше всего приспособившихся).

Функция приспособленности также получила свое название непосредственно из генетики. Она оказывает сильное влияние на функционирование генетических алгоритмов и должна иметь точное и корректное определение. На каждой итерации генетического алгоритма приспособленность каждой особи данной популяции оценивается при помощи функции приспособленности, и на этой основе создается следующая популяция

особей, составляющих множество потенциальных решений проблемы, например, задачи оптимизации.

Классический ГА состоит из следующих шагов:

- инициализация, или выбор исходной популяции хромосом;
- оценка приспособленности хромосом в популяции – расчет функции приспособленности для каждой хромосомы;
- проверка условия остановки алгоритма;
- селекция хромосом – выбор тех хромосом, которые будут участвовать в создании потомков для следующей популяции;
- применение генетических операторов – мутации и скрещивания;
- формирование новой популяции;
- выбор «наилучшей» хромосомы.

В работе реализован ГА, популяция которого сменяет предварительно заданное количество n_{rate} жизненных циклов. Во время каждого жизненного цикла последовательно происходят процессы размножения, мутации и отмирания.

В процессе размножения популяция делится на группы по n_{gr} особей и внутри каждой группы рулеточным методом выбирается одна особь для размножения. Выбор особей рулеточным методом заключается в том, что i -й особи в группе определенный соотносится диапазон значений

$$[x_i, x_{i+1}], x_{i+1} = x_i + L_i,$$

где длина этого диапазона L_i обратно пропорциональна средней ошибке обучения ИНС особи.

Затем формируется случайная величина r из диапазона $[x_0, x_{2*ngt}]$, и для размножения выбирается та особь, в диапазон которой попадает случайная величина r .

После отбора особей для размножения особи из двух соседних групп скрещиваются с помощью одноточечного стохастического кроссинговера, суть которого состоит в следующем:

- вся хромосома преобразуется в набор бит, представляющий собой конкатенированные двоичные представления элементов хромосомы – значений параметров конфигурации конкретной ИНС;
- случайным образом избирается два соседствующих бита одной хромосомы;
- часть хромосомы, находящаяся с левой стороны от промежутка между выбранными битами хромосомы, меняется с аналогичной частью другой хромосомы.

Затем происходит мутация случайной особи популяции. Мутация заключается в том, что каждый параметр конфигурации ИНС вычитается от максимально допустимого значения этого параметра:

$$P_k = P_{maxk} - P_k.$$

Так формируются новая хромосома, и если хромосома жизнеспособна, то особь остается в популяции с измененными генами.

Происходит отмирание всех неприспособленных особей, их место занимают особи, рожденные в текущем жизненном цикле. Неприспособленными признаются те особи, значение целевой функции которых меньше среднего, представленного в популяции.

Блок-схема применяемого ГА для отбора оптимальных параметров ИНС представлена на рисунке 2.

Методика экспериментального исследования

Проведены настройка и экспериментальное исследование ГА для задачи предсказания параметров погоды. По имеющимся данным о погоде за последние семь дней, требовалось предсказать параметры погоды

на завтра. В качестве временных рядов использовались значения следующих параметров погоды:

- среднесуточная температура воздуха (°C),
- давление воздуха (мм рт. ст.),
- давление воздуха на уровне моря, влажность (%),
- скорость ветра (м/с).

Исходные данные о параметрах погоды на каждый день были получены из открытого информационного ресурса [13].

Перед обработкой значений временного ряда в ИНС выполняется их нормализация:

$$p_{norm} = \frac{p - p_{min}}{p_{max} - p_{min}},$$

где p_{norm} – нормализованное значение параметра погоды, p_{min} и p_{max} – минимальное и максимальное значения параметров погоды в рассматриваемом временном ряду, p – исходное значение параметра погоды.

Температура воздуха измеряется в градусах Цельсия и находится в диапазоне $[-37^{\circ}, +40^{\circ}]$. Давление воздуха измеряется на уровне города Хабаровска и на уровне моря. Давление измеряется в миллиметрах ртутного столба и находится в диапазоне $[725, 780]$. Влажность измеряется в процентах и находится в диапазоне $[10, 100]$. Скорость ветра измеряется в метрах в секунду и находится в диапазоне $[0, 20]$.

Результаты эксперимента

Результаты эксперимента для множества конфигураций ИНС с популяциями разного размера представлены на рисунке 3. На графике отображена зависимость эффективности поиска от количества особей в популяции при неизменной вычислительной сложности ГА.

Было произведено тестирование системы с популяцией численностью 100, числом поколений – 10 и числом итераций для определения ошибки обучения НС – 100. Объем обучающей выборки составил 2000 примеров, объем тестовой – 500 примеров. В результате работы ГА была найдена конфигурация ИНС с 84 нейронами на первом скрытом слое ИНС, 80 нейронами – на втором, 86 нейронами – на третьем, 109 нейронами – на четвертом. При этом норма скорости обучения η составила 3.1, а коэффициент функции




Рис. 2. Блок-схема генетического алгоритма




Рис. 3. Зависимость эффективности поиска от размера популяции ГА




Рис. 4. Зависимость среднеквадратичной погрешности обучения от количества итераций обучения

активации $\alpha = 10$. В результате обучения такой ИНС в течение 4000 итераций ошибка тестирования составила 3 %. График обучения нейронной сети представлен на рисунке 4.

Заключение

Таким образом, оптимальная архитектура нейронной сети, найденная ГА: 84 нейрона первого, 80 нейронов второго, 86 нейронов третьего, 109 нейронов четвертого скрытых слоев, $\eta = 3.1$, $\alpha = 10$.

Было обнаружено, что скорость обучения персептрона (сходимость) прямо пропорциональна числу нейронов в скрытых слоях. Минимальная ошибка обучения на временных рядах данных погоды достигла 1,2 %.

Список литературы

1. Золкин А.Л., Просви́ров Ю.Е., Ворошилов Э.А. Разработка структурной схемы автоматизированной системы контроля технического состояния коллекторов тяговых электродвигателей // *Вестник Ростовского государственного университета путей сообщения*. Ростов-на-Дону: РГУПС. 2009, № 1. С. 45–51.
2. Тормозов В.С. Подсчет и распознавание автомобилей на спутниковых снимках // *Ученые заметки ТОГУ*. 2017. Т. 8, № 3. С. 126–134.
3. Тормозов В.С. Автоматическое детектирование дорожного покрытия на космических снимках сверхвысокого разрешения // *Молодые ученые – Хабаровскому краю. Материалы XIX краевого конкурса молодых ученых и аспирантов*. Хабаровск: Издательство Тихоокеанского государственного университета. 2017. С. 131–135.

4. Бураков М.В. *Генетический алгоритм: теория и практика*. СПб.: ГУАП, 2008. 164 с.

5. Божич В.И., Лебедев О.Б., Шницер Ю.Л. Разработка генетического алгоритма обучения нейронных сетей // *Известия ТРТУ (тематический выпуск)*. 2001. Т. 22, № 4. С. 170–174.

6. Чипига А.Ф., Воронкин Р.А. Обучение искусственных нейронных сетей путем совместного использования методов локальной оптимизации и генетических алгоритмов // *Известия ТРТУ*, 2003. Т. 33, № 4. С. 172–174.

7. Koehn P. Combining Genetic Algorithms and Neural

Networks: The Encoding Problem // *Master of Science Degree the University of Tennessee*, Knoxville. 1994.

8. Moriarty D. E., Miikkulainen R. Forming Neural Networks through Efficient and Adaptive Coevolution // *Evolutionary Computation*. 1998, no. 5(4).
9. Gomez F., Miikkulainen R. Incremental evolution of complex general behavior // *Adaptive Behavior*. 1997, no. 5, pp. 317–342.
10. Stanley K.O., Miikkulainen R. Evolving Neural Topologies through Augmenting Topologies // *Evolutionary Computation*. The MIT Press. 2002, no. 10(2), pp. 99–127.
11. Goldberg D.E., Richardson J. Genetic algorithms with sharing for multimodal function optimization // *Proceedings of the Second International Conference on Genetic Algorithms*, Morgan Kaufmann. San Francisco, California. 1987, pp. 148–154.
12. Gruau F. Genetic synthesis of Boolean neural networks with a cell rewriting developmental process // *Combination of Genetic Algorithms and Neural Networks*, IEEE Computer Society Press, 1992.
13. Расписание погоды: сайт – расписание погоды. 20.04.2020. Электронный ресурс: <http://rp5.ru/>.

References

1. Zolkin A.L., Prosvirov Yu.Ye., Voroshilov E.A. Razrabotka strukturnoy skhemy avtomatizirovannoy sistemy kontrolya tekhnicheskogo sostoyaniya kollektorov tyagovykh elektrodvigatelay [Development of a structural diagram of an automated system for monitoring the technical condition of traction electric motor collectors]. *Vestnik Rostovskogo gosudarstvennogo universiteta putey soobshcheniya* [Bulletin of the Rostov State University of Railways]. Rostov-na-Donu: RGUPS. 2009, no. 1, pp. 45–51.

2. Tormozov V.S. Podschet i raspoznanie avtomobiley na sputnikovykh snimkakh [Counting and recognition of cars on satellite images]. *Uchenye zametki TOGU* [Scientists notes of the Pacific state University]. 2017. Vol. 8, no. 3, pp. 126–134.
3. Tormozov V.S. Avtomaticheskoe detektirovanie dorozhnogo pokrytiya na kosmicheskikh snimkakh sverkhvysokogo razresheniya. *Molodye uchenye – Khabarovskomu krayu. Materialy XIX kraevogo konkursa molodykh uchenykh i aspirantov* [Automatic detection of road surface on ultra-high resolution satellite images. Young scientists – Khabarovsk Krai. Materials of the XIX regional competition of young scientists and graduate students]. Khabarovsk: Izdatelstvo Tikhookeanskogo gosudarstvennogo universiteta [Khabarovsk: Pacific State University Publishing House]. 2017. S. 131–135.
4. Burakov M.V. *Geneticheskiy algoritm: teoriya i praktika* [Genetic algorithm: theory and practice]. SPb.: GUAP [St. Petersburg: Publishing house of St. Petersburg State University of Aerospace Instrumentation]. 2008. 164 p.
5. Bozhich V.I., Lebedev O.B., Shnitser Yu.L. Razrabotka geneticheskogo algoritma obucheniya neyronnykh setey [Development of a genetic algorithm for learning neural networks]. *Izvestiya TRTU (tematicheskiy vypusk)* [Bulletin of Taganrog State Radio Engineering University (thematic issue)]. 2001. Vol. 22, no. 4, pp. 170–174.
6. Chipiga A.F., Voronkin R.A. Obucheniye iskusstvennykh neyronnykh setey putem sovmestnogo ispolzovaniya metodov lokalnoy optimizatsii i geneticheskikh algoritmov [Training artificial neural networks by using local optimization methods and genetic algorithms together]. *Izvestiya TRTU* [Bulletin of Taganrog State Radio Engineering University]. 2003. Vol. 33, no. 4, pp. 172–174.
7. Koehn P. Combining Genetic Algorithms and Neural Networks: The Encoding Problem. *Master of Science Degree the University of Tennessee*, Knoxville. 1994.
8. Moriarty D. E., Miikkulainen R. Forming Neural Networks through Efficient and Adaptive Coevolution. *Evolutionary Computation*. 1998, no. 5(4).
9. Gomez F., Miikkulainen R. Incremental evolution of complex general behavior. *Adaptive Behavior*. 1997, no. 5, pp. 317–342.
10. Stanley K.O., Miikkulainen R. Evolving Neural Topologies through Augmenting Topologies. *Evolutionary Computation*. The MIT Press. 2002, no. 10(2), pp. 99–127.
11. Goldberg D.E., Richardson J. Genetic algorithms with sharing for multimodal function optimization. *Proceedings of the Second International Conference on Genetic Algorithms, Morgan Kaufmann*. San Francisco, California. 1987, pp. 148–154.
12. Gruau F. Genetic synthesis of Boolean neural networks with a cell rewriting developmental process. *Combination of Genetic Algorithms and Neural Networks, IEEE Computer Society Press*, 1992.
13. *Raspisanie pogody: sayt – raspisanie pogody* [Weather schedule: website – weather schedule]. 20.04.2020. Available at: <http://rp5.ru/>

Информация об авторах

Тормозов Владимир Сергеевич, аспирант кафедры «Вычислительная техника», соискатель ученой степени кандидата технических наук, старший преподаватель кафедры «Программное обеспечение вычислительной техники и автоматизированных систем»

Федеральное государственное бюджетное образовательное учреждение высшего образования «Тихоокеанский государственный университет»
680054, Российская Федерация, г. Хабаровск, ул. Тихоокеанская, д. 136

Золкин Александр Леонидович, кандидат технических наук

Самарский филиал Федерального государственного бюджетного образовательного учреждения высшего образования «Волжский государственный университет водного транспорта»

443099, Российская Федерация, г. Самара, Молодогвардейская ул., д. 62

Василенко Константин Александрович, преподаватель высшей категории

Колледж сервиса и дизайна при Владивостокском университете экономики и сервиса (ВГУЭС)

690092, Российская Федерация, г. Владивосток, ул. Добровольского, 20

Information about the authors

Tormozov Vladimir Sergeevich, Postgraduate Student of the Department «Computer Engineering», Applicant for Degree of the Scientific Degree of Candidate of Technical Sciences, Senior Lecturer of the Department of Computer Software and Automated Systems

Federal State Budgetary Institution of Higher Education «Pacific State University»

680054, Russian Federation, Khabarovsk, Tikhookeanskaya Str., 136

Zolkin Aleksandr Leonidovich, Candidate of Technical Sciences

Samara branch of the Volga State University of Water Transport of the Federal State Budgetary Educational Institution of Higher Education

443099, Russian Federation, Samara, Molodogvardeiskaya Str., 62

Vasilenko Konstantin Aleksandrovich, Senior Lecturer of the Highest Category

College of Service and Design at the Vladivostok University of Economics and Service

690092, Russian Federation, Vladivostok, Dobrovolskaya Str., 20