

Мурлин Алексей Георгиевич

Кубанский государственный технологический университет

Колесников Даниил Сергеевич

Кубанский государственный технологический университет

Бгане Аскер Асланович

Кубанский государственный технологический университет

Использование нейросетей при решении задач оптимизации

Аннотация. Данная статья посвящена актуальным методам использования нейронных сетей для решения задач оптимизации. Особо отмечается прямая экономическая выгода от их применения: нейросети позволяют значительно сокращать издержки, повышать эффективность использования ресурсов и максимизировать ключевые финансовые показатели. Выделяются их главные достоинства: способность работать с огромными массивами данных, находить сложные, нелинейные связи и приспосабливаться к меняющейся среде. Исследуются различные архитектуры нейросетей, включая многослойные перцептроны, сверточные, рекуррентные и комбинированные модели. Особое внимание уделяется процессам обучения и методам регуляризации. Приводятся примеры успешного внедрения в логистике, финансах и промышленности. Подчеркивается эффективность нейросетевых подходов и их потенциал для дальнейшего развития в практических сферах.

Ключевые слова: нейронные сети, градиентный спуск, машинное обучение, искусственный интеллект, стохастическая оптимизация, многокритериальные задачи, обучение модели, глубинное обучение, адаптивные алгоритмы.

Murlin Alexey Georgievich

Kuban State University of Technology

Kolesnikov Daniil Sergeevich

Kuban State University of Technology

Bgane Asker Aslanovich

Kuban State University of Technology

The use of neural networks in solving optimization problems

Abstract. This article is devoted to current methods of using neural networks to solve optimization problems. The direct economic benefits of their use are highlighted: neural networks can significantly reduce costs, increase resource efficiency, and maximize key financial indicators. Their main advantages stand out: the ability to work with huge amounts of data, find complex, nonlinear relationships, and adapt to a changing environment. Various architectures of neural networks are being investigated, including multilayer perceptrons, precise, recurrent and combined models. Special attention is paid to learning processes and regularization methods. Examples of successful implementation in logistics, finance and industry are given. The effectiveness of neural network approaches and their potential for further development in practical areas is emphasized.

Key words: neural networks, gradient descent, machine learning, artificial intelligence, stochastic optimization, multi-criteria tasks, model learning, deep learning, adaptive algorithms.

В инженерном деле, экономике и IT постоянно возникают вопросы, связанные с поиском наилучшего варианта. Этот процесс, известный как оптимизация, нацелен на

выбор оптимального решения из всех возможных, принимая во внимание существующие рамки и условия, которые определяют, какие из решений являются допустимыми [1].

Суть подобных задач — подобрать значения управляемых параметров так, чтобы показатель эффективности системы, называемый целевой функцией, достиг своего пикового значения (наименьшего или наибольшего). Данная функция количественно связывает варьируемые параметры с итоговым результатом. Например, если стоит задача выбрать самый короткий путь, целевая функция будет описывать расстояние, которое нужно сократить.

Важно подчеркнуть, что поиск решения почти никогда не ведется без учета различных ограничений, формализованных через равенства или неравенства. Таким образом, модель оптимизации — это, по сути, поиск экстремального значения целевой функции внутри границ, очерченных этими правилами [1].

Проблема исследования заключается в принципиальном противоречии между стохастической природой нейросетей и требованием детерминированных решений в критически важных оптимизационных задачах.

Целью данного исследования является разработка и экспериментальное обоснование детерминированного нейросетевого алгоритма, преодолевающего стохастическую неопределённость за счёт гибридного подхода (нейросеть + аналитические методы), обеспечивающего воспроизводимые решения для трёх критически важных классов оптимизационных задач.

Для решения поставленной проблемы и достижения цели исследования предлагается комплексный подход, сочетающий теоретическое обоснование, алгоритмическую разработку и практическую верификацию.

Теоретико-аналитическая часть включает формализацию условий детерминированного поведения нейросетевых моделей в оптимизационных задачах. На основе методов выпуклого анализа и теории стохастической аппроксимации будут разработаны критерии устойчивости решений. Особое внимание уделяется доказательству теорем о сходимости гибридного алгоритма при различных типах ограничений.

Алгоритмическая разработка основана на синтезе глубоких нейросетей с гарантированно сходящимися оптимизационными процедурами. Предполагается создание специализированной архитектуры, где начальные слои осуществляют стохастическое исследование пространства решений, а финальные этапы реализуют детерминированную постобработку через интегрированные аналитические методы.

Экспериментальная валидация строится на трех уровнях тестирования: базовые benchmarks для верификации корректности реализации, промышленные кейсы для оценки практической применимости, и специально сконструированные вырожденные случаи для проверки устойчивости. Применяются оригинальные метрики, оценивающие не только точность решений, но и их воспроизводимость при многократных запусках [5].

Интерпретационный компонент исследования использует методы визуальной аналитики и топологического анализа данных для выявления закономерностей в работе гибридного алгоритма. Это позволит установить границы применимости подхода и выявить критические параметры, влияющие на детерминированность выходов.

Нейросети обладают уникальной способностью моделировать сложные зависимости благодаря своей архитектуре и принципам работы [3]. Так, например, при многослойной архитектуре (рис. 1). нейронные сети построены по принципу многоуровневой организации, где несколько вычислительных слоёв, состоящих из нейронов, последовательно обрабатывают поступающую информацию. С каждым новым уровнем происходит всё более глубокое и сложное преобразование данных, что даёт возможность выявлять абстрактные и сложные закономерности. Благодаря такому устройству, эти системы успешно справляются с анализом и моделированием сложных нелинейных зависимостей между различными параметрами.




Рис. 1. Многослойная архитектура нейронных сетей

Работа нейронной сети стартует с входного слоя, который принимает исходные данные. На данном этапе информация не подвергается изменениям — она просто передаётся дальше по сети. Этот слой выполняет функцию посредника, обеспечивая поступление данных в более глубокие уровни модели, где происходит их основное преобразование.

Попадая во внутренние слои, информация подвергается интенсивному анализу. В ходе этого анализа система выявляет важные взаимосвязи и последовательно конструирует иерархию признаков — от простых элементов к сложным абстракциям [2]. Каждый нейрон в скрытом слое принимает информацию от нейронов предыдущего слоя и использует веса, которые определяют степень важности каждого входа. Результаты вычислений, полученные от нейронов, затем передаются на следующий слой, а процесс обработки повторяется на каждом последующем уровне.

Каждый нейрон в скрытых слоях, кроме того, применяет определённую функцию активации, которая помогает сети моделировать нелинейные зависимости.

Нейросеть продолжает этот процесс до последнего слоя, который является выходным. В выходном слое происходит подведение итогов вычислений и получение ответа, будь то классификация объекта, прогнозирование значений или любое другое требуемое действие [3]. Мощность нейронной сети во многом определяется числом ее внутренних слоев. Добавление новых уровней обработки позволяет системе выявлять все более тонкие и комплексные зависимости в исходной информации, выстраивая многоступенчатую систему признаков.

Сильной стороной таких моделей является их обучение на обширных данных [4]. В основе этого подхода лежит самонастройка — процесс, в ходе которого алгоритм независимо обнаруживает, исследует и систематизирует скрытые закономерности. В отличие от стандартных методов, где инженерам приходится вручную создавать признаки, нейросети сами находят сложные паттерны, что делает анализ более результативным и сокращает объем подготовительной работы.

Эта особенность крайне востребована в оптимизационных задачах, где связи между параметрами часто носят нелинейный, многофакторный и плохо поддающийся формализации характер. Классические алгоритмы в таких условиях не всегда справляются, поскольку не могут охватить всю палитру скрытых факторов, определяющих итоговый показатель.

Обучаясь на больших выборках, нейросети фиксируют даже слабые и косвенные корреляции. Это открывает широкие возможности для их применения в прогнозировании, анализе комплексных процессов и создании адаптивных моделей, чутко реагирующих на изменения входных данных [4].

В процессе обучения нейронная сеть учится распознавать сложные и неочевидные на первый взгляд закономерности (табл. 1). К примеру, она может выявить, каким образом разнородные факторы — такие как изменения погоды, динамика рынка или предпочтения

пользователей — воздействуют на итоги оптимизации.

Таблица 1. Сравнение нейросетей с обучением на больших данных и традиционных алгоритмов

Критерий	Нейросети	Традиционные методы
Обработка скрытых закономерностей	Автоматически выявляют сложные связи	Требуют ручного описания правил
Зависимость от объема данных	Чем больше данных — тем лучше результаты	Эффективность ограничена моделью
Учет неочевидных взаимосвязей	Способны находить нелинейные зависимости	Работают с явными параметрами
Пример применения	Прогнозирование рыночных трендов	Линейная регрессия продаж

Для изучения проблематики статьи был разработан рабочий прототип нейронной сети, способной решать оптимизационную задачу классического типа.

Задача заключается в оптимизации сочетания параметров технических объектов, в частности конструкции автомобиля с целью снижения веса (что улучшает топливную эффективность) и одновременно повышения уровня безопасности (что требует усиленной конструкции). Это многоцелевая задача, поскольку цели противоречат друг другу, так как снижение веса часто означает использование более легких, но менее прочных материалов.

Реализованная нейросеть (рис. 2, 3) используется для анализа и прогнозирования характеристик различных материалов и конструктивных элементов автомобиля, таких как рама, кузов и подвеска и др., с учетом множества факторов: материала, жесткости, веса, устойчивости к столкновениям и других. Для изучения уровни безопасности каждой машины бралась информация из EURO NCAP (специальная организация, ежегодно анализирующая машины на безопасность в результате ДТП и краш-тестов). Информация о входных признаках модели каждой машины получена непосредственно от производителей.

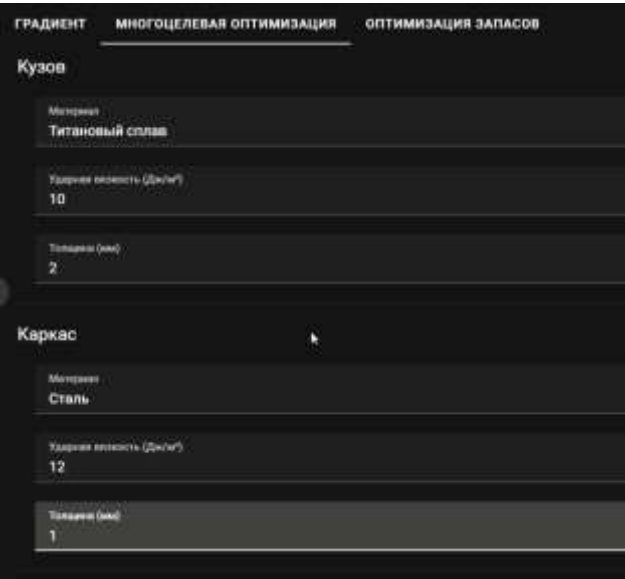


Рис. 2. Решение многоцелевой оптимизационной задачи

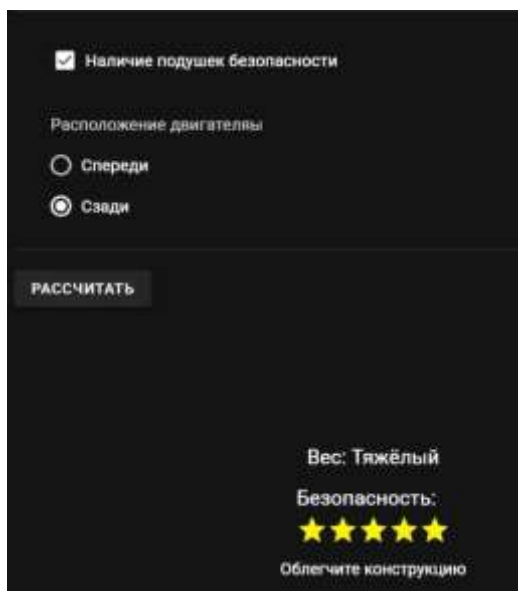


Рис. 3. Результат анализа конструкции автомобиля искусственной нейронной сетью

Основное достоинство нейросетей – их способность быстро приспосабливаться к меняющимся условиям. В отличие от устаревших методов, которые оперируют статичными данными, нейросети анализируют постоянно обновляющуюся информацию, обнаруживая сложные взаимосвязи и скрытые тренды, например, в колебаниях спроса. Это позволяет принимать более взвешенные решения при управлении запасами.

Благодаря способности к самообучению и постоянной корректировке прогнозов, нейросети обеспечивают гибкость в принятии решений. Они оперативно реагируют на изменения на рынке, уменьшая риски и оптимизируя бизнес-процессы в режиме реального времени.

Нейросети уже продемонстрировали свою эффективность в оптимизации, и с развитием искусственного интеллекта и увеличением вычислительных ресурсов их возможности будут только расширяться. С каждым годом применение нейросетей становится все более эффективным, открывая новые горизонты для адаптивного управления и оптимизации бизнес-процессов.

Список источников

1. Антонов, В. В. Интеллектуальный метод поддержки принятия решений в типовой ситуации / В. В. Антонов, К. А. Конев // Онтология проектирования. – 2021. – Т. 11, No 1(39). – С. 126–136. – DOI 10.18287/2223-9537-2021-11-1-126-136.
2. Сегаран, Т. Программируем коллективный разум. – Пер. с англ. / Т. Сегаран. – СПб.: Символ-Плюс, 2008. – 368 с.
3. Дилигенский, Н. В. Нечеткое моделирование и многокритериальная оптимизация производственных систем в условиях неопределенности: технология, экономика, экология / Н. В. Дилигенский, Л. Г. Дымова, П. В. Севастьянов. – М. : Изд-во Машино-строение – 1, 2004. – 397 с.
4. Ярушкина, Н. Г. Интеллектуальный анализ временных рядов. / Н. Г. Ярушкина, Т. В. Афанасьева, И. Г. Перфильева. – Ульяновск : УлГТУ, 2010. – 320 с.
5. Гладков, Л. А. Генетические алгоритмы / Л. А. Гладков, В. В. Курейчик, В. М. Курейчик. – 2010.

Сведения об авторах

Мурлин Алексей Георгиевич, к.т.н, доцент, ФГБОУ ВО «Кубанский государственный технологический университет (КубГТУ)», Краснодар, Россия
Колесников Даниил Сергеевич, студент, ФГБОУ ВО «Кубанский государственный

технологический университет (КубГТУ)», Краснодар, Россия

Бгане Аскер Асланович, студент, ФГБОУ ВО «Кубанский государственный технологический университет (КубГТУ)», Краснодар, Россия

Information about the authors

Murlin Alexey Georgievich, PhD., associate professor, KubSTU, Krasnodar, Russia

Kolesnikov Daniil Sergeevich, student, KubSTU, Krasnodar, Russia

Bganе Asker Aslanovich, student, KubSTU, Krasnodar, Russia