

ИСПОЛЬЗОВАНИЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА В СИСТЕМАХ ПОДДЕРЖКИ ПРИНЯТИЯ РЕШЕНИЙ: АЛГОРИТМЫ И ПРИЛОЖЕНИЯ

Дужан Т. О., магистрант 2 курса по направлению подготовки

«Информационные системы и технологии»

Бардин А. К., к.э.н., доцент,

ФГБОУ ВО «Кубанский Государственный аграрный университет»

г. Краснодар, Россия

Аннотация: Искусственный интеллект (ИИ) меняет подходы к поддержке принятия решений, предлагая эффективные инструменты для анализа данных и оптимизации сложных процессов. В статье исследуются гибридные алгоритмы ИИ, объединяющие методы глубинного обучения и эвристические подходы. Представлены результаты сравнительного анализа с традиционными методами и предложены направления для дальнейшего развития.

Ключевые слова: Системы поддержки принятия решений, искусственный интеллект, гибридные алгоритмы, глубинное обучение, эвристические методы, оптимизация, прогнозирование.

Системы поддержки принятия решений (СППР) давно используются для оптимизации процессов, анализа данных и формирования рекомендаций. Однако с ростом объема данных и усложнением задач традиционные методы теряют свою эффективность. Современные требования включают способность адаптироваться к изменениям, быстро обрабатывать данные и предлагать оптимальные решения в условиях неопределенности.

Искусственный интеллект, включая машинное обучение и нейронные сети, предоставляет инструменты для обработки больших данных, выявления скрытых закономерностей и точного прогнозирования. Методы обработки естественного языка делают СППР более интуитивно понятными для пользователей. Однако внедрение ИИ сопряжено с трудностями, такими как зависимость от данных, интерпретация сложных моделей и высокая вычислительная нагрузка.

В данной статье рассматривается гибридный подход, который объединяет методы глубинного обучения и эвристические алгоритмы для повышения точности и эффективности СППР. Основная цель — экспериментально подтвердить преимущества такого подхода в сравнении с традиционными методами, включая линейное программирование и стандартные эвристики.

Основная задача современных СППР заключается в обеспечении высокой точности и эффективности принятия решений при обработке больших массивов данных. Однако классические методы, такие как линейная регрессия и математическое программирование, часто оказываются недостаточными для решения сложных задач в динамичной среде.

В книге *"Operations Research: An Introduction"* Хамди А. Таха отмечается, что традиционные алгоритмы хорошо справляются с фиксированными условиями, но их применение ограничено в задачах, где параметры изменяются в реальном времени [4]. Эти ограничения подтверждаются исследованиями в книге *"Deep Learning"*

Йошуа Бенджио, Иэна Гудфеллоу и Аарона Курвиля, где подчёркивается способность нейронных сетей выявлять сложные зависимости в данных при условии значительных вычислительных ресурсов и сложности интерпретации [1].

Кроме того, точность решений и скорость работы зависят от качества входных данных и настройки алгоритмов. Недостаточная гибкость традиционных методов затрудняет их использование в задачах управления производственными ресурсами, где требуется учитывать, как экономические, так и технические ограничения.

Эти проблемы требуют подходов, которые объединяют сильные стороны ИИ и традиционных методов. В данном исследовании предложен гибридный метод, сочетающий прогнозирующую мощь глубинного обучения с адаптивностью

эвристических алгоритмов. Такое сочетание позволяет решать задачи многокритериальной оптимизации, где требуется как точное прогнозирование, так и гибкость в условиях неопределенности.

Для преодоления ограничений традиционных методов и повышения эффективности СППР в статье предложен гибридный подход, сочетающий возможности глубинного обучения для прогнозирования и эвристических алгоритмов для оптимизации.

Основные компоненты подхода

1. **Модуль прогнозирования на основе глубинного обучения:** для выявления зависимостей в данных и повышения точности прогнозов была разработана многослойная нейронная сеть (MLP). Она использует метод обратного распространения ошибки и оптимизатор Adam. Согласно *"Deep Learning"*

[1], такие сети эффективны при анализе сложных и нелинейных взаимосвязей. Настройка гиперпараметров включала выбор количества слоев и нейронов, чтобы достичь баланса между точностью и вычислительной сложностью. В качестве входных данных использовались параметры, моделирующие задачи управления ресурсами: объемы ресурсов, затраты на их использование и прогнозируемая прибыль.

2. **Эвристический алгоритм для оптимизации:** в качестве основного инструмента был использован генетический алгоритм (ГА). Этот

метод

описан

в

книге

"*An Introduction to Genetic Algorithms*"

Дэвида

Голдберга

[2].

Кодирование решений: ресурсы представляются в виде генов, где каждая хромосома обозначает конкретное распределение.

Оценка приспособленности (*fitness function*): учитывались точность прогнозов и соответствие ограничениям, включая время выполнения и экономические показатели.

Операторы кроссовера и мутации: эти механизмы способствовали поиску глобального оптимума, избегая локальных минимумов.

Эксперимент включал следующие этапы:

1. Подготовка данных

- Использован синтетический набор данных, моделирующий реальные производственные условия.
- Нормализация данных для обеспечения стабильного обучения нейронной сети.

2. Обучение нейронной сети

- Разделение данных на тренировочные и тестовые (80% и 20%).
- Оценка точности модели с использованием метрик MAE (средняя абсолютная ошибка) и RMSE (корень средней квадратичной ошибки).

3. Оптимизация с использованием ГА

- Настройка параметров алгоритма, таких как размер популяции и вероятность мутации.
- Поиск оптимального распределения ресурсов на основе прогнозов нейронной сети.

Точность прогнозов

Гибридный подход показал значительное улучшение точности по сравнению с традиционными методами. Метрики MAE и RMSE для линейной регрессии и глубинного обучения представлены в таблице:

Метод

MAE

RMSE

Линейная регрессия

7,12

8,54

Глубинное обучение

3,47

4,21

Таблица 1. Оценка точности

Глубинное обучение позволило снизить среднюю абсолютную ошибку более чем на 50%, что подтверждает его эффективность в обработке сложных данных.

Эффективность оптимизации

Использование генетического алгоритма в сочетании с прогнозами нейронной сети продемонстрировало улучшение распределения ресурсов.

Метод

Максимальная прибыль

Использование ресурсов

Время выполнения

Традиционные методы

420 тыс. руб.

95%

30 сек

Гибридный подход

451 тыс. руб.

98%

25 сек

Таблица 2. Оценка эффективности

Интеграция прогнозов и оптимизации позволила увеличить прибыль на 7,4% при сохранении или улучшении других параметров.

Результаты эксперимента продемонстрировали значительные преимущества гибридного подхода для решения задач, характерных для СППР.

Основные достижения:

Улучшение точности прогнозирования: глубинное обучение оказалось особенно эффективным в обработке данных с высоким уровнем шума, что характерно для реальных производственных процессов. Это согласуется с исследованиями, представленными в книге *"Deep Learning"* [1].

Эффективность эвристического подхода: генетический алгоритм обеспечил гибкость и адаптивность, которых не хватает линейным моделям. Как отмечает Дэвид Голдберг в работе *"An Introduction to*

Genetic Algorithms"

такие методы полезны в задачах, где пространство решений сложно определить заранее [2].

Сравнимая вычислительная сложность: несмотря на дополнительную нагрузку, связанную с обучением нейронной сети, гибридный подход показал приемлемое время выполнения, что делает его подходящим для применения в реальных системах.

Несмотря на положительные результаты, предложенный подход имеет ряд ограничений:

- **Зависимость от качества данных:** ошибки в обучающем наборе данных существенно влияют на результаты прогнозирования. Это подтверждается выводами из книги *"Machine Learning"* Питера Флаха [3].
- **Сложность настройки гиперпараметров:** как в нейронной сети, так и в генетическом алгоритме результаты зависят от правильной настройки параметров, что требует значительного времени и опыта.
- **Ограниченная интерпретируемость:** хотя гибридный подход улучшает точность и оптимизацию, объяснить процесс принятия решений для конечных пользователей остаётся сложной задачей.

Проведённое исследование подтвердило высокую эффективность предложенного

гибридного подхода для систем поддержки принятия решений. Основные достижения включают:

- Снижение ошибки прогнозирования более чем на 50% благодаря использованию глубинного обучения.
- Увеличение прибыли на 7,4% за счёт оптимального распределения ресурсов.
- Сохранение вычислительной сложности на уровне традиционных методов.

Эти результаты подчёркивают перспективность интеграции методов искусственного интеллекта в СППР. Тем не менее, выявленные ограничения указывают на необходимость дальнейших исследований, особенно в области улучшения интерпретируемости решений и повышения устойчивости к ошибкам данных.

Практическое значение работы заключается в возможности адаптации предложенного подхода для различных задач, таких как управление производственными процессами, оптимизация логистики и прогнозирование финансовых показателей. Развитие и внедрение гибридных подходов способствуют повышению эффективности управления сложными системами в условиях ограниченных ресурсов.

Литература

1. Бенджио Й., Гудфеллоу И., Курвиль А. Глубокое обучение. — М.: ДМК Пресс, 2020. — 800 с.
2. Голдберг Д. Генетические алгоритмы: Основы теории и практика. — М.: Мир, 1999. — 432 с.
3. Плах П. Машинное обучение. Научный подход. — СПб.: Питер, 2022. — 416 с.
4. Таха Х. Введение в исследование операций. — М.: Вильямс, 2005. — 912 с.
5. Mitchel T. Machine Learning. — New York: McGraw-Hill Education, 1997. — 414 p.
6. Russell S., Norvig P. Artificial Intelligence: A Modern Approach. — 4th ed. — Boston: Pearson, 2021. — 1152 p.