

Смородников Виталий Алексеевич

*магистрант, институт магистратуры, Санкт-Петербургский
государственный экономический университет, Санкт-Петербург*

ПРИМЕНЕНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ РАБОТЫ С НЕОПРЕДЕЛЁННОСТЬЮ: СРАВНИТЕЛЬНЫЙ АНАЛИЗ ПОДХОДОВ

В статье рассматриваются современные методы машинного обучения, ориентированные на работу с неопределённостью в системах поддержки принятия решений (СППР). Анализ проводится с акцентом на различия между алеаторической и эпистемической неопределённостью, а также на сравнении эффективности различных групп методов: байесовских моделей, ансамблевых подходов, нечеткой логики и гибридных решений. В работе использованы исследования российских и зарубежных авторов, демонстрирующие значение учёта неопределённости для повышения надёжности аналитических систем. Показано, что наиболее перспективными являются гибридные модели, объединяющие вероятностные, нейросетевые и нечеткие подходы. Результаты исследования могут быть использованы при разработке интеллектуальных СППР в условиях высокой изменчивости данных и ограниченной определённости.

The article examines modern machine learning methods designed to address uncertainty in decision support systems (DSS). The analysis focuses on the distinction between aleatoric and epistemic uncertainty, as well as on comparing the effectiveness of various groups of methods: Bayesian models, ensemble approaches, fuzzy logic, and hybrid solutions. The study incorporates findings from Russian and international researchers, highlighting the importance of uncertainty quantification for improving the reliability of analytical systems. The results demonstrate that the most promising approaches are hybrid models that combine probabilistic techniques, neural networks, and fuzzy logic. The findings can be applied in the development of

intelligent DSS operating under conditions of high data variability and limited certainty.

Ключевые слова: машинное обучение; неопределённость; aleatoric неопределённость; epistemic неопределённость; системы поддержки принятия решений; байесовские методы; нечеткая логика; ансамблевые модели; гибридные подходы.

Keywords: machine learning; uncertainty; aleatoric uncertainty; epistemic uncertainty; decision support systems; Bayesian methods; fuzzy logic; ensemble models; hybrid approaches.

Введение

Современные системы поддержки принятия решений (СППР) всё чаще функционируют в условиях высокой неопределённости, вызванной неполнотой, противоречивостью и стохастичностью данных. Усложнение управленческих задач, рост объёма информации и её динамическое обновление требуют применения методов, способных обеспечивать устойчивые прогнозы даже при отсутствии полной картины о состоянии исследуемой системы. Как отмечают Hüllermeier и Waegeman, неопределённость является фундаментальным аспектом машинного обучения и проявляется как в данных, так и в самих моделях, влияя на надёжность и интерпретируемость результатов [3].

В научной литературе выделяются два ключевых типа неопределённости: алеаторическая, обусловленная случайной природой данных, и эпистемическая, возникающая вследствие неполных знаний о системе. Их корректное различение имеет принципиальное значение для разработки методов машинного обучения, способных обеспечивать адекватную оценку достоверности принимаемых решений [3; 5]. Исследования российских авторов подтверждают, что отсутствие механизмов обработки неопределённости приводит к снижению точности моделей и ограничивает их использование в критически важных областях, таких как анализ рисков, диагностика и финансовое прогнозирование [1].

В ответ на эти вызовы активно развиваются подходы количественной оценки неопределённости в ML-моделях. Обзор Nemani и соавторов демонстрирует, что методы оценки вероятностных распределений, байесовские методы и ансамблевые алгоритмы играют ключевую роль в создании надёжных прогнозных моделей, особенно в инженерных и медицинских приложениях [4].

Помимо вероятностных подходов, значительную роль играют методы нечеткой логики, которые позволяют формализовать экспертные знания и эффективно работать с качественными и слабо структурированными данными. Как указывает Веселов, нечеткие модели и нейро-нечеткие системы обеспечивают дополнительную гибкость при работе с эпистемической неопределённостью и широко применяются в задачах управления, планирования и оценки состояний систем [2]. Аналогичное внимание к интеграции экспертного и вероятностного подходов прослеживается в российской литературе, где подчёркивается необходимость использования гибридных моделей СППР для комплексной обработки неопределённости [6].

Международные исследования также фиксируют рост интереса к гибридным и мультикомпонентным подходам. Fakour и соавторы отмечают, что объединение глубоких нейронных сетей и вероятностного моделирования позволяет повышать устойчивость моделей к шуму, компенсировать недостаток данных и обеспечивать более точную оценку доверительных интервалов [7]. Аналогичные выводы приводятся в работе Cheng и коллег, где акцент делается на важности методов ассимиляции данных и вероятностной аппроксимации для анализа сложных динамических систем [8].

Обработка неопределённости является одной из ключевых проблем в современном машинном обучении и разработке СППР. Повышение точности прогнозирования, интерпретируемости моделей и устойчивости решений напрямую связано с использованием методов, специально ориентированных на работу с различными типами неопределённости.

Целью настоящей статьи является проведение сравнительного анализа методов машинного обучения, применяемых для обработки неопределённости, и выявление их возможностей, ограничений и перспектив использования в системах поддержки принятия решений.

Методы

Методологической основой исследования является сравнительный анализ существующих подходов машинного обучения, применяемых для обработки различных типов неопределённости в системах поддержки принятия решений. Для проведения исследования использованы методы систематизации научных публикаций и теоретического обобщения, опирающиеся на работы российских и зарубежных исследователей в области количественной оценки неопределённости.

На основе рассмотренных источников сформирован набор критериев для сравнительного анализа методов машинного обучения:

- тип обрабатываемой неопределённости;
- интерпретируемость модели;
- вычислительная сложность;
- применимость в различных типах СППР;
- устойчивость к шуму и неполным данным.

Эти критерии обоснованы анализом зарубежных обзоров [3; 4; 5; 7; 8] и российских публикаций [1; 2; 6].

Методологическая база исследования сочетает в себе вероятностные, нечеткие и гибридные подходы к обработке неопределённости, а также сравнительный анализ их применимости в современных системах поддержки принятия решений.

Результаты

В ходе исследования были систематизированы основные подходы машинного обучения, применяемые для обработки неопределённости в системах поддержки принятия решений. Сравнительный анализ проводился с учётом типа неопределённости, интерпретируемости моделей,

вычислительной сложности и применимости в практических задачах. Полученные результаты обобщены ниже.

1. Сопоставление типов неопределённости и применяемых методов

Анализ работ Hüllermeier и Waegeman [3], Psaros и Karniadakis [5], а также Fakour и соавторов [7] позволил выделить устойчивую тенденцию разделения методов ML в зависимости от типа неопределённости.

Алеаторическая неопределённость преимущественно обрабатывается ансамблевыми методами, вероятностным моделированием и симуляциями Монте-Карло.

Эпистемическая неопределённость наиболее эффективно учитывается байесовскими моделями и нечеткими системами.

Российские исследования подтверждают необходимость комплексного применения методов обоих классов в задачах СППР [1; 6].

2. Характеристики и сравнительные свойства методов

В результате анализа установлено, что каждая группа методов обладает уникальными сильными и слабыми сторонами.

Байесовские методы

Согласно [3] и [4], байесовские модели обеспечивают наивысшую степень интерпретируемости и прозрачную вероятность-ориентированную оценку неопределённости. Их ключевым преимуществом является способность формировать апостериорные распределения, однако высокая вычислительная сложность ограничивает их использование в масштабируемых системах.

Ансамблевые методы

Ансамбли Random Forest, Gradient Boosting и их вариации показали устойчивую эффективность в задачах с высокой алеаторической неопределённостью. Psaros и Karniadakis подчёркивают их способность снижать влияние шума и повышать надёжность предсказаний путём усреднения результатов множества моделей [5]. Исследование Nemaní и

соавторов указывает на их практическую применимость в инженерных системах и медицинской диагностике [4].

Нечёткие модели и нейро-нечёткие системы

Нечёткие модели оказались наиболее эффективными при работе с экспертными, качественными и слабо структурированными данными. Веселов отмечает, что они позволяют компенсировать недостаток формализованных данных, что делает их полезными для СППР в управлении, проектировании и планировании [2]. Ограничением является зависимость от корректности настроек функций принадлежности.

Вероятностное моделирование

Методы Монте-Карло и гауссовы процессы демонстрируют высокую точность моделирования распределений ошибок и используются в задачах анализа сложных динамических систем. Исследование Cheng и соавторов показывает их эффективность для прогнозирования поведения систем в условиях переменной внешней среды [8].

Глубокие модели с оценкой неопределённости

Анализ работы Fakour и коллег [7] позволил выделить современные методы оценки неопределённости в глубоких нейронных сетях:

- дроп-аут как аппроксимация байесовского вывода;
- ансамбли глубоких моделей;
- вероятностные слои в нейросетевых архитектурах.

Эти подходы демонстрируют высокую точность в задачах обработки больших данных, но требуют значительных вычислительных ресурсов.

3. Обобщение результатов: области применения

На основании изученных источников можно выделить следующие области, в которых методы машинного обучения наиболее эффективно применяются для обработки неопределённости:

Таблица 1.

Области применения

Область применения	Наиболее эффективные методы
---------------------------	------------------------------------

Анализ рисков	Байесовские методы, вероятностное моделирование
Инженерные и технические системы	Ансамблевые модели, вероятностные симуляции
Управление и экспертные системы	Нечёткие модели, гибридные подходы
Прогнозирование динамических процессов	Гауссовы процессы, методы ассимиляции данных

4. Классификация методов машинного обучения для обработки неопределённости

Результаты анализа позволили выделить три группы методов:

1. Вероятностные методы (байесовские модели, Монте-Карло, гауссовы процессы) — характеризуются высокой точностью и прозрачностью результата [3; 4; 8].
2. Ансамблевые методы — обеспечивают стабильность решений и устойчивость к шумам данных [5].
3. Лингвистические и гибридные методы (нечеткая логика, нейро-нечеткие модели) — эффективны при недостатке структурированных данных [2; 6].

5. Общий итог анализа

Сравнение методов показало, что наиболее перспективным направлением является разработка гибридных систем, которые объединяют вероятностное моделирование, глубинное обучение и элементы нечеткой логики. Такой вывод поддерживается результатами Fakour и соавторов [7], где подчёркивается значение комбинированных подходов для повышения устойчивости и интерпретируемости современных моделей.

Анализ и обсуждение

Результаты сравнительного анализа методов машинного обучения позволяют выявить ключевые тенденции и особенности подходов к обработке неопределённости, представленные в современной научной литературе. Анализ продемонстрировал, что эффективность конкретного метода определяется не только типом неопределённости, но и характеристиками

данных, структурой задачи, требованиями к интерпретируемости и ресурсными ограничениями.

1. Обсуждение вероятностных и байесовских моделей

Исследования Hüllermeier и Waegeman подчёркивают, что байесовский подход является одним из наиболее строгих инструментов для моделирования как алеаторической, так и эпистемической неопределённости [3]. Байесовские нейронные сети и вариационные методы позволяют получать апостериорные распределения параметров, что делает такие модели особенно полезными для задач, требующих количественной оценки доверия к результатам. Однако высокая вычислительная сложность и необходимость точного задания априорных распределений ограничивают их применение в реальном времени. Аналогичные выводы приводятся Nemani и соавторами, которые отмечают, что байесовские методы остаются перспективными, но требуют значительных усилий для инженерной реализации [4].

2. Интерпретация ансамблевых подходов

Ансамблевые методы показали устойчивость и высокую точность в условиях стохастичности данных. Psaros и Karniadakis указывают, что ансамбли уменьшают влияние выбросов и шума за счёт усреднения результатов множества моделей [5]. Однако этот же механизм приводит к снижению интерпретируемости, что особенно критично в тех областях, где требуется объяснимость принимаемых решений (финансы, медицина, управление проектами). В работах Nemani и коллег также подчёркивается практическая эффективность ансамблевых моделей, но акцентируется внимание на необходимости внедрения дополнительных механизмов объяснимого ИИ [4].

3. Роль нечетких моделей в обработке экспертных данных

Нечёткие модели занимают уникальную позицию среди методов обработки неопределённости. Веселов отмечает, что нечеткая логика позволяет формализовать человеческие знания и использовать лингвистические переменные, что делает этот подход особенно ценным в

задачах управления, планирования и экспертной оценки [2]. Однако зависимость от экспертных настроек и сложность выбора корректных функций принадлежности ограничивают масштабируемость таких систем. Российские исследователи также подчёркивают необходимость применения нечеткой логики в СППР, где данные носят слабоструктурированный характер [6].

4. Обсуждение вероятностно-статистических методов

Вероятностные подходы, включая методы Монте-Карло и гауссовы процессы, продемонстрировали высокую точность при работе с aleatoric-неопределённостью. Cheng и коллеги показывают, что такие методы являются наиболее эффективными в задачах анализа динамических систем, требующих моделирования сложных зависимостей и учёта многомерных распределений [8]. Однако их вычислительные затраты существенно возрастают с ростом размерности данных, что делает необходимым использование оптимизационных процедур или гибридных моделей.

5. Значение гибридных методов и тенденции развития

Обзор Fakour и соавторов показывает, что ключевой тренд последних лет развитие гибридных подходов, объединяющих преимущества вероятностного моделирования, глубоких нейронных сетей и нечеткой логики [7]. Такие методы позволяют компенсировать недостатки отдельных подходов:

- повысить интерпретируемость сложных моделей;
- улучшить устойчивость к шуму и пропускам;
- обеспечить более точную оценку доверительных интервалов;
- адаптироваться к изменяющимся условиям среды.

Эта тенденция согласуется с выводами российских авторов, которые указывают на необходимость комплексного подхода к обработке неопределённости в СППР [1; 6].

6. Итоговое обсуждение

Обобщая результаты анализа, можно отметить, что ни один из подходов не является универсальным для всех типов задач, связанных с

неопределённостью. Наиболее важными факторами при выборе метода являются:

- тип доминирующей неопределённости;
- требования к интерпретируемости решения;
- наличие экспертных знаний;
- вычислительные ограничения;
- характер данных (структурированные/неструктурированные, количественные/качественные).

Применение машинного обучения в условиях неопределённости требует сочетания нескольких методов. Именно гибридные модели обеспечивают наиболее высокий потенциал для разработки перспективных СППР, что подтверждается как российскими, так и международными исследованиями [1; 2; 3; 4; 7].

Заключение

Проведённый обзор и сравнительный анализ методов машинного обучения, применяемых для обработки неопределённости в системах поддержки принятия решений, позволяют сделать ряд значимых выводов. Во-первых, современные исследования подтверждают, что неопределённость является неотъемлемым свойством данных и моделей, и её игнорирование приводит к снижению качества и надёжности принимаемых решений. Это подчёркивается в работах как зарубежных, так и российских исследователей [1; 3; 5].

Байесовские методы продолжают оставаться наиболее строго обоснованным подходом к моделированию как алеаторической, так и эпистемической неопределённости, однако их применение ограничивается высокой вычислительной сложностью и требованиями к априорным предположениям [3; 4]. Ансамблевые методы демонстрируют высокую устойчивость и точность, но уступают в интерпретируемости, что критично для ряда прикладных областей [5]. Нечёткая логика и гибридные модели оказываются особенно значимыми в контекстах, где требуется формализация

экспертных знаний, что подтверждается исследованиями в области СППР [2; 6].

Обзор современных тенденций показывает, что наиболее перспективным направлением развития является интеграция вероятностных, нейросетевых и нечетких подходов, формирующая гибридные архитектуры обработки неопределённости. Такие модели способны компенсировать ограничения отдельных методов и обеспечивать повышенную точность, устойчивость и адаптивность, что подчёркивается в новых исследованиях Fakour, Cheng и других авторов [7; 8].

Полученные результаты позволяют утверждать, что для построения эффективных СППР будущего необходимо использовать комплексный подход, включающий оценку неопределённости на уровне данных, моделей и выводов. Это соответствует современным международным рекомендациям по развитию «научного машинного обучения», где неопределённость рассматривается как ключевой компонент надёжных аналитических систем [5].

Проведённый анализ подтверждает высокую актуальность и значимость интеграции методов машинного обучения в системы поддержки принятия решений, функционирующие в условиях неопределённости. Полученные выводы могут служить теоретической основой для последующих исследований, направленных на разработку гибридных интеллектуальных систем и повышение надёжности управления в различных предметных областях.

Список литературы:

1. Арьков В. Ю., Шарипова А. М., Куликов Г. Г. Оценивание неопределённости в машинном обучении // Вестник ЮУрГУ. Серия: Компьютерные технологии, управление, радиоэлектроника. — 2023. — Т. 23, № 3. — С. 15–24.

2. Веселов О. В. Нечёткая логика и нейронные сети в системах: учебное пособие. — Владимир: ВлГУ, 2023. — 72 с.
3. Hüllermeier E., Waegeman W. Aleatoric and epistemic uncertainty in machine learning: an introduction to concepts and methods // Machine Learning. — 2021. — Vol. 110, No. 3. — P. 457–506.
4. Nemani V., Chen Y., Wang S., et al. Uncertainty Quantification in Machine Learning for Engineering Design and Health Prognostics: a tutorial. — 2023.
5. Psaros A. F., Seshadri P., Karniadakis G. E. Uncertainty Quantification in Scientific Machine Learning: methods, metrics, and comparisons. — 2022.
6. Садовникова Н. П., Парыгин Д. С., Щербаков М. В. Системы поддержки принятия решений: учебное пособие. — Волгоград: ВолгГТУ, 2021. — 128 с.
7. Fakour F., Mosleh A., Ramezani R. A structured review of literature on uncertainty in machine learning and deep learning. — 2024.
8. Cheng S., Zhang Z., Liu Y., et al. Machine learning with data assimilation and uncertainty quantification for dynamical systems: a review. — 2023.