

ПРИМЕНЕНИЕ ИНСТРУМЕНТАРИЯ В СИСТЕМНОМ АНАЛИЗЕ

Машура А.Ю., студентка группы СГНЗ-32Б

Московский государственный технический университет им. Н.Э. Баумана

*Научный руководитель: Муравьева Е.О., старший преподаватель кафедры
«Информационная аналитика и политические технологии»
muraviova@bmstu.ru*

Аннотация: в статье рассматриваются различные методы и инструменты ML (машинного обучения), которые могут быть эффективно применены в системном анализе, анализируются ключевые алгоритмы и методы, включая обучение с учителями и без учителей. В статье также освещаются примеры успешного применения ML в системном анализе, включая прогнозирование, выявление закономерностей и оптимизацию процессов. Кроме того, выделяются преимущества и ограничения использования ML в контексте системного анализа, а также значимость интеграции ML в уже существующий комплекс аналитических методов для повышения точности и эффективности при принятии решений.

Ключевые слова: ML (Machinelearning), системный анализ, визуализация информации, автоматизация процессов.

Системный анализ – это методологический подход к изучению сложных систем, который помогает понять их структуру, взаимосвязи, функции и поведение. Он применяется для анализа и решения комплексных проблем в различных областях, таких как экономика, инженерия, информационные технологии, управление и наука. Основная цель системного анализа – найти оптимальное решение, учитывающее все важные аспекты и факторы, влияющие на систему.

Системный анализ обеспечивает строгий подход к техническим особенностям процесса принятия решений. Он используется для исследования альтернатив и включает моделирование и имитацию, анализ затрат, анализ технических рисков и анализ эффективности.

Машинное обучение (ML) тесно связано с системным анализом, так как оно предоставляет мощные инструменты для обработки, анализа и прогнозирования данных, которые помогают более эффективно решать задачи системного анализа. Системный анализ часто сталкивается с большим количеством данных и сложными взаимосвязями, и ML становится необходимым для выявления закономерностей, прогнозирования и оптимизации процессов в сложных системах.

ML – это сокращение от английского *Machine Learning*, что переводится как «машинное обучение». Это раздел искусственного интеллекта, который позволяет компьютерам обучаться и улучшать свои действия без явного программирования на каждый конкретный случай. На практике машинное обучение применяется во многих областях,

включая обработку естественного языка, распознавание изображений, рекомендательные системы, диагностику заболеваний, автономное вождение и прогнозирование рыночных тенденций. Развитие машинного обучения способствует автоматизации сложных процессов, повышая их точность и скорость, а также открывает новые возможности для исследований и разработок в науке и промышленности.

АВТОМАТИЗАЦИЯ ПРОЦЕССОВ В СИСТЕМНОМ АНАЛИЗЕ С ПОМОЩЬЮ МЕТОДОВ ML

В системном анализе часто работают с большими и разнородными наборами данных. ML позволяет автоматизировать обработку данных и выявлять скрытые зависимости и аномалии, что сложно или невозможно сделать вручную. Анализ больших данных с помощью ML происходит поэтапно.

На рис. 1 показан процесс анализа больших данных с использованием методов пакетной обработки, который включает несколько этапов. Каждый из этих этапов играет важную роль в обеспечении точности, масштабируемости и эффективности обработки данных.

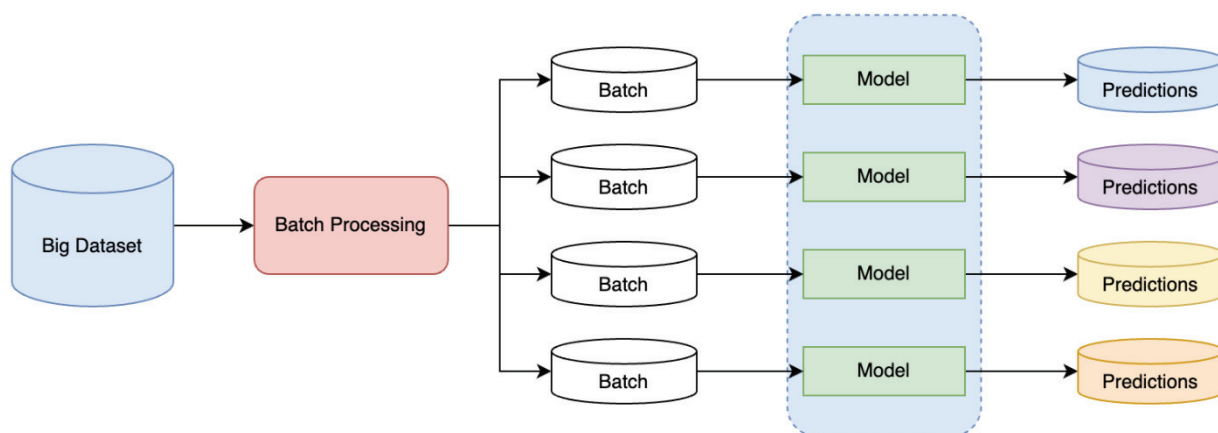


Рис. 1

Процесс начинается с поступления исходного большого набора данных (**Big Dataset**). Эти данные могут поступать из различных источников: датчиков, баз данных, журналов событий или веб-ресурсов. Для упрощения и ускорения анализа данные разбиваются на отдельные пакеты (**Batch Processing**), каждый из которых обрабатывается независимо. Такой подход позволяет работать с большими объемами информации и снижает нагрузку на систему.

После разбиения на пакеты данные поступают в блок обучения моделей (**Model**). Предварительная обработка данных: очистка, нормализация и преобразование в формат, подходящий для алгоритма машин-

ного обучения. Обучение моделей: применение методов машинного обучения, таких как линейная регрессия, деревья решений, нейронные сети или ансамблевые методы. Оценка качества: проверка того, насколько хорошо каждая обученная модель справляется с поставленной задачей, с помощью показателей точности, полноты или F1-меры.

Обученные модели используют данные из соответствующих пакетов для создания прогнозов (**Predictions**). Каждый набор данных обрабатывается своей моделью, что позволяет добиться высокой параллельности процесса. Например, одна модель может прогнозировать спрос на товары в регионе, другая – выявлять аномалии в работе систем, третья – классифицировать текстовые сообщения.

Полученные прогнозы объединяются, анализируются и представляются в удобном для пользователя формате. Это может быть в разных форматах. Такие как визуализация данных (графики, диаграммы). Формирование отчетов или автоматизацию процессов на основе результатов. Использование результатов для принятия решений, таких как планирование, управление рисками или оптимизация ресурсов.

При использовании ML в системном анализе акцент делается на построении моделей, которые могут обрабатывать и интерпретировать данные для различных целей, включая прогнозирование и моделирование.

После подготовки данных выбираются методы машинного обучения, которые подходят для решаемой задачи. Например, если необходимо предсказать значение какого-либо показателя на основе исторических данных, могут использоваться регрессионные модели. Если же задача заключается в классификации объектов или событий, то используются другие методы ML. Важно отметить, что выбор алгоритма во многом зависит от структуры данных и специфики задачи.

Классическим примером применения методов ML в системном анализе является линейная регрессия (рис. 2), где предполагается линейная зависимость между входными и выходными данными. Линейная регрессия довольно проста и легко интерпретируема, но она не всегда может захватить более сложные зависимости в данных.

На представленном ниже графике показана линейная регрессия, описывающая зависимость переменной Npg (negative population growth) от времени (в годах) для региона «Москва».

Ось X: горизонтальная ось отражает временную шкалу, представленную в годах (с 1990 по 2015 год).

Ось Y: вертикальная ось отображает значения Npg, величины, которая принимает отрицательные и положительные значения.

Данные: точки на графике (розового цвета) представляют эмпирические значения Npg, собранные в разные годы.

Линейная регрессия: прямая линия (бордового цвета) демонстрирует результат моделирования линейной зависимости между годами и значениями N_{pg} . Этот тренд указывает на постепенное увеличение N_{pg} с течением времени.

Прогноз: черная точка обозначает прогнозируемое значение N_{pg} на определенный год (судя по тренду, около 2015 года).

График наглядно демонстрирует, что зависимость N_{pg} от года хорошо описывается линейной моделью. Тренд имеет положительный наклон, что свидетельствует о росте N_{pg} в исследуемый период.

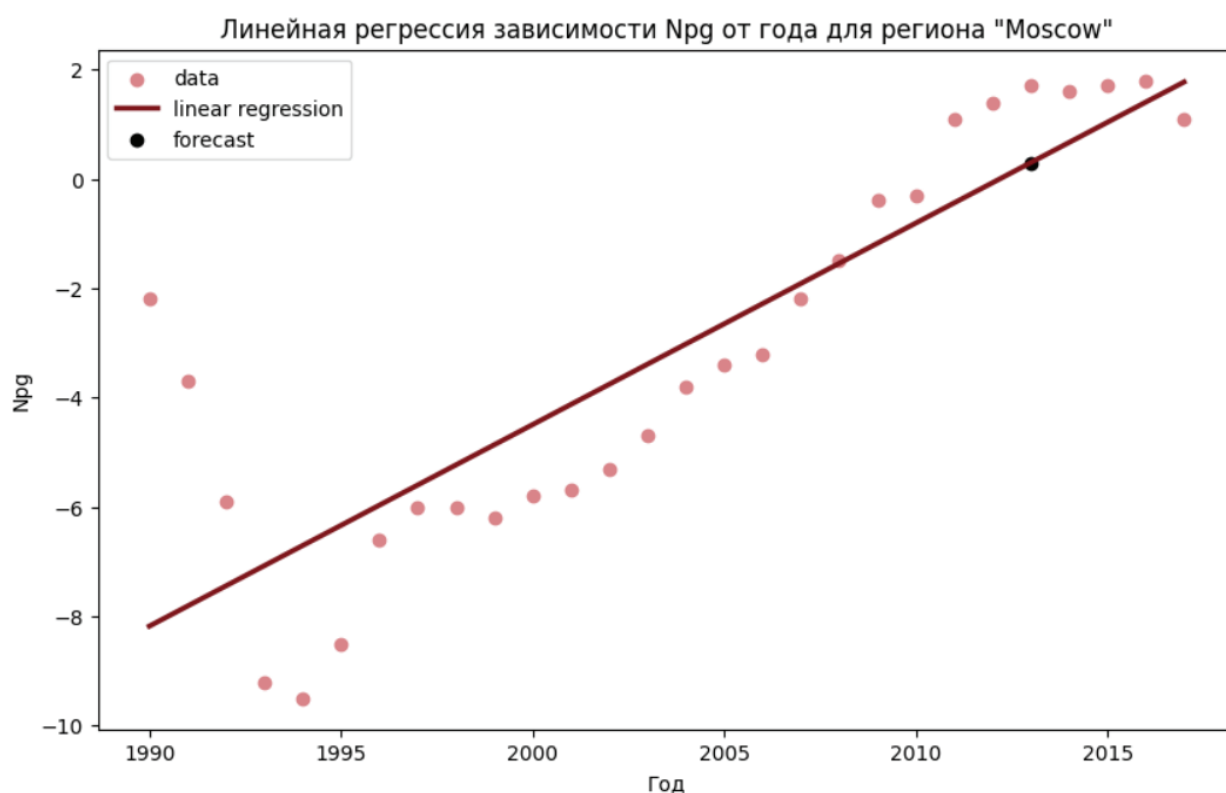


Рис. 2

Кроме регрессии, в машинном обучении используются и другие методы, такие как классификация, которая применяется для определения категорий, к которым могут принадлежать данные. Алгоритмы классификации включают логистическую регрессию, наивный байес, опорные вектора, а также более сложные модели, такие как нейронные сети.

Кластеризация рис. 3 – это еще один важный подход в машинном обучении, который позволяет выделять группы в данных, основываясь на их схожести. Алгоритмы, такие как k-средних или иерархическая кластеризация, позволяют анализировать классификации без предварительных аннотаций.




Рис. 3

На данном графике реализован метод Agglomerative Clustering использует иерархическую кластеризацию, которая объединяет близкие точки в кластеры.

Методы глубокого обучения, основанные на нейронных сетях, сейчас широко применяются в различных задачах, включая обработку изображений, текстов и даже в играх. Эти модели способны выявлять сложные паттерны благодаря многоуровневым структурам.

Одним из ключевых преимуществ использования машинного обучения в системном анализе является возможность учитывать множество факторов одновременно, что позволяет более точно моделировать сложные системы. Например, в экономике или экологии, где на результаты влияет множество взаимосвязанных переменных, ML может помочь выявить скрытые зависимости и предсказать поведение системы в будущем.

Однако следует помнить, что применение ML не исключает необходимость глубокого понимания системы и предметной области. Модели могут быть сложными и «черными ящиками», что затрудняет интерпретацию результатов. Поэтому важно сочетать количественные методы машинного обучения с качественными подходами системного анализа, что позволит глубже понять и адаптировать модели к специфике исследуемой системы.

ПРЕИМУЩЕСТВА ИСПОЛЬЗОВАНИЯ ML ДЛЯ СИСТЕМНОГО АНАЛИЗА

Использование машинного обучения (ML) в системном анализе открывает новые горизонты для обработки и интерпретации больших объемов данных, что существенно увеличивает эффективность анализа.

Одним из основных преимуществ является способность ML обнаруживать сложные зависимости и паттерны в данных, которые могут быть неочевидны при традиционных методах анализа. Это позволяет не только углубить понимание систем, но и выявлять скрытые тенденции, что может помочь в принятии более обоснованных решений.

Кроме того, алгоритмы машинного обучения способны адаптироваться к изменениям в данных, что делает их особенно полезными в динамичных средах, где условия могут меняться быстро и непредсказуемо. Это обеспечивает большую гибкость и скорость реакции на изменения, что является ключевым фактором в современных условиях динамичного бизнеса и технологий.

Еще одним значительным преимуществом является автоматизация рутинных процессов анализа. Модели ML могут обрабатывать данные в режиме реального времени, что позволяет существенно сократить время на выполнение задач и повысить эффективность работы специалистов. Это дает им возможность сосредоточиться на более творческих и стратегических аспектах системного анализа, требующих человеческого участия.

Использование машинного обучения также способствует улучшению точности прогнозирования и принятия решений. Благодаря возможности обрабатывать и анализировать большие объемы разнообразной информации, ML-модели способны предоставлять более точные и надежные предсказания, что в свою очередь увеличивает уверенность в принимаемых решениях.

В статье рассматривается применение машинного обучения (ML) в системном анализе, а именно анализ больших данных и визуализациях данных в различных сферах. ML позволяет выявлять скрытые зависимости и паттерны в больших объемах информации, что особенно актуально для сложных систем. Использование алгоритмов машинного обучения способствует более точному моделированию и прогнозированию поведения систем, а также оптимизации процессов на различных уровнях.

В заключение подчеркивается, что интеграция методов машинного обучения в системный анализ открывает новые возможности для исследования и управления сложными системами, способствуя более глубокому пониманию различных процессов и повышению их эффективности.

Литература и источники:

1. Анохин А.О., Парыгин Д.С., Садовникова Н.П., Финогеев А.А., Гуртяков А.А. Моделирование поведения интеллектуальных агентов на основе методов машинного обучения в моделях конкуренции // Программные продукты и системы. 2023. № 1.

2. Бочарников И.В., Овсянникова О.А. Риски и вызовы информационной работы при проведении специальных военных и полицейских операций // Вестник Академии военных наук. 20224. № 1. С. 22–29.
3. Васильченко А.М. Решение задач анализа данных на основе машинного обучения // Universum: технические науки. 2023. № 9-1 (114).
4. Власенко А.В., Дзьобан П.И., Жук Р.В. Обзор инструментов машинного обучения и их применения в области кибербезопасности // Прикаспийский журнал: управление и высокие технологии. 2020. № 1 (49).
5. Карпенко П.П., Селезнев А.В., Пелогейко А.В., Чебунина М.В., Буравцова Д.А., Башкинцева М.В. Основы системного анализа // Столыпинский вестник. 2022. № 4.
6. Информационная аналитика в современном социально-политическом процессе: теория и практика / Ремарчук В.Н., Бочарников И.В., Артемьев А.А., Галаганова С.Г., Гришнова Е.Е., Егоров В.Г., Карась Р.А., Катков О.Н., Ламинина О.Г., Смутьский С.В., Шевчун В.Н., Урсул В.И. Москва, 2024.
7. Ремарчук В.Н. Управление смыслами как инструмент современной политики: технологии, вероятные последствия // Этносоциум и межнациональная культура. 2019. № 2 (128). С. 9–21.
8. Ремарчук В.Н. Модернизация России в социальном измерении В книге: Безопасность России – 2011. Экспертно-аналитическое обозрение. Москва, 2010. С. 111–124.
9. Украинский кризис в условиях трансформации современного миропорядка: тенденции развития, угрозы и вызовы для России / Баранов В.П., Бартош А.А., Бочарников И.В., Дульнев П.А., Караваев И.Н., Кардаш И.Л., Карпович О.Г., Корабельников А.А., Кулаков А.А., Манойло А.В., Овсянникова О.А., Петренко А.И., Ремарчук В.Н., Стригунов К.С., Сурма И.В., Суханов П.В. (2-е издание, исправленное) Москва, 2022.