

ПРИМЕНЕНИЕ АЛГОРИТМОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ РЕШЕНИЯ ЗАДАЧ ПРОГНОЗИРОВАНИЯ ТЕХНИЧЕСКОГО СОСТОЯНИЯ СРЕДСТВ РАДИОСВЯЗИ

Чихачев А.В.¹, Будко П.А.², Шмидт А.А.³

DOI:10.24682/3034-4050-2024-3-33-40

Ключевые слова: национальная стратегия развития, национальная программа развития, искусственный интеллект, машинное обучение, алгоритмы машинного обучения, прогнозирование.

Аннотация

Цель работы: состоит в анализе и выборе наиболее подходящих алгоритмов машинного обучения для решения задач прогнозирования технического состояния средств радиосвязи.

Метод исследования: алгоритмы линейной и логистической регрессии, деревья решений, случайные леса, градиентный бустинг, метод опорных векторов, K-ближайших соседей и искусственные нейронные сети.

Результаты исследования: В статье представлен анализ существующих зарубежных и отечественной национальных стратегий развития искусственного интеллекта, основные определения, направления и применяемые технологии.

Более подробно рассмотрено одно из направлений искусственного интеллекта — машинное обучение, применяемое для решения различных задач прогнозирования, в том числе прогнозирования технического состояния средств радиосвязи искусственные нейронные сети, являющиеся одним из самых популярных методов машинного обучения, которое, в свою очередь, является одним из направлений искусственного интеллекта, наиболее предпочтительны для решения задач прогнозирования технического состояния средств радиосвязи.

Также в статье подробно представлено пошаговое описание работы алгоритмов, их достоинства и недостатки.

Практическая ценность: новые возможности, связанные с использованием искусственного интеллекта, открывают новые горизонты для развития современных технологий, в том числе на основе применения искусственных нейронных сетей. Прогнозирование технического состояния средств радиосвязи является ключевым элементом управления и эксплуатации радиосистем и позволяет создавать надежные системы связи, способные эффективно функционировать в любых условиях, минимизировать время простоя и оптимизировать процессы обслуживания.

Введение

Анализ существующих зарубежных национальных стратегий развития искусственного интеллекта показывает их взаимное сходство, при этом особое внимание стоит обратить на США, Великобританию и Китай, чьи стратегии имеют четкие тенденции в области национальной безопасности и обороны. Если в 2017 году стран, сформировавших свои национальные стратегии развития искусственного интеллекта, было всего 7, то в 2024 году их количество увеличилось более чем в 5 раз. Учитывая сложившуюся мировую обстановку, Россия не осталась в стороне и уже в 2019 году приняла национальную программу развития технологий искусственного интеллекта Указом Президента Российской Федерации

№ 490 «О развитии искусственного интеллекта в Российской Федерации» вместе с «Национальной стратегией развития искусственного интеллекта на период до 2030 года» (внесены изменения 15 февраля 2024 года).

«Предотвратить развитие искусственного интеллекта, в том числе сверхинтеллекта, который начинает чувствовать, который различает запахи, у него появляются когнитивные возможности, который сам себя развивает. Предотвратить развитие невозможно. А значит, нужно возглавить. Во всяком случае, нужно сделать все для того, чтобы мы могли быть одними из лидеров в этом направлении» — поделился мнением Президент Российской Федерации В. В. Путин.

¹Чихачев Антон Владимирович, кандидат технических наук, доцент, начальник кафедры технического обеспечения связи и автоматизации Военной академии связи, г. Санкт-Петербург, Россия. E-mail: anton_best@mail333.com

²Будко Павел Александрович, доктор технических наук, профессор, профессор кафедры технического обеспечения связи и автоматизации Военной академии связи, г. Санкт-Петербург, Россия. E-mail: budko62@mail.ru

³Шмидт Анна Алексеевна, адъюнкт кафедры технического обеспечения связи и автоматизации Военной академии связи, г. Санкт-Петербург, Россия. E-mail: anutikaaa@mail.ru

Искусственный интеллект (далее— ИИ) — комплекс технологических решений, позволяющий имитировать когнитивные функции человека (включая самообучение и поиск решений без заранее заданного алгоритма) и получать при выполнении конкретных задач результаты, сопоставимые, как минимум, с результатами интеллектуальной деятельности человека. Комплекс технологических решений включает в себя информационно-коммуникационную инфраструктуру, программное обеспечение (в том числе, в котором используются методы машинного обучения), процессы и сервисы по обработке данных и поиску решений. Внедряются такие технологии, как интеллектуального анализа данных, визуализации данных, анализа пространственных данных, рекомендательных систем, систем управления базами данных, больших данных и машинного обучения [1].

Машинное обучение — это область ИИ, которая позволяет системам автоматически обучаться и улучшаться на основе опыта без явного программирования. Алгоритмы машинного обучения анализируют данные, выявляют паттерны и делают прогнозы или принимают решения на основе этих данных. Они могут быть с учителем или без него, с частичным, активным или глубоким обучением, а также обучением с подкреплением [2, 3].

Наиболее часто алгоритмы машинного обучения применяются для анализа данных и прогнозирования. В первом случае используются для анализа больших объемов данных, выявления скрытых закономерностей и трендов, во втором — помогают прогнозировать будущие события на основе исторических, статистических данных.

Основные разновидности алгоритмов машинного обучения

Существует множество алгоритмов машинного обучения, которые используются для решения различных задач прогнозирования. В зависимости от характера данных и типа задачи, некоторые алгоритмы могут работать лучше, чем другие.

К наиболее популярным относятся [4, 5]:

- линейная регрессия — подходит для прогнозирования непрерывных значений и хорошо работает, если существует линейная зависимость между признаками и целевой переменной;
- логистическая регрессия — применяется для классификационных задач при прогнозировании категориальных значений;
- деревья решений — подходят как для регрессии, так и для классификации. Основное преимущество — интерпретируемость результата;

- «случайные леса» — мощные и гибкие алгоритмы, которые могут также использоваться для регрессии и классификации. Они снижают вероятность переобучения за счёт объединения результатов множества деревьев решений;
- градиентный бустинг — используется для повышения точности прогноза путём объединения нескольких слабых моделей в одну сильную;
- метод опорных векторов, также как деревья решений и случайные леса, хорошо работает для задач классификации и регрессии. Эффективен в пространствах с высокими признаковыми измерениями;
- алгоритм К-ближайших соседей — простой и интуитивно понятный алгоритм, используемый для классификации и регрессии, полезен для небольших и среднеразмерных наборов данных;
- искусственные нейронные сети — применяются для решения сложных задач прогнозирования, включая временные ряды, обработку изображений и естественный язык. К ним относятся:
 - глубокие нейронные сети, которые могут находить скрытые зависимости в данных, но требуют больших вычислительных ресурсов и объёмов данных;
 - рекуррентные нейронные сети, которые особенно полезны для анализа временных рядов и последовательностей данных.

Для достижения наилучших результатов часто применяют ансамблирование, технику объединения нескольких моделей для повышения точности прогноза [6].

Важно отметить, что выбор алгоритма во многом зависит от специфики задачи, характеристик данных и доступных ресурсов [7].

Основные этапы, достоинства и недостатки алгоритмов машинного обучения

Рассмотрим пошаговое описание алгоритмов более подробно.

1. **Линейная регрессия** — один из самых простых и широко используемых алгоритмов машинного обучения для прогнозирования непрерывных значений. Основная идея заключается в том, чтобы найти наилучшую прямую, которая минимизирует разницу между предсказанными и фактическими значениями.

Этапы алгоритма линейной регрессии:

- 1) определение задачи — построение модели, которая предсказывает целевую переменную (Y)

- на основании набора данных с признаками (X);
- 2) формирование уравнения прямой — уравнения линейной регрессии;
 - 3) обучение модели — нахождение таких значений, которые минимизируют ошибку предсказания на основе метода наименьших квадратов, который минимизирует сумму квадратов ошибок;
 - 4) решение оптимизационной задачи путём минимизации функции ошибки в виде матричного представления для упрощения вычислений.
 - 5) проверка модели — оценка таких метрик, как коэффициент детерминации, среднеквадратическая ошибка, средняя абсолютная ошибка на тестовых данных;
 - 6) прогнозирование — применение обученной модели для предсказания значений целевой переменной на новых данных.

Достоинства алгоритма линейной регрессии:

- простота и понимание — легко интерпретируется и реализуется;
- быстрота обучения — требует меньше вычислительных ресурсов и времени на обучение по сравнению с более сложными моделями;
- анализ влияния переменных — позволяет оценить влияние каждого независимого признака на зависимую переменную;
- подходит для линейных зависимостей между входными и выходными данными.

Недостатки алгоритма линейной регрессии:

- чувствительность к выбросам — наличие аномалий может существенно исказить результаты;
- линейные предположения — предполагает линейную связь, что может быть не всегда верно.
- ограниченная гибкость — не подходит для моделирования сложных, нелинейных зависимостей.
- мультиколлинеарность — высокая корреляция между независимыми переменными может привести к нестабильным коэффициентам.

2. Логистическая регрессия — алгоритм статистического анализа, использующийся для предсказания вероятности наступления события на основе одного или нескольких признаков. Он чаще всего применяется в задачах бинарной классификации.

Этапы алгоритма логистической регрессии:

- 1) определение задачи — предсказание вероят-

ности того, что целевая переменная (Y) примет значение 1 на основании набора данных с признаками (X);

- 2) формирование модели — вместо линейной функции используется логистическая функция, которая принимает значения от 0 до 1;
- 3) обучение модели — нахождении коэффициентов с использованием максимизации функции правдоподобия;
- 4) оптимизация — получение значений коэффициентов с использованием методов градиентного спуска или специализированных оптимизационных алгоритмов, например, метода Ньютона-Рафсона;
- 5) проверка модели — оценка качества модели, используя метрики, такие как точность, полнота и сравнение предсказанных вероятностей с фактическими значениями для измерения эффекта;
- 6) прогнозирование — применение обученной модели и логистической функции для предсказания вероятности, что $Y = 1$, применение при необходимости порога (например, 0.5) для определения класса.

Достоинства алгоритма логистической регрессии:

- простота и интерпретируемость — коэффициенты модели могут быть интерпретированы как изменения в логарифмическом отношении шансов;
- эффективность при малых выборках — подходит для ограниченного доступа к данным;
- подход для бинарных и многоклассовых задач;
- отсутствие предположения о распределении — не предполагает, что данные имеют нормальное распределение, что делает её более универсальной в некоторых случаях;
- выявление влияния независимых переменных.

Недостатки алгоритма логистической регрессии:

- чувствительность к выбросам — наличие аномалий может существенно исказить результаты;
- линейная зависимость между независимыми переменными и логарифмом шансов, что может быть ограничением в сложных задачах;
- мультиколлинеарность — высокая корреляция между независимыми переменными может привести к нестабильным коэффициентам;
- не подходит для сложных зависимостей;
- проблема несбалансированных классов — в

случае значительной диспропорции между классами (например, много отрицательных и очень мало положительных примеров) модель может иметь низкую точность для меньшего класса.

3. Дерево решений — иерархическая модель, состоящая из узлов (или вершин) и рёбер (или ветвей). Основная идея заключается в рекурсивном разбиении пространства признаков на подпространства, что позволяет сделать предсказание для каждой подгруппы.

Этапы алгоритма дерева решений:

- 1) инициализация корневого узла, который содержит весь набор обучающих данных;
- 2) разбиение данных на основании значений выбранного признака — нахождение лучшего признака для разделения данных, вычисление критериев разбиения, таких как энтропия, прирост информации для классификации, среднеквадратичная ошибка для регрессии;
- 3) рекурсивное разбиение — повторение процесса разбиения для каждого получившегося подузла до тех пор, пока одно из следующих условий не будет достигнуто:
 - все узлы содержат данные одного класса (в случае задачи классификации);
 - узлы не могут быть дальше разбиты (например, потому что максимальная глубина дерева достигнута или минимальное количество примеров в узле слишком маленькое);
 - улучшение после разбиения становится незначительным.
- 4) формирование листовых узлов — каждый конечный узел (лист) содержит предсказание при достижении остановки, например, это может быть класс (в задачах классификации) или среднее значение (в задачах регрессии).

Достоинства алгоритма дерева решений:

- простота и удобство интерпретации;
- отсутствие необходимости в масштабировании данных, что упрощает предварительную обработку;
- работа с разными типами данных, как числовыми, так и категориальными;
- возможность выявления важности признаков;
- не подвержены переобучению на небольших данных.

Недостатки алгоритма дерева решений:

- схожесть к переобучению;
- нестабильность — небольшие изменения в данных могут привести к значительным изменениям в структуре дерева;

- сложность в обобщении — плохая работа на новых, неожиданных данных, особенно если они очень отличаются от обучающей выборки;
- склонность к модельной предвзятости — создание моделей, которые слишком зависят от определённых данных, что может снизить их обобщающую способность;
- может быть неэффективным на больших наборах данных.

4. «Случайный лес» — алгоритм машинного обучения, который использует множество деревьев решений для улучшения точности и устойчивости модели. Основная идея случайного леса заключается в обучении нескольких деревьев решений на разнообразных подмножествах данных и последующем усреднении их предсказаний (в случае регрессии) или голосовании (в случае классификации).

Этапы алгоритма «случайного леса»:

- 1) генерация данных;
- 2) разделение данных на обучение и тестирование, чтобы можно было оценить производительность модели;
- 3) создание модели случайного леса со 100 деревьями и обучение;
- 4) прогнозирование на тестовой выборке;
- 5) оценка модели — точность и матрица ошибок используются для оценки производительности.

Достоинства алгоритма «случайного леса»:

- высокая точность благодаря использованию ансамблевой технологии, которая комбинирует результаты множества деревьев;
- устойчивость к переобучению за счет усреднения результатов нескольких деревьев «случайный лес» менее подвержен переобучению по сравнению с отдельными деревьями решений;
- обработка больших объемов данных с большим количеством признаков, что делает его универсальным инструментом;
- устойчивость к выбросам и шуму в данных, что позволяет получать более надежные результаты;
- выявление важности признаков, что помогает в понимании структуры данных и в выборе переменных для модели.

Недостатки алгоритма «случайного леса»:

- сложность модели по сравнению с простыми алгоритмами, что может затруднить интерпретацию и понимание результатов;
- медлительность при предсказаниях — генерация результатов может занять больше вре-

мени, особенно если количество деревьев велико, что может быть проблемой в задачах с повышенными требованиями к скорости.

- зависимость от гиперпараметров, например, количества деревьев, максимальной глубины и т. д.;
- объем памяти — проблема при работе с устройствами с ограниченными ресурсами.
- проблемы с пропущенными данными — алгоритм не всегда справляется с пропущенными данными так эффективно, как другие модели, и иногда требуется предварительная обработка данных.

5. Градиентный бустинг — алгоритм машинного обучения, который комбинирует несколько слабых моделей (обычно деревьев решений) для создания более сильной модели. Он улучшает модель путем последовательного добавления новых деревьев, которые обучаются на остатках ошибок предыдущих деревьев.

Этапы алгоритма градиентного бустинга:

- 1) генерация данных;
- 2) разделение данных на обучение и тестирование, чтобы можно было оценить производительность модели;
- 3) создание модели градиентного бустинга со 100 деревьями, скоростью обучения и максимальной глубиной деревьев и обучение;
- 4) прогнозирование на тестовой выборке;
- 5) оценка модели — точность и матрица ошибок используются для оценки производительности.

Достоинства алгоритма градиентного бустинга:

- высокая точность;
- устойчивость к переобучению при правильной настройке гиперпараметров;
- работа с разнородными данными, как числовыми, так и категориальными;
- поддержка регуляризации, что помогает контролировать сложность модели и предотвращает переобучение;
- важность признаков, что помогает в интерпретации модели и выборе наилучших переменных.

Недостатки алгоритма градиентного бустинга:

- долгое время обучения;
- сложность параметров;
- вариабельность модели;
- трудность интерпретации;
- проблемы с выбросами данных, что может негативно повлиять на качество предсказаний.

6. Алгоритм метода опорных векторов —

алгоритм машинного обучения, основная идея которого заключается в поиске гиперплоскости, которая максимально разделяет данные на классы.

Этапы алгоритма метода опорных векторов:

- 1) генерация данных;
- 2) разделение данных на обучение и тестирование, чтобы можно было оценить производительность модели;
- 3) создание модели метода опорных векторов с линейным ядром и параметром регуляризации $C = 1.0$ и обучение;
- 4) прогнозирование на тестовой выборке;
- 5) оценка модели — точность и матрица ошибок используются для оценки производительности.

Достоинства алгоритма метода опорных векторов:

- эффективность в высоких измерениях;
- четкое разделение классов — алгоритм находит оптимальную гиперплоскость, которая максимально разделяет классы, что позволяет достигать высокой точности классификации;
- регуляризация — возможность использования параметра регуляризации помогает избежать переобучения и улучшает общую производительность модели;
- поддержка различных функций ядер, например, линейное, полиномиальное, радиально-базисное, что позволяет адаптировать модель для различных типов данных;
- устойчивость к переобучению.

Недостатки алгоритма метода опорных векторов:

- высокие вычислительные затраты;
- сложность выбора параметров;
- проблемы с несбалансированными данными, что требует дополнительных методов обработки данных;
- трудности интерпретации;
- проблемы с шумом и выбросами.

7. Алгоритм K-ближайших соседей — алгоритм машинного обучения, основывающийся на принципе, что объекты, находящиеся близко друг к другу в многомерном пространстве, имеют схожие характеристики.

Этапы алгоритма K-ближайших соседей:

- 1) выбор параметров — определение значения K (количества ближайших соседей, которые будут учитываться при классификации);
- 2) подготовка данных для обучения и тестирования, проведение необходимой предварительной обработки данных, включая нормализацию, если требуется;
- 3) вычисление расстояний для каждого объекта

в тестовом наборе данных до всех объектов в обучающем наборе, используя метрики Евклидова расстояния, Манхэттенского расстояния, косинусного расстояния;

- 4) сортировка и выбор ближайших K соседей;
- 5) присвоение класса каждому из K соседей, применение метода голосования (класс, который наибольшее количество раз представлен среди соседей, становится предсказанным классом) — для задачи классификации; выбор среднего значения (или другого агрегированного значения) выходных переменных K соседей — для задачи регрессии;
- 6) предоставление предсказанного класса или значения для тестируемого объекта.

Достоинства алгоритма K -ближайших соседей:

- простота и легкость реализации;
- отсутствие обучения, что позволяет адаптироваться к новым данным моментально;
- гибкость — использование как для задач классификации, так и для регрессии, что делает его универсальным инструментом;
- непараметрическая природа — алгоритм не делает предположений о распределении данных, что позволяет работать с различными типами данных;
- естественная интерпретация.

Недостатки алгоритма K -ближайших соседей:

- высокие вычислительные затраты;
- чувствительность к выбору K — слишком маленькое K может привести к переобучению, а слишком большое — к недообучению;
- чувствительность к шкале данных;
- проблемы с несбалансированными данными;
- сложность с многомерными данными, что затрудняет поиск ближайших соседей.

8. Искусственные нейронные сети (далее — ИНС) применяются для решения сложных задач прогнозирования, способны выявлять сложные зависимости в данных и эффективно обрабатывать большие объемы информации [8].

Этапы алгоритма ИНС:

- 1) определение задачи прогнозирования;
- 2) сбор данных, которые будут использоваться для обучения модели;
- 3) предобработка данных — очистка, нормализация и стандартизация, кодирование категориальных переменных, разделение данных;
- 4) создание модели — определение архитектуры, количества нейронов, равных числу признаков, количества и размера скрытых слоев, выбор соответствующей активационной функции;

5) компиляция модели — определение функции потерь, выбор оптимизатора и метрики для оценки качества модели;

6) обучение модели на обучающих данных, передача в неё валидационные данные для мониторинга во время обучения;

7) оценка модели на тестовой выборке, чтобы проверить её производительность;

8) постобработка результатов — анализ ошибок и визуализация предсказания модели, чтобы понять её поведение и выявить паттерны;

9) улучшение модели — на основе проведенного анализа можно внести изменения в архитектуру, гиперпараметры, данные (например, используя технику увеличения данных), чтобы улучшить качество предсказаний;

10) развертывание в реальной системе или приложении, чтобы начать использовать для прогноза новых данных;

11) мониторинг и обновление.

Достоинства ИНС [7, 8]:

- способность к обучению на больших объемах данных, выявляя сложные зависимости и закономерности, которые могут быть неочевидны при использовании традиционных методов;
- гибкость архитектуры — ИНС подходят для различных типов задач (регрессия, классификация, временные ряды) с использованием разнообразных архитектур (например, многослойные перцептроны, свёрточные и рекуррентные сети);
- устойчивость к шуму;
- выявление сложных и нелинейных связей, что делает их особенно полезными для проблем с высокой размерностью;
- автоматическое извлечение признаков, что уменьшает необходимость в предварительной обработке данных.
- адаптивность к изменениям в данных и их распределению, что позволяет им быть более актуальными в динамичных средах.

Недостатки ИНС [9, 10]:

- необходимость большого объема данных;
- сложность настройки гиперпараметров;
- отсутствие интерпретируемости;
- долговременные вычисления;
- риск переобучения;
- чувствительность к параметрам.

Применимость алгоритмов машинного обучения в задачах прогноза

Прогнозирование технического состояния средств радиосвязи является ключевым элементом

управления и эксплуатации радиосистем. Это позволяет обеспечить надежность связи, минимизировать время простоя и оптимизировать процессы обслуживания [11-13].

Прогнозирование состояния средств радиосвязи является многоаспектной задачей, требующей применения, как традиционных методов, так и современных технологий. Интеграция этих подходов позволит создавать надежные системы связи, способные эффективно функционировать в любых условиях.

К задачам прогнозирования технического состояния средств радиосвязи относятся:

- прогнозирование отказов — определение вероятности и сроков возможных отказов оборудования;
- оценка состояния — определение текущего состояния средств радиосвязи для планирования всех работ;
- оптимизация планирования — работа на основе прогноза для уменьшения затрат на обслуживание и ремонта;
- улучшение надежности — обеспечение надежной работы систем и предотвращение критических инцидентов.

Заключение

На проходившем недавно Международном военно-техническом форуме «Армия-2024» министром обороны Российской Федерации А. Р. Белоусовым было уделено пристальное внимание необходимости совершенствования системы управления вооружени-

ями, военной и специальной техникой (далее — ВВСТ) через внедрение комплексов поддержки принятия решений, в том числе на основе искусственного интеллекта.

Проведенный в работе анализ алгоритмов машинного обучения, как инструментов интеллектуализации процесса управления ВВСТ через процедуры контроля и мониторинга технического состояния позволяет сделать вывод о целесообразности их применимости в отношении наблюдения за средствами радиосвязи в автоматизированных системах (радиосетях):

- на этапе использования по назначению — индивидуальный прогноз;
- по времени продолжительности — краткосрочный прогноз;
- по используемым методам прогноза — метод анализа и прогнозирования рядов данных (временных рядов);
- по используемому математическому аппарату — вероятностный или статистический прогноз (а также их комбинации, например, ИНС).

В случае применения ИНС, математических моделей, их программного или аппаратного воплощения в среде программирования реализуется принцип сбора, анализа и сравнения контролируемых параметров с уже заданными ранее (при обучении). При этом чаще всего для прогнозирования используются многослойные, как правило трехслойные нейронные сети прямого распространения.

Литература

1. Мусаев А. А. Интеллектуальный анализ данных. — СПб.: СПбГТИ(ТУ). — 2018. — 56 с.
2. Воронина В. В., Михеев А. В., Ярушкина Н. Г., Святков К. В. Теория и практика машинного обучения. Ульяновский государственный технический университет, Ульяновск. 2017. — 290 с.
3. Хенрик Б., Джозеф Р., Марк Ф. Машинное обучение. — СПб.: Питер, 2017. — 336 с.
4. Вьюгин В. В. Математические основы машинного обучения и прогнозирования. — М.: 2013, 2018. — 484 с.
5. Морозова В. И. Прогнозирование методом машинного обучения // Молодой ученый. — 2022. — № 21 (416). — С. 202–204.
6. Аллакин В. В. Анализ методов оценки временных рядов сервером мониторинга информационно-телекоммуникационной сети общего пользования // Техника средств связи. 2021. № 2 (154). С. 60–80.
7. Шелест А. В., Пархоменко К. А. Обзор методов и моделей прогнозирования временных рядов // Компьютерное проектирование и технология производства электронных систем: сборник тезисов 54 научной конференции аспирантов, магистрантов и студентов, Минск, 23–27 апреля 2018 г. / Белорусский государственный университет информатики и радиоэлектроники, отв. ред. Раднёнок А. Л. — Минск, 2018. — С. 112–113.
8. Пономарева К. А. Применение искусственных нейронных сетей при решении задач прогнозирования // Наука без границ. — 2020. — № 1(41). — С. 42–47.
9. Горева Т. И., Портнягин Н. Н., Пюкке Г. А. Нейросетевые модели диагностики технических систем // Вестник КРАУНЦ. Физ.-мат. науки. — 2017. — № 1 (4). — С. 31–43.
10. Хаханов В. И. Применение искусственных нейронных сетей для диагностирования цифровых сетей // Радиоэлектронные и компьютерные системы. — 2017. — № 5 (46). — С. 15–20.
11. Шмидт А. А., Косырев А. В. Анализ научно-методического аппарата диагностики и контроля, мониторинга и прогнозирования технического состояния военной техники связи // Техника средств связи. 2023. № 4 (164). С. 81–92.
12. Будко П. А., Шмидт А. А., Голюнов М. В., Сафиулов Д. М. Прогнозирование технического состояния в системе технического обеспечения связи и автоматизированных систем управления // IX Межвузовская научно-практическая конференция «Проблемы технического обеспечения войск в современных условиях». Труды конференции: Сборник материалов. — СПб.: ВАС, 2024. — С. 40–44.
13. Будко П. А., Шмидт А. А., Голюнов М. В., Сафиулов Д. М. Анализ методов прогнозирования технического состояния средств радиосвязи // IX Межвузовская научно-практическая конференция «Проблемы технического обеспечения войск в современных условиях». Труды конференции: Сборник материалов. — СПб.: ВАС, 2024. — С. 45–49.

APPLICATION OF MACHINE LEARNING ALGORITHMS TO SOLVE PROBLEMS OF PREDICTING THE TECHNICAL CONDITION OF RADIO COMMUNICATION FACILITIES

Chikhachev A.V.¹, Budko P.A.², Schmidt A.A.³

Keywords: national development strategy, national development program, artificial intelligence, machine learning, machine learning algorithms, forecasting.

Abstract

The purpose of the work is to analyze and select the most suitable machine learning algorithms for solving the problems of predicting the technical condition of radio communication facilities.

Research method: linear and logistic regression algorithms, decision trees, random forests, gradient boosting, support vector method, K-nearest neighbors, and artificial neural networks.

Research results: The article presents an analysis of existing foreign and domestic national strategies for the development of artificial intelligence, the main definitions, directions and technologies used.

One of the areas of artificial intelligence is considered in more detail — machine learning, which is used to solve various forecasting problems, including predicting the technical condition of radio communication facilities. Artificial neural networks, which are one of the most popular methods of machine learning, which, in turn, is one of the areas of artificial intelligence, the most preferable for solving the problems of predicting the technical condition of radio communication facilities.

The article also provides a detailed step-by-step description of the algorithms, their advantages and disadvantages.

Practical value: new opportunities associated with the use of artificial intelligence open up new horizons for the development of modern technologies, including those based on the use of artificial neural networks. Predicting the technical condition of radio communication equipment is a key element in the management and operation of radio systems and allows you to create reliable communication systems that can function effectively in any conditions, minimize downtime and optimize maintenance processes.

References

1. Musaev A. A. Intellektual'nyj analiz dannyh. – SPb.: SPbGTI(TU). – 2018. – 56 s.
2. Voronina V. V., Miheev A. V., Jarushkina N. G., Svjatov K. V. Teorija i praktika mashinnogo obucheniya. Ul'janovskij gosudarstvennyj tehničeskij universitet, Ul'janovsk. 2017. – 290 s.
3. Henrik B., Dzhozef R., Mark F. Mashinnoe obuchenie. – SPb.: Piter, 2017. – 336 s.
4. V'jugin V. V. Matematicheskie osnovy mashinnogo obucheniya i prognozirovanija. – M.: 2013, 2018. – 484 s.
5. Morozova V. I. Prognozirovanie metodom mashinnogo obucheniya // Molodoj učenij. – 2022. – № 21 (416). – S. 202–204.
6. Allakin V. V. Analiz metodov ocenki vremennyh rjadov serverom monitoringa informacionno-telekommunikacionnoj seti obshhego pol'zovanija // Tehnika sredstv svjazi. 2021. № 2 (154). S. 60–80.
7. Shelest A. V., Parhomenko K. A. Obzor metodov i modelej prognozirovanija vremennyh rjadov // Komp'juternoje proektirovanie i tehnologija proizvodstva jelektronnyh sistem: sbornik tezisov 54 nauchnoj konferencii aspirantov, magistrantov i studentov, Minsk, 23–27 aprelja 2018 g. / Belorusskij gosudarstvennyj universitet informatiki i radiojelektroniki, otv. red. Radnjonok A. L. – Minsk, 2018. – S. 112–113.
8. Ponomareva K. A. Primenenie iskusstvennyh nejronnyh setej pri reshenii zadach prognozirovanija // Nauka bez granic. – 2020. – № 1(41). – S. 42–47.
9. Goreva T. I., Portnjagin N. N., Pjucke G. A. Nejrosetevye modeli diagnostiki tehničeskijh sistem // Vestnik KRAUNC. Fiz-mat. nauki. – 2017. – № 1 (4). – S. 31–43.
10. Hahanov V. I. Primenenie iskusstvennyh nejronnyh setej dlja diagnostirovanija cifrovych setej // Radiojelektronnye i komp'juternye sistemy. – 2017. – № 5 (46). – S. 15–20.
11. Shmidt A. A., Kosyrev A. V. Analiz nauchno-metodičeskogo apparata diagnostiki i kontrolja, monitoringa i prognozirovanija tehničeskogo sostojanija voennoj tehniki svjazi // Tehnika sredstv svjazi. 2023. № 4 (164). S. 81–92.
12. Budko P. A., Shmidt A. A., Goljunov M. V., Safiulov D. M. Prognozirovanie tehničeskogo sostojanija v sisteme tehničeskogo obespečenija svjazi i avtomatizirovannyh sistem upravlenija // IX Mezhvuzovskaja nauchno-praktičeskaja konferencija «Problemy tehničeskogo obespečenija vojsk v sovremennyh uslovijah». Trudy konferencii: Sbornik materialov. – SPb.: VAS, 2024. – S. 40–44.
13. Budko P. A., Shmidt A. A., Goljunov M. V., Safiulov D. M. Analiz metodov prognozirovanija tehničeskogo sostojanija sredstv radiosvjazi // IX Mezhvuzovskaja nauchno-praktičeskaja konferencija «Problemy tehničeskogo obespečenija vojsk v sovremennyh uslovijah». Trudy konferencii: Sbornik materialov. – SPb.: VAS, 2024. – S. 45–49.

¹Anton V. Chikhachev, Ph.D., Associate Professor, Head of the Department of Technical Support of Communications and Automation of the Military Academy of Communications, St. Petersburg, Russia. E-mail: anton_best@mail333.com

²Pavel A. Budko, Dr.Sc., Professor, Professor of the Department of Technical Support of Communications and Automation of the Military Academy of Communications, St. Petersburg, Russia. E-mail: budko62@mail.ru

³Anna A. Schmidt, Adjunct of the Department of Technical Support of Communications and Automation, Military Academy of Communications, St. Petersburg, Russia. E-mail: anutikaaa@mail.ru