

# ПРИМЕНЕНИЕ МАШИННОГО ОБУЧЕНИЯ ДЛЯ АДАПТАЦИИ СТРУКТУРЫ ВОЕННЫХ ВЫЧИСЛИТЕЛЬНЫХ СИСТЕМ В ЗАДАЧАХ УПРАВЛЕНИЯ БПЛА

## THE USE OF MACHINE LEARNING TO ADAPT THE STRUCTURE OF MILITARY COMPUTING SYSTEMS IN UAV CONTROL TASKS

**A. Vorganov  
I. Kurdyumov  
V. Prokhorov  
G. Zhilin**

*Summary.* This article discusses the application of machine learning to adapt the structure of military computing systems in the tasks of controlling unmanned aerial vehicles (UAVs). The rapid development of military technologies requires increasing flexibility and adaptability from computing systems, which makes traditional UAV control methods insufficiently effective. Machine learning offers solutions that can provide the high accuracy, responsiveness and adaptability that are critical to the successful execution of military operations. The implementation of such systems requires careful planning and consideration of many factors, but the results justify the efforts, providing significant improvements in the efficiency and reliability of UAV control.

*Keywords:* machine learning, unmanned aerial vehicles (UAVs), military computing systems, adaptability, UAV control.

**Ворганов Александр Александрович**

Начальник учебной части,

Российский технологический университет МИРЭА

**Курдюмов Иван Алексеевич**

Российский технологический университет МИРЭА

kurdyumov-2003@mail.ru

**Прохоров Вадим Александрович**

Российский технологический университет МИРЭА

**Жилин Глеб Владимирович**

Российский технологический университет МИРЭА

*Аннотация.* В данной статье рассматривается применение машинного обучения для адаптации структуры военных вычислительных систем в задачах управления беспилотными летательными аппаратами (БПЛА). Стремительное развитие военных технологий требует от вычислительных систем все большей гибкости и адаптивности, что делает традиционные методы управления БПЛА недостаточно эффективными. Машинное обучение предлагает решения, которые могут обеспечить высокую точность, оперативность и адаптивность, что критически важно для успешного выполнения военных операций. Внедрение таких систем требует тщательного планирования и учета множества факторов, но результаты оправдывают усилия, обеспечивая значительное улучшение эффективности и надежности управления БПЛА.

*Ключевые слова:* машинное обучение, беспилотные летательные аппараты (БПЛА), военные вычислительные системы, адаптивность, управление БПЛА.

## Введение

В современном мире военные технологии продолжают стремительно развиваться, что требует от вычислительных систем все большей гибкости и адаптивности. Одним из ключевых и быстроразвивающихся элементов современных военных операций являются беспилотные летательные аппараты (БПЛА), которые используются для разведки, наблюдения, целеуказания, ретрансляции связи, корректировки огня, боевых атак. Управление БПЛА требует высокой точности и оперативности, что делает их управление особенно сложным.

Целью нашего исследования является изучение и анализ внедрения в военные вычислительные системы машинного обучения, ведь на примере последних лет, можно заметить, что традиционные методы управления БПЛА часто оказываются недостаточно гибкими и адаптивными для быстро меняющихся условий боевых

действий. В таких условиях необходимость в автоматическом и адаптивном управлении становится критически важной.

Машинное обучение, как одна из наиболее перспективных областей искусственного интеллекта, предлагает решения, которые могут значительно улучшить эффективность и надежность управления БПЛА.

Научная новизна исследования заключается в рассмотрении уже имеющихся методов машинного обучения, с целью адаптации систем управления беспилотными аппаратами в условиях современных военных конфликтов.

Актуальность темы исследования заключается в том, что использование машинного обучения позволяет создавать алгоритмы, способные адаптироваться к новым получаемым данным, что делает их идеальными для ис-

пользования в быстроменяющихся условиях. Адаптивные алгоритмы могут автоматически настраиваться под изменяющиеся задачи, обеспечивая высокую точность и оперативность управления БПЛА. Это особенно важно, когда время реакции и точность действий могут определять успех или провал военной операции.

### 1. Определение машинного обучения и его роль в управлении БПЛА

Машинное обучение представляет собой раздел искусственного интеллекта, который занимается разработкой алгоритмов и моделей, способных учиться на данных и принимать решения или делать прогнозы без необходимости явного программирования. В управлении беспилотными летательными аппаратами (БПЛА) машинное обучение позволяет системам адаптироваться к новым условиям и задачам в режиме реального времени. Кроме того, оно помогает создавать адаптивные алгоритмы, которые могут автоматически изменять свои параметры в зависимости от новых данных, обеспечивая высокую точность и эффективность управления. Это особенно важно для военных операций, где скорость реакции и точность выполнения задач могут быть критическими для успеха миссии.

Для эффективного управления БПЛА анализировались различные алгоритмы машинного обучения с целью выявления наиболее подходящих для данной области. Рассмотрим несколько таких алгоритмов.

Градиентный бустинг — это мощный алгоритм машинного обучения, применяемый как для решения задач классификации, так и регрессии. Его суть заключается в создании ансамбля слабых моделей (чаще всего деревьев решений), которые последовательно улучшают друг друга, уменьшая ошибки предыдущих моделей.

Алгоритм работает следующим образом:

1. Изначально всем данным присваивается средний прогноз.
2. Вычисляются ошибки с использованием антиградиента функции потерь.
3. Строится регрессионное дерево и выполняется прогноз.
4. Новый прогноз добавляется к предыдущему, и процесс повторяется для каждого последующего дерева.
5. После завершения обучения всех деревьев делается итоговый прогноз.
6. Итоговая сумма всех прогнозов и является окончательным результатом.

Преимущества градиентного бустинга: высокая точность, хорошая работа с разнообразными данными, возможность создания различных модификаций на его

основе. Недостатки: низкая скорость обучения на больших наборах данных, возможные проблемы с категориальными признаками, риск переобучения при неадекватной подготовке данных. Однако, эти недостатки были частично или полностью решены в некоторых модификациях алгоритма.

Рекуррентная нейронная сеть (RNN) — это модель, вдохновленная биологической нейронной сетью, состоящая из множества взаимосвязанных искусственных нейронов. Процесс обучения сети заключается в подборе весов нейронов таким образом, чтобы входные данные преобразовывались в требуемый выход. Одной из простейших моделей нейронных сетей является перцептрон. Он представляет собой математическую модель, имитирующую работу нейронных сетей мозга, состоящую из сенсоров, ассоциативных и реагирующих элементов.

Процесс работы перцептрона можно описать следующим образом:

1. Сенсоры получают сигналы, которые могут быть либо нулевыми (покой), либо единичными (состояние возбуждения).
2. Сигналы передаются ассоциативным элементам через связи с весами, которые могут принимать значения -1, 0 или 1. Если сумма сигналов на ассоциативном элементе превышает определённый порог, элемент генерирует сигнал, равный 1, иначе — нулевой.
3. Ассоциативные элементы передают сигналы сумматору, который складывает их и, при превышении порога, выдаёт выходной сигнал 1.
4. Если порог не превышен, выходной сигнал будет равен 0.

Преимущества нейронных сетей: они способны обобщать информацию, решать задачи при отсутствии явных закономерностей, устойчивы к шумам в данных, адаптируются к изменениям окружающей среды и могут демонстрировать высокую производительность. Недостатки: сложность процесса обучения, необходимость тщательной подготовки обучающей выборки, долгий процесс обучения, а также отсутствие гарантий логического поведения обученной сети.

### 2. Обзор текущих методов управления БПЛА

Метод управления на основе правил предполагает использование заранее определенных правил и сценариев для координации действий БПЛА. Эти правила могут включать условия для выполнения различных задач, таких как патрулирование, разведка или атака. К преимуществам можно отнести, что метод прост в реализации и не требует сложных вычислительных ресурсов, а также предсказуемость поведения БПЛА, что упрощает плани-

рование и координацию. Но предсказуемость является одновременно и минусом: метод не может эффективно адаптироваться к изменяющимся условиям и новым задачам. Также требуется постоянное обновление правил для учета новых сценариев и условий. Управление на основе правил может применяться в системах, где требуется высокая предсказуемость и простота реализации. Однако его ограниченная гибкость делает его менее подходящим для динамически изменяющихся условий.

Метод управления на основе моделей использует математические модели для прогнозирования поведения БПЛА и окружающей среды. Эти модели могут включать динамические уравнения, описывающие движение БПЛА и модели окружающей среды.

Метод основан на нескольких аспектах:

1. Разработка математической модели, которая учитывает физические характеристики ЛА, такие как масса, форма, аэродинамические силы и моменты.
2. Линейное и нелинейное моделирование. Линейные модели проще в анализе, но нелинейные лучше описывают реальное поведение.
3. Методы управления: используются различные алгоритмы управления, такие как PID-контроль, управление на основе состояния или адаптивное управление, которые опираются на разработанную модель.
4. Симуляция и тестирование: применяются компьютерные симуляции для тестирования разработанных алгоритмов управления в различных условиях, что позволяет выявить возможные проблемы до реальных полетов.

Преимущества метода: наибольшая точность прогнозирования поведения БПЛА, сводящая к минимуму возможности отклонения во время выполнения задачи и возможность учета динамики системы и внешних факторов, что повышает точность управления. К недостаткам относятся сложность реализации, требуются значительные вычислительные ресурсы и сложные математические модели, и все так же ограниченная адаптивность, но только в этом случае отклонение БПЛА практически невозможно. Управление на основе моделей обеспечивает высокую точность прогнозирования и учет динамики системы. Однако сложность и ограниченная адаптивность делают его менее подходящим для действий в реальном времени.

Метод управления на основе распределенных систем предполагает использование множества центров управления, которые координируют действия БПЛА. Метод обладает повышенной устойчивостью, он менее уязвим к сбоям и атакам, так как не зависит от единого центра управления, так же дает возможность незави-

симой координации действий БПЛА. Но координация данным методом требует надежной и быстрой коммуникации между центрами управления для эффективной координации. Управление на основе распределенных систем является устойчивым и гибким, однако сложность координации и требование к надежной коммуникации делают его менее подходящим в непостоянных условиях конфликта.

Метод управления на основе машинного обучения использует машинные алгоритмы и модели для автоматизации процессов управления, планирования и адаптации системы управления под изменяющиеся условия и задачи. Эти алгоритмы могут включать методы обучения как с учителем, так и без него. Преимущества данного метода заключается в возможности автоматической адаптации системы под новые данные и условия быстроменяющейся обстановки, способности самостоятельно принимать решения в реальном времени и адаптации к новым задачам. Однако метод машинного обучения требует большого объема данных и пока что подвержен ошибкам и неопределенностям, особенно в условиях недостаточного объема данных. Управление на основе машинного обучения применяется там, где требуется высокая адаптивность и гибкость. Метод активно развивается и открывает перспективы дальнейшей минимизации участия человека в прямой близости от столкновения.

### 3. Сравнение алгоритмов машинного обучения для адаптации структуры вычислительных систем

Метод градиентного бустинга представляет собой ансамблевый метод машинного обучения, который последовательно строит деревья решений, каждое из которых корректирует ошибки предыдущих деревьев. Этот метод особенно эффективен для задач регрессии и классификации, что делает его подходящим для адаптации структуры вычислительных систем в условиях быстро меняющихся задач и условий. Для разработки алгоритма градиентного бустинга необходимо собрать и подготовить данные, которые будут использоваться для обучения модели. Эти данные могут включать в себя параметры состояния БПЛА, такие как скорость, высота, угол наклона, данные сенсоров, такие как температура, влажность, видимость, а также информацию о внешних условиях, таких как погодные условия и наличие препятствий. После сбора и подготовки данных необходимо определить начальную модель, которая будет использоваться для предсказания поведения системы. В данном случае мы будем использовать простую линейную модель для начального предсказания. Эта модель будет использоваться для определения начальных ошибок, которые будут корректироваться последующими деревьями решений. Для построения деревьев решений используется алгоритм градиентного бустинга, такой как XGBoost

или LightGBM. LightGBM строит деревья по принципу: «На каждом шаге делим вершину с наилучшим скором», а основным критерием остановки выступает максимально допустимое количество вершин в дереве. Это приводит к тому, что деревья получаются несимметричными, то есть поддеревья могут иметь разную глубину — например, левое поддерево может иметь глубину 2, а правое может разрастись до глубины 15 (Рис. 1).

С одной стороны, это позволяет быстро подстроиться под обучающие данные. С другой — бесконтрольный рост дерева в глубину неизбежно ведет к переобучению, поэтому LightGBM позволяет помимо количества вершин ограничивать и максимальную глубину. Впрочем, это ограничение обычно все равно выше, чем для XGBoost. XGBoost строит деревья по принципу: «Строим дерево последовательно по уровням до достиже-

ния максимальной глубины». Отдельного ограничения на количество вершин нет, так как оно естественным образом получается из ограничения на глубину дерева. В XGBoost деревья «стремятся» быть симметричными по глубине, и в идеале получается полное бинарное дерево, если это не противоречит другим ограничениям (например, ограничению на минимальное количество объектов в листе) (Рис. 2). Такие деревья обычно являются более устойчивыми к переобучению.

Например, мы можем использовать XGBoost с параметрами: количество деревьев ( $n\_estimators$ ) = 100, максимальная глубина дерева ( $max\_depth$ ) = 6, и скорость обучения ( $learning\_rate$ ) = 0.1. Эти параметры могут быть настроены с помощью кросс-валидации для достижения оптимальной производительности.

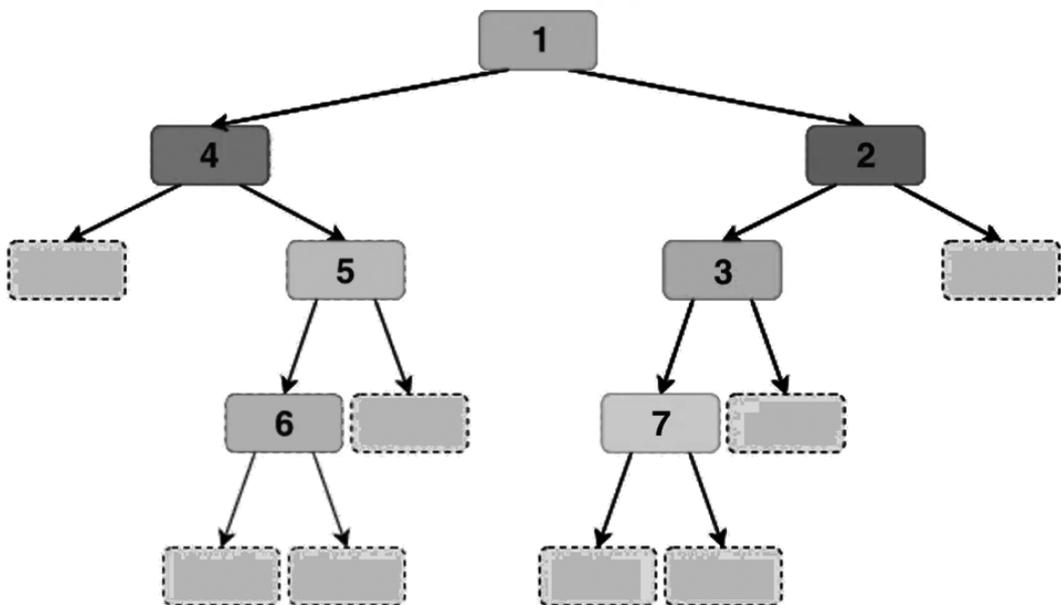


Рис. 1. Пример построения дерева при помощи LightGBM модели

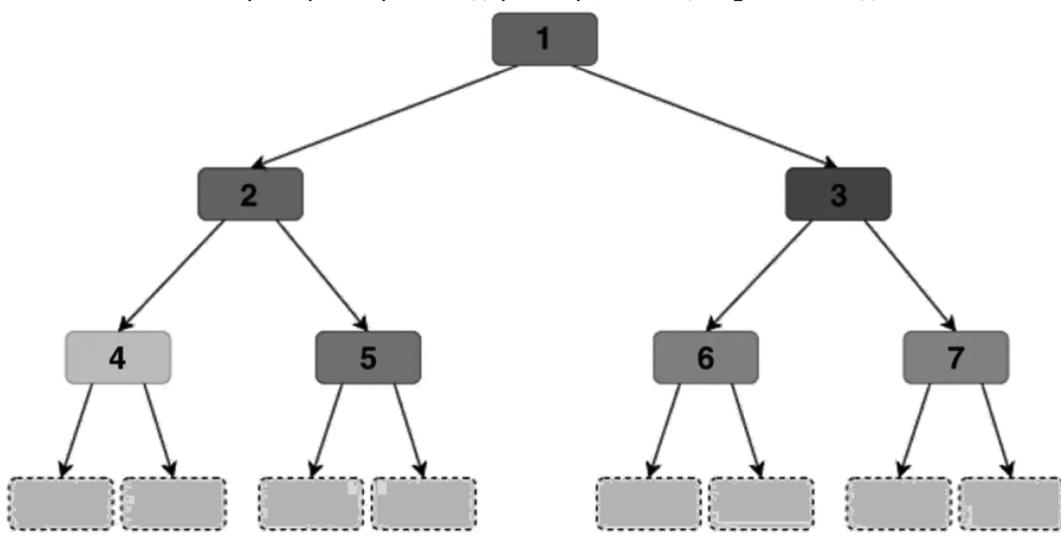


Рис. 2. Пример построения дерева при помощи XGBoost модели

Метод рекуррентных нейронных сетей (RNN) представляет собой модель машинного обучения, специально разработанную для обработки последовательных данных. RNN могут быть использованы для задач, связанных с временными рядами, таких как прогнозирование траекторий движения БПЛА и анализ временных данных сенсоров. Этот метод особенно эффективен для задач, требующих учета временной зависимости данных. Плюс рекуррентных нейронных сетей, или RNN, в том, что они обеспечивают последовательности с вариативными длинами как для входа, так и для вывода. Вот несколько примеров того, как может выглядеть рекуррентная нейронная сеть (Рис. 3).

Для разработки алгоритма RNN необходимо собрать и подготовить данные, которые будут использоваться для обучения модели (Рис. 4). Эти данные могут включать в себя временные ряды параметров состояния БПЛА, такие как скорость, высота, угол наклона, данные сенсоров, такие как температура, влажность, видимость, а также информацию о внешних условиях, таких как погодные условия и наличие препятствий.

После сбора и подготовки данных необходимо определить архитектуру нейронной сети, которая будет использоваться для предсказания поведения системы. В данном случае мы будем использовать архитектуру

RNN с двумя скрытыми слоями, каждый из которых содержит 128 нейронов. Входной слой будет содержать 20 нейронов, соответствующих количеству признаков в данных. Выходной слой будет содержать один нейрон для задачи регрессии или несколько нейронов для задачи классификации. Для обучения нейронной сети используется алгоритм обратного распространения ошибки (backpropagation) с функцией потерь, такой как среднеквадратичная ошибка (MSE) для задачи регрессии или кросс-энтропия для задачи классификации. Обучение проводится с использованием оптимизатора, такого как Adam, с параметрами: скорость обучения (learning\_rate) = 0.001, количество эпох (epochs) = 100, и размер батча (batch\_size) = 32. Эти параметры могут быть настроены с помощью кросс-валидации для достижения оптимальной производительности.

### Заключение

В ходе работы был проведен обширный анализ источниковой базы и сделаны выводы, что применение машинного обучения для адаптации структуры военных вычислительных систем в задачах управления беспилотными летательными аппаратами (БПЛА) представляет собой значительный шаг вперед в области военных технологий. В условиях стремительного развития военных технологий и возрастающих требований к гибкости

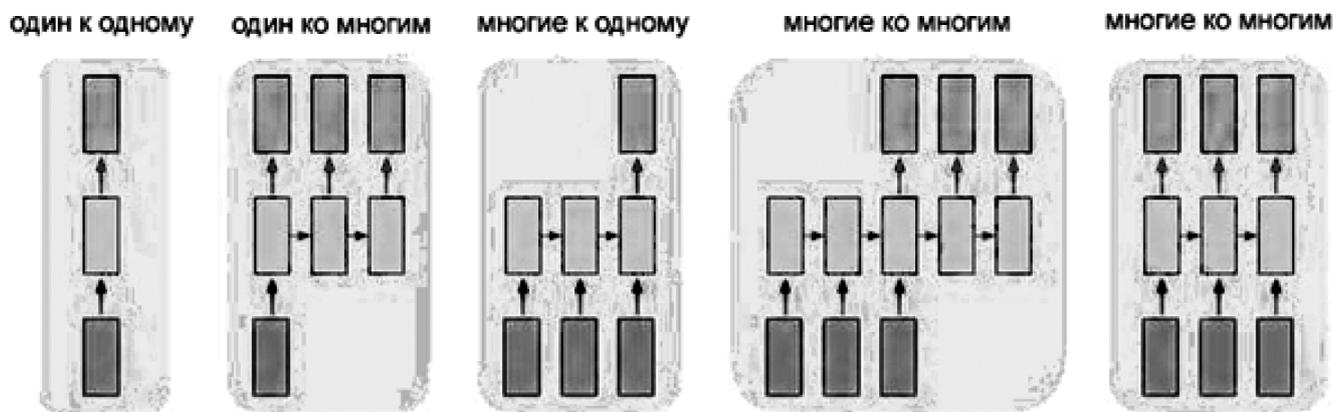


Рис. 3. Виды RNN



Рис. 4. Многомерная RNN модель

и адаптивности вычислительных систем, машинное обучение предлагает решения, которые значительно улучшают эффективность и надежность управления БПЛА.

Обзор текущих методов управления БПЛА показал, что традиционные методы, такие как управление на основе правил, моделей и распределенных систем, имеют свои преимущества и недостатки. Управление на основе правил просто в реализации, но ограничено в адаптивности, на основе моделей обеспечивает высокую точность, но сложно в реализации и ограничено в адаптивности, а управление на основе распределенных систем устойчиво, но требует надежной коммуникации. В свою очередь, управление на основе машинного обучения

предлагает высокую адаптивность и гибкость, хотя и требует большого объема данных и подвержено ошибкам.

Анализ эффективности и надежности указывает на то, что алгоритмы машинного обучения значительно превосходят традиционные методы по точности предсказаний, времени реакции и способности адаптироваться к изменяющимся условиям. Надежность и устойчивость адаптивных систем также были подтверждены, благодаря способности ML-систем выявлять и компенсировать неисправности сенсоров и актуаторов, а также учитывать внешние воздействия, такие как погодные изменения или электронные помехи.

#### ЛИТЕРАТУРА

1. Puente-Castro A. et al. A review of artificial intelligence applied to path planning in UAV swarms //Neural Computing and Applications. — 2022. — Т. 34. — №. 1. — С. 153–170.
2. Petrovski A., Radovanović M., Behlić A. Application of drones with artificial intelligence for military purposes //10th International Scientific Conference on Defensive Technologies–OTEN. — 2022. — Т. 2022. — С. 92–100.
3. Szabadföldi I. Artificial intelligence in military application—opportunities and challenges // Land Forces Academy Review. — 2021. — Т. 26. — №. 2. — С. 157–165.
4. Кутахов В.П., Мещеряков Р.В. Управление групповым поведением беспилотных летательных аппаратов: постановка задачи применения технологий искусственного интеллекта //Проблемы управления. — 2022. — №. 1. — С. 67–74.
5. Малинина Н.В. Управления БПЛА при помощи искусственного интеллекта //Инновации. Наука. Образование. — 2021. — №. 32. — С. 1408–1418.
6. Горохова С.С. Искусственный интеллект в контексте обеспечения национальной безопасности //Национальная безопасность/nota bene. — 2020. — №. 3. — С. 15–31.

© Ворганов Александр Александрович; Курдюмов Иван Алексеевич (kurdyumov-2003@mail.ru);  
Прохоров Вадим Александрович; Жилин Глеб Владимирович  
Журнал «Современная наука: актуальные проблемы теории и практики»