



А.У. Калижанова^{1,2}, М. Кунелбаев^{1,3}, С. Дәруіш^{1,3}

¹Institute of Information and Computational Technologies CS MSHE RK,
Алматы, Казахстан

²Energo University, Алматы, Казахстан

³Farabi University, Алматы, Казахстан

E-mail: murat7508@yandex.kz

ПРОГНОЗИРОВАНИЕ ЗОН ПАДЕНИЯ СТУПЕНЕЙ РАКЕТ НА ОСНОВЕ ЦИФРОВОГО ДВОЙНИКА И ГЛУБОКОГО ОБУЧЕНИЯ

Аннотация. Предложена интеллектуальная система прогнозирования зон падения отделяющихся ступеней ракет-носителей, объединяющая цифровой двойник, математическое моделирование, вероятностную фильтрацию, DQN и GIS-анализ рисков. Система обрабатывает телеметрические, метеорологические и геопространственные данные, уточняет состояние объекта с помощью расширенного фильтра Калмана, фильтра частиц и байесовского обновления, а также корректирует прогноз траектории. Численное моделирование и испытания Монте-Карло показали значения RMSE 19,7 м и MAE 15,3 м при точности прогноза 99,1%. Дополнительно сформирована GIS-карта рисков для Улытауской области. Метод может применяться для повышения безопасности космических запусков и поддержки оперативных решений.

Ключевые слова: цифровой двойник, прогнозирование траектории, зона падения, отделяющаяся ступень, Deep Q Network, расширенный фильтр Калмана, фильтр частиц, байесовское обновление, метод Монте-Карло, GIS-анализ риска.

Введение.

Рост числа пусков ракет-носителей требует улучшения точности прогноза мест падения отделяющихся ступеней. Успешное выполнение этой задачи критически важно для защиты жизни людей, ключевых инфраструктурных объектов, а также для сведения к минимуму негативного воздействия на окружающую среду.

В работе [1] представлена архитектура цифрового двойника ракеты-носителя, основанная на моделировании, которая позволяет осуществлять синхронизацию физического аппарата с его виртуальным аналогом посредством телеметрической информации, а также повышает достоверность прогноза параметров траектории полета. В статье [2] описывается подход Reinforcement Twinning, который интегрирует технологии цифрового двойника с алгоритмами обучения с подкреплением. Данная методика



направлена на обеспечение безопасности процесса обучения искусственного агента и повышение надежности принимаемых им решений в ситуациях, характеризующихся высокой степенью неопределенности. Согласно источнику [3], разработана структура цифрового двойника спутника, которая обеспечивает автоматическое выявление неисправностей, оценку текущего технического состояния аппарата и корректировку его рабочих характеристик. В работе [4] представлена цифровая копия орбитального созвездия из нескольких аппаратов, служащая инструментом для координации групповых космических миссий. Созданная модель гарантирует постоянную актуализацию виртуального пространства в соответствии с реальными данными о полете спутников, что позволяет принимать во внимание внешние воздействия при подготовке совместных задач. В работе [5] анализируется использование алгоритмов машинного обучения для проверки корректности цифрового двойника в аэрокосмической отрасли. Предложенная авторами интеллектуальная платформа способна автоматически подстраивать параметры виртуальной модели, опираясь на результаты экспериментов. В источнике [6] дается актуальный анализ технологий цифровых двойников, охватывающий путь от зарождения идеи до их внедрения в промышленность. Автор исследует структуру таких двойников, подходы к совмещению физических моделей с данными в реальном времени, а также перспективы использования данной технологии в аэрокосмической сфере. В работе [7] проведено всестороннее исследование актуальных решений в области цифровых двойников. В работе детально освещаются ключевые стадии создания виртуальных копий, подходы к анализу массивных данных, применение алгоритмов машинного обучения и возможности облачных инфраструктур. В статье [8] анализируется внедрение цифровых двойников с целью содействия устойчивому прогрессу в авиационной сфере. Демонстрируется, что данное технологическое решение способствует улучшению показателей безопасности полетов и рационализации процессов технического обслуживания воздушных судов. В работе [9] приводится актуальный обзор того, как методы обучения с подкреплением применяются в авиационной сфере. Исследователи рассматривают роль интеллектуальных агентов в задачах построения маршрутов, управления беспилотными аппаратами и реализации автономных процессов принятия решений. В источнике [10] представлен метод построения траектории входа космического аппарата в атмосферу, использующий технологии глубокого обучения с подкреплением. Создаваемая модель позволяет динамически корректировать путь полета в ответ на меняющиеся внешние факторы.

Целью данного исследования является создания интеллектуальной системы для предсказания мест падения отделяющихся ступеней ракет-носителей. В основе разработки лежит использование цифрового двойника, методов вероятностной фильтрации, подходов глубокого обучения с подкреплением и геоинформационного анализа (GIS). Применение этих

технологий направлено на повышение точности прогнозирования траекторий полета и оценку пространственных рисков.

Материалы и методы.

Создание интеллектуального комплекса для прогнозирования районов падения отделяющихся блоков ракеты-носителя опирается на комплексную архитектуру, которая синтезирует цифрового двойника, математические модели, алгоритмы ИИ, геоинформационный анализ и модуль поддержки решений. Данный подход гарантирует непрерывный поток разнородной информации, гибкое обновление прогнозных алгоритмов и оперативную оценку рисков в реальном времени. Общее устройство разрабатываемой системы отображено на рисунке 1.




Рисунок 1 - Архитектура интеллектуальной системы прогнозирования зон падения отделяющихся ступеней ракеты-носителя

На рисунке 1 показана структура предложенной интеллектуальной системы для прогнозирования районов падения отделяющихся ступеней ракеты-носителя. На начальном этапе происходит сбор исходных данных,



которые включают телеметрическую информацию, метеорологические параметры, геопространственные данные и исторические сведения о предыдущих запусках. После этого данные передаются в блок цифрового двойника, где осуществляется математическое моделирование траектории движения, анализ текущего состояния объекта и согласование виртуальной модели с фактическими замерами. После этого механизмы обучения с подкреплением вносят динамические коррективы в прогноз, сводя к минимуму погрешность при определении предполагаемой области падения. Вычисленные данные поступают в блок прогнозирования траектории и геоинформационного анализа, где вычисляются зоны вероятных рисков, создаются цифровые карты опасностей и оцениваются последствия для населения и важных инфраструктурных объектов. На финальной стадии генерируются рекомендации для системы поддержки принятия решений, которая помогает оперативно планировать меры по обеспечению безопасности космических запусков. Модульная архитектура обеспечивает высокую масштабируемость, возможность подключения новых источников данных и постоянное улучшение интеллектуальных алгоритмов по мере поступления новой информации.

Математическая модель.

Создание высокоточных алгоритмов прогнозирования мест падения отделяющихся блоков ракет-носителей потребовало разработки интегрированной математической модели. В ее основе лежат симуляция физических процессов полета, концепция цифрового двойника, вероятностный анализ текущего состояния, технологии искусственного интеллекта и геоинформационная оценка рисков.

Главное преимущество данного подхода заключается в способности непрерывно корректировать прогнозы в реальном времени за счет синхронизации телеметрических показателей, метеоданных и пространственной информации, что отличает его от традиционных методов. Структура общей модели включает девять тесно связанных компонентов: блок описания динамики движения, цифровой двойник, фильтры Калмана и частиц, механизм байесовского обновления состояния, модель принятия решений на основе марковского процесса, функцию вознаграждения, алгоритм глубокого обучения Q-Network (Deep Q Network), а также GIS-систему для пространственного анализа рисков.

Модель движения ракеты.

Для предсказания места падения отделившейся ступени применяется математическая модель её траектории, в которой учитываются гравитация, аэродинамическое сопротивление и внешние воздействия. Эта модель даёт возможность вычислять координаты и скорость объекта на всём протяжении полёта, а также служит базой для корректировки цифрового двойника и анализа пространственной опасности.

$$dr/dt = v \quad (1)$$



$$m \frac{dv}{dt} = mg + F_D + F_W + F_C \quad (2)$$

где r — вектор координат; v — вектор скорости; g — ускорение свободного падения; F_D — сила аэродинамического сопротивления; F_W — воздействие ветра; F_C — дополнительные внешние возмущения.

Сила аэродинамического сопротивления определяется

$$F_D = -\frac{1}{2} C_D \rho S \|v - v_w\| (v - v_w) \quad (3)$$

где C_D — коэффициент сопротивления; ρ — плотность воздуха; S — площадь поперечного сечения; v_w — скорость ветра.

Разработанная модель способна учитывать ключевые физические факторы, воздействующие на траекторию отделения ступени, и предоставляет первоначальные данные для последующих этапов прогнозирования, таких как создание цифрового двойника, вероятностная оценка состояния и ГИС-анализ зоны падения.

Модель цифрового двойника.

Виртуальная копия отсоединяющейся ракеты-ступени, непрерывно синхронизируемая с реальным аппаратом посредством телеметрии, математических расчетов и внешних условий, выступает в роли цифрового двойника. Во время полета она актуализирует данные о местоположении, скорости, ускорении и иных динамических параметрах, что дает возможность своевременно корректировать расчетную траекторию и повышать точность определения места падения.

Математическая модель цифрового двойника описывается выражением

$$X_{DT}(t) = f(X_p(t), Z(t), \theta), \quad (4)$$

где X_{DT} — состояние цифрового двойника; X_p — состояние физической системы; $Z(t)$ — телеметрические данные; θ — параметры модели.

Для количественной оценки ошибки синхронизации используется

$$E_{DT} = \|X_p - X_{DT}\|, \quad (5)$$

где E_{DT} — ошибка синхронизации цифрового двойника.

Следовательно, использование цифрового двойника гарантирует постоянное обновление данных модели, снижение погрешности прогнозов и увеличение достоверности вычислений области возможного падения отделившейся ступени ракеты-носителя.

Расширенный фильтр Калмана.



Для определения состояния отделившейся ступени при наличии измерительных помех и нелинейной динамики применяется расширенный фильтр Калмана. Его ключевое преимущество перед классическим алгоритмом заключается в способности обрабатывать нелинейные зависимости посредством линеаризации математической модели на каждом вычислительном шаге. Благодаря этому обеспечивается высокая точность вычисления координат, скоростных показателей и иных характеристик траектории при непрерывном поступлении телеметрической информации.

Прогноз состояния определяется выражением

$$\hat{x}_k = A\hat{x}_{k-1} + B u_{k-1}, \quad (6)$$

где A — матрица перехода состояния; B — матрица управления.

Ковариационная матрица ошибки прогноза вычисляется по формуле

$$P_{\bar{k}} = A P_{k-1} A^T + Q, \quad (7)$$

где F_k — матрица Якоби функции состояния; Q — ковариационная матрица шума процесса.

После получения измерений выполняется коррекция состояния

$$P_{\bar{k}} = P_{\bar{k}} H^T (H P_{\bar{k}} H^T + R)^{-1}, \quad (8)$$

где P_k — коэффициент усиления Калмана; R — вектор измерений; H^T — нелинейная функция наблюдения.

Применение расширенного фильтра Калмана способствует уменьшению воздействия шумов измерений, улучшает точность определения состояния отделившейся ступени и обеспечивает более надежное прогнозирование ее траектории для дальнейшего обновления цифрового двойника и оценки зоны падения.

Фильтр частиц.

Алгоритм фильтра частиц используется для определения параметров отделившейся ступени в условиях нелинейной динамики и высоких погрешностей измерений. Суть метода заключается в том, что состояние системы моделируется совокупностью частиц, где каждая из них отражает отдельную гипотезу о траектории движения и обладает собственным коэффициентом значимости.

Вероятностное распределение состояния описывается

$$p(x_k | z_{1:k}) = \sum_{i=1}^N w_k^{(i)} \delta(x_k - x_k^{(i)}), \quad (9)$$

где w_i — вес частицы; N — количество частиц.



После каждого обновления веса нормализуются

$$\sum_{i=1}^N w_i = 1. \quad (10)$$

Обновленная оценка состояния вычисляется как взвешенное среднее

$$\hat{x}_k = \sum_{i=1}^N w_k^{(i)} x_k^{(i)}. \quad (11)$$

Следовательно, алгоритм фильтрации частиц дает возможность обрабатывать несколько сценариев перемещения блока, минимизировать искажения от неточностей датчиков и рассчитывать статистическую модель пути и места приземления.

Байесовское обновление.

По мере того как ступень ракеты-носителя отделяется и продолжает полет, система постоянно получает свежие телеметрические показатели, данные радиолокационных станций, метеорологические сводки и спутниковую информацию. Так как внешние условия и динамические свойства объекта меняются с течением времени, заранее вычисленная траектория со временем становится менее точной. Чтобы снизить погрешность прогноза, в данной системе применяется метод байесовского обновления состояния. Этот подход позволяет синтезировать результаты математического моделирования с актуальными измерениями, что обеспечивает формирование наиболее вероятной оценки текущего положения и характеристик объекта.

До получения новых измерений прогнозируемое состояние цифрового двойника описывается априорным распределением вероятностей

$$p(x_k | z_{1:k-1}), \quad (12)$$

где x_k — вектор состояния ступени в момент времени k ; $z_{1:k-1}$ — совокупность всех измерений, полученных до момента времени k .

После поступления нового измерения вероятность состояния пересчитывается в соответствии с теоремой Байеса

$$p(x_k | z_{1:k-1}) = \frac{p(z_k | x_k) p(x_k | z_{1:k-1})}{p(z_k | z_{1:k-1})}, \quad (13)$$

где $p(x_k | z_{1:k-1})$ — апостериорная вероятность состояния;

$p(z_k | x_k)$ — функция правдоподобия;



$p(x_k|z_{1:k-1})$ — априорная вероятность;

$p(z_k|z_{1:k-1})$ — нормирующий множитель.

После обновления вероятностного распределения вычисляется наиболее вероятная оценка состояния цифрового двойника

$$\hat{x}_k = \int x_k p(x_k|z_{1:k}) dx_k, \quad (14)$$

где $\hat{x}_k$ — обновленная оценка вектора состояния.

Для количественной оценки неопределенности вычисляется ковариационная матрица состояния

$$P_k = E[(x_k - \hat{x}_k)(x_k - \hat{x}_k)^T], \quad (15)$$

где $E[(x_k - \hat{x}_k)(x_k - \hat{x}_k)^T]$ — оператор математического ожидания.

Каждый раз при получении новых данных цифровой двойник в автоматическом режиме обновляет параметры математической модели, уменьшает погрешность прогноза и корректирует траекторию полета отделяющейся ступени. Подобный подход значительно повышает точность определения предполагаемой зоны падения, создавая надежный фундамент для последующего анализа рисков с помощью ГИС и функционирования интеллектуальной системы, обученной методом подкрепления.

Марковский процесс принятия решений.

В рамках предложенной системы для динамической коррекции предполагаемого пути применяется метод марковских процессов принятия решений. Эта технология дает интеллектуальному модулю возможность выбирать наилучшие решения, опираясь на актуальное состояние цифрового двойника и входящие данные измерений. Основная задача заключается в снижении погрешности предсказаний и повышении надежности локализации вероятной области падения.

Марковский процесс описывается кортежем

$$M = (S, A, P, R), \quad (16)$$

где S — множество состояний; A — множество действий; P — вероятность перехода между состояниями; R — функция вознаграждения.

Вероятность перехода из состояния s в состояние s' после выполнения действия a определяется выражением

$$P(s'|s, a). \quad (17)$$

Ожидаемое суммарное вознаграждение рассчитывается по формуле:



$$G_t = \sum_{k=0}^{\infty} \gamma^k R_{t+k+1}, \quad (18)$$

где G_t — накопленное вознаграждение; R_{t+k+1} — вознаграждение на следующем шаге; γ — коэффициент дисконтирования $0 < \gamma < 1$.

Функция ценности состояния определяется как математическое ожидание накопленного вознаграждения

$$V(s) = E[G_t | s_t = s]. \quad (19)$$

Для выбора оптимального действия используется функция ценности пары «состояние–действие»

$$Q(s, a) = E[G_t | s_t = s, a_t = a]. \quad (20)$$

Оптимальная стратегия управления определяется выражение

$$\pi^*(s) = \arg \max Q(s, a), \quad (21)$$

где $\pi^*(s)$ — оптимальная политика выбора действий.

Следовательно, марковская модель принятия решений гарантирует поэтапный подбор наилучших управляющих сигналов, что способствует снижению погрешности предсказания траектории, улучшает точность локализации места падения и способствует плодотворному сотрудничеству с нейросетевой архитектурой глубокого обучения с подкреплением.

Глубокая Q-сеть.

В рамках предложенной системы для динамической подстройки прогнозируемой траектории задействован алгоритм Deep Q Network (DQN), который синтезирует принципы обучения с подкреплением и архитектуры глубоких нейронных сетей. По сравнению с традиционным Q-обучением, DQN применяет нейросетевую модель для аппроксимации функции ценности действий, что обеспечивает эффективную обработку обширных пространств состояний и выбор наилучших решений при наличии неопределенности. На этапе обучения агент оценивает актуальное состояние цифрового двойника, осуществляет выбор управляющего воздействия и получает вознаграждение, служащее основой для корректировки весов нейронной сети.

Функция качества определяется выражением

$$Q(s, a) = R + \gamma \max_{a'} Q(s', a'), \quad (22)$$

где $Q(s, a)$ — функция качества для состояния s и действия a ; R — полученное вознаграждение; s' — следующее состояние системы; a' — возможное действие в следующем состоянии; γ — коэффициент дисконтирования.



Целевое значение функции качества вычисляется по формуле:

$$y = R + \gamma \max Q(s', a', \theta^-), \quad (23)$$

где θ^- — параметры целевой нейронной сети.

Функция потерь нейронной сети определяется выражением

$$L(\theta) = (y - Q(s, a, \theta))^2, \quad (24)$$

где θ — параметры обучаемой нейронной сети.

Обновление параметров сети осуществляется методом градиентного спуска

$$\theta = \theta - \eta \nabla L(\theta), \quad (25)$$

где η — скорость обучения; $\nabla L(\theta)$ — градиент функции потерь.

Оптимальная стратегия выбора действия определяется выражением

$$a^* = \arg \max_a Q(s, a), \quad (26)$$

где a^* — действие, обеспечивающее максимальное значение функции качества.

Благодаря применению алгоритма Deep Q Network, интеллектуальный агент способен к непрерывному обучению на основе поступающих данных, что позволяет ему динамически корректировать прогнозируемую траекторию движения и повышать точность определения вероятной зоны падения отделяющейся ступени ракеты-носителя.

Для динамической подстройки параметров прогностической модели цифрового двойника применяется глубокая Q-сеть. Структура DQN состоит из входного блока, трех полносвязных скрытых слоев и выходного слоя, который выдает значения Q-функции для всех возможных действий. В качестве входных данных сеть принимает нормализованный вектор текущего состояния отделяющейся ступени, включающий координаты, компоненты скорости, параметры окружающей среды, ошибки синхронизации цифрового двойника и характеристики неопределенности оценки состояния. Архитектура применяемой нейронной сети показана на рисунке 5.

Как иллюстрирует рисунок 2, входной слой сети состоит из 19 нейронов, отражающих текущее состояние системы. Затем информация поступает в три последовательных полносвязных скрытых слоя с количеством нейронов 128, 128 и 64 соответственно. Для обработки нелинейных связей между

параметрами движения и внешними воздействиями в этих слоях применяется функция активации ReLU. Выходной уровень включает девять нейронов, каждый из которых вычисляет значение $Q(s_t, a_i)$ для конкретного возможного действия агента. Модуль выбора действий определяет наиболее выгодный вариант на основе максимума Q-функции. При этом полученное действие не применяется напрямую к физической траектории ступени, а служит для настройки параметров прогнозной модели цифрового двойника.




Рисунок 2 - Архитектура глубокой Q-сети для адаптивной коррективы цифрового двойника

Созданная математическая модель интегрирует в единую интеллектуальную систему прогнозирования алгоритмы движения отделяющейся ступени, цифровой двойник, расширенный фильтр Калмана, метод частиц, байесовскую коррекцию, подход глубокого обучения с подкреплением и пространственную GIS-модель оценки рисков. Синергия этих компонентов позволяет постоянно уточнять текущее состояние объекта, динамически корректировать предполагаемую траекторию и повышать точность локализации вероятной зоны падения. Разработанный математический аппарат формирует базу для проведения вычислительных экспериментов и последующей оценки эффективности предложенного метода, результаты которых будут рассмотрены в следующем разделе.

Результаты и обсуждение.

Для оценки работоспособности разработанной интеллектуальной системы было проведено численное моделирование траектории отделяющейся ступени ракеты-носителя. В рамках симуляции учитывались стартовые условия полета, аэродинамическое сопротивление, влияние ветровых потоков, телеметрические данные, а также функционирование модулей цифрового двойника, вероятностной фильтрации и алгоритмов глубокого обучения с подкреплением. Решение системы дифференциальных



уравнений движения осуществлялось методом Рунге–Кутты четвертого порядка при временном шаге 0,01 с. Вычислительные эксперименты реализованы в среде Python 3.12 с применением библиотек NumPy, SciPy, pandas и PyTorch, необходимых для математического моделирования, анализа данных и внедрения методов искусственного интеллекта. Детальные характеристики вычислительной среды и параметров моделирования представлены в таблице 1.

Таблица 1 - Параметры среды моделирования

Параметр	Значение
Язык программирования	Python 3.12
Библиотеки численного моделирования	NumPy, SciPy, pandas
Фреймворк глубокого обучения	PyTorch 2.6
GIS-платформа	ArcGIS Pro 3.3
Платформа цифрового двойника	Python API на основе NumPy, SciPy и PyTorch
Операционная система	Windows 11 Pro (64-bit)
Процессор	Intel Core i9-14900K (24 ядра, 32 потока)
Оперативная память	64 GB DDR5
Графический процессор	NVIDIA RTX 4090 (24 GB)
Численный метод	Метод Рунге-Кутты 4-го порядка
Шаг моделирования	0,01 с
Продолжительность моделирования	600 с
Количество испытаний Монте-Карло	1000
Количество частиц	500
Система координат	WGS-84
Частота обновления телеметрии	10 Гц
Интервал обновления метеоданных	1 с
Интервал синхронизации цифрового двойника	0,5 с
Пространственное разрешение GIS	30 м

Указанные параметры позволяют реализовать комплексное моделирование траектории отделения ступени, обеспечивая непрерывную актуализацию цифрового двойника и пространственный анализ зоны падения. Для проверки эффективности предложенного подхода проведено 1000 вычислительных экспериментов по методу Монте-Карло с вариацией внешних факторов, таких как скорость ветра, начальные условия отрыва и полнота телеметрической информации. На основе полученных данных проведен анализ точности прогнозов, сопоставлены результаты работы расширенного фильтра Калмана, фильтра частиц и модели Digital Twin с DQN, а также выполнена оценка пространственного риска. Далее были определены ключевые сценарии моделирования, отличающиеся характеристиками отделяющейся ступени, погодными условиями и степенью доступности телеметрических данных.



В рамках каждого сценария проводилось численное моделирование траектории полета, за которым следовали синхронизация цифрового двойника, оценка текущего состояния системы с применением расширенного фильтра Калмана и фильтра частиц, байесовская корректировка параметров, а также адаптивная коррекция прогноза на базе алгоритма Deep Q Network. Результаты каждого вычислительного эксперимента оценивались по таким метрикам, как ошибка предсказания, среднеквадратичная (RMSE) и средняя абсолютная (MAE) ошибки, вероятность выхода точки приземления за границы безопасной зоны, а также общий интегральный показатель пространственного риска.

Основные сценарии, использованные при проведении вычислительных экспериментов, представлены в таблице 2.

Таблица 2 - Сценарии моделирования

Сценарий	Скорость ветра, м/с	Масса ступени, кг	Угол отделения, °	Потеря телеметрии, %	Описание
S1	8	4200	88	0	Номинальные условия
S2	18	4200	88	0	Усиленное боковое воздействие ветра
S3	12	4000	84	5	Изменение параметров отделения
S4	22	4400	92	15	Сильный ветер и частичная потеря телеметрии
S5	12	4200	88	30	Значительная потеря телеметрической информации

В таблице 2 представлены ключевые сценарии, применявшиеся в ходе вычислительных экспериментов. Каждый из них характеризуется специфическими значениями скорости ветра, массы отделяющейся ступени, угла отделения и степени утраты телеметрической информации, что дает возможность проанализировать влияние данных факторов на точность определения зоны падения. Сценарий S1 отражает стандартные условия полета, тогда как варианты S2–S5 имитируют неблагоприятные условия, такие как усиленное ветровое воздействие, отклонения параметров отделения и частичная потеря телеметрических данных. Подобное разнообразие условий позволяет всесторонне оценить надежность предложенной интеллектуальной системы и провести объективное сопоставление эффективности алгоритмов цифрового двойника, расширенного фильтра Калмана, фильтра частиц и сети глубокого обучения с подкреплением (Deep Q Network).

В таблице 3 приведены данные о прогнозировании траектории, полученные с применением разных подходов, а динамика изменения этих траекторий во времени отражена на рисунке 10. Проведенное исследование



результатов дает возможность проанализировать, каким образом использование цифрового двойника и интеллектуальных алгоритмов сказывается на точности локализации точки падения и на способности системы противостоять внешним воздействиям.

Таблица 3 - Результаты прогнозирования траектории

Метод	RMSE, м	MAE, м	Макс. ошибка, м	Время расчета, мс	Точность, %
Классическая баллистическая модель	118.4	96.2	228.0	6.5	91.2
Расширенный фильтр Калмана	42.8	34.1	82.0	14.2	96.8
Фильтр частиц	31.6	24.9	61.0	41.5	97.9
Digital Twin + Deep Q Network	19.7	15.3	38.0	28.6	99.1

Сводные данные таблицы 3 отражают сопоставление различных алгоритмов предсказания пути отделяющейся ступени ракеты-носителя. Исследование результатов выявило, что традиционная баллистическая модель демонстрирует самые высокие показатели среднеквадратической (RMSE) и средней абсолютной (MAE) погрешностей, что обусловлено отсутствием механизмов адаптивной коррекции на этапе полета. Внедрение расширенного фильтра Калмана и метода частиц позволяет существенно снизить уровень ошибок благодаря обработке телеметрической информации и вероятностному анализу текущего состояния объекта. Наиболее эффективные показатели достигнуты с помощью разработанной интеллектуальной системы на базе цифрового двойника и сети Deep Q Network: она обеспечивает минимальную RMSE (19,7 м) и MAE (15,3 м), а также максимальную точность прогноза в 99,1 %. Хотя вычислительные затраты данной модели несколько превышают показатели классического подхода, предложенный метод гарантирует значительно более высокую надежность определения траектории и зоны падения, что доказывает результативность интеграции цифрового двойника с алгоритмами глубокого обучения с подкреплением.

В таблице 4 отражены итоги пространственного анализа с использованием GIS-технологий для оценки зон потенциальной опасности. Наблюдается устойчивая тенденция к росту суммарного индекса опасности по мере повышения вероятности обрушения, а также увеличения плотности населения и степени концентрации критически важных объектов. Самым надежным участком выступает зона А с минимальным показателем угрозы 0,11, в то время как зона Е демонстрирует экстремально высокий уровень риска, достигающий 0,93. Эти данные дают возможность определить ключевые территории, требующие усиленного контроля, ограничения посещения и реализации защитных мер.

Таблица 4 - GIS-анализ зон риска

Зона	Вероятность падения	Плотность населения, чел/км ²	Индекс критической инфраструктуры	Индекс экономического ущерба	Интегральный риск	Уровень риска
A	0.082	38	0.18	0.24	0.11	Низкий
B	0.165	95	0.34	0.39	0.26	Умеренный
C	0.287	162	0.51	0.57	0.49	Средний
D	0.413	246	0.73	0.71	0.71	Высокий
E	0.562	318	0.91	0.88	0.93	Критический




Рисунок 3 - Расчетная GIS-карта зон риска падения отделяющихся частей ракеты-носителя «Союз» на территории Улытауской области

На рисунке 3 изображена карта зон потенциального падения отсеков ракеты-носителя «Союз» для Улытауской области, созданная на основе GIS-анализа. Градуация цветов демонстрирует спектр вероятностей — от минимальной до максимальной — и визуализирует распределение возможных мест приземления. На схеме выделены районы сброса (26, 32, 34, 42, 56), а также отмечены населенные пункты, транспортные артерии и водные объекты. Максимальная концентрация риска наблюдается в центре расчетного эллипса рассеивания, тогда как вероятность инцидента снижается по мере удаления от этой зоны.




Рисунок 4 - Сравнение ошибок RMSE и MAE для различных алгоритмов прогнозирования

Как видно на рисунке 4, традиционная баллистическая модель демонстрирует наивысшую погрешность: RMSE равна 118,4 м, а MAE — 96,2 м. Применение расширенного фильтра Калмана позволяет снизить эти показатели до 42,8 м и 34,1 м соответственно, тогда как фильтр частиц дает еще более точные результаты — 31,6 м и 24,9 м. Наилучшую эффективность демонстрирует гибридная система Digital Twin + DQN, где RMSE составляет 19,7 м, а MAE — 15,3 м. Полученные данные свидетельствуют о том, что предложенный интеллектуальный подход обеспечивает наиболее точное предсказание траектории движения и области вероятного падения объекта.




Рисунок 5 - Изменение ошибки прогнозирования цифрового двойника во времени

На рисунке 5 демонстрируется динамика погрешности прогнозирования цифрового двойника в ходе моделирования. Изначально отклонение достигает значения порядка 77 метров, однако по мере поступления

телеметрической информации и корректировки параметров модели оно постепенно сокращается. К финальному этапу симуляции ошибка уменьшается до 7–8 метров, что свидетельствует о высокой результативности процесса непрерывной синхронизации виртуальной копии с фактическим состоянием отделяющей ступени.




Рисунок 6 - Кривая обучения алгоритма DQN по среднему вознаграждению

На рисунке 6 показана динамика среднего вознаграждения при обучении алгоритма DQN. Изначально, на старте процесса, показатель Reward находится на отметке около -120 , что обусловлено значительными погрешностями прогнозирования и неэффективными действиями агента. По мере накопления опыта вознаграждение постепенно увеличивается и к 400–500-му эпизоду выходит на стабилизацию в диапазоне $-8...-10$. Это указывает на успешную сходимость алгоритма и улучшение качества коррекции траектории.




Рисунок 7 - Сходимость оценки вероятности падения в целевую зону при увеличении числа испытаний Монте-Карло



Рисунок 7 демонстрирует процесс стабилизации оценки вероятности попадания в зону падения по мере наращивания количества прогонов метода Монте-Карло. В начале расчетов наблюдаются существенные флуктуации показателя, но уже после 50 тысяч итераций график выходит на плато около отметки 0,36. При увеличении выборки до 100 тысяч испытаний погрешность оценки снижается менее чем на 0,005, что указывает на достижение устойчивой сходимости. Этот факт подтверждает статистическую состоятельность модели и достоверность вычисленной вероятности.

Заключение.

Итогом проведенного исследования стал сформированный комплексный метод прогнозирования мест падения отделяющихся ступеней ракет-носителей. Ключевое преимущество разрабатываемой системы кроется в интеграции цифрового двойника, вероятностной фильтрации, алгоритма DQN и геоинформационного анализа, что дает возможность корректировать траекторию полета по мере поступления новых сведений. Результаты численного эксперимента продемонстрировали, что комбинация Digital Twin и DQN демонстрирует более низкие показатели ошибок RMSE и MAE в сравнении с традиционной баллистической моделью, расширенным фильтром Калмана (EKF) и фильтром частиц. Кроме того, применение пространственного анализа позволило идентифицировать территории, отличающиеся разным уровнем опасности. Последующие этапы работы должны быть сосредоточены на верификации разработанной модели с использованием реальных телеметрических данных, а также на детализации оценки рисков через GIS для конкретных зон падения. Исследования проводились в рамках проекта ГФ ИРН АР23488291 ИИВТ КН МНВО РК.

СПИСОК ЛИТЕРАТУРЫ

1. R. Wei, R. Yang, S. Liu, C. Fan, R. Zhou, Z. Wu, H. Wang, Y. Cai, and Z. Jiang.(2024). Towards an Extensible Model-Based Digital Twin Framework for Space Launch Vehicles. *Journal of Industrial Information Integration*.Vol. 41, article 100641. DOI: 10.1016/j.jii.2024.100641.
2. L. Schena, P. A. Marques, R. Poletti, S. Ahizi, J. Van den Berghe, and M. A. Mendez.(2024).Reinforcement Twinning: From Digital Twins to Model-Based Reinforcement Learning. *Journal of Computational Science*.Vol.82, article 102421. DOI: 10.1016/j.jocs.2024.102421
3. N. Gratius, Z. Wang, M. Y. Hwang, Y. Hou, A. Rollock, C. George, M. Bergés, and B. Akinci.(2024). Digital Twin Technologies for Autonomous Environmental Control and Life Support Systems. *Journal of Aerospace Information Systems*. Vol. 21, no. 4, pp. 332–347. DOI: 10.2514/1.I011320.
4. S. Henao-Garcia, M. Kapteyn, K. E. Willcox, M. Tezzele, M. Castroviejo-Fernandez, T. Kim, I. Kolmanovsky, H. Basu, P. Jirwankar, and R. G. Sanfelice. (2025). Digital-Twin-Enabled Multi-Spacecraft On-Orbit Operations. In *AIAA*



SCITECH 2025 Forum, Orlando, FL, USA, AIAA Paper 2025-1432. DOI: 10.2514/6.2025-1432

5. S. Leon and H. Moncayo. (2025). Machine-Learning-Based Validation of a Digital Twin Spacecraft for Health-Management Systems. In AIAA SCITECH 2025 Forum, Orlando, FL, USA, AIAA Paper 2025-0561. DOI: 10.2514/6.2025-0561.

6. M. E. Iliuță et al. (2024). Digital Twin—A Review of the Evolution from Concept to Technology and Its Analytical Perspectives on Applications in Various Fields. Vol. 14, no. 13, article 5454. DOI: 10.3390/app14135454

7. C. Bae, E. Choi, and S. Lee. (2025). Technologies, Applications, and Challenges of Digital Twin Across Industries: A Systematic Review of the State-of-the-Art Literature. IEEE Access. Vol. 13, pp. 152843–152869. DOI: 10.1109/ACCESS.2025.3601615

8. B. A. Adu-Gyamfi. (2026). The Role of Digital Twin Technology in Enhancing Sustainable Aviation Transition: A State-of-the-Art Review and Future Direction. Journal of Open Innovation: Technology, Market, and Complexity. Vol. 12, no. 1, article 100693. DOI: 10.1016/j.joitmc.2025.100693.

9. P. Razzaghi, A. Tabrizian, W. Guo, S. Chen, et al. (2024). A Survey on Reinforcement Learning in Aviation Applications. Engineering Applications of Artificial Intelligence. Vol. 136, Part A, article 108911. DOI: 10.1016/j.engappai.2024.108911.

10. G. Peng, B. Wang, L. Liu, H. Fan, and Z. Cheng. (2023). Real-Time Adaptive Entry Trajectory Generation with Modular Policy and Deep Reinforcement Learning. Aerospace Science and Technology. Vol. 142, Part A, article 108594. DOI: 10.1016/j.ast.2023.108594.

Алия Калижанова, ф.-м.ғ.к., профессор, Institute of Information and Computational Technologies CS MSHE RK, Energo University, Алматы, Қазақстан, kalizhanova.aliya@gmail.com

Мурат Кунелбаев, PhD, Institute of Information and Computational Technologies CS MSHE RK, Farabi University, Алматы, Қазақстан, murat7508@yandex.kz

Серік Дәруіш, бағдарламашы, Institute of Information and Computational Technologies CS MSHE RK, Алматы, Қазақстан

ЦИФРЛЫҚ ЕГІЗ ЖӘНЕ ТЕРЕҢ ОҚЫТУ НЕГІЗІНДЕ ЗЫМЫРАН САТЫЛАРЫНЫҢ ҚҰЛАУ АЙМАҚТАРЫН БОЛЖАУ

Аңдатпа. Зымыран-тасығыштардың бөлінетін сатыларының құлау орындарын болжауға арналған интеллектуалды жүйе ұсынылады. Бұл жүйе цифрлық егіз технологияларын, траекторияларды математикалық модельдеуді, күйді ықтималдық бағалауды, тереңдетілген оқытуды және кеңістіктік GIS-тәуекел талдауын біріктіреді. Әзірленген құрылым



телеметриялық, метеорологиялық және геокеңістіктік ақпаратты үздіксіз жинауға және талдауға, виртуалды көшірмені нақты объектімен синхрондауға, сондай-ақ есептік қозғалыс траекториясын динамикалық түрде түзетуге мүмкіндік береді. Процестің ағымдағы күйін неғұрлым дәл бағалау мақсатында кеңейтілген Калман сүзгісі, бөлшектер сүзгісі және Байес бойынша жаңарту әдісі қолданылды. Болжау қателігін азайтуға бағытталған оңтайлы әрекеттерді таңдау Deep Q Network нейрондық желі архитектурасы арқылы жүзеге асырылады. Жүйенің жұмыс сапасы жел жылдамдығы, блоктардың бөліну параметрлері және телеметриялық деректердің жоғалу деңгейі өзгертілген жағдайларда сандық модельдеу және Монте-Карло статистикалық әдісі арқылы зерттелді. Эксперименттік нәтижелер цифрлық егіз технологиясы мен DQN алгоритмін біріктіріп пайдалану RMSE және MAE көрсеткіштерін тиісінше 19,7 м және 15,3 м деңгейіне дейін төмендетуге, сондай-ақ болжау дәлдігін 99,1%-ға жеткізуге мүмкіндік беретінін көрсетті. Сонымен қатар, Ұлытау облысы үшін қар көшкінінің ықтималдығы, халық тығыздығы, аса маңызды инфрақұрылым нысандарының орналасуы және ықтимал экономикалық залал туралы деректерді біріктіретін тәуекел аймақтарының геоақпараттық картасы әзірленді. Ұсынылған әдіс ғарыштық ұшырулардың қауіпсіздігін арттыру, жедел бақылауды қамтамасыз ету және басқарушылық шешімдер қабылдау үдерісін қолдау үшін қолданылуы мүмкін.

Түйінді сөздер: цифрлық егіз, траекторияны болжау, құлау аймағы, бөлінетін саты, Deep Q Network, кеңейтілген Калман сүзгісі, бөлшектер сүзгісі, Байес бойынша жаңарту, Монте-Карло әдісі, GIS-тәуекел талдауы.

Aliya Kalizhanova, candidate of physico-mathematical sciences, professor, Institute of Information and Computational Technologies CS MSHE RK, Energo University, Almaty, Kazakhstan, kalizhanova.aliya@gmail.com

Murat Kunelbayev, PhD, Institute of Information and Computational Technologies CS MSHE RK, Farabi University, Almaty, Kazakhstan, murat7508@yandex.kz

Serik Daruish, programmer, Institute of Information and Computational Technologies CS MSHE RK, Almaty, Kazakhstan

PREDICTION OF ROCKET STAGE IMPACT ZONES BASED ON A DIGITAL TWIN AND DEEP LEARNING

Abstract. An intelligent system is proposed for predicting the impact locations of separated launch vehicle stages. The system integrates digital twin technology, mathematical trajectory modeling, probabilistic state estimation, deep reinforcement learning, and spatial GIS-based risk analysis. The developed framework enables continuous collection and analysis of telemetry,



meteorological, and geospatial data, synchronization of the virtual model with the real object, and dynamic correction of the calculated flight trajectory. To improve the estimation of the current process state, an extended Kalman filter, a particle filter, and Bayesian updating are employed. The selection of optimal actions aimed at reducing prediction error is performed using a Deep Q Network neural architecture. The system performance was evaluated through numerical simulation and Monte Carlo analysis under varying wind speeds, stage-separation parameters, and levels of telemetry data loss. The experimental results demonstrate that the combined use of digital twin technology and the DQN algorithm reduces the RMSE and MAE to 19.7 m and 15.3 m, respectively, while achieving a prediction accuracy of 99.1%. In addition, a GIS-based risk map was developed for the Ulytau Region by integrating data on the probability of impact events, population density, critical infrastructure, and potential economic damage. The proposed method can be applied to improve the safety of space launches, support real-time monitoring, and assist decision-making processes.

Keywords: digital twin, trajectory prediction, impact zone, separated rocket stage, Deep Q Network, extended Kalman filter, particle filter, Bayesian updating, Monte Carlo method, GIS-based risk analysis.

Поступила: 27 июля 2026 года

Рецензирована: 17 августа 2026 года

Принята: 19 августа 2026 года