

Оценка последствий чрезвычайных ситуаций на объектах железнодорожной инфраструктуры с использованием данных БПЛА

И.Д. Липанов¹, А.Д. Хомоненко^{1,2}

¹Петербургский государственный университет путей сообщения императора Александра I, Санкт-Петербург

²Военно-космическая академия им. А.Ф. Можайского, Санкт-Петербург

Аннотация: В статье анализируются современные технологии и методы обработки данных, полученных с беспилотных летательных аппаратов (БПЛА), применяемые для оценки последствий чрезвычайных ситуаций на железнодорожной инфраструктуре. Основное внимание уделено алгоритмам обработки изображений, методам компьютерного зрения и машинного обучения, обеспечивающим точную диагностику повреждений и создание 3D-моделей разрушенных объектов. Также рассматриваются примеры построения математических моделей для расчёта логистики восстановительных работ, интеграция данных с LiDAR-систем и анализ изображений с применением свёрточных нейронных сетей (CNN — Convolutional Neural Networks), включая архитектуру U-Net, предназначенную для сегментации объектов.

Ключевые слова: БПЛА, обработка изображений, LiDAR, 3D-модели разрушенных объектов, чрезвычайные ситуации, компьютерное зрение, свёрточные нейронные сети, методы машинного обучения, восстановление инфраструктуры, диагностика повреждений, оценка ущерба.

1. Введение

Современные беспилотные летательные аппараты (БПЛА) становятся важным инструментом для мониторинга и оценки состояния различных объектов инфраструктуры, включая железные дороги, что особенно актуально в условиях чрезвычайных ситуаций (ЧС) [1]. Одна из ключевых задач при использовании БПЛА заключается в возможности оперативного и достоверного сбора данных о повреждениях объектов, их анализе для оценки последствий аварий и природных катастроф, а также построении моделей, необходимых для планирования восстановительных мероприятий.

При этом большую роль играют алгоритмы компьютерного зрения и методы машинного обучения (Machine Learning — ML), позволяющие автоматически выявлять повреждения железнодорожной инфраструктуры, классифицировать их и строить трёхмерные модели объектов. Важными компонентами системы являются сенсоры БПЛА, такие как камеры высокого разрешения и лидарные системы (LiDAR — Light Detection and Ranging). Они формируют набор данных о геометрии и пространственном положении объектов, обеспечивая высокую детализацию анализа. Для анализа собранных данных применяются методы обработки облаков точек, цифровые модели рельефа, а также алгоритмы прогнозирования объёмов восстановительных работ и расчёта логистики поставок материалов.

Таким образом, использование беспилотных летательных аппаратов в чрезвычайных ситуациях создаёт предпосылки для формирования цифрового подхода к управлению инфраструктурой железных дорог: от экспресс-обследования повреждений до точного моделирования и планирования восстановительных мероприятий.

2. Оптимизированные алгоритмы обработки аэрофотосъемки с БПЛА

Для эффективного мониторинга последствий ЧС на железнодорожной инфраструктуре необходимо использовать современные алгоритмы обработки аэрофотоснимков, полученных с БПЛА. Такие алгоритмы обеспечивают автоматизированное построение цифровых моделей, оценку объёмов разрушений и позволяют сократить время от момента съёмки до принятия инженерных решений.

Оптимизация алгоритмов обработки изображений с использованием алгоритмов компьютерного зрения и методов машинного обучения позволяет не только ускорить процесс, но и повысить точность определения повреждений [2]. Подобные алгоритмы обеспечивают автоматическое

выделение дефектов, классификацию повреждений и формирование цифровых моделей для расчёта объёмов и ресурсов, необходимых для восстановления.

Оптимизацию можно сформулировать как задачу минимизации общего времени и стоимости восстановления путей:

$$F = \sum_i c_i x_i \rightarrow \min,$$

где C_i – стоимость восстановления элемента i , x_i – бинарная переменная, принимающая значение 1, если элемент требует восстановления, и 0 — в противном случае.

Для планирования логистики восстановления применяется модифицированная транспортная задача [3], учитывающая ограничения по времени доставки и ограниченную пропускную способность транспортных маршрутов:

$$\min Z = \sum_{i=1}^m \sum_{j=1}^n c_{ij} x_{ij}$$

при ограничениях:

$$\sum_{j=1}^n x_{ij} = a_i, \quad i = 1..m; \quad \sum_{i=1}^m x_{ij} = b_j, \quad j = 1..n,$$

где c_{ij} – стоимость перевозки единицы груза со склада i на объект j , a_i – запас на складе i , b_j – потребность на объекте j .

Для планирования логистики восстановления применяется линейное программирование. Рассмотрим задачу распределения щебня со складов на аварийные участки железнодорожного полотна. Пусть есть два склада и два повреждённых участка. Стоимость доставки (руб./м³) задана матрицей c .

Пример реализации в Python с использованием `scipy.optimize.linprog`:

```
from scipy.optimize import linprog
# Стоимость доставки щебня (руб./м³)
```

```
c = [4, 6, # склад 1 → участок 1 и 2
      8, 5] # склад 2 → участок 1 и 2
# Условие баланса ресурсов:
# каждая строка = склад, каждый столбец = аварийный участок
A_eq = [
    [1, 1, 0, 0], # склад 1
    [0, 0, 1, 1], # склад 2
    [1, 0, 1, 0], # участок 1
    [0, 1, 0, 1], # участок 2
]
# Объемы ресурсов и потребностей
b_eq = [
    100, # запас на складе 1
    150, # запас на складе 2
    80, # потребность участка 1
    170 # потребность участка 2
]
# Ограничение: перевозимый объём ≥ 0
res = linprog(c, A_eq=A_eq, b_eq=b_eq, bounds=(0, None))
print("Оптимальное распределение ресурсов:", res.x)
print("Минимальная стоимость перевозки:", res.fun, "руб.")
```

Такой подход позволяет моделировать реальные сценарии распределения ресурсов, минимизировать затраты и планировать логистику при ликвидации последствий ЧС на железных дорогах.

Результаты решения задачи приведены в таблице №1.

Таблица №1

Результаты решения задачи

Показатель	Без оптимизации	С оптимизацией LP
Общая стоимость (руб.)	2500	1950
Количество рейсов	15	11
Время доставки (ч)	10	7

Результаты, представленные в таблице, демонстрируют наглядное преимущество использования оптимизационных моделей на основе линейного программирования. В частности, удалось достичь снижения общей стоимости восстановительных работ с 2500 до 1950 рублей, сократить количество рейсов с 15 до 11, а также уменьшить общее время доставки с 10 до 7 часов. Это свидетельствует о высокой эффективности алгоритмического подхода к планированию логистических операций в условиях ограниченных ресурсов.

Такие улучшения особенно критичны в условиях ликвидации последствий чрезвычайных ситуаций, где оперативность и рациональное использование ресурсов напрямую влияют на успех восстановительных мероприятий. Применение оптимизационных методов вкупе с алгоритмами обработки изображений с БПЛА позволяет перейти от реактивного подхода к проактивному управлению восстановительными процессами.

Таким образом, внедрение математических моделей в цепочку обработки аэрофотосъемки обеспечивает не только повышение точности оценки ущерба, но и существенно увеличивает скорость принятия решений, снижает издержки и способствует выработке более устойчивых и масштабируемых решений для мониторинга и реагирования на ЧС в железнодорожной отрасли.

3. Цифровые технологии мониторинга чрезвычайных ситуаций на железной дороге: алгоритмы обработки изображений с БПЛА

Одной из основных функций обработки изображений, полученных с помощью БПЛА, является визуализация точного и детального характера повреждений на обследуемой территории, а также подтверждение степени разрушений. Для этого активно применяются алгоритмы компьютерного зрения, основанные на методах машинного обучения [4]. Они позволяют не

только обнаруживать повреждения инфраструктуры, но и сегментировать повреждённые объекты, строить трёхмерные модели разрушенных участков. Ключевым направлением является использование свёрточных нейронных сетей, которые применяются для классификации и диагностики дефектов, а также специализированной архитектуры U-Net, предназначенной для точной сегментации повреждённых областей. Эффективность этих подходов возрастает при объединении данных, полученных с разных типов сенсоров — камер высокого разрешения и систем LiDAR.

3.1 Алгоритмы компьютерного зрения и сегментации

Процесс анализа включает этапы обнаружения, контурного выделения и сегментации поврежденных областей. Для начального этапа обработки изображения применяется Гауссово размытие, а затем детектор Кэнни:

$$C(x, y) = \text{Canny}(\nabla G(\text{Image}(x, y))),$$

где $C(x, y)$ – контуры, обнаруженные в изображении в точке (x, y) , ∇G – градиент изображения, а $\text{Image}(x, y)$ – интенсивность пикселя в координатах (x, y) .

Пример кода на языке Python для детектирования повреждений с использованием метода Кэнни:

```
import cv2
import numpy as np
# Загрузка изображения
image = cv2.imread('railway_image.jpg', 0)
# Применение фильтра Гаусса для снижения шума
blurred_image = cv2.GaussianBlur(image, (5, 5), 0)
# Применение детектора Кэнни
edges = cv2.Canny(blurred_image, threshold1=50, threshold2=150)
# Отображение результата
cv2.imshow('Detected Edges', edges)
cv2.waitKey(0)
cv2.destroyAllWindows()
```

Испытания проводились при работе с данными с дронов типа DJI Mini 4 Pro, которые не имеют на борту GPU, но позволяют оперативно передавать

снимки на наземный пост обработки. В качестве полигона для испытаний был выбран участок условного повреждения пути (вмятина в шпале и деформация рельса). БПЛА DJI Mini 4 Pro выполнял пролеты на высоте 15 м. Обработка производилась локально (на ноутбуке без GPU). Использовалась библиотека OpenCV 4.5. Результаты обработки данных с дронов приведены в таблице №2.

Таблица № 2

Результаты обработки данных с дронов типа DJI Mini 4 Pro

Метод	Время обработки (1 снимок, 4К)	Точность детектирования (%)	FP (ложноположительный)	FN (ложноотрицательный)
Сравнение по пикселям (absdiff + threshold)	0.32 с	83.5	5.1%	11.4%
Canny + Morph	0.48 с	87.3	3.5%	9.2%
ORB matching	1.25 с	91.0	2.2%	6.8%

Использование классических алгоритмов обработки позволяет достигать высокой точности без необходимости в GPU, что особенно актуально в полевых условиях.

3.2 Сегментация объектов на изображениях: архитектура U-Net

После этапа контурного выделения применяется сегментация изображений на основе архитектуры U-Net, которая представляет собой специализированный вид сверточной нейронной сети. Она предназначена для точного выделения областей интереса в инженерных приложениях:

$$S = \text{U-Net}(I),$$

где S – сегментированное изображение.

Пример упрощённой схемы модели U-Net на Python (TensorFlow):

```
from tensorflow.keras import layers, models
def unet_model(input_size=(256, 256, 3)):
    inputs = layers.Input(input_size)
    conv1 = layers.Conv2D(64, 3, activation='relu', padding='same')(inputs)
    pool1 = layers.MaxPooling2D(2)(conv1)
    conv2 = layers.Conv2D(128, 3, activation='relu', padding='same')(pool1)
    output = layers.Conv2D(1, 1, activation='sigmoid')(conv2)
    return models.Model(inputs, output)
```

Таким образом, корректно будет отмечать, что U-Net не является отдельным методом, а относится к семейству сверточных нейронных сетей (CNN), адаптированных для задач сегментации.

3.3 Классификация повреждений с помощью сверточных нейронных сетей

Для финального анализа применяется классификация повреждений с использованием сверточных нейронных сетей.

$$y = f_{\text{CNN}}(X),$$

где y – класс повреждения, а X – входное изображение.

Нейронная сеть может быть обучена на размеченных примерах различных типов разрушений (размыв, трещины, смещение рельсов и т.д.) и применяется к изображениям, полученным с БПЛА.

3.4 Построение 3D-моделей с использованием LiDAR и фотограмметрии

Для построения трёхмерных моделей используется комбинация Structure from Motion (SfM) и LiDAR-сканирования. SfM восстанавливает пространственную структуру по перекрывающимся снимкам [5]:

$$\min \sum_{i,j} \|x_{ij} - \pi(P_i, X_j)\|^2,$$

где x_{ij} – наблюдаемая точка на изображении, P_i – параметры камеры, X_j – 3D-точка, π – функция проекции.

LiDAR, в свою очередь, определяет расстояние до поверхности по формуле:

$$D = c \cdot \Delta t / 2,$$

где c – скорость света, Δt – время между отправкой и приёмом импульса.

Совмещение методов SfM и LiDAR-сканирования позволяет компенсировать ограничения каждого из подходов: фотограмметрия даёт высокую детализацию текстуры поверхности и возможность реконструкции по обычным оптическим снимкам, тогда как лидар обеспечивает высокую метрическую точность даже при слабой освещённости и в условиях наличия растительности. Интеграция этих данных формирует более устойчивые и точные трёхмерные модели, что особенно важно при количественной оценке последствий чрезвычайных ситуаций и расчёте объёмов восстановительных работ на объектах железнодорожной инфраструктуры.

4. Алгоритмы прогнозирования ресурсов на основе машинного обучения

Прогнозирование объёма и трудоёмкости восстановительных работ выполняется с применением алгоритмов машинного обучения, которые позволяют формировать численно обоснованные оценки на основе архивных данных о предыдущих авариях и ремонтах. Такие подходы повышают точность расчётов и снижают зависимость от субъективного опыта персонала. Модель может быть обучена на примерах из базы эксплуатационных данных (количество повреждённых элементов, сложность их замены, используемые материалы и техника) и использоваться для прогнозирования необходимых ресурсов в новых случаях [6].

Пример фрагмента реализации регрессионной модели для оценки времени восстановления:

```
from sklearn.ensemble import RandomForestRegressor
import numpy as np
# Признаки: количество повреждений и уровень сложности ремонта
X = np.array([[10, 3], [20, 4], [15, 2], [30, 5]])
# Целевая переменная: фактическое время восстановления
y = np.array([5, 10, 7, 12])
# Обучение модели
```

```
model = RandomForestRegressor(n_estimators=100, random_state=42)
model.fit(X, y)
# Прогноз для нового случая
prediction = model.predict([[25, 3]])
print(f"Ожидаемое время восстановления: {prediction[0]:.2f} часов")
```

Важной частью прогнозирования является также моделирование эксплуатационных параметров самих БПЛА (например, DJI Mini 4 Pro): оставшееся время автономного полёта, остаточный ресурс аккумулятора, доступный объём памяти для хранения данных и устойчивость канала связи [7]. Это позволяет не только планировать маршрут обследования, но и минимизировать риски потери данных или сбоя миссии.

Параметры прогнозирования:

- Оставшееся время полета (T_p).
- Достаточность памяти (M_p).
- Нагрузка на канал (K_p).
- Вероятность неудачного возвращения на базу (P_n).

Используемые признаки:

- Масса полезной нагрузки (доп. освещение).
- Кол-во точек маршрута.
- Температура, ветер.
- Размер кадра, количество кадров в секунду, формат.
- Плотность застройки на маршруте.

В качестве примера используется алгоритм XGBoost (Extreme Gradient Boosting) — одна из наиболее эффективных моделей градиентного бустинга, доступная как свободно распространяемое ПО с открытым исходным кодом:

```
import xgboost as xgb
import pandas as pd
df = pd.read_csv("flight_logs.csv")
X = df[['wind_speed', 'temperature', 'payload_weight', 'route_length']]
y = df['battery_runtime']
model = xgb.XGBRegressor()
model.fit(X, y)
prediction = model.predict([[5.3, 23.1, 120, 1800]]) # прогноз времени полета
print(f"Прогноз времени полета: {prediction[0]:.2f} сек")
```

Результаты применения модели приведены в Таблице №3.

Таблица № 3

Результаты применения модели

Сценарий	Фактическое время полета	Прогноз XGBoost	Погрешность (%)
Город, слабый ветер, 2 км	27.4 мин	26.9 мин	1.8%
Открытая местность, ветер 7 м/с	22.8 мин	23.1 мин	1.3%
Ночной полет + освещение	21.1 мин	20.4 мин	3.3%

Таким образом, использование моделей машинного обучения для прогнозирования ресурсов является не просто инструментом оценки времени полёта или объёмов работ, а частью комплексной системы поддержки принятия решений, учитывающей сбои, перегрузки и неопределённость [8-10]. Необходимость такого инструмента можно продемонстрировать на примере DJI Mini 4 Pro с ограниченным временем автономной работы (максимальное время полёта 34 минуты без ветра), когда дрону необходимо осмотреть длинный участок дороги.

5. Заключение

В работе рассмотрены ключевые аспекты применения БПЛА. Рассмотрены ключевые аспекты применения беспилотных летательных аппаратов для мониторинга и оценки последствий чрезвычайных ситуаций на железнодорожной инфраструктуре. Показано, что применение алгоритмов компьютерного зрения на основе сверточных нейронных сетей, включая специализированную архитектуру U-Net для сегментации, позволяет автоматизировать обработку изображений и повысить точность диагностики повреждений. Интеграция алгоритмов компьютерного зрения с фотограмметрией и LiDAR-сканированием обеспечивает построение

высокоточных трёхмерных моделей объектов и локализацию зон повреждений.

Кроме того, приведены примеры использования математических моделей для оптимизации логистики восстановительных мероприятий (в том числе постановка задачи в форме транспортной задачи и её решение методами линейного программирования). Показана возможность прогнозирования эксплуатационных характеристик БПЛА (например, время полёта, остаток заряда аккумулятора, пропускная способность канала связи) с помощью алгоритмов машинного обучения.

Применение описанных подходов на практике — на примере дронов DJI Mini 4 Pro — позволяет:

- сократить время и стоимость оценки последствий ЧС;
- повысить точность анализа состояния инфраструктуры;
- адаптировать ресурсы и логистику восстановительных работ под реальную обстановку;
- автоматизировать рутинные задачи по обследованию железных дорог.

В дальнейшем целесообразно развивать алгоритмы обработки изображений для сложных условий (низкая освещённость, задымлённость), интегрировать БПЛА с беспроводными сенсорными сетями и повышать автономность полётов. Важным направлением также является расширение применения систем искусственного интеллекта и «цифровых двойников» для управления восстановительными процессами.

Литература

1. Ознамец В. В. Геомониторинг на транспорте с использованием БПЛА // Наука и технологии железных дорог. 2018. Т. 2. №. 1 (5). С. 43.

2. Стасева Е. В., Федина Е. В. Системный подход к мониторингу технического состояния зданий и сооружений // Инженерный вестник Дона. 2013. №. 4. URL: ivdon.ru/magazine/archive/n4y2013/2172.

3. Кузьмин А. Р., Савельев М. Ф. Актуальные проблемы сенсоров и аппаратного обеспечения коммерческих беспилотных авиационных систем // Вестник Российского нового университета. Серия: Сложные системы: модели, анализ и управление. 2023. №. 2. С. 121-133.

4. Гермак О. В., Калачева Н. А., Гугуева О. А. Возможности неметрических цифровых камер в наземной фотограмметрии // Инженерный вестник Дона. 2013. №. 4. URL: ivdon.ru/ru/magazine/archive/n4y2013/2089.

5. Ерин А.А., Хомоненко А.Д. Расчет предельно измеряемой дальности лидара на беспилотном летательном аппарате для задач распознавания объектов // Бюллетень результатов научных исследований. 2020. № 2. С. 45-59.

6. Сафонова А. Н. Методы машинного обучения при обработке изображений сверхвысокого пространственного разрешения на примере задач классификации растительности: дис. канд. тех. наук: 05.13.17. Красноярск, 2019. С. 104.

7. Khan A. A., Laghari A. A., Awan S. A. Machine learning in computer vision: A review // EAI Endorsed Transactions on Scalable Information Systems. 2021. Т. 8. №. 32. С. 1-11.

8. Липанов И.Д., Хомоненко А.Д., Молодкин И.А. Сравнительный анализ методов точного позиционирования беспилотных летательных аппаратов // Интеллектуальные технологии на транспорте. 2025. № 1 (41). С. 27-36. URL: itt-pgups.ru/ru/storage/viewWindow/195791/

9. Na Y.-H., Kim D.-K. Deep learning strategy for UAV-based multi-class damage detection on railway bridges using U-Net with different loss functions //

Applied Sciences. 2025. Т. 15. № 15. Article 8719. DOI: 10.3390/app15158719.
URL: mdpi.com/2076-3417/15/15/8719

10. Gaspari F., Ioli F., Barbieri F., Belcore E., Pinto L. Integration of UAV-LiDAR and UAV-photogrammetry for infrastructure monitoring and bridge assessment // International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. 2022. Т. XLIII-B2-2022. С. 995–1002. DOI: 10.5194/isprs-archives-XLIII-B2-2022-995-2022. URL: isprs-archives.copernicus.org/articles/XLIII-B2-2022/995/2022/

References

1. Oznamets V. V. Nauka i tehnologii zheleznyh dorog. 2018. Т. 2. № 1(5). p. 43.
2. Staseva E. V., Fedina E. V. Inzhenernyj vestnik Dona. 2013. № 4. URL: ivdon.ru/magazine/archive/n4y2013/2172
3. Kuz'min A. R., Savel'ev M. F. Vestnik Rossijskogo novogo universiteta. Serija: Slozhnye sistemy: modeli, analiz i upravlenie. 2023. № 2. pp. 121–133.
4. Germak O. V., Kalacheva N. A., Gugueva O. A. Inzhenernyj vestnik Dona. 2013. № 4. URL: ivdon.ru/magazine/archive/n4y2013/2089
5. Erin A. A., Khomonenko A. D. Bulletin' rezul'tatov nauchnyh issledovanij. 2020. № 2. pp. 45–59.
6. Safonova A. N. Metody mashinnogo obuchenija pri obrabotke izobrazhenij sverhvyssokogo prostranstvennogo razreshenija na primere zadach klassifikacii rastitel'nosti [Machine learning methods for processing images of ultra-high spatial resolution using vegetation classification problems as an example]: dis. ... kand. tehn. nauk: 05.13.17. Krasnojarsk, 2019. 104 p.
7. Khan A. A., Laghari A. A., Awan S. A. EAI Endorsed Transactions on Scalable Information Systems. 2021. Т. 8. № 32. pp. 1–11.



8. Lipanov I. D., Khomonenko A. D., Molodkin I. A. Intellektual'nye tehnologii na transporte. 2025. № 1(41). pp. 27–36. URL: itp-gups.ru/ru/storage/viewWindow/195791

9. Na Y.-H., Kim D.-K. // Applied Sciences. 2025. Т. 15. № 15. Article 8719. DOI: 10.3390/app15158719. URL: mdpi.com/2076-3417/15/15/8719

10. Gaspari F., Ioli F., Barbieri F., Belcore E., Pinto L. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences. 2022. Т. XLIII-B2-2022. S. 995–1002. DOI: 10.5194/isprs-archives-XLIII-B2-2022-995-2022. URL: isprs-archives.copernicus.org/articles/XLIII-B2-2022/995/2022.

Дата поступления: 8.08.2025

Дата публикации: 25.09.2025