Проблемы искусственного интеллекта. 2026. N 3 (42). С. 149-160
*Problems of Artificial Intelligence*. 2026;3(42):149-160
Системный анализ, управление и обработка информации, статистика
Научная статья

УДК 004.8:632.9 **DOI** 10.24412/2413-7383-2026-3-42-149-160

А. Ф. Рогачев[1], В. М. Габдерахманов[2]
Федеральное государственное бюджетное образовательное учреждение высшего образования «Волгоградский государственный аграрный университет»,
400002, г. Волгоград, просп. Университетский, 26
[1]rafr@mail.ru; ORCID: 0000-0002-3077-6622
[2] gabderahmanov99@gmail.com; ORCID: 0009-0001-8973-710X

# НЕЙРОСЕТЕВАЯ ОЦЕНКА РОБАСТНОСТИ МУЛЬТИМОДАЛЬНОЙ СИСТЕМЫ ДИАГНОСТИКИ БОЛЕЗНЕЙ РАСТЕНИЙ ПРИ ОТКАЗАХ И ПРОПУСКАХ ВХОДНЫХ МОДАЛЬНОСТЕЙ

A. F. Rogachev[1], V. M. Gabderakhmanov[2]
Federal State Budgetary Educational Institution of Higher Education “Volgograd State Agrarian University”, 400002, Volgograd, Universitetsky Prospekt, 26
[1]rafr@mail.ru; ORCID: 0000-0002-3077-6622
[2] gabderahmanov99@gmail.com; ORCID: 0009-0001-8973-710X

# NEURAL NETWORK ASSESSMENT OF THE ROBUSTNESS OF A MULTIMODAL PLANT DISEASE DIAGNOSTIC SYSTEM UNDER INPUT MODALITY FAILURES AND MISSINGNESS

Цель статьи - оценить деградацию качества мультимодальной нейросетевой системы диагностики болезней Cucumis sativus при контролируемом исключении входных модальностей и сформировать воспроизводимый протокол оценки робастности. На контролируемом датасете выполнен абляционный анализ конфигураций на основе MobileNetV2/MobileNetV3 и ruBERT. Научная новизна заключается в доказательстве того, что в использованной постановке метаданные оказывают наибольшее влияние на точность, тогда как вклад текста зависит от архитектуры. Результаты интерпретируются как оценка устойчивости к полному отсутствию канала в условиях синтетически сформированных метаданных и текстов; они не являются доказательством эксплуатационной надёжности в полевых условиях. Предложен протокол расширенной проверки: частичные пропуски, шум и смещение датчиков, деградация изображений, внешняя валидация и статистическое сравнение с поправкой на множественность проверок.
**Ключевые слова:** мультимодальная нейронная сеть; робастность; пропуски модальностей; нейросетевые методы; абляционный анализ; диагностика болезней растений; MobileNetV3; ruBERT.

Objective — to assess the quality degradation of a multimodal neural network system for diagnosing Cucumis sativus diseases under controlled exclusion of input modalities and to formulate a reproducible robustness-evaluation protocol. An ablation analysis of configurations based on MobileNetV2/MobileNetV3 and ruBERT was conducted on a controlled dataset. The scientific novelty lies in proving that, in the setup used, metadata has the greatest impact on accuracy, while the contribution of the text depends on the architecture.The results are interpreted as robustness estimates for complete channel absence in the presence of synthetically constructed metadata and texts, rather than evidence of field reliability. An extended protocol is proposed, including partial missingness, sensor noise and bias, image degradation, external validation, and multiplicity-adjusted statistical inference.
**Key words:** multimodal neural network; robustness; missing modalities; neural network methods; ablation analysis; plant disease diagnosis; MobileNetV3; ruBERT.

# Введение

Автоматизированная диагностика фитопатологий на основе компьютерного зрения является актуальной задачей для обеспечения продовольственной безопасности и устойчивого развития агропромышленного комплекса. Традиционные методы визуальной экспертной оценки субъективны и трудоёмки. Современные исследования в основном используют унимодальные свёрточные нейросети, анализирующие только изображения [1–3]. Однако такие системы демонстрируют ограниченную эффективность при схожих визуальных симптомах разных заболеваний.

Мультимодальный подход, объединяющий визуальные признаки с агроклиматическими метаданными и текстовыми описаниями симптомов, потенциально позволяет повысить полноту информационного обеспечения диагностики. Вместе с тем в полевой системе каждый канал имеет собственный профиль отказов: датчики могут выдавать пропуски, шум или систематическое смещение; изображение может быть размытым, частично закрытым или сжатым; текстовое описание может отсутствовать либо содержать ошибки. Поэтому для специальности 2.3.1 принципиальна не только максимальная точность полной модели, но и системная оценка её деградации при заданных сценариях неполноты информации. Ранее нами была показана высокая точность двухмодальной архитектуры на валидационной выборке [4]. Также эффективность подобного объединения данных подтверждена в смежных задачах, в частности при обработке снимков с БПЛА для регрессии и классификации [5]. Однако эта оценка сама по себе не характеризует устойчивость к отказам каналов и не заменяет внешнюю полевую валидацию.

**Цель работы** — количественно оценить деградацию качества мультимодальной нейросетевой системы диагностики болезней огурца при полном исключении входных модальностей, выявить наиболее чувствительные каналы и сформировать протокол расширенной оценки робастности при отказах и пропусках данных.

Для достижения цели поставлены задачи:

1. Провести абляционный анализ обученных мультимодальных моделей, последовательно исключая изображения, метаданные и текст на этапе инференса, и явно интерпретировать этот эксперимент как стресс-тест полного отказа канала.
2. Провести сравнительную оценку изменения Accuracy для ключевых архитектур в семи режимах неполноты данных. Учитывая, что в основной редакции результатов доступна только Accuracy, ограничить выводы данной метрикой. Оценить изменение Accuracy, macro-F1 и balanced accuracy для ключевых архитектур в режимах неполноты.
3. Проверить статистическую значимость парных различий тестом Мак-Немара и бутстреп-интервалами, а также применять поправку на множественные сравнения и сообщать доверительные интервалы эффекта.

# Материалы и методы

## 2.1. Датасет

Использован публичный датасет Cucumber Disease Recognition Dataset [6], содержащий 6400 изображений огурца высокого разрешения (2296×1724 пикселей), равномерно распределённых между 8 классам: Anthracnose, Bacterial Wilt, Belly Rot, Downy Mildew, Fresh Cucumber, Fresh Leaf, Gummy Stem Blight, Pythium Fruit Rot. Каждый класс представлен 800 изображениями.

Для каждого изображения синтезированы три агроклиматических признака: температура (°C), относительная влажность (%) и возраст растения (дни). Диапазоны заданы на основе фитопатологической литературы и экспертных оценок (табл. 1) [7–16]; значения генерировались равномерно внутри диапазонов с добавлением нормального шума. Такие

метаданные являются модельными, а не результатами синхронных полевых измерений. Следовательно, их использование допустимо для контролируемого стресс-теста архитектур, но может создавать связь между меткой класса и признаками. По этой причине полученные показатели нельзя переносить на реальные условия без независимой проверки на полевом наборе, где признаки измерены до установления диагноза.

Таблица 1 – Агроклиматические условия для развития заболеваний огурца

| Заболевание | Температура, °C | Влажность, % | Возраст, дни |
|---|---|---|---|
| 1.Anthracnose (Антракноз) | 23-27 | 90-100 | 35-55 |
| 2.Bacterial Wilt (Бактериальное увядание) | 25-30 | 70-90 | 20-40 |
| 3.Belly Rot (Гниль донца плода) | 28-32 | 85-95 | 5-15 |
| 4.Downy Mildew (Ложная мучнистая роса) | 15-22 | 90-100 | 25-50 |
| 5.Pythium Fruit Rot (Питиозная гниль) | 10-18 | 95-100 | 5-25 |
| 6.Gummy Stem Blight (Гоммоз стебля) | 20-25 | 85-100 | 30-60 |
| 7.Fresh leaves (Здоровые листья) | 22-26 | 60-75 | 20-60 |
| 8.Fresh cucumber (Здоровый огурец) | 22-26 | 60-75 | 2-10 |

Текстовые описания симптомов сформированы в три этапа: сбор экспертных описаний, генеративная аугментация и синонимическое варьирование. Поскольку тексты создавались с учётом класса, а часть метаданных могла включаться в текст, они также являются синтетическим контролируемым источником информации. При интерпретации эксперимента это ограничение учитывается: сравнение full и no_text характеризует вклад данного способа кодирования информации, а не независимую диагностическую ценность свободного пользовательского текста. Для последующей валидации следует использовать сообщения пользователей или экспертов, собранные независимо от метки, а также отдельный вариант текста без агроклиматических числовых признаков.

### 2.2 Архитектура мультимодальной сети

Общая архитектура включает три параллельных потока (в соответствии с рисунком 1):

1. Визуальный поток: предобученные на ImageNet свёрточные энкодеры MobileNetV2 или MobileNetV3Small с GlobalAveragePooling2D.
2. Поток метаданных: полносвязные слои (64 → 32 нейрона) с нормализацией StandardScaler и Dropout.
3. Текстовый поток: замороженные энкодеры ruBERT, ruBERT Tiny или ruBERT Tiny lite. Токенизация до 128 токенов, извлечение эмбеддингов с помощью Weighted Mean Pooling (размерность 756, 312 и 256 соответственно).

Признаки доступных потоков конкатенируются и подаются на классификационную голову. Размерность объединённого вектора зависит от выбранного текстового энкодера и набора активных модальностей; поэтому для воспроизводимости для каждой конфигурации необходимо отдельно фиксировать размерности, число параметров, режим заморозки/дообучения BERT, функцию потерь, оптимизатор, learning

rate, размер batch, число эпох, критерий ранней остановки и seed. В настоящей постановке абляция проводится после обучения; она измеряет чувствительность базовой модели к отказу канала, но не обучает модель компенсировать этот отказ.

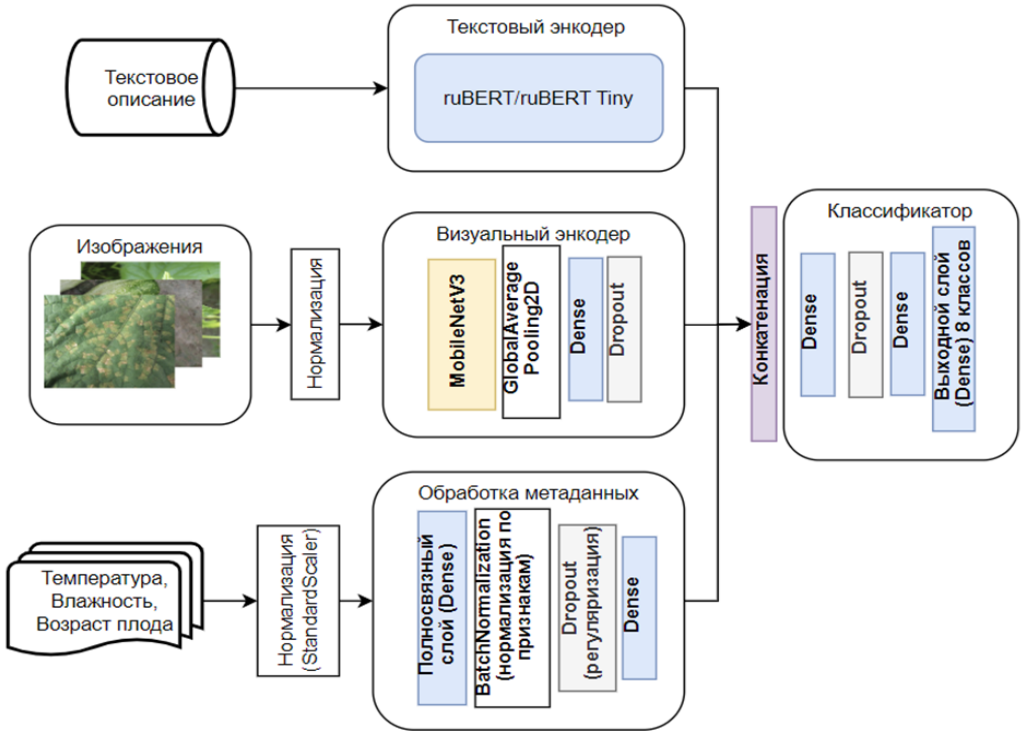



Рисунок 1 – Архитектура мультимодальной нейросети (адаптировано из [4]).

## 2.3 Характеристика датасета и предобработка данных

Для проведения экспериментального исследования был обоснован состав и сформирован многоклассовый мультимодальный датасет, содержащий три типа признаков: визуальные данные (путь к изображениям), агрономические метаданные и текстовые данные – эмбеддинги (в соответствии с рисунком 2).

| | label | temperature | humidity | fruit_age | text_description | bert_embedding | group_idx |
|---|---|---|---|---|---|---|---|
| **0** | Anthracnose | 23.3 | 95.3 | 51 | Плоды покрываются темными вдавленными участкам... | [ 3.02222988e-01 1.01064769e-01 -8.87850081e-... | 0 |
| **1** | Anthracnose | 26.6 | 97.1 | 51 | На листьях и плодах появились округлые вдавлен... | [-0.04087926 0.22858757 -0.46466675 -0.456090... | 1 |
| **2** | Anthracnose | 25.4 | 95.3 | 52 | На листьях видны хлоротичные пятна, позже они ... | [ 0.04607394 0.57702033 -0.19349971 -0.483089... | 2 |
| **3** | Anthracnose | 26.6 | 100.0 | 35 | Заболевание проявляется в виде бурых язв на пл... | [ 0.58450725 0.09630153 -0.25657047 -0.608983... | 3 |
| **4** | Anthracnose | 26.3 | 98.3 | 42 | На плодах появляются вдавленные язвы, покрытые... | [ 3.04136485e-01 -1.04163586e-01 -1.45681300e-... | 4 |
| **...** | ... | ... | ... | ... | ... | ... | ... |
| **6395** | Fresh cucumber | 24.6 | 60.9 | 9 | Плод здоровый, с блестящей поверхностью, без т... | [ 0.43200737 0.3834769 -0.78399647 -0.461990... | 795 |
| **6396** | Fresh cucumber | 26.7 | 71.5 | 7 | Плод здоровый, с блестящей поверхностью, без т... | [ 1.85390742e-01 3.69113431e-01 -7.77970909e-... | 796 |
| **6397** | Fresh cucumber | 23.5 | 73.1 | 5 | Свежий огурец, темно-зеленый, с плотной мякоть... | [ 0.08364587 0.21002287 -0.61847694 -0.715458... | 797 |
| **6398** | Fresh cucumber | 26.0 | 74.6 | 2 | Огурец здоровый, кожура гладкая, без пятен. Вл... | [ 1.07802453e-01 5.43644069e-01 -5.42216211e-... | 798 |
| **6399** | Fresh cucumber | 23.3 | 70.9 | 10 | Плод здоровый, с блестящей поверхностью, без т... | [ 1.44056494e-01 5.05413198e-01 -8.44080553e-... | 799 |

Рисунок 2 – Фрагмент мультимодального датасета в формате Keras

Каждый класс датасета включает репрезентативную выборку из 800 изображений, что обеспечивает его межклассовую сбалансированность (в соответствии с рисунком 3).

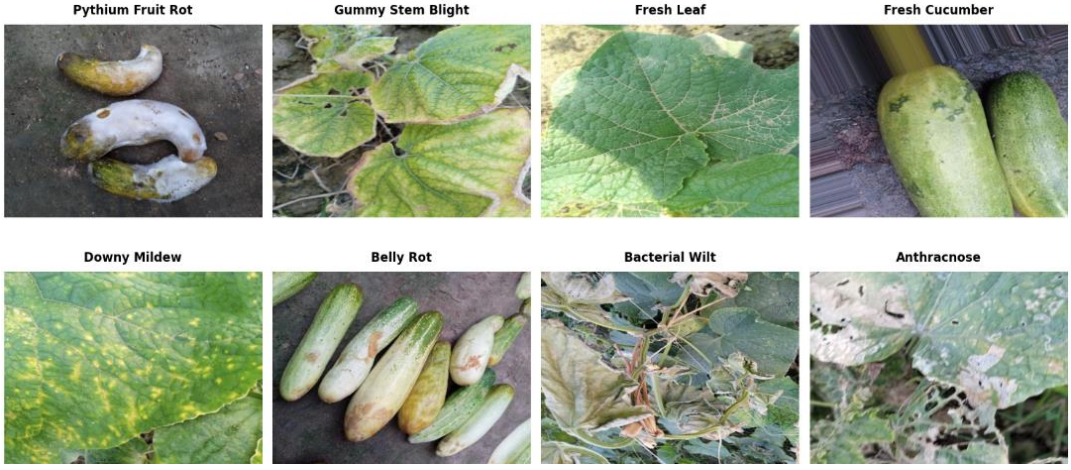



Рисунок 3 – Типовые изображения классов пораженных растений графической части датасета

С целью повышения качества нейросетевой диагностики применены методы предобработки, аугментации и трансферного обучения [17–20]. Предобработка изображений включала изменение разрешения до 224×224 пикселей с сохранением исходных пропорций. Нормализация значений пикселей выполнялась с применением функций предобработки для используемых архитектур нейронных сетей из пакета Keras applications: mobilenet_v2.preprocess_input для MobileNetV2, mobilenet_v3.preprocess_input для MobileNetV3.

Для получения текстовых признаков в эксперименте были использованы энкодеры: ruBERT, ruBERT Tiny и ruBERT Tiny Lite. Выбор BERT-эмбеддингов обусловлен их успешным применением в задачах классификации текстов, в том числе для русского языка [21]. Процесс включал в себя токенизацию: разбиение текста на токены с помощью AutoTokenize, дополнение служебными токенами – [CLS] и [SEP], далее текст обрезается или дополняется до максимальной длины (128 токенов). После этого токены попадали в энкодер и он в свою очередь возвращал числовое значение – трехмерный тензор. Далее применялся Weighted Mean Pooling (взвешенное усреднение), на этом шаге происходит преобразование трехмерного тензора в двумерный вектор. Этот вектор является семантическим слепком всего текста: в нем закодирована информация о симптомах, цвете, влажности и температуре, описанных в предложении.

Биоклиматические метаданные предварительно нормализованы с использованием `StandardScaler`, что обеспечило приведение признаков к единому масштабу и улучшило сходимость процесса обучения. На этапе обучения были вычислены следующие статистические параметры для каждого из признаков (Таблица 2):

Таблица 2 – Параметры нормализации агрономических метаданных

| Признак | Среднее значение | Стандартное отклонение | Исходный диапазон |
|---|---|---|---|
| Температура, °C | 23,20 | 4,95 | 10-35 |
| Влажность, % | 85,62 | 12,19 | 50-100 |
| Возраст плода, дней | 28,16 | 16,57 | 1-70 |

Эксперименты проводились на рабочей станции с процессором Intel Core i7-1165G7 и 16 ГБ оперативной памяти. Программная реализация алгоритмов выполнена на языке Python с использованием фреймворков TensorFlow, Keras и scikit-learn для предобработки и оценки.

## 2.4 Абляционный анализ

Для первичной оценки робастности использован посттренировочный абляционный анализ: модель остаётся неизменной, а на этапе инференса соответствующие входные тензоры заменяются нулевыми векторами. Такой приём моделирует предельный сценарий полного отсутствия канала и позволяет сопоставить чувствительность архитектур в одинаковых условиях. Он не моделирует все реальные механизмы неполноты: частичные пропуски, шум, смещение датчика, деградацию изображения и ошибки текста. Поэтому далее он рассматривается как базовый стресс-тест, а не как исчерпывающая оценка эксплуатационной робастности.

Рассмотрены семь режимов неполноты (табл. 3). Во всём тексте используется единая нотация: full, no_text, no_metadata, no_image, image_only, text_only, metadata_only.

Таблица 3 – Сценарии неполноты модальностей

| Режим | Доступные модальности | Исключённые модальности |
|---|---|---|
| full | Изображение + метаданные + текст | — |
| no_text | Изображение + метаданные | Текст |
| no_metadata | Изображение + текст | Метаданные |
| no_image | Текст + метаданные | Изображение |
| image_only | Только изображение | Метаданные + текст |
| text_only | Только текст | Изображение + метаданные |
| metadata_only | Только метаданные | Изображение + текст |

Оценка проведена для ключевых архитектур, выбранных по результатам предыдущих экспериментов [4]. Для каждого режима вычислялись точность (Accuracy). Использована та же тестовая выборка (960 образцов), что и в [4], что обеспечивает сопоставимость результатов.

## 2.5. Статистическая оценка и расширенный протокол оценки робастности

Для объективного сравнения качества моделей при исключении модальностей используются парный тест Мак-Немара и бутстреп-интервалы разности Accuracy. Тест Мак-Немара применим, поскольку сравниваются предсказания полной и абляционной версии на одних и тех же объектах. При этом вывод относится к фиксированной тестовой выборке и одной обученной реализации модели; для оценки неопределённости обучения необходимы повторные запуски с разными seed.

Тест Мак-Немара используется для проверки гипотезы о равенстве долей правильных ответов полной и абляционной версии на одних и тех же объектах. Строится таблица сопряжённости 2×2, вычисляется точный p-value; уровень значимости $\alpha$=0,05.

Бутстреп-метод применяется для построения 95%-ных доверительных интервалов разности Accuracy между полной и абляционной версиями: выполняется 2000 ресемплирований объектов тестовой выборки с возвращением, для каждого вычисляется разность метрик, затем определяются 2,5-й и 97,5-й процентили. Наряду с p-value необходимо сообщать саму разность метрик и её доверительный интервал, поскольку статистическая значимость не заменяет оценку практической величины эффекта.

Все расчёты выполнены с использованием библиотек statsmodels и sklearn.utils в среде Python.

# Результаты

## 3.1. Сравнение эффективности мультимодальных архитектур

В соответствии с рисунком 4 представлена общая картина результатов для фактически показанных конфигураций и семи режимов.

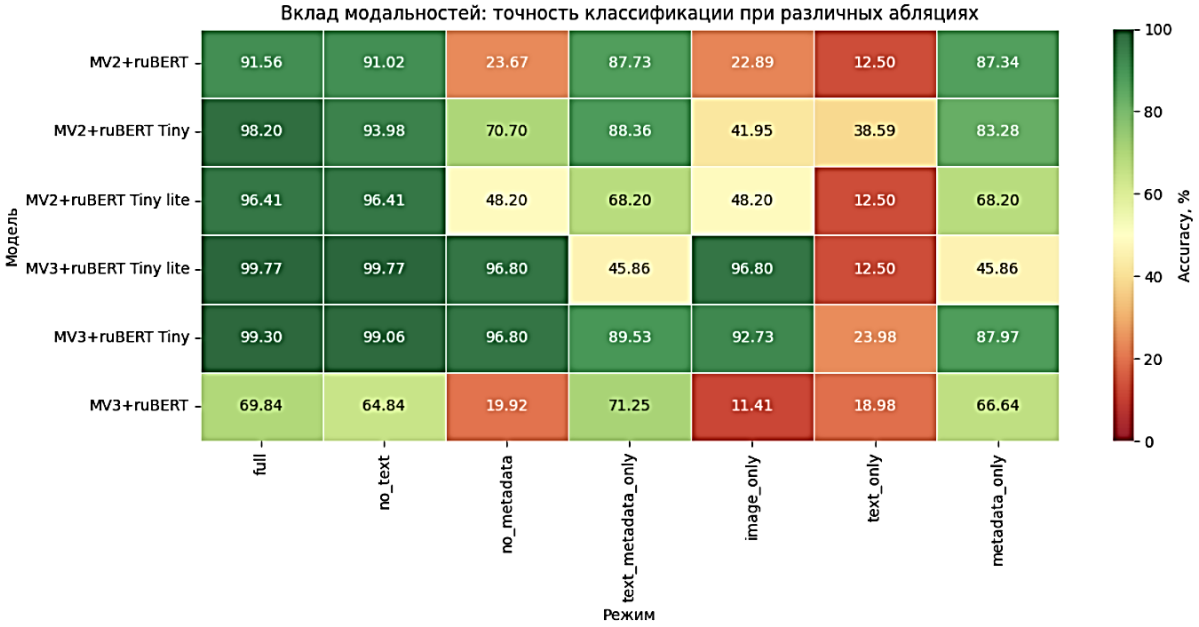



Рисунок 4 – Точность ключевых мультимодальных архитектур в зависимости от режима неполноты данных

В рамках использованного контролируемого набора абляционный анализ выявляет различную чувствительность архитектур к исключению модальностей. Однако эти результаты не следует трактовать как универсальную диагностическую значимость метаданных, текста или изображений: синтетическое формирование метаданных и текстов может усиливать связь между входами и классом. Корректная интерпретация — сравнительная оценка уязвимости конкретных обученных конфигураций в заданной экспериментальной среде.

В большинстве представленных конфигураций удаление метаданных (режим no_metadata) сопровождается заметным снижением Accuracy. Например, для MobileNetV2 с ruBERT Tiny точность уменьшается с 98,20% до 70,70%, а для MobileNetV3Small с ruBERT Tiny lite — с 99,77% до 96,80%. Эти различия подтверждают сильную зависимость моделей от метаданных в данной постановке, но не доказывают, что аналогичный эффект будет воспроизводиться на полевых измерениях.

Исключение текстовой модальности (режим no_text) для ряда облегчённых конфигураций не ухудшает Accuracy: для MobileNetV2 с ruBERT Tiny lite и MobileNetV3Small с ruBERT Tiny lite значения full и no_text совпадают. Корректнее трактовать это как отсутствие добавочного эффекта синтетически сформированного текстового канала в этих конфигурациях. Для вывода об информативности реального текстового описания требуется независимый корпус сообщений без включённых метаданных и без генерации по метке класса.

Роль изображений варьируется в зависимости от архитектуры. Для MobileNetV3Small с ruBERT Tiny lite исключение изображений (режим no_image) снижает Accuracy с 99,77% до 45,86%, тогда как для MobileNetV2 с ruBERT разница между full (91,56%) и no_image (87,73%) меньше. Это характеризует архитектурную зависимость от визуального потока в данном тесте; для проверки устойчивости самого канала необходимо дополнить полный отказ уровнями деградации изображения.

В отдельных случаях, например для MobileNetV3Small с ruBERT Tiny, модель в режиме image_only достигает 92,73%, что ниже полной версии (99,30%). Конфигурация MobileNetV3Small с ruBERT показывает снижение качества при совместном использовании каналов. Возможные причины — несогласованное масштабирование признаков, переобучение на ограниченном синтетическом корпусе или особенности оптимизации.

### 3.2 Статистическая значимость различий

В таблице 4 приведены p-value для сравнения `full` vs `no_text`, `full` vs `no_metadata` и `full` vs `no_image` (для моделей, где эти режимы определены). Различия, обусловленные исключением метаданных, являются статистически значимыми для всех без исключения рассмотренных архитектур ($p < 0{,}0001$). В то же время различия, связанные с исключением текстовой модальности, для большинства облегчённых конфигураций не достигают уровня статистической значимости ($p = 1{,}0$ либо $p > 0{,}05$). Исключения изображений оказываются статистически значимыми для архитектур.

Таблица 4 – p-value для сравнения full с урезанными режимами

| Архитектура | full vs no_text | full vs no_metadata | full vs no_image |
|---|---|---|---|
| MobileNetV2 + ruBERT | 0.0391* | <0.0001* | 0.1093 |
| MobileNetV2 + ruBERT Tiny | 0.0000* | <0.0001* | 0.0002* |
| MobileNetV2 + ruBERT Tiny lite | 1.0000 | <0.0001* | <0.0001* |
| MobileNetV3Small + ruBERT Tiny lite | 1.0000 | <0.0001* | <0.0001* |
| MobileNetV3Small + ruBERT Tiny | 0.2500 | <0.0001* | <0.0001* |
| MobileNetV3Small + ruBERT | 0.0000* | <0.0001* | 0.4651 |

*Примечание: * — статистически значимо при α=0.05.*

## Заключение

В работе выполнена нейросетевая оценка чувствительности мультимодальных систем диагностики болезней Cucumis sativus к полному исключению входных модальностей. На контролируемом датасете сопоставлены конфигурации MobileNetV2/MobileNetV3 и ruBERT; в представленном эксперименте наибольшая деградация Accuracy наблюдается при исключении метаданных, а эффект текстового канала зависит от архитектуры. Эти выводы относятся к использованной процедуре генерации метаданных и текстов и к посттренировочной абляции, поэтому не должны интерпретироваться как доказательство полевой эксплуатационной робастности. Практический результат работы состоит в формировании воспроизводимого протокола оценки нейросетевой робастности: описание механизмов неполноты, единая нотация режимов, парное статистическое сравнение с доверительными интервалами и поправкой на множественность, а также проверка на внешних данных. Дальнейшее развитие связано с

обучением моделей с modality dropout и адаптивным слиянием признаков, оценкой частичных пропусков и искажений, поклассовых метрик, калибровки вероятностей и мобильных характеристик модели. Только после такой валидации возможна рекомендация системы для полевого применения.

## Список источников


1. Рогачев, А. Ф. Мультиклассовое распознавание аэрофотоснимков участков сельскохозяйственных полей / А. Ф. Рогачев, Е. В. Мелихова // Известия Нижневолжского агроуниверситетского комплекса: Наука и высшее профессиональное образование. 2020. № 3(59). С. 142-152. DOI 10.32786/2071-9485-2020-03-14. EDN HNRBZJ.
2. Брагинский, М. Я. Оценка состояния растений с использованием сверточных нейронных сетей / М. Я. Брагинский, Д. В. Тараканов // Вестник кибернетики. 2021. № 1(41). С. 41-50. DOI 10.34822/1999-7604-2021-1-41-50. EDN UWYLWR.
3. Ариничева, И. В. Детекция и классификация грибных вредоносных болезней пшеницы на различных стадиях вегетации растения / И. В. Ариничева, И. В. Ариничев // Передовые исследования Кубани: Сборник материалов Ежегодной отчетной конференции грантодержателей Кубанского научного фонда, Сочи, 20–22 июня 2022 года. Краснодар: Унитарная некоммерческая организация «Кубанский научный фонд», 2022. С. 104-111. EDN ITAXDB.
4. Рогачев, А. Ф. Фитотронный комплекс с интеллектуальной системой выявления заболеваний растений на основе мультимодальной нейронной сети / А. Ф. Рогачев, Е. В. Мелихова, В. М. Габдерахманов // Известия Волгоградского государственного технического университета. 2026. № 4(311). С. 53-61. DOI 10.35211/1990-5297-2026-4-311-53-61. EDN TEYWKZ.
5. Павленко, Б. В. Подход к мультимодальному объединению данных в задачах регрессии и классификации на снимках с БПЛА / Б. В. Павленко // Проблемы искусственного интеллекта. 2025. № 4(39). С. 4–18.
6. Cucumber Disease Recognition Dataset [Электронный ресурс] // Kaggle URL: https://www.kaggle.com/datasets/sujaykapadnis/cucumber-disease-recognition-dataset (дата обращения: 04.10.2025).
7. Daunde A. T. Management of prevalent diseases of cucumber (Cucumis sativus) through integrated approach / A. T. Daunde, R. D. Baghele, V. S. Khandare // International Journal of Current Microbiology and Applied Sciences. 2020. Т. 9. №. 7. С. 3022-3028.
8. The cucurbit downy mildew pathogen Pseudoperonospora cubensis / Savory E. A. [et al.] // Molecular plant pathology. 2011. Т. 12. № 3. С. 217-226.
9. Scheufele S. B. Evaluation of Resistant Cultivars for Management of Downy Mildew in Fall Cucumbers in South Deerfield, MA, 2024 / S. B. Scheufele, G. Higgins, A. Shokoohi // Plant Health Progress. 2025. Т. 26. №. 1. С. 114.
10. Biological control of Pythium aphanidermatum, the causal agent of tomato root rot by two Streptomyces root symbionts / Hassanisaadi M. [et al.] // Agronomy. 2021. Т. 11. №. 5. С. 846.
11. A dataset for successful recognition of cucumber diseases / Sultana N. [et al.] // Data in Brief. 2023. Т. 49. С. 109320.
12. Ascochyta rabiei: A threat to global chickpea production / Singh R. [et al.] //Molecular Plant Pathology. 2022. Т. 23. № 9. С. 1241-1261.
13. Daunde A. T. Management of prevalent diseases of cucumber (Cucumis sativus) through integrated approach / A. T. Daunde, R. D. Baghele, V. S. Khandare // International Journal of Current Microbiology and Applied Sciences. 2020. Т. 9. № 7. С. 3022-3028.
14. First report of Pythium myriotylum D., causing damping off and root rot in chili pepper (Capsicum annum L.) from Punjab, Pakistan / Hyder S. [et al.] // Plant Dis. 2018. Т. 102. №. 3. С. 687-687.
15. A deep learning-based approach for the detection of cucumber diseases / Raufer L. [et al.] // PloS one. 2025. Т. 20. №. 4. С. e0320764.
16. Influence of Temperature and Humidity on Microbial, Enzymatic, and Physical Changes of Stored, Pickling Cucumbers [Electronic resource] / Etchells JL, Bell T.A., Costilow R.N., Hood C.E., Anderson T.E. // Appl Microbiol26. 1973. URL: https://doi.org/10.1128/am.26.6.943-950.1973
17. Рогачев А.Ф. Нейросетевая система управления программируемым аграрным производством с использованием ретроспективных данных и результатов дистанционного зондирования: монография / А.Ф. Рогачев, Е.В. Мелихова, Т.В. Плещенко. Волгоград: ФГБОУ ВО Волгоградский ГАУ, 2021. 172 с.

18. MobileNetV2: Inverted Residuals and Linear Bottlenecks [Electronic resource] / Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L. // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 4510-4520. URL: https://doi.org/10.1109/CVPR.2018.00474.
19. Computer Optimization of ANN Hyperparameters for Retrospective Information Processing [Electronic resource] / Melikhova, E. [et al.] // Networked Control Systems for Connected and Automated Vehicles. NN 2022. Lecture Notes in Networks and Systems / In: Guda, A. (eds) 2023. Vol 509. Springer, Cham. Pp. 723-730 URL: https://doi.org/10.1007/978-3-031-11058-0_72
20. Neural Network Modelling of Crop Yields Cultivated in Water Scarcity Conditions [Electronic resource] / Rogachev, D.A. [et al.] // Web Intelligence and Human-Machine Interaction. ICWIHI 2025. Advances in Intelligent Systems and Computing / In: Vasanthi, R., Palaniappan, R., Radhakrishnan, K. (eds). Vol. 3. Springer, Singapore. URL: https://doi.org/10.1007/978-981-96-8563-9_10 (2026).
21. Чжан, Ю. Классификация текстовых эмоций на основе модели BERT / Ю. Чжан // Проблемы искусственного интеллекта. 2026. № 1(40). С. 102–111. DOI: 10.24412/2413-7383-2026-1-40-102-111.

# References

1. Rogachev, A. F. Multiclass recognition of aerial photographs of agricultural field plots / A. F. Rogachev, E. V. Melikhova // Proceedings of the Lower Volga Agro-University Complex: Science and Higher Professional Education. – 2020. – No 3(59). – P. 142-152. – DOI 10.32786/2071-9485-2020-03-14. – EDN HNRBZJ.
2. Braginsky, M. Ya. Assessment of plant condition using convolutional neural networks / M. Ya. Braginsky, D. V. Tarakanov // Bulletin of Cybernetics. – 2021. – No 1(41). – P. 41-50. – DOI 10.34822/1999-7604-2021-1-41-50. – EDN UWYLWR.
3. Arinicheva, I. V. Detection and classification of fungal harmful diseases of wheat at different stages of plant vegetation / I. V. Arinicheva, I. V. Arinichev // Advanced Research of Kuban: Collection of materials of the Annual Reporting Conference of Grant Holders of the Kuban Science Foundation, Sochi, June 20–22, 2022. – Krasnodar: Unitary Non-Profit Organization «Kuban Science Foundation», 2022. – P. 104-111. – EDN ITAXDB.
4. Rogachev, A. F. Phytotron complex with an intelligent system for detecting plant diseases based on a multimodal neural network / A. F. Rogachev, E. V. Melikhova, V. M. Gabderakhmanov // Proceedings of Volgograd State Technical University. – 2026. – No. 4(311). – P. 53-61. – DOI 10.35211/1990-5297-2026-4-311-53-61. – EDN TEYWKZ.
5. Pavlenko, B. V. An approach to multimodal data fusion in regression and classification tasks on UAV images / B. V. Pavlenko // Problems of Artificial Intelligence. – 2025. – No. 4(39). – P. 4–18.
6. Cucumber Disease Recognition Dataset [Electronic resource] // Kaggle. – URL: https://www.kaggle.com/datasets/sujaykapadnis/cucumber-disease-recognition-dataset (accessed: 04.10.2025).
7. Daunde, A. T. Management of prevalent diseases of cucumber (Cucumis sativus) through integrated approach / A. T. Daunde, R. D. Baghele, V. S. Khandare // International Journal of Current Microbiology and Applied Sciences. – 2020. – Vol. 9. – No. 7. – P. 3022-3028.
8. The cucurbit downy mildew pathogen Pseudoperonospora cubensis / Savory, E. A. [et al.] // Molecular Plant Pathology. – 2011. – Vol. 12. – No. 3. – P. 217-226.
9. Scheufele, S. B. Evaluation of Resistant Cultivars for Management of Downy Mildew in Fall Cucumbers in South Deerfield, MA, 2024 / S. B. Scheufele, G. Higgins, A. Shokoohi // Plant Health Progress. – 2025. – Vol. 26. – No. 1. – p. 114.
10. Biological control of Pythium aphanidermatum, the causal agent of tomato root rot by two Streptomyces root symbionts / Hassanisaadi, M. [et al.] // Agronomy. – 2021. – Vol. 11. – No. 5. – 846 p.
11. A dataset for successful recognition of cucumber diseases / Sultana, N. [et al.] // Data in Brief. – 2023. – Vol. 49. –109320 p.
12. Ascochyta rabiei: A threat to global chickpea production / Singh, R. [et al.] // Molecular Plant Pathology. – 2022. – Vol. 23. – No 9. – P. 1241-1261.
13. Daunde, A. T. Management of prevalent diseases of cucumber (Cucumis sativus) through integrated approach / A. T. Daunde, R. D. Baghele, V. S. Khandare // International Journal of Current Microbiology and Applied Sciences. – 2020. – Vol. 9. – No. 7. – P. 3022-3028.
14. First report of Pythium myriotylum D., causing damping off and root rot in chili pepper (Capsicum annum L.) from Punjab, Pakistan / Hyder, S. [et al.] // Plant Disease. – 2018. – Vol. 102. – No. 3. – P. 687-687.

15. A deep learning-based approach for the detection of cucumber diseases / Raufer, L. [et al.] // PLoS One. – 2025. – Vol. 20. – No. 4. – e0320764 p.
16. Etchells, J. L. Influence of Temperature and Humidity on Microbial, Enzymatic, and Physical Changes of Stored, Pickling Cucumbers [Electronic resource] / J. L. Etchells, T. A. Bell, R. N. Costilow, C. E. Hood, T. E. Anderson // Applied Microbiology. – 1973. – Vol. 26. – No. 6. – P. 943–950. – URL: https://doi.org/10.1128/am.26.6.943-950.1973
17. Neural network system for managing programmable agricultural production using retrospective data and remote sensing results: monograph / A. F. Rogachev, E. V. Melikhova, T. V. Pleshchenko. – Volgograd: FSBEI HE Volgograd State Agrarian University, 2021. – 172 p.
18. Sandler, M. MobileNetV2: Inverted Residuals and Linear Bottlenecks [Electronic resource] / M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, L. Chen // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. – 2018. – P. 4510-4520. – URL: https://doi.org/10.1109/CVPR.2018.00474.
19. Computer Optimization of ANN Hyperparameters for Retrospective Information Processing [Electronic resource] / Melikhova, E. [et al.] // Networked Control Systems for Connected and Automated Vehicles. NN 2022. Lecture Notes in Networks and Systems, Vol. 509 / A. Guda (ed.). – Springer, Cham, 2023. – P. 723-730. – URL: https://doi.org/10.1007/978-3-031-11058-0_72
20. Neural Network Modelling of Crop Yields Cultivated in Water Scarcity Conditions [Electronic resource] / Rogachev, D. A. [et al.] // Web Intelligence and Human-Machine Interaction. ICWIHI 2025. Advances in Intelligent Systems and Computing, Vol. 3 / R. Vasanthi, R. Palaniappan, K. Radhakrishnan (eds.). – Springer, Singapore, 2026. – URL: https://doi.org/10.1007/978-981-96-8563-9_10
21. Zhang, Yu. Classification of text emotions based on the BERT model / Yu. Zhang // Problems of Artificial Intelligence. – 2026. – No. 1(40). – P. 102–111. – DOI: 10.24412/2413-7383-2026-1-40-102-111.

## RESUME

*A. F. Rogachev, V. M. Gabderakhmanov*

*Neural Network Assessment of the Robustness Of A Multimodal Plant Disease Diagnostic System Under Input Modality Failures And Missingness*

Research on multimodal neural networks for plant disease diagnostics is actively developing; however, in field conditions, failures of individual input channels are possible: image corruption, unavailability of meteorological sensors, or lack of internet connection.

The use of additional semantics in the form of agroclimatic metadata and textual symptom descriptions can improve accuracy, but their contribution under incomplete data remains unclear. An ablation analysis of 23 configurations (MobileNetV2/V3, ruBERT) was conducted on a dataset of 6400 cucumber images.

It was established that metadata are critical (accuracy drop up to 67.9 p.p., $p < 0.0001$), text is redundant ($p > 0.05$), and the contribution of images is situational. The most robust configuration is MobileNetV3Small + ruBERT Tiny lite + Dense. For mobile systems, MobileNetV3Small + Dense without a text encoder is recommended, providing accuracy >99% and robustness to sensor failures.

## РЕЗЮМЕ

*А. Ф. Рогачев, В. М. Габдерахманов*

*Нейросетевая оценка робастности мультимодальной системы диагностики болезней растений при отказах и пропусках входных модальностей*

Исследования мультимодальных нейросетей для диагностики болезней растений активно развиваются, однако в полевых условиях возможны отказы отдельных каналов ввода: повреждение изображения, недоступность метеодатчиков или отсутствие интернет-соединения.

Использование дополнительной семантики в виде агроклиматических метаданных и текстовых описаний симптомов позволяет повышать точность, но их вклад в условиях

неполноты данных остаётся неясным. Проведён абляционный анализ 23 конфигураций (MobileNetV2/V3, ruBERT) на датасете из 6400 изображений огурца.

Установлено, что метаданные критичны (падение точности до 67,9 п.п., $p<0,0001$), текст избыточен ($p>0,05$), а вклад изображений ситуативен. Наиболее устойчива MobileNetV3Small + ruBERT Tiny lite + Dense. Для мобильных систем рекомендуется MobileNetV3Small + Dense без текстового энкодера, обеспечивающая точность >99% и устойчивость к отказам датчиков.

**Рогачев Алексей Фруминович –** доктор технических наук, профессор, кафедра математического моделирования и информатики, Волгоградский государственный аграрный университет, 400002, Российская Федерация, г. Волгоград, просп. Университетский, 26, e-mail: rafr@mail.ru. Область научных интересов: моделирование, оптимизация параметров и системы поддержки решений с применением информационных технологий в сложных технико-экономических системах. ORCID: 0000-0002-3077-6622

**Габдерахманов Вадим Миннурович –** аспирант, кафедра математического моделирования и информатики, Волгоградский государственный аграрный университет, 400002, Российская Федерация, г. Волгоград, просп. Университетский, 26, e-mail: gabderahmanov99@gmail.com. Область научных интересов: теория алгоритмов, искусственный интеллект. ORCID: 0009-0001-8973-710X

**Alexey Fruminovich Rogachev** – Doctor of Technical Sciences, Professor, Department of Mathematical Modeling and Informatics, Volgograd State Agrarian University, 400002, Russian Federation, Volgograd, Universitetsky Prospekt, 26, e-mail: rafr@mail.ru. Research interests: modeling, parameter optimization, and decision support systems using information technologies in complex technical and economic systems. ORCID: 0000-0002-3077-6622

**Vadim Minnurovich Gabderakhmanov** – postgraduate student, Department of Mathematical Modeling and Informatics, Volgograd State Agrarian University, 400002, Russian Federation, Volgograd, Universitetsky Prospekt, 26, e-mail: gabderahmanov99@gmail.com. Research interests: theory of algorithms, artificial intelligence. ORCID: 0009-0001-8973-710X

Статья поступила в редакцию 24.08.2026;
одобрена после рецензирования 30.08.2026; принята к публикации 02.09.2026
The article was submitted 24.08.2026; approved after reviewing 30.08.2026;
accepted for publication 02.09.2026.