

ИНФОРМАТИКА

УДК 004.93

MSC 93В03

Методы генерации синтетических данных для обучения нейросетей в задаче сегментации уровня азотного режима растений на снимках беспилотных летательных аппаратов на сельскохозяйственном поле*А. Е. Молин¹, И. С. Блеканов¹, Е. П. Митрофанов^{1,2}, О. А. Митрофанова^{1,2}*¹ Санкт-Петербургский государственный университет,

Российская Федерация, 199034, Санкт-Петербург, Университетская наб., 7–9

² Агрофизический научно-исследовательский институт,

Российская Федерация, 195220, Санкт-Петербург, Гражданский пр., 14

Для цитирования: *Молин А. Е., Блеканов И. С., Митрофанов Е. П., Митрофанова О. А.* Методы генерации синтетических данных для обучения нейросетей в задаче сегментации уровня азотного режима растений на снимках беспилотных летательных аппаратов на сельскохозяйственном поле // Вестник Санкт-Петербургского университета. Прикладная математика. Информатика. Процессы управления. 2024. Т. 20. Вып. 1. С. 20–33.
<https://doi.org/10.21638/11701/spbu10.2024.103>

Работа посвящена автоматизации процесса построения масок изображений объектов сельского хозяйства больших размеров в задачах точного земледелия для обучения нейросетевых методов анализа обеспеченности растений полезными веществами по геопривязанным снимкам. Это направление крайне актуально, поскольку позволяет автоматизировать и заменить ручной процесс разметки данных, существенно сократив затраты ресурсов на подготовку обучающей выборки. Предложены четыре новых метода генерации синтетических данных для обучения нейросетей, направленных на сегментацию снимков беспилотных летательных аппаратов (БПЛА) по уровню обеспеченности растений азотом на сельскохозяйственном поле. В частности, описаны алгоритмы генерации синтетических данных на основе построения рядов, парабол и пятен. Поставлен эксперимент по тестированию и оценке качества приведенных алгоритмов на восьми современных методах сегментации изображений: два классических метода машинного обучения (Random Forest и XGBoost), четыре сверточных нейросетевых метода на базе архитектуры U-Net, два трансформера (TransUnet и UnetR). Эксперимент показал, что два алгоритма на основе пятен показывают наилучшую точность для обучения сверточных нейросетей и трансформеров — 98–100 %. Классические методы машинного обучения на сгенерированных синтетических данных показали очень низкие значения по всем метрикам качества — 27–44 %.

Ключевые слова: сегментация уровня азота, глубокое обучение, машинное обучение, генерация синтетических данных, снимки БПЛА, разметка данных дистанционного зондирования земли, умное сельское хозяйство.

1. Введение. В последние годы, благодаря активному развитию нейросетевых методов анализа данных, автоматизация получила широкое распространение в различных сферах человеческой деятельности, в том числе в области сельского хозяйства. Разные решения, разработанные для семантической сегментации изображений, сейчас активно используются в умном сельском хозяйстве и применяются в таких задачах как анализ растительного покрова [1–3], сегментация видов лесных деревьев [4], обнаружение сорняков [5], прогнозное сельское хозяйство [6], обнаружение вредителей и болезней [7] и т. д.

В настоящее время методы семантической сегментации постепенно вытесняют традиционные методы мониторинга состояния полей и лабораторные измерения, играя, таким образом, важную роль в современном сельском хозяйстве. Применение данных алгоритмов позволяет контролировать процесс посева и рост растений, что дает возможность повысить качество продукции и производительность сельского хозяйства. При сегментации вредителей [8] можно идентифицировать их разновидность и персонализировать использование пестицидов в зависимости от вида. Также при анализе состояния растений можно управлять эффективностью применения удобрений [9].

Однако при решении подобных задач с помощью алгоритмов глубокого обучения ключевое значение имеют размеченные данные и объем обучающей выборки. В случае анализа изображений объектов сельского хозяйства больших размеров в задачах точного земледелия возникает глобальная проблема, связанная с трудоемкостью разметки данных дистанционного зондирования сельскохозяйственного поля для обучения нейросетевых моделей. Существуют разные методики получения таких размеченных данных:

- 1) ручная разметка данных с помощью наземных измерений агрохимических и агрофизических показателей почвы и растений, сделанных экспертами при отборе проб [10];
- 2) автоматизированная разметка данных датчиками IoT измерения этих показателей [11];
- 3) разметка изображений, благодаря ручному построению масок сегментации, например при детектировании заболевания растений [12] или обнаружении сорняков на сельскохозяйственных полях [13].

Первый и второй подходы к построению размеченных данных требуют привлечения большого количества ресурсов, как денежных, так и человеческих. Третий подход применяется в основном для маркировки данных на ограниченных открытых пространствах с использованием сложно реализуемых полевых растениеводческих экспериментов [13], а для разметки изображений объектов сельского хозяйства больших размеров (более 10 га) ограничен и трудозатратен в реализации.

Кроме того, при недостаточном объеме обучающих данных возникает проблема переобучения, из-за которой снижается точность сегментации. Ручное создание обучающих данных требует огромных трудовых и временных затрат. Для решения проблемы недостаточного объема обучающих данных применяются различные техники аугментации изображений, в частности: повороты, сдвиги, изменение масштаба и размытие [14], создание новых изображений из частей других [15, 16], случайное размещение объектов на изображении [17–19], применение генеративных моделей [20, 21].

Цель работы — разработка и оценка качества алгоритмов генерации размеченных синтетических данных для обучения классических методов машинного обучения в задаче сегментации уровня обеспеченности растений азотом на снимках беспилотных летательных аппаратов (БПЛА) сельскохозяйственного поля, нейросетевых методов и трансформеров. Предлагаемые алгоритмы основаны на использовании аэрофотоснимков тестовых площадок сельскохозяйственного поля зерновых культур с соответствующим фиксированным уровнем содержания азотного питания растений (от 0 до 200 кг действующего вещества на 1 га) и имитации условий изменчивости внутри-полевых показателей, приближенных к реальному полю.

2. Алгоритмы генерации изображений. В настоящем исследовании были разработаны и протестированы четыре алгоритма генерации изображений сельскохозяйственного поля. Для генерации синтетических данных применялись снимки тестовых площадок размером 128×128 пикселей, выделенных из ортофотопланов двух полей. Ортофотопланы были составлены из отдельных снимков, сделанных квадрокоптером. Сами сельскохозяйственные поля находятся на биополигоне Агрофизического научно-исследовательского института (рис. 1).

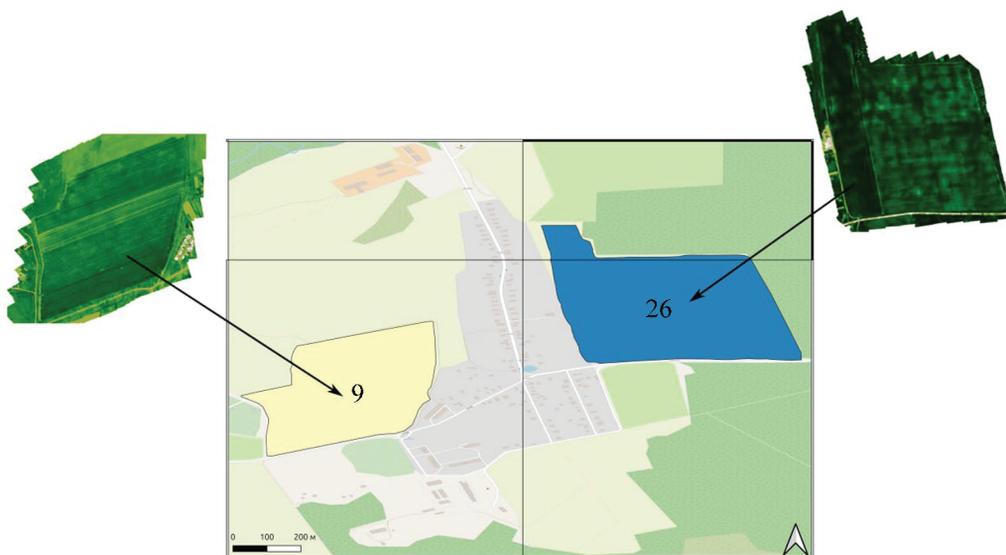


Рис. 1. Биополигон с сельскохозяйственными полями 9 и 26

Для поля были получены 72 изображения тестовых площадок, которые попарно смешивались путем поочередной замены строк одного изображения на строки из другого. В итоге половина использовалась для генерации синтетических данных для обучающей выборки, другая — для тестирования точности работы алгоритмов глубокого и машинного обучения.

Таким образом, основой синтетических данных служат 36 изображений тестовых площадок, а в целях тестирования применяются еще 36 изображений тестовых площадок, не использовавшихся при генерации и обучении.

Сами алгоритмы синтетических данных создают новые изображения путем наложения друг на друга снимков с разным уровнем азотного питания растений. Как показано на блок-схеме (рис. 2), процесс генерации состоит из нескольких этапов:

- 1) сначала случайным образом составляется группа из снимков тестовых площадок, снятых в одно время и на одном поле;
- 2) выбирается первое изображение тестовой площадки с известным уровнем азота;
- 3) выбирается второе изображение другой тестовой площадки;
- 4) создается специальная маска для наложения второго изображения на первое. Маска представляет собой двумерный массив, в котором ненулевые значения соответствуют пикселям выбранного изображения для наложения;
- 5) в соответствии с маской происходит наложение двух изображений, в результате на первом изображении появляются участки с пикселями второго;
- 6) выполняется процедура проверки наличия оставшихся других изображений из группы, выбранных для наложения. Если изображение имеется, то поверх сгенерированного в предыдущих итерациях изображения накладываются еще новые. Если нет, то процесс генерации прекращается.

Стоит отметить, что все описанные ниже алгоритмы генерации синтетических изображений отличаются друг от друга количеством выбранных изображений и созданием маски для наложения.

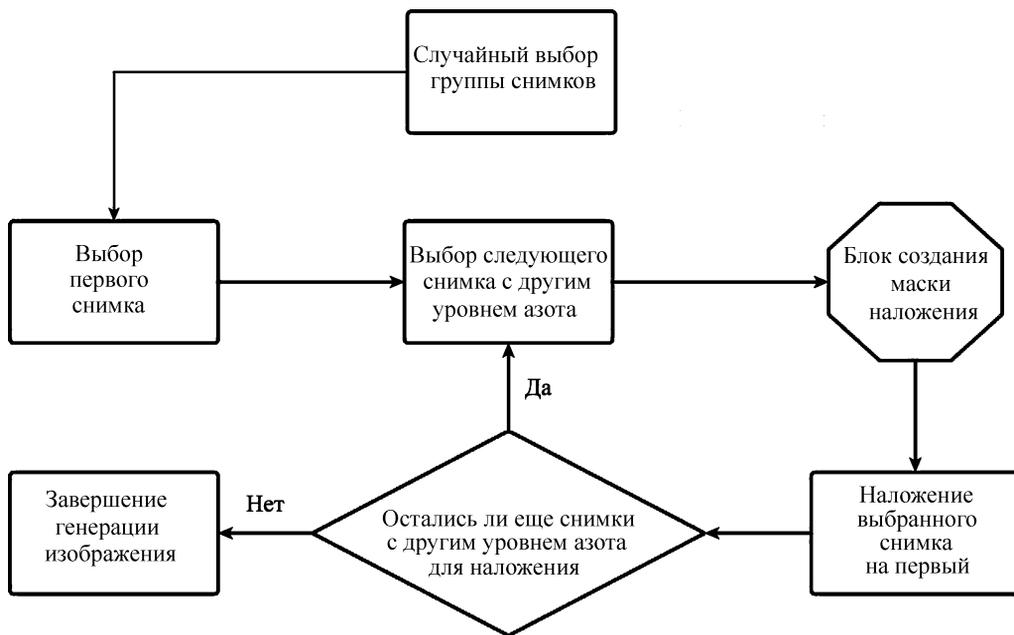


Рис. 2. Схема генерации изображений

2.1. Алгоритм на основе построения рядов. Этот метод накладывает на первое случайно выбранное изображение другие изображения в виде рядов (рис. 3). Количество рядов, их размер и положение выбираются случайным образом. При этом применяются все изображения из группы снимков. Таким образом, в одном сгенерированном изображении присутствуют все 6 уровней азота.

Для наложения используется маска — двумерный массив, где ненулевые значения обозначают пиксели изображения для замещения пикселями другого изображения. После создания фигур и вставки их в маску в массиве будут содержаться только зна-

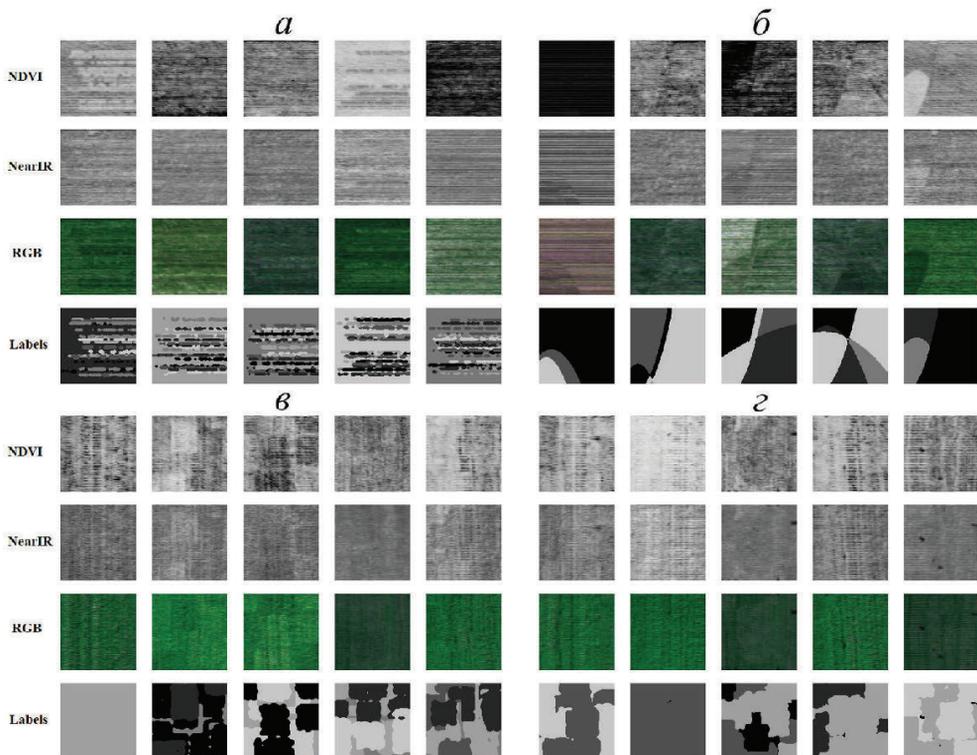


Рис. 3. Алгоритмы на основе рядов (а), парабол (б), пятен* (в), пятен** (г)
 Строки каждого фрагмента а–г обозначают каналы изображения: RGB, NeaIR и NDVI; столбцы — отдельные примеры сгенерированных изображений с учетом специфики каждого алгоритма; последняя строка Labels — примеры масок сегментации с размеченными данными.

чения 0 и 255. Перед наложением создается и применяется на маску сглаживающий фильтр K , усредняющий величины пикселей, чтобы сделать переход между разными изображениями более плавным. В данном исследовании используется усредняющий фильтр с заданным ядром свертки:

$$K = \frac{1}{25} \begin{bmatrix} 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 1 \end{bmatrix}.$$

Значения в маске варьируются в диапазоне от 0 до 255. Далее для получения нового изображения как результата наложения двух изображений разных тестовых площадок при использовании маски применяется соотношение

$$img_res = \frac{img_mask}{255 * img_for_overlay} + \frac{255 - img_mask}{255 * img_orig},$$

где img_orig — исходное изображение; $img_for_overlay$ — накладываемое изображение; img_mask — маска для наложения. Чем ближе величина пикселей в маске

изображений к значению 255, тем сильнее сдвигается пиксель исходного изображения к пикселю накладываемого изображения.

Затем наложение применяется к размеченным данным (маскам сегментации для обучения), содержащим данные об уровне азота. Перед этим в маске для наложения все значения выше 127 приравниваются к 255, а все значения ниже — к 0.

Algorithm 1. Построение рядов

Input: изображение тестовых площадок с соответствующими масками.

Output: группа N новых сгенерированных изображений с соответствующими размеченными масками.

for от 1 до N **do**

- (1) Случайный выбор папки с изображениями
- (2) Случайный выбор первого изображения из папки

for от 1 до 6 **do**

- (1) Случайный выбор следующего изображения для наложения
- (2) Создание пустой маски для наложения
- (3) Случайный выбор числа создания фигур в диапазоне от 3 до 7

for от 1 до 4–7 **do**

- (1) Создание фигуры длиной 128 пикселей и случайной шириной с заполнением ее кругами
- (2) Вставка фигуры в маску для наложения

end for

- (4) Применение сглаживающего фильтра на маску наложения
- (5) Наложение выбранного изображения на первое с использованием маски

end for

- (3) Преобразование сгенерированных масок в формат one-hot encoding

end for

В дальнейшем приведенное на с. 24 соотношение используется для генерации новых изображений и их размеченных масок сегментации ко всем остальным разработанным алгоритмам генерации синтетических данных с учетом особенностей каждого.

На рис. 3, а представлены примеры работы алгоритма построения рядов в виде пяти сгенерированных изображений с разметкой и их масок наложения.

2.2. Алгоритм на основе построения парабол. В этом методе для наложения изображений в качестве масок использовались параболы. Размеры и характеристики парабол создаются случайным образом. Их количество не превышает число уровней азота. Снимки из группы также выбираются случайно в соответствии с количеством созданных парабол. Таким образом, в отличие от первого алгоритма здесь на одном сгенерированном изображении не всегда присутствуют все уровни азота. Часть исходных снимков не подвергается изменениям и в дальнейшем подается в неизменном виде.

Примеры работы данного алгоритма представлены на рис. 3, б.

2.3. Алгоритм построения пятен*. Третий подход основан на экспертном знании агрономов-исследователей об изменчивости внутривидовых агрофизических и агрохимических характеристик в реальных условиях и генерирует синтетические размеченные изображения, имитируя распределения азота на настоящем поле в фор-

Algorithm 2. Построение парабол

Input: изображение тестовых площадок с соответствующими масками.

Output: группа N новых сгенерированных изображений с соответствующими размеченными масками.

for от 1 до N **do**

- (1) Случайный выбор папки с изображениями
- (2) Построение трех парабол со случайно определенными коэффициентами
- (3) Заполнение созданных областей числами, соответствующими случайно выбранному уровню азота
- (4) Преобразование сгенерированных масок в формат one-hot encoding
- (5) Создание списка изображений, соответствующих сгенерированным маскам
- (6) Выбор первого изображения из списка

for от 0 до 0–6 **do**

- (1) Выбор следующего изображения из списка, если он не пуст
- (2) Применение сглаживающего фильтра на маску наложения
- (3) Наложение выбранного изображения на первое с использованием маски

end for

end for

Algorithm 3. Построение пятен*

Input: изображение тестовых площадок с соответствующими масками.

Output: группа N новых сгенерированных изображений с соответствующими размеченными масками.

for от 1 до N **do**

- (1) Случайный выбор папки с изображениями
- (2) Случайный выбор первого изображения из папки
- (3) Создание пустого контрольного изображения

for от 0 до 0–4 **do**

- (1) Случайный выбор следующего изображения для наложения
- (2) Создание пустой маски для наложения
- (3) Случайный выбор числа создания фигур в диапазоне от 3 до 7

for от 3 до 7 **do**

- (1) Нахождение координат пустой области в контрольном изображении
- (2) Создание фигуры длиной и шириной 50–80 пикселей с заполнением ее кругами
- (3) Вставка фигуры в маску для наложения по найденным координатам
- (4) Наложение маски на контрольное изображение

end for

- (4) Применение сглаживающего фильтра на маску наложения

- (5) Наложение выбранного изображения на первое с использованием маски

end for

- (4) Преобразование сгенерированных масок в формат one-hot encoding

end for

ме пятен. Данный алгоритм схож с первым, но со следующими принципиальными отличиями:

- 1) вместо полос используются пятна;
- 2) в генерации новых изображений применяются до 4 снимков из группы;
- 3) как и в методе генерации парабол, часть изображений остается в неизменном виде;
- 4) расположение пятен выбирается не случайным образом, а чтобы было наименьшее перекрытие с другими пятнами.

С учетом вышеописанных отличительных особенностей данный алгоритм имеет следующий вид:

Примеры работы алгоритма 3 представлены на рис. 3, в.

2.4. Алгоритм построения пятен.** Этот подход отличается от всех предыдущих тем, что полностью создает новые изображения вместо того, чтобы использовать в качестве основы первое выбранное. Имеет некоторые сходства с алгоритмом 3:

- 1) в генерации новых изображений используются до 4 снимков из группы;
- 2) во время генерации находит пустые не заполненные области новых изображений тем же способом;
- 3) при генерации изображений применяется маска наложения с пятнами тех же размеров;
- 4) если в список внесено только одно изображение, то оно остается в неизменном виде.

Примеры работы данного алгоритма представлены на рис. 3, г.

Algorithm 4. Построение пятен**

Input: изображение тестовых площадок с соответствующими масками.

Output: группа N новых сгенерированных изображений с соответствующими размеченными масками.

for от 1 до N **do**

- (1) Случайный выбор папки с изображениями
- (2) Случайный выбор и запись в список 1–3 изображений из папки
- (3) Создание пустого изображения и маски для обучения

while 0 **in** image **do**

- (1) Выбор изображения из списка для наложения
- (2) Создание пустой маски для наложения
- (3) Нахождение координат пустой области в созданном изображении
- (4) Создание фигуры длиной 50–80 пикселей и шириной 50–80 пикселей с заполнением ее кругами
- (5) Вставка фигуры в маску для наложения по найденным координатам
- (6) Применение сглаживающего фильтра на маску наложения
- (7) Наложение выбранного изображения на новое с использованием маски

end while

- (4) Преобразование сгенерированных масок в формат one-hot encoding

end for

3. Алгоритмы глубокого и машинного обучения. Были исследованы сгенерированные синтетические данные с помощью шести архитектур сверточных нейросетей: U-Net [22], Attention U-Net [23], R2U-Net, Attention R2U-Net [24], U-Net++ [25] и U-Net3+ [26] и двух архитектур трансформеров: TransUnet [27] и UnetR [28]. Каждым алгоритмом было сгенерировано 15 000 изображений для обучающей выборки и 50 изображений для оценки точности во время обучения с целью сохранения лучшей модели, а также для уменьшения скорости обучения при достижении плато.

Дополнительно обучающая выборка, состоящая из сгенерированных предложенными алгоритмами изображений (примеры представлены на рис. 3), была расширена до 25 000 с помощью стандартной процедуры аугментации с использованием вращений, горизонтальных/вертикальных смещений и горизонтальных переворотов.

Изначально скорость обучения составляла 1×10^{-4} , и при достижении плато она уменьшалась умножением на 0.15. Максимальное количество итераций обучения было задано числом 100. Если скорость обучения изменялась 4 раза, то обучение досрочно прекращалось.

Помимо алгоритмов глубокого обучения для исследования также применялись классические алгоритмы машинного обучения: Random Forest [29] и XGBoost [30]. Для этого сгенерированные изображения преобразовывались в одномерный массив. Параметры для алгоритмов классического обучения подбирались с помощью поиска по решетке.

Для оценки качества алгоритмов были использованы следующие метрики: Accuracy, Balanced Accuracy, Intersection over Union (IoU), Precision, Recall, F1-score.

4. Результаты экспериментов. Был поставлен эксперимент по оценке эффективности предложенных методов для обучения трех классов алгоритмов сегментации изображений: классическое машинное обучение, сверточные нейросети, трансформеры. В ходе тестирования синтетических данных алгоритмами глубокого и машинного обучения наилучшие результаты были достигнуты при использовании данных, созданных методом построения пятен** вместе с трансформером UnetR. Для демонстрации полученных результатов в табл. 1, 2 были выбраны алгоритмы (отмечены жирным шрифтом), показавшие наибольшую точность.

Также результаты свидетельствуют, что алгоритмы глубокого обучения имеют гораздо большую точность — от 96 до 100 % (табл. 1) по сравнению с алгоритмами машинного обучения в табл. 2 (43–44 %).

5. Заключение. В статье были предложены алгоритмы генерации синтетических данных для обучения методов машинного и глубокого обучения, а также трансформеров. Полученные алгоритмы основаны на использовании аэрофотоснимков тестовых площадок сельскохозяйственного поля зерновых культур с соответствующим фиксированным уровнем содержания азотного питания растений (от 0 до 200 кг действующего вещества на 1 га) и имитации условий изменчивости внутривидовых показателей, приближенных к реальному полю. Главная идея, на которой базируются предложенные методы, состоит в наложении друг на друга изображений тестовых площадок с разным уровнем обеспеченности азотом. Наложение изображения достигалось путем создания специальной маски.

Результаты эксперимента показали, что лучше всего подходит алгоритм на основе случайного наложения пятен (см. п. 2.4), который продемонстрировал наилучшую точность в обучении сверточных нейросетей и трансформеров — 98–100 %. Рассмотренные классические методы машинного обучения показали очень низкие значения по всем метрикам качества — 27–44 %.

Таблица 1. Точность алгоритмов глубокого обучения

Алгоритм	Accuracy	Balanced Accuracy	IOU	Precision	Recall	F1-мера
R2U-Net (t2)						
Ряды	0.996	0.99601	0.99203	0.996	0.99601	0.996
Параболы	0.97654	0.97752	0.9548	0.97654	0.97752	0.97663
Пятна*	0.99846	0.99847	0.99693	0.99846	0.99847	0.99846
Пятна**	0.99503	0.99505	0.99013	0.99503	0.99505	0.99503
Attention R2U-Net (t2)						
Ряды	0.99386	0.99391	0.98781	0.99386	0.99391	0.99386
Параболы	0.99388	0.99393	0.98786	0.99388	0.99393	0.99388
Пятна*	0.99895	0.99895	0.99791	0.99895	0.99895	0.99895
Пятна**	0.99832	0.99833	0.99666	0.99832	0.99833	0.99832
Unet++						
Ряды	0.98616	0.98621	0.97274	0.98616	0.98621	0.98615
Параболы	0.98487	0.98505	0.97044	0.98487	0.98505	0.98482
Пятна*	0.97603	0.97637	0.95322	0.97603	0.97637	0.97594
Пятна**	0.98027	0.98054	0.96138	0.98027	0.98054	0.98026
Unet3+						
Ряды	0.99454	0.99455	0.98915	0.99454	0.99455	0.99453
Параболы	0.99137	0.99152	0.98298	0.99137	0.99152	0.99139
Пятна*	0.99784	0.99784	0.99569	0.99784	0.99784	0.99784
Пятна**	0.99639	0.99641	0.99283	0.99639	0.99641	0.99639
TransUnet						
Ряды	0.95776	0.95977	0.91895	0.95776	0.95977	0.95768
Параболы	0.96166	0.96419	0.92828	0.96166	0.96419	0.9619
Пятна*	0.99716	0.9972	0.99435	0.99716	0.9972	0.99716
Пятна**	0.98246	0.98303	0.9658	0.98246	0.98303	0.98247
UnetR						
Ряды	0.97334	0.9736	0.9481	0.97334	0.9736	0.97331
Параболы	0.99924	0.99924	0.99847	0.99924	0.99924	0.99924
Пятна*	0.99997	0.99997	0.99994	0.99997	0.99997	0.99997
Пятна**	1	1	1	1	1	1

Таблица 2. Точность алгоритмов машинного обучения

Алгоритм	Accuracy	Balanced Accuracy	IOU	Precision	Recall	F1-мера
Random Forest						
Ряды	0.43462	0.4248	0.27845	0.43462	0.4248	0.42755
Параболы	0.43315	0.42311	0.27369	0.43315	0.42311	0.42153
Пятна*	0.43787	0.43118	0.28294	0.43787	0.43118	0.43334
Пятна**	0.4361	0.4292	0.28143	0.4361	0.4292	0.4315
XGBoost						
Ряды	0.43555	0.42911	0.28098	0.43555	0.42911	0.43151
Параболы	0.43328	0.4244	0.27523	0.43328	0.4244	0.42418
Пятна*	0.43676	0.43143	0.28224	0.43676	0.43143	0.43297
Пятна**	0.43478	0.4288	0.28038	0.43478	0.4288	0.43066

В дальнейшем планируется развить полученные результаты, сопоставив результаты нейросетевых методов сегментации уровня азота по снимкам БПЛА, обученных на сгенерированных предложенными алгоритмами синтетических данных, с точечной ручной разметкой на основе взятия экспертами при отборе проб наземных измерений агрохимических и агрофизических показателей почвы и растений.

Литература

1. *Yang S., Chen Q., Yuan X., Liu X.* Adaptive coherency matrix estimation for polarimetric SAR imagery based on local heterogeneity coefficients // *IEEE Transactions on Geoscience and Remote Sensing*. 2016. Vol. 56. P. 6732–6745.
2. *Kussul N., Lavreniuk M., Skakun S., Shelestov A.* Deep learning classification of land cover and crop types using remote sensing data // *IEEE Geoscience and Remote Sensing Letters*. 2017. Vol. 14. P. 778–782.
3. *Jadhav J. K., Singh R. P.* Automatic semantic segmentation and classification of remote sensing data for agriculture // *Mathematical Models in Engineering*. 2018. Vol. 4. P. 112–137.
4. *Dechesne C., Mallet C., Le Bris A., Gouet-Brunet V.* Semantic segmentation of forest stands of pure species as a global optimization problem // *ISPRS Annals of Photogrammetry Remote Sensing, Spatial Information Sciences*. 2017. Vol. 4. P. 141–148.
5. *Zou K., Chen X., Wang Y., Zhang C., Zhang F.* A modified U-Net with a specific data argumentation method for semantic segmentation of weed images in the field // *Computers and Electronics in Agriculture*. 2021. Vol. 187. Art. N 106242.
6. *Anand T., Sinha S., Mandal M., Chamola V., Yu F.* AgriSegNet: Deep aerial semantic segmentation framework for IoT-assisted precision agriculture // *Mathematical Models in Engineering*. 2021. Vol. 21. P. 17581–17590.
7. *Singh P., Verma A., Alex J.* Disease and pest infection detection in coconut tree through deep learning techniques // *Computers and Electronics in Agriculture*. 2021. Vol. 182. Art. N 105986.
8. *Zhao S., Liu J., Bai Z., Hu C., Jin Y.* Crop pest recognition in real agricultural environment using convolutional neural networks by a parallel attention mechanism // *Mathematical Models in Engineering*. 2022. Vol. 13. P. 1–14.
9. *Blekanov I., Molin A., Zhang D., Mitrofanov E., Mitrofanova O., Yin L.* Monitoring of grain crops nitrogen status from uav multispectral images coupled with deep learning approaches // *Computers and Electronics in Agriculture*. 2023. Vol. 212. Art. N 108047.
10. *Salas E. A. L., Subburayalu S. K., Slater B., Dave R., Parekh P., Zhao K., Bhattacharya B.* Assessing the effectiveness of ground truth data to capture landscape variability from an agricultural region using Gaussian simulation and geostatistical techniques // *Heliyon*. 2021. Vol. 7. Iss. 7. Art. N e07439.
11. *Lynda D., Brahim F., Hamid S., Hamadoun C.* Towards a semantic structure for classifying IoT agriculture sensor datasets: an approach based on machine learning and web semantic technologies // *Journal of King Saud University – Computer and Information Sciences*. 2023. Vol. 35. Iss. 8. Art. N 101700.
12. *Wang H., Ding J., He S., Feng C., Zhang C., Fan G., Wu Y., Zhang Y.* MFBP-UNet: A network for pear leaf disease segmentation in natural agricultural environments // *Plants*. 2023. Vol. 12. P. 3209.
13. *Sa I., Popovic M., Khanna R., Chen Z., Lottes P., Liebisch F., Nieto J., Stachniss C., Walter A., Siegwart R.* WeedMap: A large-scale semantic weed mapping framework using aerial multispectral imaging and deep neural network for precision farming // *Remote Sensing*. 2018. Vol. 10. P. 1423.
14. *Nasiri A., Omid M., Taheri-Garavand A., Jafari A.* Deep learning-based precision agriculture through weed recognition in sugar beet fields // *Sustainable Computing: Informatics and Systems*. 2022. Vol. 35. Art. N 100759.
15. *Takahashi R., Matsubara T., Uehara K.* Data augmentation using random image cropping and patching for deep CNNs // *IEEE Transactions on Circuits and Systems for Video Technology*. 2020. Vol. 30. P. 2917–2931.
16. *Su D., Kong H., Qiao Y., Sukkarieh S.* Data augmentation for deep learning based semantic segmentation and crop-weed classification in agricultural robotics // *Computers and Electronics in Agriculture*. 2021. Vol. 190. Art. N 106418.
17. *Picon A., San-Emeterio M. G., Bereciartua-Perez A., Klukas C., Eggers T., Navarra-Mestre R.* Deep learning-based segmentation of multiple species of weeds and corn crop using synthetic and real image datasets // *Computers and Electronics in Agriculture*. 2022. Vol. 194. Art. N 106719.
18. *Venkataramanan A., Faure-Giovagnoli P., Regan C., Heudre D., Figus C., Usseglio-Polatera P., Pradalier C., Laviiale M.* Usefulness of synthetic datasets for diatom automatic detection using a deep-learning approach // *Engineering Applications of Artificial Intelligence*. 2023. Vol. 117. Pt B. Art. N 105594.
19. *Yang S., Zheng L., Yang H., Zhang M., Wu T., Sun S., Tomasetto F., Wang M.* A synthetic datasets based instance segmentation network for high-throughput soybean pods phenotype investigation // *Expert Systems with Applications*. 2022. Vol. 192. Art. N 116403.
20. *Abbas A., Jain S., Gour M., Vankudothu S.* Tomato plant disease detection using transfer learning with C-GAN synthetic images // *Computers and Electronics in Agriculture*. 2021. Vol. 187. Art. N 106279.

21. Tempelaere A., Van De Looverbosch T., Kelchtermans K., Verboven P., Tuytelaars T., Nicolai B. Synthetic data for X-ray CT of healthy and disordered pear fruit using deep learning // *Postharvest Biology and Technology*. 2023. Vol. 200. Art. N 112342.
22. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional networks for biomedical image segmentation // *Medical Image Computing and Computer-Assisted Intervention — MICCAI 2015*. 2015. Vol. 9351. P. 234–241.
23. Oktay O., Schlemper J., Folgoc L., Lee M., Heinrich M., Misawa K., Mori K., McDonagh S., Hammerla N. Y., Kainz B., Glocker B., Rueckert D. Attention U-Net: Learning where to look for the pancreas // *arXiv: 1804.03999*. 2018.
24. Alom Z., Hasan M., Yakopcic C., Taha T. M., Asari V. K. Recurrent residual convolutional neural network based on U-Net (R2U-Net) for medical image segmentation // *arXiv: 1802.06955*. 2018.
25. Zhou Z., Siddiquee M. R., Tajbakhsh N., Liang J. UNet++: A nested U-Net architecture for medical image segmentation // *arXiv: 1807.10165*. 2018.
26. Huang H., Lin L., Tong R., Hu H., Zhang Q., Iwamoto Y., Han X., Chen Y. W., Wu J. UNet 3+: A full-scale connected UNet for medical image segmentation // *arXiv: 2004.08790*. 2020.
27. Chen J., Lu Y., Yu Q., Luo X., Adeli E., Wang Y., Lu L., Yuille A. L., Zhou Y. TransUNet: Transformers make strong encoders for medical image segmentation // *arXiv: 2102.04306*. 2021.
28. Hatamizadeh A., Tang Y., Nath V., Yang D., Myronenko A., Landman B., Roth H., Xu D. UNETR: Transformers for 3d medical image segmentation // *Proceedings of the IEEE/CVF. Winter Conference on Applications of Computer Vision*. 2022. P. 1748–1758.
29. Breiman L. Random forests // *Machine Learning*. 2001. Vol. 45. P. 5–32.
30. Tianqi C., Carlos G. XGBoost: Scalable tree boosting system // *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. 2016. P. 785–794.

Статья поступила в редакцию 15 ноября 2023 г.

Статья принята к печати 26 декабря 2023 г.

Контактная информация:

Молин Александр Евгеньевич — аспирант; malocsoft@yandex.ru

Блеканов Иван Станиславович — канд. техн. наук, доц.; i.blekanov@spbu.ru

Митрофанов Евгений Павлович — канд. техн. наук; mjeka89@gmail.com

Митрофанова Ольга Александровна — канд. техн. наук; omitrofa@gmail.com

Synthetic data generation methods for training neural networks in the task of segmenting the level of crop nitrogen status in images of unmanned aerial vehicles in an agricultural field

A. E. Molin¹, I. S. Blekanov¹, E. P. Mitrofanov^{1,2}, O. A. Mitrofanova^{1,2}

¹ St. Petersburg State University, 7–9, Universitetskaya nab., St. Petersburg, 199034, Russian Federation

² Agrophysical Research Institute, 14, Grazhdansky pr., St. Petersburg, 195220, Russian Federation

For citation: Molin A. E., Blekanov I. S., Mitrofanov E. P., Mitrofanova O. A. Synthetic data generation methods for training neural networks in the task of segmenting the level of crop nitrogen status in images of unmanned aerial vehicles in an agricultural field. *Vestnik of Saint Petersburg University. Applied Mathematics. Computer Science. Control Processes*, 2024, vol. 20, iss. 1, pp. 20–33. <https://doi.org/10.21638/11701/spbu10.2024.103> (In Russian)

This study is devoted to the automatization of the image masks' construction of large-sized agricultural objects in precision farming tasks for training neural network methods for crop's nitrogen status analysis using georeferenced images. The scientific direction is extremely relevant because it allows to automate and replace the manual process of data labeling, significantly reducing the cost of preparing training samples. In the paper, four new synthetic data generation methods are proposed for training neural networks aimed at

UAV image segmentation by the level of crop nitrogen supply on an agricultural field. In particular, the paper gives a description of synthetic data generation algorithms based on nitrogen covering with lines, parabolas, and areas. Experiments were carried out to test and evaluate the quality of these algorithms using eight modern image segmentation methods: two classical machine learning methods (Random Forest and XGBoost), four convolutional neural network methods based on U-Net architecture, and two transformers (TransUNet and UnetR). The results showed that two algorithms based on areas gave the best accuracy for convolutional neural networks and transformers — 98–100 %. Classical machine learning methods showed very low values for all quality metrics — 27–44 %.

Keywords: nitrogen level segmentation, deep learning, machine learning, synthetic data generation, UAV images, remote sensing data labeling, smart agriculture.

References

1. Yang S., Chen Q., Yuan X., Liu X. Adaptive coherency matrix estimation for polarimetric SAR imagery based on local heterogeneity coefficients. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, vol. 56, pp. 6732–6745.
2. Kussul N., Lavreniuk M., Skakun S., Shelestov A. Deep learning classification of land cover and crop types using remote sensing data. *IEEE Geoscience and Remote Sensing Letters*, 2017, vol. 14, pp. 778–782.
3. Jadhav J. K., Singh R. P. Automatic semantic segmentation and classification of remote sensing data for agriculture. *Mathematical Models in Engineering*, 2018, vol. 4, pp. 112–137.
4. Dechesne C., Mallet C., Le Bris A., Gouet-Brunet V. Semantic segmentation of forest stands of pure species as a global optimization problem. *ISPRS Annals of Photogrammetry Remote Sensing, Spatial Information Sciences*, 2017, vol. 4, pp. 141–148.
5. Zou K., Chen X., Wang Y., Zhang C., Zhang F. A modified U-Net with a specific data argumentation method for semantic segmentation of weed images in the field. *Computers and Electronics in Agriculture*, 2021, vol. 187, art. no. 106242.
6. Anand T., Sinha S., Mandal M., Chamola V., Yu F. AgriSegNet: Deep aerial semantic segmentation framework for IoT-assisted precision agriculture. *Mathematical Models in Engineering*, 2021, vol. 21, pp. 17581–17590.
7. Singh P., Verma A., Alex J. Disease and pest infection detection in coconut tree through deep learning techniques. *Computers and Electronics in Agriculture*, 2021, vol. 182, art. no. 105986.
8. Zhao S., Liu J., Bai Z., Hu C., Jin Y. Crop pest recognition in real agricultural environment using convolutional neural networks by a parallel attention mechanism. *Mathematical Models in Engineering*, 2022, vol. 13, pp. 1–14.
9. Blekanov I., Molin A., Zhang D., Mitrofanov E., Mitrofanova O., Yin L. Monitoring of grain crops nitrogen status from uav multispectral images coupled with deep learning approaches. *Computers and Electronics in Agriculture*, 2023, vol. 212, art. no. 108047.
10. Salas E. A. L., Subburayalu S. K., Slater B., Dave R., Parekh P., Zhao K., Bhattacharya B. Assessing the effectiveness of ground truth data to capture landscape variability from an agricultural region using Gaussian simulation and geostatistical techniques. *Heliyon*, 2021, vol. 7, iss. 7, art. no. e07439.
11. Lynda D., Brahim F., Hamid S., Hamadoun C. Towards a semantic structure for classifying IoT agriculture sensor datasets: an approach based on machine learning and web semantic technologies. *Journal of King Saud University – Computer and Information Sciences*, 2023, vol. 35, iss. 8, art. no. 101700.
12. Wang H., Ding J., He S., Feng C., Zhang C., Fan G., Wu Y., Zhang Y. MFBP-UNet: A network for pear leaf disease segmentation in natural agricultural environments. *Plants*, 2023, vol. 12, p. 3209.
13. Sa I., Popovic M., Khanna R., Chen Z., Lottes P., Liebisch F., Nieto J., Stachniss C., Walter A., Siegwart R. WeedMap: A large-scale semantic weed mapping framework using aerial multispectral imaging and deep neural network for precision farming. *Remote Sensing*, 2018, vol. 10, p. 1423.
14. Nasiri A., Omid M., Taheri-Garavand A., Jafari A. Deep learning-based precision agriculture through weed recognition in sugar beet fields. *Sustainable Computing: Informatics and Systems*, 2022, vol. 35, art. no. 100759.
15. Takahashi R., Matsubara T., Uehara K. Data augmentation using random image cropping and patching for deep CNNs. *IEEE Transactions on Circuits and Systems for Video Technology*, 2020, vol. 30, pp. 2917–2931.
16. Su D., Kong H., Qiao Y., Sukkariéh S. Data augmentation for deep learning based semantic segmentation and crop-weed classification in agricultural robotics. *Computers and Electronics in Agriculture*, 2021, vol. 190, art. no. 106418.

17. Picon A., San-Emeterio M. G., Bereciartua-Perez A., Klukas C., Eggers T., Navarra-Mestre R. Deep learning-based segmentation of multiple species of weeds and corn crop using synthetic and real image datasets. *Computers and Electronics in Agriculture*, 2022, vol. 194, art. no. 106719.
18. Venkataramanan A., Faure-Giovanoli P., Regan C., Heudre D., Figus C., Usseglio-Polatera P., Pradalier C., Laviale M. Usefulness of synthetic datasets for diatom automatic detection using a deep-learning approach. *Engineering Applications of Artificial Intelligence*, 2023, vol. 117, pt B, art. no. 105594.
19. Yang S., Zheng L., Yang H., Zhang M., Wu T., Sun S., Tomasetto F., Wang M. A synthetic datasets based instance segmentation network for high-throughput soybean pods phenotype investigation. *Expert Systems with Applications*, 2022, vol. 192, art. no. 116403.
20. Abbas A., Jain S., Gour M., Vankudothu S. Tomato plant disease detection using transfer learning with C-GAN synthetic images. *Computers and Electronics in Agriculture*, 2021, vol. 187, art. no. 106279.
21. Tempelaere A., Van De Looverbosch T., Kelchtermans K., Verboven P., Tuytelaars T., Nicolai B. Synthetic data for X-ray CT of healthy and disordered pear fruit using deep learning. *Postharvest Biology and Technology*, 2023, vol. 200, art. no. 112342.
22. Ronneberger O., Fischer P., Brox T. U-Net: Convolutional networks for biomedical image segmentation. *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015*, 2015, vol. 9351, pp. 234–241.
23. Oktay O., Schlemper J., Folgoc L., Lee M., Heinrich M., Misawa K., Mori K., McDonagh S., Hammerla N. Y., Kainz B., Glocker B., Rueckert D. Attention U-Net: Learning where to look for the pancreas. *arXiv: 1804.03999*, 2018.
24. Alom Z., Hasan M., Yakopcic C., Taha T. M., Asari V. K. Recurrent residual convolutional neural network based on U-Net (R2U-Net) for medical image segmentation. *ArXiv: 1802.06955*, 2018.
25. Zhou Z., Siddiquee M. R., Tajbakhsh N., Liang J. UNet++: A nested U-Net architecture for medical image segmentation. *ArXiv: 1807.10165*, 2018.
26. Huang H., Lin L., Tong R., Hu H., Zhang Q., Iwamoto Y., Han X., Chen Y. W., Wu J. UNet 3+: A full-scale connected UNet for medical image segmentation. *ArXiv: 2004.08790*, 2020.
27. Chen J., Lu Y., Yu Q., Luo X., Adeli E., Wang Y., Lu L., Yuille A. L., Zhou Y. TransUNet: Transformers make strong encoders for medical image segmentation. *ArXiv: 2102.04306*, 2021.
28. Hatamizadeh A., Tang Y., Nath V., Yang D., Myronenko A., Landman B., Roth H., Xu D. UNETR: transformers for 3d medical image segmentation. *Proceedings of the IEEE/CVF, Winter Conference on Applications of Computer Vision*, 2022, pp. 1748–1758.
29. Breiman L. Random forests. *Machine Learning*, 2001, vol. 45, pp. 5–32.
30. Tianqi C., Carlos G. XGBoost: Scalable tree boosting system. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2016, pp. 785–794.

Received: November 15, 2023.

Accepted: December 26, 2023.

Authors' information:

Alexander E. Molin — Postgraduate Student; malocsoft@yandex.ru

Ivan S. Blekanov — PhD in Technics, Associate Professor; i.blekanov@spbu.ru

Evgenii P. Mitrofanov — PhD in Technics; mjeka89@gmail.com

Olga A. Mitrofanova — PhD in Technics; omitrofa@gmail.com