

Перевод на английский язык <https://vavilov.elpub.ru/jour>

Обзор современных методов обнаружения и идентификации болезней растений на основе анализа гиперспектральных изображений

А.Ф. Чешкова 

Сибирский федеральный научный центр агробиотехнологий Российской академии наук, р.п. Краснообск, Новосибирская область, Россия
 cheshanna@yandex.ru

Аннотация. Болезни растений приводят к значительным экономическим потерям в секторе сельскохозяйственного производства во всем мире. Раннее выявление, количественная оценка и идентификация болезней имеют решающее значение для целенаправленного применения мер защиты в растениеводстве. В настоящее время ведутся интенсивные научные исследования по разработке инновационных методов диагностики болезней растений, основанных на гиперспектральных технологиях. Анализ спектра отражения растительной ткани позволяет проводить классификацию здоровых и больных растений, оценивать тяжесть заболевания, дифференцировать виды патогенов и выявлять симптомы биотических стрессов на ранних стадиях, в том числе в инкубационный период, когда симптомы не видны человеческому глазу. В обзоре описаны основные принципы измерения спектра отражения растительной ткани. Обсуждаются и оцениваются возможности применения различных типов гиперспектральных сенсоров и платформ для диагностики болезней растений. Гиперспектральный анализ является новой областью, соединяющей в себе методы оптической спектроскопии и методы анализа изображений, которые позволяют одновременно оценивать как физиологические, так и морфологические параметры. Описаны главные этапы анализа гиперспектральных данных: получение и предварительная обработка изображения; извлечение и обработка данных; моделирование и анализ данных. Приведен перечень алгоритмов и методов, применяемых на каждом из этапов. Рассмотрены основные области применения гиперспектральных сенсоров в диагностике болезней растений, такие как обнаружение болезней, дифференциация и идентификация типа заболевания, оценка степени поражения, оценка устойчивости генотипов. Приведен всесторонний обзор научных публикаций, подчеркивающий преимущества гиперспектральных технологий при исследовании взаимодействий между растениями и патогенами в различных масштабах измерений. Несмотря на обнадеживающий прогресс, достигнутый за последние несколько десятилетий в мониторинге болезней растений на основе гиперспектральных технологий, остаются нерешенными некоторые технические проблемы, препятствующие применению этих методов на практике. В заключение обсуждаются проблемы и перспективы практического использования новых технологий в сельскохозяйственном производстве.

Ключевые слова: гиперспектральные технологии; болезни растений; анализ изображений; спектральный анализ.

Для цитирования: Чешкова А.Ф. Обзор современных методов обнаружения и идентификации болезней растений на основе анализа гиперспектральных изображений. *Вавиловский журнал генетики и селекции*. 2022;26(2):202-213. DOI 10.18699/VJGB-22-25

A review of hyperspectral image analysis techniques for plant disease detection and identification

A.F. Cheshkova 

Siberian Federal Scientific Center of AgroBioTechnology of the Russian Academy of Sciences, Krasnoobsk, Novosibirsk region, Russia
 cheshanna@yandex.ru

Abstract. Plant diseases cause significant economic losses in agriculture around the world. Early detection, quantification and identification of plant diseases are crucial for targeted application of plant protection measures in crop production. Recently, intensive research has been conducted to develop innovative methods for diagnosing plant diseases based on hyperspectral technologies. The analysis of the reflection spectrum of plant tissue makes it possible to classify healthy and diseased plants, assess the severity of the disease, differentiate the types of pathogens, and identify the symptoms of biotic stresses at early stages, including during the incubation period, when the symptoms are not visible to the human eye. This review describes the basic principles of hyperspectral measurements and different types of available hyperspectral sensors. Possible applications of hyperspectral sensors and platforms on different scales for diseases diagnosis are discussed and evaluated. Hyperspectral analysis is a new subject that combines optical spectroscopy and image analysis methods, which make it possible to simultaneously evaluate both physiological and morphological parameters. The review describes the main steps of the hyperspectral data analysis process: image acquisition and prepro-

cessing; data extraction and processing; modeling and analysis of data. The algorithms and methods applied at each step are mainly summarized. Further, the main areas of application of hyperspectral sensors in the diagnosis of plant diseases are considered, such as detection, differentiation and identification of diseases, estimation of disease severity, phenotyping of disease resistance of genotypes. A comprehensive review of scientific publications on the diagnosis of plant diseases highlights the benefits of hyperspectral technologies in investigating interactions between plants and pathogens at various measurement scales. Despite the encouraging progress made over the past few decades in monitoring plant diseases based on hyperspectral technologies, some technical problems that make these methods difficult to apply in practice remain unresolved. The review is concluded with an overview of problems and prospects of using new technologies in agricultural production.

Key words: hyperspectral technologies; plant diseases; image analysis; spectral analysis.

For citation: Cheshkova A.F. A review of hyperspectral image analysis techniques for plant disease detection and identification. *Vavilovskii Zhurnal Genetiki i Selekcii = Vavilov Journal of Genetics and Breeding*. 2022;26(2):202-213. DOI 10.18699/VJGB-22-25

Введение

Болезни растений повсеместно ведут к потерям урожая, снижению качества сельскохозяйственной продукции и даже могут угрожать здоровью людей. В связи с этим сельхозтоваропроизводителям необходимы современные и эффективные инструменты для раннего обнаружения и идентификации болезней растений (Mahlein et al., 2019b). Традиционные методы диагностики, такие как визуальная экспертиза и микробиологический лабораторный анализ, являются высокзатратными по времени и человеческим ресурсам, что ограничивает возможность их применения в крупных сельскохозяйственных предприятиях.

В последние годы быстрыми темпами развиваются новые неинвазивные методы диагностики болезней растений с использованием сенсорных технологий, робототехники, компьютерного зрения и машинного обучения (Singh A. et al., 2016; Демидчик и др., 2020; Zheng et al., 2021). Они обладают высокой производительностью, позволяют получать данные в режиме реального времени и анализировать информацию о целом спектре физиологических параметров (Walter et al., 2015). Большое количество информации, получаемой от современных датчиков и сенсоров, трансформируется в новые знания с помощью компьютерной обработки данных и моделирования, сокращая расстояние от фундаментальной науки до практического применения результатов (Афонников и др., 2016; Tardieu et al., 2017). Такие подходы позволяют за счет автоматизации существенно ускорить процесс диагностики, увеличить его точность, устранив субъективизм, присущий человеку (Fahlgren et al., 2015; Lobos et al., 2017).

Новые цифровые технологии включают в себя анализ изображений в различных областях спектра. Регистрация изображений осуществляется при помощи таких оптических сенсоров, как гиперспектральные, термальные и RGB-камеры, сенсоры флуоресценции, томографы (Bock et al., 2010; Li L. et al., 2014).

Значительное развитие получили методы диагностики болезней растений на основе анализа гиперспектральных снимков (Mahlein, 2016; Mahlein et al., 2018; Дубровская и др., 2018). В базе данных Scopus за последние 15 лет зарегистрировано 412 научных публикаций по ключевым словам 'plant disease' и 'hyperspectral' (рис. 1). Гиперспектральный анализ соединяет в себе методы оптической спектроскопии и методы анализа изображений, позволяя одновременно оценивать как физиологические, так и морфологические параметры.

Цель данной публикации – предоставить читателю обзор современных технологий диагностики болезней растений на основе анализа гиперспектральных изображений. В первой части статьи рассматриваются главные принципы и инструментарий гиперспектральных технологий. Далее описываются алгоритмы и методы анализа гиперспектральных изображений. Затем приводится краткий обзор научных публикаций, посвященных данной тематике. И в заключение обсуждаются проблемы и перспективы использования новых технологий.

Основные принципы и инструментарий гиперспектральных технологий

Взаимодействие света (электромагнитного излучения) и растений

Свет может взаимодействовать с тканью растения следующими способами: отражение, рассеяние, поглощение и пропускание. Отражательная характеристика зависит от биохимического состава растительной ткани и от ее физических свойств (Mishra et al., 2017). Взаимодействие света и растений зависит также от длины волны. В видимом диапазоне длин волн (400–700 нм) поверхность растения имеет низкую отражательную способность в связи с поглощением света светочувствительными пигментами (хлорофиллами, антоцианами и каротиноидами). В ближнем инфракрасном диапазоне (700–1100 нм) коэффициент отражения повышается по причине рассеивания света в межклеточном пространстве. В диапазоне коротковолнового инфракрасного излучения (1100–2500 нм) здоровые растения имеют низкий коэффициент отражения из-за абсорбции света водой, белками и другими углеродными составляющими (Lowe et al., 2017). Зеленая окраска листа согласуется с характерным пиком отражения при длине волны 550 нм.

Спектральные профили здоровых и больных растений могут различаться. В результате воздействия биотических и абиотических стрессоров меняется биохимический состав растительных тканей, отражающийся в изменении цвета и формы листьев, скорости транспирации, морфологии растительного покрова и, следовательно, в спектральных характеристиках растений (Zhang J. et al., 2019). Более того, каждое индивидуальное взаимодействие растения и патогена имеет определенную пространственную и временную динамику, и данные процессы влияют на различные диапазоны электромагнитного спектра. Так,

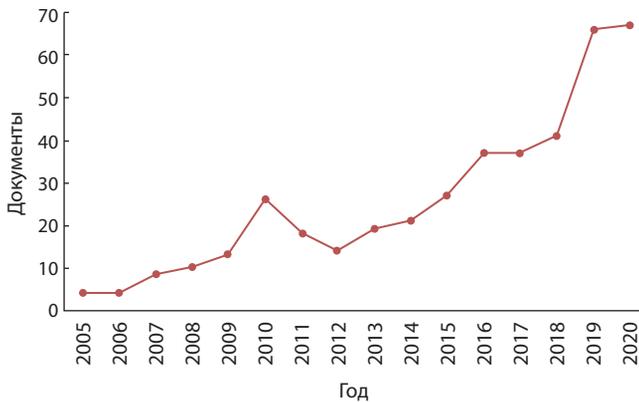


Рис. 1. Число опубликованных статей по диагностике болезней растений на основе анализа гиперспектральных изображений (Scopus).

например, изменение фотосинтетической активности, вызванное воздействием патогенов, сказывается на отражательной способности в видимом диапазоне спектра. Изменения на клеточном уровне оказывают большое влияние на ближний инфракрасный спектр. Некроз ткани приводит к увеличению отражения в диапазоне коротковолнового инфракрасного излучения (Zhang N. et al., 2020).

Таким образом, анализ спектральных характеристик, связанных с воздействием биотических и абиотических стрессоров, лежит в основе новых технологий диагностики болезней растений.

Гиперспектральные сенсоры и платформы

Базовый принцип гиперспектральных сенсоров сопоставим с принципом, лежащим в основе камер RGB и мультиспектральных камер (Thomas et al., 2018b). Все эти системы измеряют количество света, попадающего на датчик, и сохраняют информацию. В отличие от камер RGB (3 полосы спектра) и мультиспектральных камер (<20 полос), гиперспектральный сенсор измеряет до нескольких сотен полос электромагнитного спектра в диапазоне длин волн датчика. Каждая из этих спектральных полос составляет всего несколько нанометров электромагнитного спектра, что обеспечивает высокое спектральное разрешение.

Различают два основных типа сенсоров: датчики изображений и датчики, не формирующие изображения. Датчики, не формирующие изображения, измеряют средний спектр отражения в определенной области поверхности без сохранения пространственной информации. Размер

области усреднения зависит от величины фокусного расстояния, угла обзора и расстояния до объекта съемки. Большинство датчиков, не создающих изображения, являются портативными и не требуют сложных измерительных платформ. Они имеют широкий спектральный диапазон (300–2500 нм), высокое спектральное разрешение (1–3 нм) и небольшую массу (1–5 кг). Наиболее популярны среди них спектрометры ASD FieldSpec (Analytical Spectral Devices Inc., США), SVC (Spectral Vista Corporation, США), ImSpector (Spectral Imaging Ltd., Финляндия). Эти приборы обычно используют в лабораторных, тепличных и полевых условиях (Naidu et al., 2009; Zhang J. et al., 2017; Couture et al., 2018; Bohnenkamp et al., 2019; Mahlein et al., 2019a). Существуют также микроспектрометры, например STS-VIS spectrometer (Ocean Optics Inc., США), подходящие для применения с беспилотными летательными аппаратами (БПЛА) (Burkart et al., 2015). Поскольку ранние симптомы болезни растений часто появляются при размерах менее 1 мм, то их обнаружение с помощью спектрометров ограничено. Это связано с усреднением спектра здоровой и больной ткани в области измерения (Mahlein et al., 2012).

Гиперспектральные датчики изображения формируют спектральный профиль для каждого отдельного пикселя, тем самым комбинируя спектральное и пространственное разрешение. Результирующее изображение представляет собой трехмерный массив данных (гиперкуб), содержащий два измерения пространственной информации и дополнительно одно измерение спектральной информации. В зависимости от типа используемых сенсоров существуют четыре способа получения гиперкуба данных (рис. 2): точечное сканирование (whisk-broom), линейное сканирование (push-broom), сканирование спектра (spectral scanning) и снимок без сканирования (snapshot) (Wu, Sun, 2013).

Как правило, гиперспектральные датчики изображения охватывают ограниченный спектральный диапазон: VNIR (300–1000 нм) или SWIR (1000–2500 нм) со спектральным разрешением 1–7 нм. Пространственное разрешение варьируется от микрометров до сантиметров в зависимости от расстояния до объекта и характеристик сенсора.

В случае сенсоров точечного или линейного сканирования (whisk-broom, push-broom) для создания гиперспектрального изображения необходимо перемещать объект съемки или камеру для регистрации спектра каждой отдельной точки или линии. В научных исследованиях чаще других применяют сканирующие камеры марки Specim

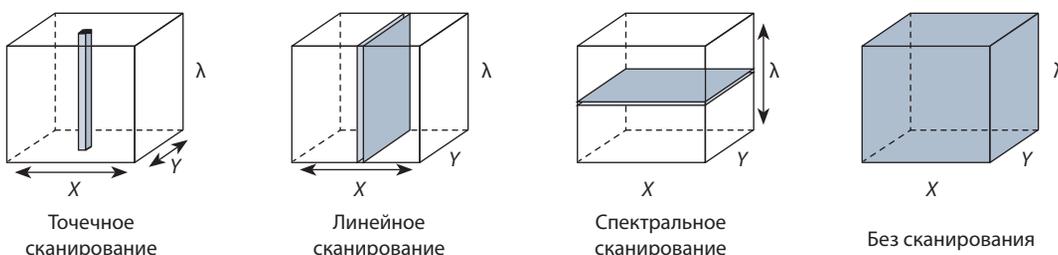


Рис. 2. Способы регистрации гиперспектральных изображений.

Направления сканирования показаны стрелками; серые области – данные, полученные за один проход.

(Spectral Imaging Ltd., Финляндия), Headwall (Headwall Hyperspec Ltd., Канада), Photonfocus (Photonfocus AG, Швейцария), Pika L (Resonon Inc., США). Большинство гиперспектральных сканирующих камер в лабораторных условиях устанавливают на специализированные подвижные платформы, обеспечивающие линейное перемещение и стабилизацию камеры (Leucker et al., 2016; Yeh et al., 2016). В тепличных условиях используют стационарные рельсовые системы (Thomas et al., 2018a), в полевых условиях – колесные транспортные средства (Vigneau et al., 2011; Williams et al., 2017) или БПЛА (Huang W. et al., 2007; Abdulridha et al., 2019). Недостатком сканирующих сенсоров является относительно длительное время получения изображения, зависящее от размера измеряемой области, что усложняет съемку подвижных объектов. Данный недостаток устранен в портативных камерах Specim IQ со встроенным сканером (Behmann et al., 2018; Альт и др., 2020; Barreto et al., 2020).

В сенсорах, основанных на принципе сканирования спектра (spectral scanning), используются LCTF-фильтры, которые пропускают только свет определенной длины волны, быстро меняющейся во время съемки (Choudhary et al., 2009; Wang et al., 2012). Эти сенсоры создают двумерные пространственные изображения для каждой длины волны в спектральном диапазоне. Работа с ними не требует перемещения объекта съемки или камеры для получения гиперкуба. Время получения изображения в основном зависит от времени экспонирования, вследствие чего регистрация изображения происходит быстрее, чем при точечном или линейном сканировании. Если объект движется, то такой принцип измерения может привести к несогласованным спектрам, поскольку отдельные полосы наблюдаются в разные моменты времени.

Недавно были разработаны сенсоры, не требующие сканирования объекта для получения гиперспектрального изображения (snapshot). В них задействован принцип мозаики обычных RGB камер. Данные сенсоры обеспечивают значительно более высокую скорость записи изображений, но более низкое пространственное разрешение по сравнению с традиционными. Известные камеры такого типа: Rikola, Senop (Senop Ltd., Финляндия), Ultris, FireFleye (Cubert Ltd., Канада). Компактный размер, короткое время съемки и возможность создания последовательностей гиперспектральных изображений движущегося объекта делают их оптимальными для использования на БПЛА (Aasen et al., 2015; Sankaran et al., 2015; Franceschini et al., 2019).

Алгоритмы и методы анализа гиперспектральных изображений

Извлечение информации из гиперспектральных изображений, характеризующихся огромным объемом данных с высокой степенью коллинеарности, является очень сложной и новой задачей, требующей нетривиальных решений. В настоящее время для этих целей успешно адаптированы методы дискриминантного и кластерного анализа, машинного обучения, нейронных сетей (ElMasry, Nakauchi, 2016; Lowe et al., 2017).

Для обработки данных применяют специализированное программное обеспечение: ENVI (Research Systems Inc.);

MATLAB (The Math-Works Inc.); Python (Python Software Foundation); R (R Software Foundation).

Процесс анализа гиперспектральных изображений, как правило, состоит из следующих этапов (рис. 3): получение и предварительная обработка изображения; извлечение и обработка данных; моделирование и анализ данных.

Получение и предварительная обработка изображения

Первый и важный шаг в анализе болезней растений – это получение высококачественных гиперспектральных изображений, отвечающих задачам исследований. Правильный выбор сенсоров и платформ, пространственного и спектрального разрешения, схемы освещения, скорости сканирования, частоты кадров и времени экспозиции является предпосылкой для получения точных результатов (Wu, Sun, 2013).

Следующий шаг – предварительная обработка изображения, включающая в себя калибровку и коррекцию спектра. Калибровка проводится для стандартизации спектральных и пространственных осей, повышения точности, обеспечения воспроизводимости данных в различных условиях эксперимента, устранения эффекта кривизны поверхности съемки, устранения приборных ошибок (Rinnan et al., 2009; Vidal, Amigo, 2012). Стандартным приемом является калибровка отражения, для которой используют два эталонных спектра: «черный» и «белый». «Черный» спектр получают, закрыв объектив камеры непрозрачной крышкой. «Белый» спектр регистрируется с помощью стандартной белой поверхности (например, из тефлона) с коэффициентом отражения около 99.9 % для получения максимально возможной интенсивности каждого пикселя на каждой длине волны. Затем исходное гиперспектральное изображение калибруется по формуле

$$R = \frac{I_S - I_D}{I_W - I_D},$$

где I_S – исходное изображение; I_D и I_W – темное и белое эталонное изображение соответственно; R – результирующее изображение.

Для устранения эффекта кривизны поверхности при калибровке применяют спектральную нормализацию изображения (Polder et al., 2004), адаптивное сферическое преобразование (Tao, Wen, 1999) или преобразование Ламберта (Gomez-Sanchis et al., 2008).

Целью корректировки спектра является улучшение качества изображения (Savitzky, Golay, 1964; Barnes et al., 1989; Burger, 2006; Esquerre et al., 2012). Так, например, алгоритмы сглаживания (скользящее среднее, фильтр Савицкого–Голея, медианный фильтр, фильтр Гаусса), а также преобразования Фурье и вейвлет-преобразования используют для уменьшения шума в спектральных данных. Первую и вторую производные – для коррекции сдвига базовой линии спектра. Для коррекции рассеивания применяют нормализацию стандартным преобразованием или мультипликативную коррекцию рассеивания.

Извлечение и обработка данных

На этом этапе выполняют сегментацию изображения и производят выбор информативных признаков для дальнейшего анализа.

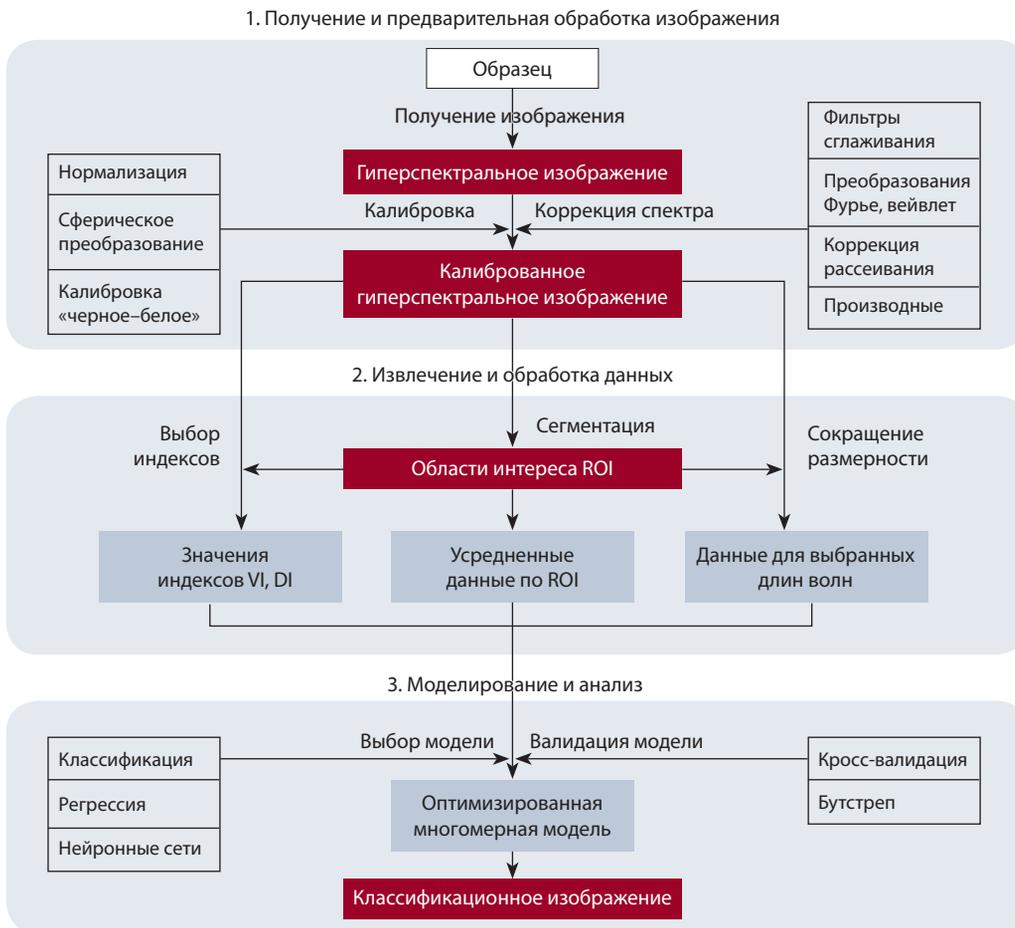


Рис. 3. Схема типичного процесса анализа гиперспектральных изображений.

Сегментация изображения используется в качестве этапа предварительной обработки данных и обычно выполняется перед спектральным анализом для выделения целевых объектов из фона и формирования областей интересов (ROI). Известны следующие методы сегментации:

- по пороговому значению (threshold-based) (Pandey et al., 2017);
- методы кластеризации (K-means) (Behmann et al., 2014);
- алгоритм водораздела (watershed algorithm) (Li J. et al., 2019);
- методы обнаружения края (edge detection) (Sun et al., 2017; Williams et al., 2017).

Выбор информативных признаков является одним из наиболее важных шагов в процессе анализа гиперспектральных изображений. Его цель – извлечение и формирование новых векторов признаков путем комбинирования и оптимизации спектральных, пространственных и текстурных характеристик, а затем их передачи в набор классификаторов или алгоритмов машинного обучения.

В качестве информативных признаков могут выступать вегетационные индексы (VI) или индексы заболеваемости (DI) (Huete et al., 2002; Gitelson et al., 2006; Mahlein et al., 2013; Candiago et al., 2015). В этом случае требуется только небольшое количество длин волн для анализа. При анализе всего спектра используют методы для сокращения

размерности и устранения автокорреляций (Steddom et al., 2003; Delalieux et al., 2007; Naidu et al., 2009; Moshou et al., 2011; Yuan et al., 2014b; Zhou et al., 2019):

- метод главных компонент (principal component analysis);
- алгоритм минимизации шума (minimum noise fraction algorithm);
- линейный дискриминантный анализ (linear discriminant analysis);
- пошаговый дискриминантный анализ (stepwise discriminant analysis);
- дискриминантный анализ частных наименьших квадратов (partial least square discriminant analysis).

Моделирование и анализ данных

На последнем этапе анализа изображений производят выбор модели и применение ее к данным. В зависимости от целей исследования это могут быть классификационные модели (для диагностики и дифференциации болезней) либо регрессионные модели (для прогнозирования и оценки взаимосвязи между целевыми переменными и спектральным откликом).

Наиболее распространенные модели:

- классификационные модели, использующие алгоритмы машинного обучения и нейронные сети (Moshou et al., 2004; Liu et al., 2010; Rumpf et al., 2010; Yeh et al.,

2013; Li Y. et al., 2017). Методы: спектрального угла (spectral angle mapper), опорных векторов (support vector machine), k -ближайших соседей (k -nearest neighbor), максимального правдоподобия (maximum likelihood classifier);

- регрессионные (Huang W. et al., 2007; Singh D. et al., 2007; Yang et al., 2007; Huang J. et al., 2012): множественная линейная регрессия (multiple linear regression), бинарная логистическая регрессия (binary logistic regression), частичная регрессия наименьших квадратов (partial least squares regression), регрессия агрегирования Дирихле (Dirichlet aggregation regression).

Области применения гиперспектральных технологий в диагностике болезней растений

Основными задачами при диагностике болезней растений являются: обнаружение болезни, дифференциация и идентификация типа заболевания, оценка степени поражения, оценка устойчивости генотипов. Данные задачи решаются на различных уровнях организации живых систем в соответствующих им масштабах измерений.

Измерения на клеточном уровне или в масштабе растительной ткани выполняют в лабораторных условиях с использованием гиперспектральных микроскопов, позволяющих наблюдать за грибковыми спорами и выявлять метаболические изменения в тканях, вызванные взаимодействием растений и патогенов. Такие эксперименты обычно проводят в контексте фундаментальных исследований и в определенной степени для идентификации патогенов и оценки устойчивости генотипов.

Измерения на уровне отдельных органов (лист, колос, стебель, корень, плод) или целого растения проводят в лабораторных, тепличных или полевых условиях с целью раннего обнаружения и дифференциации заболевания.

Измерения в масштабе растительного покрова решают задачи выявления заболевания и количественной оценки степени поражения растений.

Далее приводится краткий обзор научных публикаций, посвященных решению основных задач в диагностике болезней растений с использованием гиперспектральных технологий (см. таблицу).

Обнаружение болезней

При обнаружении болезней необходимо дифференцировать здоровые и зараженные растения. Предметом исследования при этом является только одно конкретное заболевание, его различные состояния, симптомы и динамика.

Сравнение возможностей применения различных сенсоров для раннего обнаружения фузариоза (*Fusarium graminearum*, *F. culmorum*) колоса пшеницы рассмотрено в работе (Mahlein et al., 2019a). Опыты проводились в контролируемых лабораторных условиях с использованием инфракрасной термографии, сенсоров флуоресценции хлорофилла и гиперспектральных изображений. Инфракрасная термография позволила визуализировать разницу температур внутри инфицированных колосков, начиная с 5-го дня после инокуляции растений. Также на 5-й день было подтверждено нарушение фотосинтетической активности, выраженное изменением флуоресценции хлоро-

филла колосков. Пигмент-специфическое простое соотношение, полученное на основе гиперспектральных изображений в диапазоне длин волн 400–2500 нм, позволило различать колоски, инфицированные *Fusarium*, и неинфицированные уже на 3-й день. Для классификации использовался метод опорных векторов (SVM). Точность классификации составляла 78 % для термографии, 56 % для флуоресценции хлорофилла и 78 % для гиперспектральных изображений.

В работе (Abdulridha et al., 2019) сравниваются два способа обнаружения язвенной болезни цитрусовых (*Xanthomonas citri*) на основе гиперспектральных изображений: съемка в лабораторных условиях и дистанционное зондирование с использованием БПЛА. В лаборатории гиперспектральный (400–1000 нм) сенсор применялся для выявления язвы цитрусовых на нескольких стадиях развития заболевания (бессимптомная, ранние и поздние симптомы) на листьях и незрелых плодах с использованием двух методов классификации: радиальной базисной функции (RBF) и k -ближайших соседей (KNN). Тот же сенсор, установленный на БПЛА, применялся для обнаружения язвы цитрусовых на кронах деревьев в полевых условиях. Общая точность классификации RBF была выше (94, 96 и 100 %), чем у метода KNN (94, 95 и 96 %), при выявлении язвы на листьях в лаборатории. Дистанционное зондирование с использованием БПЛА позволило достичь 100 % точности классификации для обнаружения здоровых и зараженных язвой деревьев. Среди 31 изученного вегетационного индекса более точно выявляют язвы в лабораторных и полевых условиях соответственно водный индекс (WI) и модифицированный индекс абсорбции хлорофилла (TCARI). Предложенная методика также успешно распознала плоды, инфицированные язвой, на поздней стадии (точность классификации 92 %).

Идентификация болезней

При идентификации болезней важно определить тип патогена, воздействующего на растение. Предметом исследования являются несколько видов заболеваний, их отличительные черты.

Для дифференциации болезней сельскохозяйственных культур А.-К. Mahlein с коллегами (Mahlein et al., 2013) предложили использовать специфические «спектральные индексы болезней». Модельной системой служили растения сахарной свеклы и три болезни листьев: пятнистость листьев *Cercospora*, ржавчина сахарной свеклы и мучнистая роса. Спектральный профиль здоровых и больных листьев сахарной свеклы регистрировали с помощью спектрорадиометра без визуализации на разных стадиях развития и степени поражения. Наиболее значимые длины волн и двухполосные нормализованные разности, описывающие влияние болезни на спектр отражения листьев, были извлечены из набора данных с использованием алгоритма RELIEF-F. Спектральный индекс болезни определялся подбором наилучшей взвешенной комбинации одной длины волны и нормализованной разности длин волн. Оптимизированные индексы болезней были протестированы. С высокой точностью и чувствительностью были классифицированы здоровые листья и листья сахарной свеклы, пораженные пятнистостью листьев *Cercospora*,

Использование гиперспектральных изображений для диагностики болезней растений в научной литературе

Цель	Культура	Болезнь	Масштаб/сенсор/платформа	Методы и алгоритмы	Литературный источник
Обнаружение	Пшеница	Фузариоз	Колос/ ImSpector V10E, N25E/ подвижная платформа	Опорных векторов (SVM)	Mahlein et al., 2019a
	Цитрусовые	Язвенная болезнь цитрусовых	Крона/ Pika L/ БПЛА	Вегетационные индексы, <i>k</i> -ближайших соседей (KNN), нейронные сети	Abdulridha et al., 2019
	Лук	Кислая бактериальная гниль чешуек лука (<i>Burkholderia cepacia</i>)	Луковица/ SU320KTS-1.7RT SWIR камера, LCTF-фильтр/ штатив	Главных компонент (PCA), пошаговый дискриминантный анализ (SDA)	Wang et al., 2012
	Сахарная свекла	Корнеед свеклы (<i>Rhizoctonia solani</i>)	Растение/ Specim IQ/ штатив	<i>k</i> -ближайших соседей (KNN), частичных наименьших квадратов (PLSR), случайный лес (RF), опорных векторов (SVM)	Barreto et al., 2020
Идентификация	Сахарная свекла	Пятнистость листьев <i>Cercospora</i> , ржавчина сахарной свеклы, мучнистая роса	Лист/ ASD FieldSpec Pro/ штатив	Спектральные индексы болезней, алгоритм RELIEF-F	Mahlein et al., 2013
Дифференциация	Пшеница	Бурая ржавчина, желтая ржавчина	Лист/ ImSpector V10E/ подвижная платформа	Наименьших квадратов (LSR)	Bohnenkamp et al., 2019
		Желтая ржавчина, мучнистая роса, пшеничная тля	Лист/ ASD FieldSpec/ штатив	Частичных наименьших квадратов (PLSR), линейный дискриминантный анализ Фишера (FLDA)	Yuan et al., 2014a
		Фузариоз (<i>F. graminearum</i> , <i>F. culmorum</i>)	Колос/ ImSpector V10E, ImSpector N25E/ подвижная платформа	Вегетационные индексы, опорных векторов (SVM)	Alisaac et al., 2018
Оценка степени поражения	Ячмень	Мучнистая роса	Растительный покров (делянка)/ Specim V10E/ рельсовая система	Опорных векторов (SVM), матричная факторизация (SiVM)	Thomas et al., 2018a
	Картофель	Фитофтороз картофеля	Растительный покров (делянка)/ Rikola/ БПЛА	Максимизация симплексного объема (SiVM)	Franceschini et al., 2019
	Огурец	Угловатая пятнистость	Лист/ ImSpector V10/ подвижная платформа	Частичных наименьших квадратов (PLSR)	Zhao et al., 2016
	Пшеница	Мучнистая роса	Лист/ ASD FieldSpec/ штатив	Частичных наименьших квадратов (PLSR), многомерная линейная регрессия (MLR)	Zhang J. et al., 2012
	Томат	Бактериоз (<i>Pseudomonas cichorii</i>)	Лист/ Hyperspec Headwall/ подвижная платформа	Главных компонент (PCA)	Rajendran et al., 2016
Оценка устойчивости генотипов	Сахарная свекла	Пятнистость листьев <i>Cercospora</i>	Лист/ ImSpector V10E/ подвижная платформа	Вегетационные индексы	Leucker et al., 2016
	Виноград	Ложная мучнистая роса винограда	Лист/ ASD AgriSpec spectrometer, ImSpector V10E/ подвижная платформа	Вегетационные индексы	Oerke et al., 2016
	Ячмень	Мучнистая роса	Клетки, ткань/ Specim V10E камера, Z6 APO микроскоп/ подвижная платформа	Максимизация симплексного объема (SiVM)	Kuska et al., 2015

ржавчиной и мучнистой росой (точность классификации 89, 92, 87 и 85 % соответственно).

В работе (Bohnenkamp et al., 2019) предложен новый метод обнаружения и дифференциации бурой ржавчины (*Puccinia triticina*) и желтой ржавчины (*P. striiformis*) пшеницы с использованием гиперспектральных изображений. Эксперимент проводился в масштабе листа в контролируемых лабораторных условиях. Для создания обучающей выборки были взяты эталонные спектры спор возбудителей бурой и желтой ржавчины. Факторизация методом наименьших квадратов применялась для выявления присутствия спектрального сигнала спор ржавчины в смешанных спектрах листьев пшеницы. Это исследование демонстрирует интерпретируемое разложение смеси спектральных коэффициентов отражения во время патогенеза.

Оценка степени поражения

Количественная диагностика степени поражения растений болезнью – одно из важных направлений гиперспектральных исследований. Основными критериями оценки серьезности заболевания являются интенсивность поражения и распространенность. Кроме того, в зависимости от патогенов и симптомов, которые они вызвали, часто рассматриваются как косвенные критерии оценки содержание пигментов, содержание воды и структурные параметры.

Y.-R. Zhao с коллегами (Zhao et al., 2016) использовали метод гиперспектральной визуализации для определения пространственного распределения содержания хлорофилла и каротиноидов в листьях огурца, зараженных угловатой пятнистостью. Содержание пигментов было установлено с помощью биохимических анализов. Для пяти степеней поражения были построены модели регрессии по методу частичных наименьших квадратов (PLSR) и проведен количественный анализ взаимосвязи между степенью поражения, спектром и содержанием пигментов. Затем были выбраны оптимальные длины волн для моделей. И наконец, распределения хлорофилла и каротиноидов в листьях огурца были картированы по пикселям путем применения оптимальных моделей к гиперспектральным изображениям.

В исследовании (Zhang J. et al., 2012) степень поражения листьев пшеницы мучнистой росой оценивалась на основе спектрального анализа. Гиперспектральные коэффициенты отражения нормальных листьев и листьев, пораженных мучнистой росой, измеряли с помощью спектрометра в лаборатории. Степень поражения определяли по девятибалльной шкале индекса заболевания. В общей сложности 32 спектральных индекса были рассчитаны и исследованы с помощью корреляционного анализа и независимого t-критерия. Две модели регрессии – многомерная линейная регрессия (MLR) и регрессия по методу частичных наименьших квадратов (PLSR) – применялись для оценки степени поражения мучнистой росой. По результатам кросс-валидации были отобраны семь спектральных индексов, минимизирующих относительную среднеквадратичную ошибку. Модель PLSR превзошла модель MLR с относительной среднеквадратичной ошибкой 0.23 и коэффициентом детерминации 0.80 при использовании семи выбранных индексов.

Оценка устойчивости генотипов

Анализ взаимодействия «патоген–хозяин» позволяет определить устойчивость генотипов к конкретному заболеванию и считается важной частью селекционной работы. В селекционной практике фенотипирование генотипов растений осуществляется путем трудоемкой и дорогостоящей визуальной оценки. В этом контексте гиперспектральный анализ является многообещающим неинвазивным методом для ускорения и автоматизации классических методов фенотипирования.

В работе (Leucker et al., 2016) оценивалась устойчивость пяти генотипов сахарной свеклы к пятнистости листьев *Cercospora*. Эксперимент проводился в контролируемых лабораторных условиях. Степень поражения листьев оценивали классическими количественными и качественными методами в сочетании с гиперспектральным анализом. Установлено, что спектральные характеристики пораженных участков листьев зависят от плотности спор патогена на поверхности и от их пространственного распределения, вследствие чего возможна дифференциация по степени поражения для устойчивых и неустойчивых к заболеванию генотипов. Оценка степени поражения на основе гиперспектрального анализа споруляции может быть подходящим методом для выявления тонких различий генотипов в устойчивости к болезням.

М.Т. Kuska с коллегами (Kuska et al., 2015) использовали гиперспектральный микроскоп для определения устойчивости сортов ячменя к мучнистой росе (*Blumeria graminis*). Спектр отражения инокулированных и неинокулированных листьев регистрировали ежедневно в видимом (400–700 нм) и ближнем инфракрасном (700–1000 нм) диапазоне с 3-го по 14-й день после инокуляции. Восприимчивые к патогену генотипы показали увеличение отражательной способности в видимом диапазоне в соответствии с развитием симптомов заболевания, в то время как спектральная характеристика устойчивого генотипа не претерпела значительных изменений за экспериментальный период.

Проблемы и перспективы применения гиперспектральных технологий для диагностики болезней растений

Несмотря на обнадеживающий прогресс, достигнутый за последние несколько десятилетий в мониторинге болезней растений на основе гиперспектральных технологий, все еще остаются некоторые проблемы, препятствующие применению данных методов на практике. И будущие тенденции будут определяться поиском их решения.

Одной из таких проблем является раннее обнаружение болезней растений в полевых условиях. В настоящее время в сельскохозяйственном производстве широко применяются низковысотные, бортовые и спутниковые мультиспектральные системы для мониторинга состояния растительного покрова на основе вегетационных индексов (Hatfield, Pinter, 1993; Huang Y.B. et al., 2013). Однако надежный мониторинг обычно достигается только при полном проявлении симптомов, что может быть слишком поздно для принятия мер по профилактике. В научных исследованиях по использованию гиперспектральных сенсоров для раннего обнаружения болезней растений по-

лучены значительные результаты, тем не менее их практическое применение в полевых и тепличных условиях в системах точного земледелия является еще не решенной задачей.

Связано это с тем, что большинство научных исследований по данной теме проводится в контролируемых условиях, часто с искусственным освещением и точным регулированием направлений входящего и отраженного света, регистрируемого путем размещения камеры или датчика под определенным углом к ткани листа. Условия освещения в поле сильно отличаются от лабораторных, что создает огромные трудности для надежной диагностики болезней. Области растительного покрова, расположенные на солнце, кажутся намного ярче, чем расположенные в тени. Спектральные характеристики зависят также от угла наклона объекта съемки по отношению к входящему и отраженному солнечному свету. Неоднородности в яркости изображения меняются каждую минуту. Следовательно, при установке порога для различения здоровой и пораженной ткани необходимо учитывать общую яркость конкретного изображения в данном месте и угол падения света, что является предметом интенсивных исследований (Guo et al., 2013; Yu et al., 2017).

Другая проблема заключается в том, чтобы точно определить конкретное заболевание в реальных условиях, когда на культуру одновременно воздействуют несколько стрессоров. Сейчас большинство мониторинговых исследований проводится на экспериментальных полях, где предварительно известен тип патогена. Когда же такая информация отсутствует, сложно добиться надежного и точного результата. Многие патогены, а также абиотические стрессоры имеют похожую симптоматику и, соответственно, близкую спектральную сигнатуру. Некоторые современные алгоритмы, такие как алгоритмы глубокого обучения, могут сыграть важную роль в дифференциации биотических и абиотических стрессоров в полевых и тепличных условиях (Liu et al., 2010; Mahlein et al., 2019b). Кроме того, необходимо создавать базу знаний о болезнях растений (например, о географическом распространении, благоприятных средах обитания, типах почв, климатических условиях), поскольку предварительная информация поможет снизить неопределенность при мониторинге болезней.

Заключение

Болезни растений приводят к значительным экономическим потерям в секторе сельскохозяйственного производства во всем мире, особенно под воздействием климатических изменений, происходящих в последние годы. Многообещающей технологией для неинвазивного быстрого, эффективного и надежного способа обнаружения и идентификации болезней растений является использование гиперспектральных сенсоров и платформ.

Новые технологии расширяют возможности человеческого восприятия, предоставляя информацию за пределами видимого диапазона спектра. Анализ спектра отражения растительной ткани позволяет проводить классификацию здоровых и больных растений, оценивать тяжесть заболевания, дифференцировать виды патогенов и обнаруживать симптомы биотических стрессов на ран-

них стадиях, в том числе в инкубационный период, когда симптомы не видны человеческому глазу.

В связи с большим объемом информации наиболее перспективными методами для обработки гиперспектральных данных являются машинное обучение и нейронные сети. В настоящее время гиперспектральные методы диагностики болезней растений находятся на начальной стадии разработки. Помимо того, что это дорогостоящая технология, существует множество технических трудностей, ограничивающих ее применение в производственном процессе. Однако с развитием сенсорных технологий и методов анализа данных можно ожидать, что гиперспектральная визуализация станет одним из важных инструментов для изучения болезней растений.

Список литературы / References

- Альт В.В., Гурова Т.А., Елкин О.В., Клименко Д.Н., Максимов Л.В., Пестунов И.А., Дубровская О.А., Генаев М.А., Эрст Т.В., Генаев К.А., Комышев Е.Г., Хлесткин В.К., Афонников Д.А. Использование гиперспектральной камеры Specim IQ для анализа растений. *Вавиловский журнал генетики и селекции*. 2020;24(3):259-266. DOI 10.18699/VJ19.587.
- [Alt V.V., Gurova T.A., Elkin O.V., Klimenko D.N., Maximov L.V., Pestunov I.A., Dubrovskaya O.A., Genaev M.A., Erst T.V., Genaev K.A., Komyshev E.G., Khlestkin V.K., Afonnikov D.A. The use of Specim IQ, a hyperspectral camera, for plant analysis. *Vavilovskii Zhurnal Genetiki i Selekcii = Vavilov Journal of Genetics and Breeding*. 2020;24(3):259-266. DOI 10.18699/VJ19.587. (in Russian)]
- Афонников Д.А., Генаев М.А., Дорошков А.В., Комышев Е.Г., Пшеничникова Т.А. Методы высокопроизводительного фенотипирования растений для массовых селекционно-генетических экспериментов. *Генетика*. 2016;52(7):788-803. DOI 10.7868/S001667581607002X.
- [Afonnikov D.A., Genaev M.A., Doroshkov A.V., Komyshev E.G., Pshenichnikova T.A. Methods of high-throughput plant phenotyping for large-scale breeding and genetic experiments. *Russ. J. Genet*. 2016;52(7):688-701. DOI 10.1134/S1022795416070024.]
- Демидчик В.В., Шашко А.Ю., Бондаренко В.Ю., Смоликова Г.Н., Пржевальская Д.А., Черныш М.А., Пожванов Г.А., Барковский А.В., Смолич И.И., Соколик А.И., Медведев С.С. Феномика растений: фундаментальные основы, программно-аппаратные платформы и методы машинного обучения. *Физиология растений*. 2020;67(3):227-245. DOI 10.31857/S0015330320030069.
- [Demidchik V.V., Shashko A.Yu., Bondarenko V.Yu., Smolikova G.N., Przhevalskaya D.A., Chernysh M.A., Pozhvanov G.A., Barkovskij A.V., Smolich I.I., Sokolik A.I., Medvedev S.S. Plant phenomics: fundamental bases, software and hardware platforms, and machine learning. *Russ. J. Plant Physiol*. 2020;67(3):397-412. DOI 10.1134/S1021443720030061.]
- Дубровская О.А., Гурова Т.А., Пестунов И.А., Котов К.Ю. Методы обнаружения болезней на посевах пшеницы по данным дистанционного зондирования (обзор). *Сиб. вестн. с.-х. науки*. 2018; 48(6):76-89. DOI 10.26898/0370-8799-2018-6-11.
- [Dubrovskaya O.A., Gurova T.A., Pestunov I.A., Kotov K.Yu. Methods of detection of diseases on wheat crops according to remote sensing (overview). *Sibirskii Vestnik Sel'skokhozyaistvennoi Nauki = Siberian Herald of Agricultural Science*. 2018;48(6):76-89. DOI 10.26898/0370-8799-2018-6-11. (in Russian)]
- Aasen H., Burkhart A., Bolten A., Bareth G. Generating 3D hyperspectral information with lightweight UAV snapshot cameras for vegetation monitoring: from camera calibration to quality assurance. *ISPRS J. Photogramm. Remote Sens*. 2015;108:245-259. DOI 10.1016/j.isprsjprs.2015.08.002.
- Abdulridha J., Batuman O., Ampatzidis Y. UAV-based remote sensing technique to detect citrus canker disease utilizing hyperspectral

- imaging and machine learning. *Remote Sens.* 2019;11:1373. DOI 10.3390/rs11111373.
- Alisaac E., Behmann J., Kuska M.T., Dehne H.-W., Mahlein A.-K. Hyperspectral quantification of wheat resistance to *Fusarium* head blight: comparison of two *Fusarium* species. *Eur. J. Plant Pathol.* 2018;152:869-884. DOI 10.1007/s10658-018-1505-9.
- Barnes R., Dhanoa M., Lister S.J. Standard normal variate transformation and de-trending of near-infrared diffuse reflectance spectra. *Appl. Spectrosc.* 1989;43:772-777. DOI 10.1366/0003702894202201.
- Barreto A., Paulus S., Varrelmann M., Mahlein A.-K. Hyperspectral imaging of symptoms induced by *Rhizoctonia solani* in sugar beet: comparison of input data and different machine learning algorithms. *J. Plant Dis. Prot.* 2020;127:441-451. DOI 10.1007/s41348-020-00344-8.
- Behmann J., Acebron K., Emin D., Bennertz S., Matsubara S., Thomas S., Bohnenkamp D., Kuska M.T., Jussila J., Salo H., Mahlein A.-K., Rascher U. Specim IQ: evaluation of a new, miniaturized handheld hyperspectral camera and its application for plant phenotyping and disease detection. *Sensors.* 2018;18:441. DOI 10.3390/s18020441.
- Behmann J., Steinucken J., Plumer L. Detection of early plant stress responses in hyperspectral images. *ISPRS J. Photogramm. Remote Sens.* 2014;93:98-111. DOI 10.1016/j.isprsjprs.2014.03.016.
- Bock C.H., Poole G.H., Parker P.E., Gottwald T.R. Plant disease severity estimated visually, by digital photography and image analysis, and by hyperspectral imaging. *Crit. Rev. Plant Sci.* 2010;29:59-107. DOI 10.1080/07352681003617285.
- Bohnenkamp D., Kuska M.T., Mahlein A.-K., Behmann J. Hyperspectral signal decomposition and symptom detection of wheat rust disease at the leaf scale using pure fungal spore spectra as reference. *Plant Pathol.* 2019;68:1188-1195. DOI 10.1111/ppa.13020.
- Burger J. Hyperspectral NIR image analysis. Data Exploration, Correction, and Regression. Doctoral Dissertation. Arkitektkopia, Umea, Sweden, 2006.
- Burkart A., Aasen H., Alonso L., Menz G., Bareth G., Rascher U. Angular dependency of hyperspectral measurements over wheat characterized by a novel UAV based goniometer. *Remote Sens.* 2015;7(1):725-746. DOI 10.3390/rs70100725.
- Candiago S., Remondino F., De Giglio M., Dubbini M., Gattelli M. Evaluating multispectral images and vegetation indices for precision farming applications from UAV images. *Remote Sens.* 2015;7(4):4026-4047. DOI 10.3390/rs70404026.
- Choudhary R., Mahesh S., Paliwal J., Jayas D.S. Identification of wheat classes using wavelet features from near infrared hyperspectral images of bulk samples. *Biosyst. Eng.* 2009;102(2):115-127. DOI 10.1016/j.biosystemseng.2008.09.028.
- Couture J.J., Singh A., Charkowski A.O., Groves R.L., Gray S.M., Bethke P.C., Townsend P.A. Integrating spectroscopy with potato disease management. *Plant Dis.* 2018;102:2233-2240. DOI 10.1094/PDIS-01-18-0054-RE.
- Delalieux S., van Aardt J., Keulemans W., Schrevels E., Coppin P. Detection of biotic stress (*Venturia inaequalis*) in apple trees using hyperspectral data: non-parametric statistical approaches and physiological implications. *Eur. J. Agron.* 2007;27:130-143. DOI 10.1016/j.eja.2007.02.005.
- ElMasry G.M., Nakauchi S. Image analysis operations applied to hyperspectral images for non-invasive sensing of food quality – a comprehensive review. *Biosyst. Eng.* 2016;142:53-82. DOI 10.1016/j.biosystemseng.2015.11.009.
- Esquerre C., Gowen A.A., Burger J., Downey G., O'Donnell C.P. Suppressing sample morphology effects in near infrared spectral imaging using chemometric data pre-treatments. *Chemom. Intell. Lab. Syst.* 2012;117:129-137. DOI 10.1016/j.chemolab.2012.02.006.
- Fahlgren N., Gehan M.A., Baxte I. Lights, camera, action: high-throughput plant phenotyping is ready for a close-up. *Curr. Opin. Plant Biol.* 2015;24:93-99. DOI 10.1016/j.pbi.2015.02.006.
- Franceschini M.H.D., Bartholomeus H., van Apeldoorn D.F., Suomalainen J., Kooistra L. Feasibility of unmanned aerial vehicle optical imagery for early detection and severity assessment of late blight in potato. *Remote Sens.* 2019;11:224. DOI 10.3390/rs11030224.
- Gitelson A.A., Keydan G.P., Merzlyak M.N. Three-band model for noninvasive estimation of chlorophyll, carotenoids, and anthocyanin contents in higher plant leaves. *Geophys. Res. Lett.* 2006;33(11):L11402. DOI 10.1029/2006GL026457.
- Gomez-Sanchis J., Molto E., Camps-Valls G., Gomez-Chova L., Aleixos N., Blasco J. Automatic correction of the effects of the light source on spherical objects. An application to the analysis of hyperspectral images of citrus fruits. *J. Food Eng.* 2008;85(2):191-200. DOI 10.1016/j.jfoodeng.2007.06.036.
- Guo W., Rage U.K., Ninomiya S. Illumination invariant segmentation of vegetation for time series wheat images based on decision tree model. *Comput. Electron. Agric.* 2013;96:58-66. DOI 10.1016/j.compag.2013.04.010.
- Hatfield J.L., Pinter P.J. Remote-sensing for crop protection. *Crop. Prot.* 1993;12:403-413. DOI 10.1016/0261-2194(93)90001-Y.
- Huang J., Liao H., Zhu Y., Sun J., Sun Q., Liu X. Hyperspectral detection of rice damaged by rice leaf folder (*Cnaphalocrocis medinalis*). *Comput. Electron. Agric.* 2012;82:100-107. DOI 10.1016/j.compag.2012.01.002.
- Huang W., Lamb D.W., Niu Z., Zhang Y., Liu L., Wang J. Identification of yellow rust in wheat using in-situ spectral reflectance measurements and airborne hyperspectral imaging. *Precis. Agric.* 2007;8:187-197. DOI 10.1007/s11119-007-9038-9.
- Huang Y.B., Thomson S.J., Hoffmann W.C., Lan Y.B., Fritz B.K. Development and prospect of unmanned aerial vehicle technologies for agricultural production management. *Int. J. Agric. Biol. Eng.* 2013;6(3):1-10. DOI 10.3965/j.ijabe.20130603.001.
- Huete A., Didan K., Miura T., Rodriguez E.P., Gao X., Ferreira L.G. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sens. Environ.* 2002;83(1):195-213. DOI 10.1016/S0034-4257(02)00096-2.
- Kuska M.T., Wahabzada M., Leucker M., Dehne H.-W., Kersting K., Oerke E.-C., Steiner U., Mahlein A.-K. Hyperspectral phenotyping on the microscopic scale: towards automated characterization of plant-pathogen interactions. *Plant Methods.* 2015;11:28-41. DOI 10.1186/s13007-015-0073-7.
- Leucker M., Mahlein A.-K., Steiner U., Oerke E.-C. Improvement of lesion phenotyping in *Cercospora beticola* – sugar beet interaction by hyperspectral imaging. *Phytopatology.* 2016;106:177-184. DOI 10.1094/PHYTO-04-15-0100-R.
- Li J., Zhang R., Li J., Wang Z., Zhang H., Zhan B., Jiang Y. Detection of early decayed oranges based on multispectral principal component image combining both bi-dimensional empirical mode decomposition and watershed segmentation method. *Postharvest Biol. Technol.* 2019;158:110986-110996. DOI 10.1016/j.postharvbio.2019.110986.
- Li L., Zhang Q., Huang D. A review of imaging techniques for plant phenotyping. *Sensors.* 2014;14:20078-20111. DOI 10.3390/s141120078.
- Li Y., Zhang H., Shen Q. Spectral-spatial classification of hyperspectral imagery with 3D convolutional neural network. *Remote Sens.* 2017;9:67. DOI 10.3390/rs9010067.
- Liu Z.-Y., Wu H.-F., Huang J.-F. Application of neural networks to discriminate fungal infection levels in rice panicles using hyperspectral reflectance and principal components analysis. *Comput. Electron. Agric.* 2010;72:99-106. DOI 10.1016/j.compag.2010.03.003.
- Lobos G.A., Camargo A.V., del Pozo A., Araus J.L., Ortiz R., Doonan J.H. Editorial: plant phenotyping and phenomics for plant breeding. *Front. Plant Sci.* 2017;8:2181. DOI 10.3389/fpls.2017.02181.
- Lowe A., Harrison N., French A.P. Hyperspectral image analysis techniques for the detection and classification of the early onset of plant disease and stress. *Plant Methods.* 2017;13:80-91. DOI 10.1186/s13007-017-0233-z.
- Mahlein A.-K. Plant disease detection by imaging sensors-parallels and specific demands for precision agriculture and plant phenotyping. *Plant Dis.* 2016;100:241-251. DOI 10.1094/PDIS-03-15-0340-FE.

- Mahlein A.-K., Alisaac E., Masri A.A., Behmann J., Dehne H.-W., Oerke E.-C. Comparison and combination of thermal, fluorescence, and hyperspectral imaging for monitoring *Fusarium* head blight of wheat on spikelet scale. *Sensors*. 2019a;19:2281. DOI 10.3390/s19102281.
- Mahlein A.-K., Kuska M.T., Thomas S., Wahabzada M., Behmann J., Rascher U., Kersting K. Quantitative and qualitative phenotyping of disease resistance of crops by hyperspectral sensors: seamless interlocking of phytopathology, sensors, and machine learning is needed! *Curr. Opin. Plant Biol.* 2019b;50:156-162. DOI 10.1016/j.pbi.2019.06.007.
- Mahlein A.-K., Kuska M.T., Behmann J., Polder G., Walter A. Hyperspectral sensors and imaging technologies in phytopathology: state of the art. *Annu. Rev. Phytopathol.* 2018;56:535-558. DOI 10.1146/annurev-phyto-080417-050100.
- Mahlein A.-K., Rumpf T., Welke P., Dehne H.-W., Plümer L., Steiner U., Oerke E.-C. Development of spectral indices for detecting and identifying plant diseases. *Remote Sens. Environ.* 2013;128: 21-30. DOI 10.1016/j.rse.2012.09.019.
- Mahlein A.-K., Steiner U., Hillnhütter C., Dehne H.-W., Oerke E.-C. Hyperspectral imaging for small-scale analysis of symptoms caused by different sugar beet diseases. *Plant Methods*. 2012;8:3. DOI 10.1186/1746-4811-8-3.
- Mishra P., Asaari M., Herrero-Langreo A., Lohumi S., Diezma B., Scheunders P. Close range hyperspectral imaging of plants: a review. *Biosyst. Eng.* 2017;164:49-67. DOI 10.1016/j.biosystemseng. 2017.09.009.
- Moshou D., Bravo C., Oberti R., West J.S., Ramon H., Vougioukas S., Bochtis D. Intelligent multi-sensor system for the detection and treatment of fungal diseases in arable crops. *Biosyst. Eng.* 2011;108: 311-321. DOI 10.1016/j.biosystemseng.2011.01.003.
- Moshou D., Bravo C., West J., Wahlen S., McCartney A., Ramon H. Automatic detection of 'yellow rust' in wheat using reflectance measurements and neural networks. *Comput. Electron. Agric.* 2004;44: 173-188. DOI 10.1016/j.compag.2004.04.003.
- Naidu R.A., Perry E.M., Pierce F.J., Mekuria T. The potential of spectral reflectance technique for the detection of *Grapevine leafroll-associated virus-3* in two red-berried wine grape cultivars. *Comput. Electron. Agr.* 2009;66:38-45. DOI 10.1016/j.compag.2008.11.007.
- Oerke E.-C., Herzog K., Toepfer R. Hyperspectral phenotyping of the reaction of grapevine genotypes to *Plasmopara viticola*. *J. Exp. Bot.* 2016;67(18):5529-5543. DOI 10.1093/jxb/erw318.
- Pandey P., Ge Y., Stoerger V., Schnable J.C. High throughput *in vivo* analysis of plant leaf chemical properties using hyperspectral imaging. *Front. Plant Sci.* 2017;8:1348-1359. DOI 10.3389/fpls.2017. 01348.
- Polder G., van der Heijden G.W.A.M., van der Voet H., Young I.T. Measuring surface distribution of carotenes and chlorophyll in ripening tomatoes using imaging spectrometry. *Postharvest Biol. Techn.* 2004;34(2):117-129.
- Rajendran D.K., Park E., Nagendran R., Hung N.B., Cho B.-K., Kim K.-H. Visual analysis for detection and quantification of *Pseudomonas cichorii* disease severity in tomato plants. *Plant Pathol. J.* 2016;32:300-310. DOI 10.5423/PPJ.OA.01.2016.0032.
- Rinnan A., Berg F., Engelsen S. Review of the most common pre-processing techniques for near-infrared spectra. *Trends Anal. Chem.* 2009;28(10):1201-1222. DOI 10.1016/j.trac.2009.07.007.
- Rumpf T., Mahlein A.-K., Steiner U., Oerke E.-C., Dehne H.-W., Plümer L. Early detection and classification of plant diseases with Support Vector Machines based on hyperspectral reflectance. *Comput. Electron. Agric.* 2010;74:91-99. DOI 10.1016/j.compag.2010. 06.009.
- Sankaran S., Khot L.R., Espinoza C.Z., Jarolmasjed S., Sathuvali V.R., Vandemark G.J., Miklas P.N., Carter A.H., Pumphrey M.O., Knowles N.R., Pavek K.J. Low-altitude, high-resolution aerial imaging systems for row and field crop phenotyping: a review. *Eur. J. Agron.* 2015;70:112-123. DOI 10.1016/j.eja.2015.07.004.
- Savitzky A., Golay M.J. Smoothing and differentiation of data by simplified least squares procedures. *Anal. Chem.* 1964;36:1627-1639. DOI 10.1021/ac60214a047.
- Singh A., Ganapathysubramanian B., Singh A.K., Sarkar S. Machine learning for high-throughput stress phenotyping in plants. *Trends Plant Sci.* 2016;21(2):110-124. DOI 10.1016/j.tplants.2015.10.015.
- Singh D., Sao R., Singh K.P. A remote sensing assessment of pest infestation on sorghum. *Adv. Space Res.* 2007;39:155-163. DOI 10.1016/j.asr.2006.02.025.
- Steddom K., Heidel G., Jones D., Rush C.M. Remote detection of rhizomania in sugar beets. *Phytopathology*. 2003;93:720-726. DOI 10.1094/PHYTO.2003.93.6.720.
- Sun G., Zhang A., Ren J., Ma J., Wang P., Zhang Y., Jia X. Gravitation-based edge detection in hyperspectral images. *Remote Sens.* 2017;9:592. DOI 10.3390/rs9060592.
- Tao Y., Wen Z. An adaptive spherical image transform for high-speed fruit defect detection. *Trans. ASABE*. 1999;42(1):241-246.
- Tardieu F., Cabrera-Bosquet L., Pridmore T., Bennett M. Plant phenomics, from sensors to knowledge. *Curr. Biol.* 2017;27:R770-R783. DOI 10.1016/j.cub.2017.05.055.
- Thomas S., Behmann J., Steier A., Kraska T., Müller O., Rascher U., Mahlein A.-K. Quantitative assessment of disease severity and rating of barley cultivars based on hyperspectral imaging in a non-invasive, automated phenotyping platform. *Plant Methods*. 2018a; 14:45. DOI 10.1186/s13007-018-0313-8.
- Thomas S., Kuska M.T., Bohnenkamp D. Benefits of hyperspectral imaging for plant disease detection and plant protection: a technical perspective. *J. Plant Dis. Prot.* 2018b;125:5-20. DOI 10.1007/s41348-017-0124-6.
- Vidal M., Amigo J.M. Pre-processing of hyperspectral images. Essential steps before image analysis. *Chemom. Intell. Lab.* 2012;117: 138-148. DOI 10.1016/j.chemolab.2012.05.009.
- Vigneau N., Ecartot M., Rabatel G., Roumet P. Potential of field hyperspectral imaging as a non destructive method to assess leaf nitrogen content in wheat. *Field Crops Res.* 2011;122:25-31. DOI 10.1016/j.fcr.2011.02.003.
- Walter A., Liebisch F., Hund A. Plant phenotyping: from bean weighing to image analysis (review). *Plant Methods*. 2015;11:14. DOI 10.1186/s13007-015-0056-8.
- Wang W., Li C., Tollner E.W., Gitaitis R.D., Rains G.C. Shortwave infrared hyperspectral imaging for detecting sour skin (*Burkholderia cepacia*)-infected onions. *J. Food Eng.* 2012;109(1):38-48. DOI 10.1016/j.jfoodeng.2011.10.001.
- Williams D., Britten A., McCallum S., Jones H., Aitkenhead M., Karley A., Loades K., Prashar A., Graham J. A method for automatic segmentation and splitting of hyperspectral images of raspberry plants collected in field conditions. *Plant Methods*. 2017;13:74-85. DOI 10.1186/s13007-017-0226-y.
- Wu D., Sun D.-W. Advanced applications of hyperspectral imaging technology for food quality and safety analysis and assessment: A review – Part I: Fundamentals. *Innov. Food Sci. Emerg. Technol.* 2013;19:1-14. DOI 10.1016/j.ifset.2013.04.014.
- Yang C., Cheng C., Chen R. Changes in spectral characteristics of rice canopy infested with brown planthopper and leafhopper. *Crop Sci.* 2007;47:329-335. DOI 10.2135/cropsci2006.05.0335.
- Yeh Y.F., Chung W., Liao J., Chung C., Kuo Y., Lin T. A comparison of machine learning methods on hyperspectral plant disease assessments. *IFAC Proc.* 2013;46:361-365. DOI 10.3182/20130327-3-JP-3017.00081.
- Yeh Y., Chung W., Liao J., Chung C., Kuo Y., Lin T. Strawberry foliar anthracnose assessment by hyperspectral imaging. *Comput. Electron. Agric.* 2016;122:1-9. DOI 10.1016/j.compag.2016.01.012.
- Yu K., Kirchgessner N., Grieder C., Walter A., Hund A. An image analysis pipeline for automated classification of imaging light conditions and for quantification of wheat canopy cover time series in field phenotyping. *Plant Methods*. 2017;13:15. DOI 10.1186/s13007-017-0168-4.

- Yuan L., Huang Y., Loraamm R.W., Nie C., Wang J., Zhang J. Spectral analysis of winter wheat leaves for detection and differentiation of diseases and insects. *Field Crops Res.* 2014a;156:199-207. DOI 10.1016/j.fcr.2013.11.012.
- Yuan L., Zhang J., Shi Y., Nie C., Wei L., Wang J. Damage mapping of powdery mildew in winter wheat with high-resolution satellite image. *Remote Sens.* 2014b;6:3611-3623. DOI 10.3390/rs6053611.
- Zhang J., Huang Y., Pu R., Gonzalez-Moreno P., Yuan L., Wu K., Huang W. Monitoring plant diseases and pests through remote sensing technology: a review. *Comput. Electron. Agric.* 2019;165:104943-104956. DOI 10.1016/j.compag.2019.104943.
- Zhang J., Pu R., Wang J., Huang W., Yuan L., Luo J. Detecting powdery mildew of winter wheat using leaf level hyperspectral measurements. *Comput. Electron. Agric.* 2012;85:13-23. DOI 10.1016/j.compag.2012.03.006.
- Zhang J., Wang N., Yuan L., Chen F., Wu K. Discrimination of winter wheat disease and insect stresses using continuous wavelet features extracted from foliar spectral measurements. *Biosyst. Eng.* 2017; 162:20-29. DOI 10.1016/j.biosystemseng.2017.07.003.
- Zhang N., Yang G., Pan Y., Yang X., Chen L., Zhao C. A review of advanced technologies and development for hyperspectral-based plant disease detection in the past three decades. *Remote Sens.* 2020;12: 3188. DOI 10.3390/rs12193188.
- Zhao Y.-R., Li X., Yu K.-Q., Cheng F., He Y. Hyperspectral imaging for determining pigment contents in cucumber leaves in response to angular leaf spot disease. *Sci. Rep.* 2016;6:27790. DOI 10.1038/srep27790.
- Zheng C., Abd-Elrahman A., Whitaker V. Remote sensing and machine learning in crop phenotyping and management, with an emphasis on applications in strawberry farming. *Remote Sens.* 2021;13:531. DOI 10.3390/rs13030531.
- Zhou R.-Q., Jin J.-J., Li Q.-M., Su Z.-Z., Yu X.-J., Tang Y., Luo S.-M., He Y., Li X.-L. Early detection of *Magnaporthe oryzae*-infected barley leaves and lesion visualization based on hyperspectral imaging. *Front. Plant Sci.* 2019;9:1962. DOI 10.3389/fpls.2018.01962.

ORCID ID

A.F. Cheshkova orcid.org/0000-0003-2265-7129

Благодарности. Работа выполнена при поддержке Российского научного фонда, проект № 0533-2021-0007.

Конфликт интересов. Автор заявляет об отсутствии конфликта интересов.

Поступила в редакцию 30.09.2021. После доработки 24.12.2021. Принята к публикации 27.12.2021.