

(19)



**Евразийское
патентное
ведомство**

(11) **047202**

(13) **B1**

(12) ОПИСАНИЕ ИЗОБРЕТЕНИЯ К ЕВРАЗИЙСКОМУ ПАТЕНТУ

(45) Дата публикации и выдачи патента
2024.06.20

(51) Int. Cl. **G06K 9/00** (2006.01)
G06K 9/62 (2006.01)

(21) Номер заявки
202291503

(22) Дата подачи заявки
2020.12.14

(54) СПОСОБ И СИСТЕМА АВТОМАТИЗИРОВАННОЙ МАРКИРОВКИ ИЗОБРАЖЕНИЙ РАСТЕНИЙ

(31) **19 218 722.7**

(32) **2019.12.20**

(33) **EP**

(43) **2022.10.19**

(86) **PCT/EP2020/085953**

(87) **WO 2021/122446 2021.06.24**

(71)(73) Заявитель и патентовладелец:
КВС ЗААТ СЕ & КО. КГАА (DE)

(72) Изобретатель:
**Бауэр Кристоф, Фрич Кристоф, Даль
Людмила, Джебсен Кристиан (DE)**

(74) Представитель:
Зуйков С.А. (RU)

(56) US-A1-2019384047
US-A1-2018157911

TOMBARI FEDERICO ET AL. "Automatic detection of pole-like structures in 3D urban environments", 2014 IEEE/RSJ INTERNATIONAL CONFERENCE ON INTELLIGENT ROBOTS AND SYSTEMS, IEEE, 14 September 2014 (2014-09-14), pages 4922-4929, XP032676769, DOI: 10.1109/IROS.2014.6943262, [retrieved on 2014-10-31], page 4922, left-hand column, paragraph 2nd - page 4929, right-hand column, last paragraph; figures 1-11

(57) Изобретение относится к реализуемому компьютером способу, включающему получение (406) первых обучающих изображений (108) с использованием первого метода (104) получения изображений, при этом каждое первое обучающее изображение изображает мотив, связанный с растениями; получение (402) вторых обучающих изображений (106) с использованием второго метода (102) получения изображений, при этом каждое второе обучающее изображение изображает мотив, изображенный на соответствующем одном из первых обучающих изображений; автоматическое присвоение (404), по меньшей мере, одной маркировки (150, 152, 154) каждому из полученных вторых обучающих изображений; пространственное совмещение (408) первого и второго обучающих изображений, на которых изображен один и тот же мотив, в пару совмещенных обучающих изображений; обучение (410) модели (132) машинного обучения в зависимости от совмещенных пар обучающих изображений и маркировок, при этом в процессе обучения модель (132) машинного обучения учится автоматически присваивать одну или несколько маркировок (250, 252, 254) любому тестовому изображению (205), полученному с помощью первого метода получения изображений, которое изображает мотив, связанный с растениями; и предложение (412) обученной модели (132) машинного обучения.

B1

047202

047202

B1

Область техники

Изобретение относится к способу и системе для улучшения маркировки изображений, изображающих растения и мотивы, связанные с растениями.

Уровень техники

Спектральная визуализация - это обнаружение света, отраженного от объекта, с помощью специализированных датчиков. Отраженный свет измеряется в спектральных полосах. Некоторые методы спектральной визуализации фиксируют свет во многих спектральных полосах и/или в большом диапазоне видимого или невидимого спектра. В целом, чем больше количество полос и чем больше охватываемый спектральный диапазон, тем выше точность, универсальность и информативность полученных спектральных изображений.

В настоящее время спектральная визуализация широко используется в сельском хозяйстве и точном земледелии. Например, спутники и камеры, установленные на дронах, используют технологию мультиспектральной или гиперспектральной визуализации для получения изображений сельскохозяйственных культур, которые обладают высокой информативностью и, следовательно, позволяют выполнять различные методы анализа изображений.

Например, в патентной заявке WO2017105177A1 описана система для точного земледелия с использованием карт мультиспектральных и гиперспектральных изображений, полученных с помощью высокоскоростных фотокамер высокого разрешения, установленных в нижней части беспилотных летательных аппаратов, которые, в свою очередь, являются географически привязанными.

В области точного земледелия существует несколько алгоритмов классификации изображений, основанных на данных гиперспектральных изображений. Однако гиперспектральные и мультиспектральные камеры являются дорогостоящими. Кроме того, гиперспектральные и мультиспектральные камеры часто больше и/или тяжелее, чем RGB-камеры, поэтому установка таких камер на существующих, но не очень устойчивых платформах или зданиях, или на дронах часто невозможна или по меньшей мере затруднительна или дорогостояща. Тем временем дроны с хорошими RGB-камерами доступны для широкого потребительского рынка. Большое предложение приводит к сравнительно низкой цене, в то время как дроны с гиперспектральными камерами часто изготавливаются на заказ, обслуживают лишь небольшой рынок и поэтому являются сравнительно дорогими.

Таким образом, использование данных изображений в точном земледелии и смежных технических областях сопровождается проблемой: существующие алгоритмы классификации изображений требуют в качестве входных данных гиперспектральные изображения, но получение этих данных часто намного дороже и технически сложнее, чем другие, сравнительно простые методы получения изображений, такие как съемка RGB-изображения стандартной камерой. Однако RGB-изображения обычно не могут заменить гиперспектральные изображения, поскольку их информационное содержание отличается от информационного содержания гиперспектральных изображений, и поэтому они не могут быть использованы в качестве входных данных для существующих методов анализа изображений на основе гиперспектральных изображений.

Для того чтобы системы/процессы со средствами машинного обучения могли создавать высококачественные модели, способные точно решать задачи прогнозирования, они должны быть обучены на достаточно большом объеме обучающих данных. Если база данных слишком мала или необъективна, модель, полученная в процессе обучения, будет иметь плохую обобщенность, низкую точность и будет несбалансированной. Однако аннотирование достаточно большого объема обучающих данных требует огромных трудозатрат. Это часто является препятствием для создания высокоточных моделей машинного обучения, которые могут быть использованы для различных задач прогнозирования, таких как семантическая маркировка цифровых изображений.

Нгуен и соавт. в работе "Training-Based Spectral Reconstruction from a Single RGB Image" на Европейской конференции по компьютерному зрению 2014 описывают автоматизированное воспроизведение гиперспектрального изображения из RGB-изображения. По меньшей мере в отношении некоторых задач, таких как "освещение сцены", "вычисленное" гиперспектральное изображение может быть использовано вместо "реального" гиперспектрального изображения. Однако, поскольку RGB-изображение охватывает лишь небольшую часть спектра гиперспектрального изображения, "вычисленное" гиперспектральное изображение может не позволить точно заменить "реальное" гиперспектральное изображение в других сценариях применения.

Сущность изобретения

Изобретение предлагает усовершенствованный способ, компьютерный программный продукт и систему для анализа цифровых изображений, изображающих мотивы, связанные с растениями, как указано в независимых пунктах патентной формулы. Варианты осуществления изобретения приведены в зависимых пунктах формулы изобретения. Варианты осуществления настоящего изобретения могут свободно комбинироваться друг с другом, если они не являются взаимоисключающими.

В одном аспекте изобретение относится к реализуемому компьютером способу, включающему в себя:

получение первых обучающих изображений с помощью первого метода получения изображений,

причем каждое первое обучающее изображение изображает мотив, связанный с растениями, при этом мотив, связанный с растениями, выбран из группы, включающей в себя: закрытый или открытый сельскохозяйственный участок, растение, растительный продукт, часть растения, часть растительного продукта;

получение вторых обучающих изображений с помощью второго метода получения изображений, причем каждое второе обучающее изображение изображает мотив, изображенный на соответствующем одном из первых обучающих изображений;

автоматическое присвоение по меньшей мере одной маркировки каждому из полученных вторых обучающих изображений;

пространственное совмещение первого и второго обучающих изображений, на которых изображен один и тот же мотив, в пару совмещенных обучающих изображений;

обучение модели машинного обучения в зависимости от совмещенных пар обучающих изображений и маркировок, при этом в процессе обучения модель машинного обучения учится автоматически присваивать одну или несколько маркировок любому тестовому изображению, полученному с помощью первого метода получения изображений, которое изображает мотив, связанный с растениями; и

предложение обученной модели машинного обучения.

Это может быть выгодно, поскольку варианты осуществления изобретения позволяют предложить программное обеспечение (здесь: обученную модель машинного обучения), приспособленное для автоматического вычисления и прогнозирования маркировок на основе легко получаемых цифровых изображений (полученных с помощью первого метода получения изображений), тем самым автоматически прогнозируя значение и положение одной или нескольких маркировок для легко получаемых цифровых изображений, даже если высококачественные цифровые изображения, например, гиперспектральные изображения, которые обычно используются для вычисления маркировок, недоступны.

Варианты осуществления изобретения предлагают обученную модель машинного обучения, приспособленную для автоматического прогнозирования и присвоения маркировок любому входному цифровому изображению, полученному с помощью первого метода получения изображений. Таким образом, варианты осуществления изобретения ускоряют и облегчают создание массивов промаркированных данных, которые могут быть использованы для различных целей, например, могут быть использованы для оценки здоровья растений или другой фенотипической информации. Ручное создание аннотированных обучающих данных является очень трудоемким, дорогостоящим и подверженным ошибкам процессом. Использование информации, содержащейся в насыщенных информацией цифровых изображениях, полученных с помощью второго, часто сложного и/или дорогостоящего метода получения изображений, для автоматического прогнозирования маркировок и обучение модели машинного обучения на парах совмещенных первых и вторых обучающих изображений может иметь то преимущество, что создается обученная модель машинного обучения, приспособленная для автоматического прогнозирования и создания этих маркировок также на основе первых изображений, полученных с помощью сравнительно дешевого/несложного первого метода получения изображений. Это может позволить избежать трудоемкой и необъективной ручной маркировки, так как предлагается обученная программа машинного обучения, приспособленная для вычисления и присвоения маркировок полностью автоматически.

Предложенная обученная модель машинного обучения может позволить создавать точные пространственные маркировки изображений, полученных с помощью первого метода получения изображений, на основе изученных взаимосвязей признаков первых обучающих изображений с маркировками, присвоенными вторым обучающим изображениям, при этом маркировки обучающих изображений были получены на основе спектральной и/или пространственной информации, содержащейся во вторых обучающих изображениях, которая может отсутствовать в первых обучающих изображениях. Изучение взаимосвязи между признаками изображений, полученных с помощью первого метода получения изображений, и истинными маркировками, полученными из изображений, полученных с помощью второго метода получения изображений, может позволить обойти трудоемкую и потенциально необъективную ручную попиксельную маркировку первых (обучающих и тестовых) изображений.

В точном земледелии и других смежных технических областях создание промаркированных изображений в качестве обучающих данных для различных подходов машинного обучения занимает очень много времени. В вариантах осуществления изобретения используется обученная модель машинного обучения для автоматического создания маркировок во время тестирования. Обученная модель машинного обучения может быть создана очень быстро, например, автоматически или полуавтоматически. Например, собираются вторые обучающие изображения, которые содержат достаточно информации для быстрого и автоматического прогнозирования и присвоения маркировок. Эти маркировки сопоставляются с первыми обучающими изображениями, изображающими тот же мотив. Первое обучающее изображение и маркировки используются в качестве входных данных для обучения модели машинного обучения таким образом, что модель учится прогнозировать маркировки на основе признаков первых обучающих изображений. Другими словами, вторые обучающие изображения, которые могут быть промаркированы легко и полностью автоматически, используются в качестве входных данных вместе с первыми обучающими изображениями (которые могут быть получены дешевле, быстрее и т.д.) для создания обу-

ченной модели, способной прогнозировать эти маркировки на основе цифровых изображений, полученных с помощью первого метода получения изображений.

Согласно вариантам осуществления, мотив, связанный с растениями, представляет собой макроскопический мотив размером не менее 1 мм, в частности, не менее 1 см.

Согласно вариантам осуществления, получение каждого из первых и соответствующего одного из вторых обучающих изображений выполняется одновременно или в близкой последовательности таким образом, что оптические датчики, используемые для получения первого и второго обучающих изображений, которые впоследствии образуют одну из пар совмещенных изображений, имеют в основном одинаковое или очень похожее положение датчика относительно мотива, связанного с растениями. Другими словами, первое и второе обучающие изображения, изображающие один и тот же или похожий мотив, которые пространственно совмещены друг с другом во время процесса обучения, — это изображения, полученные в одно и то же время или в близкой последовательности. Следовательно, мотив, изображенный на первом и втором обучающих изображениях каждой пары совмещенных изображений, идентичен или по меньшей мере приблизительно идентичен.

Согласно вариантам осуществления, первый метод получения изображений может быть более дешевым и/или технически менее сложным методом получения изображений, чем второй метод получения изображений. Например, первый метод получения изображений может быть получением RGB-изображений, а второй метод получения изображений может быть получением гиперспектральных изображений.

Согласно вариантам осуществления, присвоение по меньшей мере одной маркировки каждому из вторых обучающих изображений осуществляется таким образом, что каждому пикселю второго обучающего изображения присваивается соответствующая маркировка. Согласно другим вариантам осуществления, по меньшей мере некоторые из маркировок присваиваются группам пикселей, например, отдельным пиксельным блокам или сегментам изображения. Согласно еще одним вариантам осуществления, второму обучающему изображению ("глобально") присваивается одна маркировка.

Согласно вариантам осуществления, маркировка может содержать или состоять из одного или нескольких значений данных любого типа. Например, маркировка может содержать или состоять из логического значения, числового значения или буквенно-цифровой строки. Эти маркировки могут быть использованы для указания принадлежности пикселя, пиксельного блока или изображения к заранее определенному классу, такому как "почва", "здоровые растения" или "инфицированные растения".

Согласно вариантам осуществления, обученная модель машинного обучения является моделью, приспособленной для выполнения задачи прогнозирования, при этом задача прогнозирования может быть задачей регрессии или задачей классификации.

Согласно вариантам осуществления, задача прогнозирования включает в себя прогнозирование значения и положения маркировок и присвоение маркировок цифровому изображению.

Каждая маркировка может обозначать, например, название класса или числовое значение, указывающее на вероятность принадлежности к классу, или значение другого параметра, имеющего значение для последующих операций анализа изображения. Маркировки названий классов могут использоваться, например, для задач классификации изображений. Числовые маркировки могут использоваться, например, для задач регрессии либо для всего изображения, либо для частей изображения, либо для каждого отдельного пикселя (например, семантическая сегментация изображения, которая рассматривает области соседних пикселей, имеющих одинаковую или достаточно схожую маркировку, как пиксели, принадлежащие к одному сегменту).

Например, каждая маркировка может быть числом, например, целым числом или числом с плавающей точкой. Согласно вариантам осуществления, обученная модель машинного обучения научилась и настроена на автоматическое присвоение этих числовых значений в качестве маркировок любому входному изображению, полученному с помощью первого метода получения изображений во время тестирования. Таким образом, обученная модель машинного обучения научилась автоматически маркировать входные изображения числовыми значениями, например, процентными значениями. Промаркированные числовые значения одного или нескольких тестовых изображений могут быть использованы для оценки здоровья растений или другой фенотипической информации. Например, эта оценка может быть реализована как задача регрессии с использованием автоматически промаркированных тестовых изображений. Например, числовое значение может быть значением "68%", указывающим на вероятность того, что пиксель, пиксельный блок или изображение изображает объект определенного класса, например, "почва".

Согласно другому примеру, каждая маркировка представляет собой название класса, входящего в ограниченный набор заранее определенных классов. Классы могут указывать на классы объектов или мотивов, к которым принадлежит изображение, пиксельный блок или отдельный пиксель. Например, название класса может быть задано в виде логического значения (например, "true" для инфицированного и "false" для здорового) или строки ("здоровое растение", "инфицированное растение", "почва", "50%почвы-50%здорового растения", "50%почвы-50%инфицированного растения") или числового значения (например, %77% вероятности принадлежности к классу "здоровое растение"). Согласно вариантам осуществления, обученная модель машинного обучения научилась и настроена на автоматическое

присвоение этих заранее определенных названий классов в качестве маркировок любому входному изображению, полученному с помощью первого метода получения изображений во время тестирования. Таким образом, обученная модель машинного обучения научилась автоматически маркировать входные изображения названиями одного или нескольких заранее определенных классов. Маркировки, присвоенные одному или нескольким тестовым изображениям, могут быть использованы в качестве обучающих данных второго порядка, предлагаемых в качестве входных данных для дальнейшей программы машинного обучения, которая учится решать задачу классификации на основе автоматически промаркированных тестовых изображений.

Согласно вариантам осуществления, совмещение первых и вторых обучающих изображений, изображающих один и тот же мотив, выполняется вручную. Согласно другим вариантам осуществления, совмещение выполняется с помощью автоматизированных методов совмещения изображений, таких как, например, регистрация изображений, фотограмметрия или методы географической привязки. Согласно вариантам осуществления, совмещение может быть выполнено на основе каждого пикселя.

Согласно вариантам осуществления, пространственное совмещение первого и второго обучающих изображений каждой из пар включает в себя совмещение первого и второго изображений, изображающих один и тот же мотив, на основе их соответствующих геопозиций, тем самым обеспечивая приблизительно совмещенную пару изображений; и затем уточнение совмещения в зависимости от интенсивности пикселей и/или цветового сходства таким образом, чтобы разница в интенсивности и/или цветовые различия между первым и вторым изображениями были минимальными для обеспечения совмещения первого и второго изображения пары. Мотив, связанный с растениями и изображенный на тестовом изображении, предпочтительно похож на мотив, связанный с растениями и изображенный на первом и втором обучающих изображениях. Например, если обучение проводилось на отдельных растениях определенного вида, тестовое изображение также должно быть изображением растения того же или аналогичного вида, полученным при аналогичном взаимном расположении оптического датчика и растения. Если обучение проводилось на сельскохозяйственном участке, тестовое изображение также должно быть изображением сельскохозяйственного участка, полученным при аналогичном взаимном расположении оптического датчика и сельскохозяйственного участка и предпочтительно при аналогичных условиях внешней освещенности.

Согласно вариантам осуществления, способ включает в себя использование обученной модели машинного обучения для прогнозирования одной или нескольких маркировок тестового изображения и вывод промаркированного тестового изображения.

Эти этапы могут повторяться для множества тестовых изображений, полученных с помощью первого метода получения изображений. Таким образом, можно вычислить большое количество автоматически промаркированных тестовых изображений. Этот набор промаркированных изображений может быть использован для различных целей. Например, маркировки могут быть использованы для выполнения сегментации тестового изображения для идентификации областей на сельскохозяйственном участке, где необходимо применять воду, удобрения, пестициды и/или фунгициды, или где необходимо выращивать или собирать определенный тип растений. Одно или несколько промаркированных тестовых изображений, полученных обученной моделью машинного обучения, могут также использоваться в качестве обучающих изображений для различных задач машинного обучения второго порядка.

Согласно вариантам осуществления, способ далее включает в себя извлечение первых признаков (также называемых "признаками изображения") из каждого из первых обучающих изображений. Обучение модели машинного обучения выполняется таким образом, что модель машинного обучения изучает пространственную взаимосвязь первых признаков и маркировок, присвоенных вторым обучающим изображениям, на основе пространственной взаимосвязи первых признаков и маркировок в каждой из совмещенных пар первых и вторых обучающих изображений.

Например, извлечение признаков из каждого из первых обучающих изображений может быть выполнено программой машинного обучения, используемой для обучения модели машинного обучения. Например, несколько архитектур нейронных сетей, которые доступны сегодня и которые могут быть использованы для задач машинного обучения на основе изображений, уже включают в себя большое разнообразие алгоритмов извлечения признаков изображения, которые применяются к любому входному изображению, чтобы использовать извлеченные первые признаки изображения в качестве входных данных во время обучения. Например, различные нейронные сети, такие как DeepLabv3+, включают в себя алгоритмы извлечения признаков изображения. Во время обучения модель машинного обучения изучает взаимосвязь по меньшей мере некоторых из автоматически извлеченных первых признаков изображения или комбинации этих первых признаков изображения с содержанием и положением маркировок, присвоенных вторым обучающим изображениям, которые были совмещены с первыми обучающими изображениями, изображающими тот же или приблизительно тот же мотив, связанный с растениями.

Согласно вариантам осуществления, первые признаки включают в себя один или несколько признаков изображения, выбранных из группы, включающей в себя: значение интенсивности, градиент интенсивности, контраст, направление градиента интенсивности, цветовые индексы и/или спектральные индексы, а также линейные и нелинейные комбинации двух или более вышеупомянутых признаков изо-

бражения. Согласно некоторым вариантам осуществления, программное обеспечение, используемое для обучения модели машинного обучения, включает в себя один или несколько алгоритмов для автоматического извлечения множества различных признаков из изображения, и в процессе обучения модели модель изучает подмножество первых признаков и/или комбинации двух или более первых признаков, которые являются наиболее прогнозируемыми в отношении конкретной маркировки, присвоенной первому обучающему изображению.

Согласно вариантам осуществления, способ далее включает в себя извлечение вторых признаков (также называемых "признаками изображения") из каждого из вторых обучающих изображений. Автоматическое присвоение по меньшей мере одной маркировки каждому из вторых обучающих изображений включает в себя анализ вторых признаков, извлеченных из второго обучающего изображения, для прогнозирования по меньшей мере одной маркировки второго обучающего изображения в зависимости от вторых признаков, извлеченных из второго обучающего изображения.

Согласно вариантам осуществления, извлечение вторых признаков также выполняется программой машинного обучения, используемой для обучения модели машинного обучения. Однако, согласно предпочтительным вариантам осуществления, извлечение вторых признаков изображения из вторых обучающих изображений выполняется отдельным программным обеспечением или модулем извлечения признаков. Это может быть выгодно, поскольку содержание и положение маркировки может сильно варьироваться в зависимости от соответствующей вычислительной задачи, поэтому стандартные алгоритмы извлечения признаков изображения, используемые в современных системах машинного обучения, могут не охватывать тип вторых признаков изображения, необходимых для автоматического прогнозирования маркировок.

Например, вторые обучающие изображения могут быть гиперспектральными изображениями, и маркировки для присвоения вторым обучающим изображениям могут быть выбраны из ограниченного набора заранее определенных названий классов, перечисленных ниже, где "П" означает "почва", "ЗР" означает "здоровые растения" и "ИР" означает "инфицированные растения": "~100%П", "~100%ЗР", "~100%ИР", "~50%П&~50%ЗР", "~50%П&~50%ИР", "~50%ИР&~50%ЗР", "~25%П&~25%ЗР~50%ИР", "~25%П&~50%ЗР~25%ИР", "~50%П&~25%ЗР~25%ИР". Таким образом, маркировка "~50%П&~50%ЗР" означает, что область изображения, которой присвоена эта маркировка, изображает сельскохозяйственный участок, наполовину покрытый почвой и наполовину покрытый здоровыми растениями. Вторые признаки, извлеченные из каждого второго обучающего изображения, могут быть, например, спектральной сигнатурой пикселей или пиксельных блоков. Извлеченные сигнатуры можно сравнить с набором заранее определенных, известных эталонных спектральных сигнатур. Каждая эталонная спектральная сигнатура может быть характерна для соответствующего одного из одного или нескольких вышеупомянутых классов.

Например, может существовать эталонная спектральная сигнатура для "100%П", т.е. специфическая картина интенсивности в широком спектральном диапазоне, характерная для голой почвы. Кроме того, может существовать эталонная спектральная сигнатура для "100%ЗР", т.е. специфическая картина интенсивности в широком спектральном диапазоне, характерная для здоровых растений определенного вида. Сравнивая извлеченные сигнатуры ("вторые признаки изображения") с эталонными спектральными сигнатурами, можно идентифицировать ту из эталонных сигнатур, которая наиболее похожа на извлеченный второй признак, и использовать название класса, соответствующего этой идентифицированной эталонной спектральной сигнатуре, в качестве маркировки, присвоенной пикселю или пиксельному блоку, из которого была извлечена спектральная сигнатура.

Согласно вариантам осуществления, мотив, связанный с растениями, представляет собой закрытый или открытый сельскохозяйственный участок с множеством растений, растением, растительным продуктом, частью растения, частью растительного продукта, при этом ни одно из растений или растительных продуктов не было модифицировано, химически обработано и/или окрашено для обеспечения маркировки или для облегчения маркирования.

Окрашивание или химическая обработка растений для визуализации некоторых признаков может быть необязательной, поскольку, в частности, гиперспектральная эталонная сигнатура может позволить обнаружить практически любой признак растения, который влияет на то, как это растение поглощает или отражает свет.

Согласно другим вариантам осуществления, вторые признаки включают в себя один или несколько признаков изображения, выбранных из группы, включающей в себя: спектральную сигнатуру, спектральные индексы, пространственно-спектральные признаки (признаки, которые определяют связь между интенсивностью и пространством, например, спектральные градиенты), признаки, основанные на интенсивности.

Количество и тип вторых признаков и, следовательно, алгоритмы, используемые для извлечения вторых признаков, сильно зависят от маркировок, которые должны быть спрогнозированы на основе вторых признаков.

Согласно вариантам осуществления, первый и второй методы получения изображений представляют собой различные методы получения изображений, соответственно, выбранные из группы, включаю-

щей в себя:

- получение гиперспектрального изображения;

- получение RGB-изображения;

- получение монохроматического изображения; например, получение монохроматического изображения может включать в себя использование монохроматора (оптического устройства, которое пропускает механически выбираемую узкую полосу длин волн света или другого излучения, выбранную из более широкого диапазона длин волн, доступных на входе);

- получение активного изображения с помощью источника возбуждающего света;

- получение мультиспектрального изображения; и

- получение ИК-изображения.

Согласно вариантам осуществления, автоматическое присвоение маркировок пикселям или областям каждого из вторых обучающих изображений включает в себя:

- для каждого из заранее определенного набора классов мотивов, получение эталонной спектральной сигнатуры от физического эталонного мотива, принадлежащего к этому классу мотивов;

- сравнение эталонной спектральной сигнатуры со вторыми обучающими изображениями для выявления спектрального сходства между пикселями или областями вторых обучающих изображений и эталонными спектральными сигнатурами; и

- присвоение каждому пикселю или области каждого из вторых обучающих изображений маркировки, указывающей на один из классов мотивов, спектрально наиболее схожих с этим пикселем или областью.

Использование спектральных сигнатур, извлеченных из вторых обучающих изображений, и эталонных спектральных сигнатур, характерных для интересующего класса объектов, для прогнозирования маркировок может быть выгодным, поскольку спектральные сигнатуры содержат большое количество информации и могут быть легко получены при условии, что изображение охватывает достаточно широкий спектральный диапазон (это особенно актуально для гиперспектральных и мультиспектральных изображений). Таким образом, может быть предложено точное прогнозирование маркировки на основе одного типа признаков. Использование спектральных сигнатур в качестве вторых признаков для прогнозирования маркировки использует тот факт, что определенные объекты или мотивы оставляют уникальные "отпечатки" в электромагнитном спектре, которые очень характерны для определенного класса объектов.

Кроме того, способ очень универсален и может быть использован для автоматической идентификации практически любого интересующего типа объектов без существенной адаптации алгоритма извлечения признаков, используемого для извлечения вторых признаков (здесь: спектральных сигнатур). Например, для автоматического обнаружения растений определенного вида или определенного физиологического состояния на множестве вторых обучающих изображений может быть достаточно получить одно или несколько гиперспектральных или мультиспектральных эталонных изображений, изображающих сельскохозяйственный участок, покрытый этим конкретным растением. Затем из тех частей одного или нескольких эталонных изображений, на которых изображены эти растения, извлекается эталонная сигнатура. Этап извлечения признаков для извлечения вторых признаков из вторых обучающих изображений включает в себя извлечение спектральных сигнатур на каждом пикселе каждого второго обучающего изображения и их использование для разделения второго обучающего изображения на группы похожих пикселей (сегментация) с помощью различных подходов. На последнем этапе каждому из сегментов (или каждому пикселю в сегментах) присваивается маркировка, например, название класса, путем сравнения сигнатур каждого пикселя (или усредненной спектральной сигнатуры пикселей сегмента) с известной эталонной спектральной сигнатурой конкретного интересующего растения (или другого объекта). В конечном итоге правильное сопоставление спектральных сигнатур пикселей или сегментов вторых обучающих изображений с эталонной спектральной сигнатурой приводит к точному прогнозированию и присвоению маркировок вторым обучающим изображениям, которые указывают на присутствие вышеупомянутых интересующих растений. Этот подход можно легко распространить на другие классы объектов, просто добавив дополнительную эталонную спектральную сигнатуру в хранилище эталонных спектральных сигнатур, и учитывать эту дополнительную эталонную спектральную сигнатуру при сравнении сигнатур и прогнозировании маркировок.

Следовательно, использование спектральных сигнатур для прогнозирования маркировок может быть полезным, поскольку нет необходимости определять алгоритм, который явно ищет цвета, формы, текстуры или другие признаки, которые программист считает "характерными" для конкретного объекта. Преимуществом этого может быть то, что многие "характерные" признаки не входят в "видимую" часть спектра и, следовательно, не могут быть восприняты человеком.

Согласно вариантам осуществления, второй метод получения изображений представляет собой получение гиперспектрального изображения с помощью гиперспектрального датчика.

Преимуществом этого способа может быть то, что вторые обучающие изображения содержат большое количество спектральной информации. Спектральные сигнатуры, полученные для отдельных пикселей вторых обучающих изображений, могут, следовательно, быть использованы для высокоточного прогнозирования маркировок, указывающих на тип объекта, представленного на изображении (или вероят-

ность изображения этого типа объекта).

Согласно вариантам осуществления, второй метод получения изображений охватывает большую часть всего электромагнитного спектра (например, от менее одного герца до более 10^{25} герц) по сравнению с первым методом получения изображений.

Например, второй метод получения изображений может быть гиперспектральной визуализацией или мультиспектральной визуализацией, а первый метод получения изображений может быть получением RGB-изображения или получением монохромного изображения. Преимуществом этого может быть то, что вторые обучающие изображения содержат большое количество спектральной информации и, следовательно, предлагают хорошую основу для точного прогнозирования маркировок только или преимущественно на основе спектральной информации, например, спектральных сигнатур отдельных пикселей. Такие методы получения изображений, как RGB-съемка или монохромная съемка, имеют то преимущество, что используемые оптические датчики часто дешевы, механически прочны, легки и/или имеют высокое пространственное разрешение. Обучение модели машинного обучения на пространственном признаке маркировок, спрогнозированных на основе спектральной информации вторых обучающих изображений, признакам первых обучающих изображений, следовательно, предлагает обучающую модель машинного обучения, способную прогнозировать маркировки на основе признаков, извлеченных из изображений, полученных с помощью сравнительно дешевого метода получения изображений, которые могут содержать меньше спектральной информации, чем изображения, полученные с помощью второго метода получения изображений.

Согласно вариантам осуществления, второй метод получения изображений охватывает другую часть (например, ИК, а не УФ или наоборот) всего электромагнитного спектра по сравнению с первым методом получения изображений.

Согласно вариантам осуществления, второй метод получения изображений характеризуется более высоким содержанием информации на пространственную область, в частности, более высоким содержанием спектральной информации на пространственную область, в отличие от первого метода получения изображений. Например, вторые обучающие изображения могут содержать больше "слоев данных", например, больше суб-изображений спектральных диапазонов на область, чем первые обучающие изображения.

Согласно вариантам осуществления, второй метод получения изображений характеризуется иным информационным содержанием на пространственную область в отличие от первого метода получения изображений (например, спектральной информацией, относящейся к другому диапазону длин волн в электромагнитном спектре).

Согласно вариантам осуществления, первый метод получения изображений имеет более высокое пространственное разрешение по сравнению со вторым методом получения изображений.

Согласно вариантам осуществления изобретения, второй метод получения изображений представляет собой метод получения гиперспектральных изображений, а первый метод получения изображений представляет собой метод получения RGB-изображений или метод получения мультиспектральных изображений.

Например, для получения первых обучающих изображений и/или тестового изображения может быть использована "стандартная" RGB-камера смартфона, RGB-камера, встроенная на дрон, используемый в точном земледелии, или RGB-камера, встроенная в микроскоп, используемый для получения увеличенных изображений растений, растительных продуктов и их частей с высоким пространственным разрешением. Пространственное разрешение этих RGB-камер больше (часто на много порядков), чем у многих гиперспектральных камер, используемых, например, для точного земледелия. Это может быть выгодно, поскольку высокая плотность информации в отношении пространственных признаков, содержащихся в первых обучающих изображениях, может позволить модели машинного обучения научиться в процессе обучения выстраивать взаимосвязь между пространственными признаками изображения, извлеченными в виде первых признаков из первых обучающих изображений, и пространственно совмещенными маркировками, которые были спрогнозированы на основе спектральной информации, содержащейся во вторых обучающих изображениях. Следовательно, программа машинного обучения в процессе обучения "научилась" прогнозировать маркировки на основе признаков изображения, которые присутствуют только в первых обучающих изображениях, но отсутствуют (или встречаются в меньшем количестве) во вторых обучающих изображениях. Следовательно, согласно вариантам осуществления, гиперспектральные изображения низкого разрешения с большим количеством спектральной информации используются для автоматического прогнозирования маркировок, которые затем автоматически совмещаются с изображениями высокого разрешения с меньшим количеством спектральной информации. Заявитель с удивлением заметил, что изображения высокого разрешения с небольшим количеством спектральной информации (например, RGB-изображения или монохромные изображения) часто содержат признаки, которые позволяют успешно обучить точную модель машинного обучения на основе данных маркировки, полученных с помощью другого метода получения изображений, например, гиперспектральной визуализации. По сравнению с существующими подходами, такими как ручная маркировка, это требует гораздо меньше ручного труда и позволяет организовать (полу)автоматический рабочий процесс.

Например, статус развития заболевания, определяемый по спектральной сигнатуре, полученной с низким разрешением с помощью гиперспектрального датчика, может быть определен в результате процесса обучения обученной моделью машинного обучения по изменениям формы и/или цвета объектов на RGB-изображениях высокого разрешения.

Согласно вариантам осуществления, первые обучающие изображения представляют собой RGB-изображения. Вторые обучающие изображения представляют собой гиперспектральные изображения. Пространственное совмещение первого и второго обучающих изображений каждой из пар включает в себя:

для каждого пикселя второго обучающего изображения, вычисление значения интенсивности красного, зеленого и синего цветов путем усреднения значений спектральной интенсивности соответственно видимых красных, зеленых и синих спектральных полос, охватываемых вторым обучающим изображением;

создание RGB-представления второго обучающего изображения в зависимости от вычисленных значений интенсивности красного, зеленого и синего цветов; например, RGB-представление может быть вычислено путем объединения этих трех значений интенсивности красного, зеленого и синего цветов в кортежи на основе пикселей или предпочтительно на основе более сложного метода, например $k = K/(K+3+C)$, $z = 3/(K+3+C)$, $c = C/(K+3+C)$;

вычисление первого изображения зеленого цвета, причем интенсивность каждого пикселя первого изображения зеленого цвета представляет собой индекс зеленого цвета, вычисленный как функция значений интенсивности красного, зеленого и синего цветов первого обучающего изображения;

вычисление второго изображения зеленого цвета, причем интенсивность каждого пикселя второго изображения зеленого цвета представляет собой индекс зеленого цвета, вычисленный как функция значений интенсивности красного, зеленого и синего цветов RGB-представления второго обучающего изображения;

автоматическое выполнение совмещения первого и второго обучающих изображений таким образом, что разница индексов зеленого цвета первого и второго изображений сводится к минимуму.

Индекс зеленого цвета выделяет такие компоненты зеленого мотива, как растения. Зеленый цвет позволяет выделить зеленые участки на фоне остатков/почвы. Он может быть вычислен, например, в соответствии с: $\text{зеленый цвет} = 23 - K - C$ или $\text{зеленый цвет} = 23 + C - 2K$.

Использование совмещения изображений на основе индекса зеленого цвета может быть полезным, поскольку процедура совмещения по своей сути фокусируется на объектах, представляющих особый интерес, т.е. растениях и частях растений, обычно имеющих зеленый цвет. Растения и части растений - это гибкие объекты, точные очертания которых могут незначительно меняться, например, в зависимости от ветра и других параметров. Использование индекса зеленого цвета в контексте совмещения изображений может, следовательно, быть более подходящим для совмещения областей изображений, изображающих растения и части растений, чем, например, подходы к совмещению, основанные на GPS-координатах, присвоенных некоторым пикселям обучающих изображений.

Согласно вариантам осуществления, обученная модель машинного обучения настроена на присвоение одной или нескольких маркировок тестовому изображению таким образом, что по меньшей мере одна из указанных маркировок присваивается каждому пикселю тестового изображения; и семантическую сегментацию тестового изображения путем группировки пикселей тестового изображения, имеющих одну и ту же маркировку или достаточно схожую маркировку, в один и тот же сегмент.

Например, "достаточно схожая" маркировка может быть маркировкой, для которой было вычислено значение сходства по отношению к другой маркировке, при этом значение сходства выше заранее определенного порога. Согласно другому примеру, маркировки могут быть числовыми значениями, а две "достаточно схожие маркировки" могут быть маркировками, лежащими в одном и том же из множества заранее определенных числовых диапазонов, или могут быть маркировками, разница в числовых значениях которых ниже заранее определенного порога.

Эти варианты осуществления изобретения могут быть выгодны, поскольку предлагается обученная модель, которая может быть приспособлена для быстрого и точного выполнения задачи сегментации изображения, не полагаясь на получение изображений с помощью второго метода получения изображений. В другом полезном аспекте результат сегментации может быть сравнен с эталонными изображениями, содержащими границы сегментации, которые "заведомо" являются правильными, что позволяет выявить необъективности в обученной модели. Например, модель может быть способна точно выявить "сегменты почвы" и с высокой чувствительностью выявить "сегменты здоровых растений" на снимке, изображающем сельскохозяйственный участок. Однако обученная модель иногда может ошибочно считать участки с изображением инфицированных растений сегментом "здоровых растений". Сравнивая сегменты, выявленные обученной моделью, с "эталонными сегментами", которые заведомо являются правильными, можно выявить "необъективность" результатов прогнозирования модели. Это основное преимущество перед системами классификации на основе всего изображения, которые позволяют определить только общую точность. Более того, сегменты могут представлять большую ценность для различных подходов к последующей обработке, например, для определения суб-областей на сельскохозяйст-

венных участках, которые требуют орошения или применения удобрений, пестицидов и/или гербицидов.

Согласно вариантам осуществления, обученная модель машинного обучения представляет собой нейронную сеть, в частности, нейронную сеть, содержащую по меньшей мере один слой с меньшим количеством узлов. Слой с меньшим количеством узлов - это слой, в котором количество узлов меньше по сравнению с предыдущими слоями. Его можно использовать для получения представления входных данных с пониженной размерностью. Примером этого является использование автокодировщиков со слоем с меньшим количеством узлов для нелинейного уменьшения размерности.

Согласно вариантам осуществления, мотивы, изображенные на обучающих и тестовых изображениях, связанных с растениями, представляют собой закрытые и/или открытые сельскохозяйственные участки. Маркировки выбираются из группы заранее определенных классов мотивов, включающей в себя:

- участок, покрытый здоровыми растениями;
- участок, покрытый растениями, инфицированными определенной болезнью и/или паразитом;
- участок, покрытый растениями определенного вида;
- участок, покрытый растениями определенного сорта (т.е. подвида);
- участок, покрытый растениями, обработанными определенным веществом, в частности фунгицидом, пестицидом, гербицидом и/или удобрением;
- участок, покрытый растениями, обработанными в соответствии с определенной схемой орошения;
- участок, не покрытый какими-либо растениями;
- участок, покрытый определенным типом почвы;
- участок, покрытый комбинацией заранее определенных частей двух или более вышеупомянутых типов покрытия.

Эти особенности могут быть полезны, в частности, в контексте точного земледелия. Например, для каждой из вышеупомянутых маркировок и соответствующих классов объектов может быть эмпирически получена соответствующая эталонная спектральная сигнатура, которая хранится на носителе информации, оперативно соединенном с компьютером, содержащим процессор(ы), выполняющий(ие) обучение модели машинного обучения. Кроме того, эмпирическим путем могут быть получены эталонные спектральные сигнатуры, которые соответствуют смешанным классам, включающим в себя объекты двух или более вышеупомянутых классов в определенном соотношении. Например, одна из таких дополнительных эталонных спектральных сигнатур может быть получена с сельскохозяйственного участка, покрытого примерно на половину почвой, а на другую половину - здоровыми растениями. Обученная модель машинного обучения может быть использована для автоматического присвоения маркировок, указывающих на любой из вышеупомянутых классов, тестовым изображениям, полученным с помощью первого метода получения изображений. Например, это может позволить прогнозировать, нуждается ли конкретный сельскохозяйственный участок или суб-участок в поливе, обработке фунгицидами, удобрениями, гербицидами, в уборке урожая или в получении какого-либо другого вещества или обработки, например, для повышения урожайности и/или борьбы с инфекционными заболеваниями или паразитами.

Согласно другим вариантам осуществления, мотивами, изображенными на обучающих и тестовых изображениях, связанных с растениями, являются растения, растительные продукты и/или части растения или растительного продукта. Маркировки выбираются из группы заранее определенных классов мотивов, включающей в себя:

- участок поверхности растения или продукта или части этого растения, при этом участок поверхности является здоровым;
- участок поверхности растения или продукта или части этого растения, при этом на участке поверхности появляются симптомы, связанные с инфицированием этого участка определенным заболеванием;
- участок поверхности растения или продукта или части этого растения, при этом участок поверхности свидетельствует об инфицировании этого участка определенным паразитом;
- участок поверхности растения или продукта или части этого растения, при этом на участке поверхности видна клеточная структура или органелла в заранее определенном диапазоне количества;
- участок поверхности растения или продукта или части этого растения, при этом на участке поверхности видна клеточная структура или органелла в заранее определенном состоянии;
- участок поверхности растения или продукта или части этого растения, при этом на участке поверхности наблюдаются морфологические изменения, вызванные местным применением определенного вещества;
- участок поверхности, покрытый комбинацией заранее определенных частей двух или более из вышеупомянутых типов участков поверхности.

Вышеупомянутый подход может быть использован, например, в диагностических целях, например, для определения заболевания или паразита, инфицировавшего конкретное растение или часть растения. Альтернативно, метод может быть использован для контроля качества семян и других видов растительной продукции, например, для обеспечения того, что семена не заражены инфекциями и паразитами и имеют высокую вероятность прорастания. Способ также может быть использован для проверки эффективности конкретного пестицида или фунгицида, который был применен локально.

Согласно вариантам осуществления, автоматически промаркированные тестовые изображения обрабатываются для идентификации растений, обладающих одним или несколькими желательными или нежелательными признаками, и выборочного использования растений, обладающих желательным признаком и/или не обладающих нежелательным признаком, в проекте селекции растений.

В другом аспекте изобретение относится к реализуемому компьютером способу автоматического присвоения одной или нескольких маркировок тестовому изображению, полученному с помощью первого метода получения изображений. На тестовом изображении изображен мотив, связанный с растениями. Способ включает в себя:

предложение обученной модели машинного обучения, причем обученная модель машинного обучения приспособлена для автоматического прогнозирования одной или нескольких маркировок, которые будут присвоены любому входному изображению, полученному с помощью первого метода получения изображений и изображающему мотив, связанный с растениями,

использование обученной модели машинного обучения для прогнозирования одной или нескольких маркировок тестового изображения; и

вывод спрогнозированных маркировок тестового изображения.

Это может быть выгодно, поскольку даже в том случае, если второй метод получения изображений, который использовался для создания вторых обучающих изображений, недоступен (например, потому что соответствующая камера слишком дорогая, слишком сложная в использовании или обслуживании или слишком тяжелая для установки на дрон), обученная модель машинного обучения, тем не менее, способна автоматически спрогнозировать маркировки для тестового изображения, хотя тестовое изображение было получено с помощью первого метода получения изображений.

Согласно вариантам осуществления, обученная модель машинного обучения приспособлена для автоматического прогнозирования одной или нескольких маркировок на основе изученной пространственной взаимосвязи первых признаков, извлеченных из первых обучающих изображений, полученных с помощью первого метода получения изображений, и маркировок, присвоенных вторым обучающим изображениям, причем вторые обучающие изображения демонстрируют те же мотивы, что и первые обучающие изображения, и пространственно совмещены с первыми обучающими изображениями.

Выражение "тот же мотив", используемое в контексте настоящего документа согласно вариантам осуществления изобретения, означает "как минимум приблизительно тот же", поскольку во многих сценариях применения в реальном мире первые и вторые обучающие изображения одного и того же мотива получены в близкой временной последовательности, например, в течение менее одного часа, предпочтительно менее 20 минут, более предпочтительно менее 5 минут, еще более предпочтительно с задержкой менее 5 секунд. Однако этот короткий промежуток времени может вызвать небольшие абсолютные изменения в положении растений и частей растений, вызванные ветром или другими факторами окружающей среды, или может вызвать небольшие относительные изменения между положениями изображаемого мотива и движущейся камеры, используемой для получения первого и второго обучающих изображений. Однако, поскольку эти различия обычно невелики, мотивы, изображенные на первом и втором обучающих изображениях, снятых в непосредственной временной близости и пространственно совмещенных в пару обучающих изображений, можно считать, как минимум приблизительно идентичными.

Согласно вариантам осуществления, способ далее включает в себя создание обученной модели машинного обучения в соответствии со способом согласно любому из описанных здесь вариантов осуществления.

В другом аспекте изобретение относится к системе анализа изображений. Система анализа изображений включает в себя по меньшей мере один процессор и энергозависимый или энергонезависимый носитель информации. Носитель информации включает в себя интерпретируемые компьютером инструкции, которые при выполнении по меньшей мере одним процессором заставляют процессор выполнять реализуемый компьютером способ по любому из описанных здесь вариантов осуществления.

Например, система анализа изображений может представлять собой обычный компьютер, например, настольный компьютер, или распределенную вычислительную систему, например, облачную вычислительную систему.

Система анализа изображений может включать в себя интерфейс для приема первого и второго обучающих изображений и/или для приема одного или нескольких тестовых изображений, полученных с помощью первого метода получения изображений. Например, интерфейс может быть сетевым интерфейсом для приема изображений от другой вычислительной системы. Альтернативно, интерфейс может быть USB-интерфейсом для приема изображений через USB-накопитель. Кроме того, или альтернативно, система получения изображений может быть оперативно соединена с одним или несколькими оптическими датчиками, настроенными на получение первого и/или второго обучающих изображений и/или настроенными на получение одного или нескольких первых тестовых изображений. Система анализа изображений может использоваться как для обучения модели машинного обучения, так и для применения обученной модели машинного обучения к одному или нескольким тестовым изображениям. Альтернативно, различные системы анализа изображений используются для обучения модели машинного обучения и для применения обученной модели к одному или нескольким тестовым изображениям. В этом

случае каждая из систем анализа изображений может иметь вышеописанные особенности. Система анализа изображений, используемая для обучения модели машинного обучения, предпочтительно включает в себя программное приложение для извлечения вторых признаков из вторых обучающих изображений, программное обеспечение для прогнозирования маркировок в зависимости от вторых признаков и для пространственного совмещения пар первых и вторых обучающих изображений (включая их маркировки), изображающих один и тот же мотив, связанный с растениями. Система анализа изображений, используемая для обучения модели машинного обучения и/или для применения обученной модели машинного обучения, включает в себя программное обеспечение для извлечения первых признаков из любого изображения, полученного с помощью первого метода получения изображений, которое было введено в модель машинного обучения. В некоторых вариантах осуществления программное обеспечение для извлечения первых признаков может быть составной частью программного обеспечения машинного обучения, используемого для создания обученной модели машинного обучения.

"Растительным продуктом" может быть, например, одно или несколько семян, один или несколько плодов, черенки, клубень, луковица, лук, бобы и т.д.

"Обучающее изображение" в контексте настоящего документа - это цифровое изображение, используемое для обучения модели машинного обучения. Напротив, "тестовое изображение" в контексте настоящего документа - это цифровое изображение, используемое во время тестирования ("во время прогнозирования") в качестве входных данных для уже обученной модели. В то время как обучающие изображения предлагаются модели для обучения в сочетании с маркировками, считающимися правильными ("эталонные данные"), тестовое изображение предлагается обученной модели машинного обучения без присвоения какой-либо маркировки. Скорее, задача обученной программы машинного обучения состоит в том, чтобы правильно вычислить и спрогнозировать маркировки и положения маркировок.

"Спектральная сигнатура" в контексте настоящего документа представляет собой изменение отражательной способности или излучательной способности материала в зависимости от длины волны (т.е. отражательная способность/излучательная способность как функция длины волны). Например, спектральная сигнатура конкретного объекта, например, почвы, растения определенного вида, растения в определенном физиологическом состоянии и т.д., может быть характерна для определенного типа объекта или его состояния. Спектральная сигнатура объекта является функцией длины волны падающего электромагнитного излучения и взаимодействия материала с данным участком электромагнитного спектра. Согласно вариантам осуществления, спектральная сигнатура объекта, изображенного на цифровом изображении, может быть извлечена в виде признака изображения для каждого пикселя, например, для целей сегментации, или для групп пикселей, например, блоков.

На последнем этапе каждой группе присваивается класс (классификация) путем сравнения с известными спектральными сигнатурами. В зависимости от разрешения пикселя, пиксель может представлять множество спектральных сигнатур, "смешанных" вместе - именно поэтому множество анализов путем дистанционного зондирования проводится для "разделения смесей". В конечном итоге правильное сопоставление спектральной сигнатуры, регистрируемой пикселем изображения, со спектральной сигнатурой существующих элементов приводит к точной классификации в дистанционном зондировании.

"Эталонная спектральная сигнатура" в контексте настоящего документа представляет собой спектральную сигнатуру, взятую от объекта, который рассматривается как типичный представитель класса объектов. Например, программное обеспечение, используемое для прогнозирования маркировок вторых обучающих изображений, может включать в себя хранилище с эталонными спектральными сигналами. Первый из эталонных сигналов включает в себя гиперспектральную сигнатуру, полученную на основе изображения сельскохозяйственного участка, покрытого голой почвой. Второй из эталонных сигналов включает в себя гиперспектральную сигнатуру, полученную на основе изображения сельскохозяйственного участка, покрытого здоровыми растениями определенного вида. Третий из эталонных сигналов включает в себя гиперспектральную сигнатуру, полученную на основе изображения сельскохозяйственного участка, покрытого растениями определенного вида, инфицированными определенным заболеванием или паразитом. Последующие эталонные сигналы соответственно включают в себя гиперспектральную сигнатуру, полученную на основе изображения сельскохозяйственного участка, покрытого определенной смесью двух или более вышеупомянутых категорий "почва", "здоровые растения" и "инфицированные растения".

Термин "машинное обучение" в контексте настоящего документа относится к изучению, разработке или использованию вычислительного алгоритма, который может быть использован для извлечения полезной информации из обучающих наборов данных путем построения вероятностных моделей (называемых моделями машинного обучения или "моделями прогнозирования") автоматизированным способом. Алгоритмы машинного обучения строят математическую модель на основе выборочных данных, известных как "обучающие данные", чтобы делать прогнозы или принимать решения, не будучи явно запрограммированными на выполнение этой задачи. Машинное обучение может быть выполнено с использованием алгоритма обучения, такого как контролируемое или неконтролируемое обучение, алгоритма стимулированного обучения, самообучение и т.д. Машинное обучение может быть основано на различных методах, таких как кластеризация, классификация, линейная регрессия, машины опорных векторов,

нейронные сети и т.д. "Модель" или "модель прогнозирования" может, например, представлять собой структуру данных или программу, такую как нейронная сеть, машина опорных векторов, дерево решений, Байесовская сеть и т.д. или их части, приспособленные для выполнения задачи прогнозирования. Модель приспособлена для прогнозирования неизвестного значения (например, маркировки и/или положения маркировки) на основе других, известных значений.

Например, модель машинного обучения может быть моделью прогнозирования, которая научилась выполнять задачу прогнозирования, такую как классификация или регрессия. Классификация - это задача прогнозирования дискретной маркировки класса для входного сигнала, например, тестового изображения или его части. Регрессия - это задача прогнозирования выхода непрерывной величины для входа.

"Метод получения гиперспектральных изображений" в контексте настоящего документа представляет собой метод получения изображений, который собирает и обрабатывает информацию из всего электромагнитного спектра. Целью гиперспектральной визуализации является получение спектра для каждого пикселя на изображении сцены с целью поиска объектов, идентификации материалов или обнаружения процессов. При гиперспектральной визуализации регистрируемые спектры имеют высокое разрешение по длине волны и охватывают широкий диапазон длин волн. Гиперспектральная визуализация измеряет непрерывные спектральные полосы в отличие от мультиспектральной визуализации, которая измеряет разделенные спектральные полосы. Согласно вариантам осуществления, гиперспектральные датчики приспособлены для захвата электромагнитных сигналов в узких спектральных полосах в непрерывном спектральном диапазоне, создавая спектры всех пикселей в сцене. Датчик с 20 полосами также может быть гиперспектральным, если он охватывает диапазон от 500 до 700 нм с 20 полосами шириной 10 нм каждая. (В то время как датчик с 20 дискретными полосами, охватывающими видимый, ближний, коротковолновый, средневолновый и длинноволновый инфракрасный диапазоны, будет считаться мультиспектральным). Гиперспектральная визуализация (ГСВ) использует непрерывные и смежные диапазоны длин волн (например, 400-1100 нм с шагом 1 нм), в то время как мультиспектральная визуализация (МСВ) использует подмножество целевых длин волн в выбранных местах (например, 400-1100 нм с шагом 20 нм).

Было замечено, что методы получения мультиспектральных изображений (получение 5-7 полос) дают хороший обзор сельскохозяйственных культур, например, общий рост, но иногда не позволяют решить более сложные задачи, такие как идентификация сорняков или определенных заболеваний или паразитов. Гиперспектральная технология с ее более высокими возможностями обнаружения благодаря большому количеству спектральных полос может быть использована практически для любой задачи, возникающей в области точного земледелия и в смежных областях.

"Метод получения RGB-изображений" в контексте настоящего документа представляет собой любой метод получения изображений, использующий камеру или видеокамеру для предложения цифровых изображений, при этом каждому пикселю присвоено значение интенсивности красного (К), зеленого (З) и синего (С) цветов. Например, цифровая камера, использующая датчик изображения с КМОП-матрицей или ПЗС-матрицей, который включает в себя три различных датчика для трех спектральных диапазонов, соответствующих красному, зеленому и синему свету видимого спектра, может быть использована для получения RGB-изображений. Некоторые системы получения RGB-изображений могут использовать схему фильтра Байера, в которой зеленый цвет имеет в два раза больше детекторов, чем красный и синий (соотношение 1:2:1) для достижения более высокого разрешения по яркости, чем по цветности. Датчик имеет сетку из красных, зеленых и синих детекторов, расположенных так, что первый ряд — КЗКЗКЗКЗКЗ, следующий — ЗСЗСЗСЗС, и эта последовательность повторяется в последующих рядах. Для каждого канала недостающие пиксели получают путем интерполяции для построения полного изображения. Также могут быть применены другие процессы для отображения измерений интенсивности света RGB-камеры в стандартное цветовое пространство RGB.

"Метод получения мультиспектральных изображений" в контексте настоящего документа представляет собой метод получения изображений, который приспособлен для захвата изображений в дискретных и сравнительно узких полосах. "Дискретность и сравнительная узость" - это то, что отличает мультиспектральную съемку в видимом диапазоне длин волн от цветной фотографии. Мультиспектральный датчик может иметь множество полос, охватывающих спектр от видимого до длинноволнового инфракрасного диапазона. Мультиспектральные изображения не дают "спектра" объекта.

"Метод получения монохроматических изображений" в контексте настоящего документа представляет собой метод получения изображений, который приспособлен для получения цифровых изображений с одним "цветовым" каналом. Согласно некоторым подходам, для захвата монохроматического изображения используется камера, приспособленная для селективного восприятия световых сигналов в пределах одной и предпочтительно узкой спектральной полосы. Согласно другим вариантам осуществления, камера приспособлена для захвата электромагнитных сигналов широкого спектрального диапазона, при этом захваченная информация об интенсивности далее обрабатывается для создания монохроматического изображения. Например, дальнейшая обработка может включать в себя применение одного или нескольких оптических фильтров для фильтрации всех, кроме этой единственной спектральной полосы, из мультиспектрального/широкоспектрального изображения. Например, одна спектральная полоса может

охватывать сравнительно узкий спектральный диапазон, в котором длина волны отличается от медианной длины волны этого диапазона менее чем на 5%.

"Метод получения ИК-изображений" в контексте настоящего документа представляет собой метод получения изображений, который осуществляется с помощью прибора, называемого инфракрасным спектрометром (или спектрофотометром), для захвата инфракрасного спектра объекта или сцены. Инфракрасная часть электромагнитного спектра, охватываемая методом получения ИК-изображений в соответствии с вариантами осуществления изобретения, может охватывать ближний инфракрасный (длина волны 0,7-2,5 мкм), средний инфракрасный (2,5-25 мкм) и/или дальний инфракрасный (25-1000 мкм) диапазоны.

"Метод получения активных изображений" в контексте настоящего документа представляет собой любой метод получения изображений, включая любой из вышеупомянутых методов получения изображений, который использует источник возбуждающего света для освещения сцены, изображение которой должно быть получено. Например, источник возбуждающего света может быть источником УФ-света, который настроен на излучение УФ-импульсов на мотив, связанный с растениями, например, целое растение, семя или его часть. УФ-импульсы могут вызывать сигнал флуоресценции, который фиксируется камерой с ПЗС-матрицей с усилителем яркости изображения. Например, активная визуализация может использоваться для флуоресцентной визуализации растений, в частности, мультиспектральной флуоресцентной визуализации в максимумах полос эмиссии флуоресценции листьев, т.е. в синей (440 нм), зеленой (520 нм), красной (690 нм) и дальней красной (740 нм) спектральных областях. Например, синезеленая флуоресценция исходит от феруловых кислот, ковалентно связанных с клеточными стенками, а красная и дальняя красная флуоресценция исходит от хлорофилла в хлоропластах зеленых клеток мезофилла. Интенсивность флуоресценции зависит (1) от изменения концентрации излучающих веществ, (2) от внутренней оптики листьев, определяющей проникновение возбуждающего излучения и частичное поглощение испускаемой флуоресценции, и (3) от распределения энергии между фотосинтезом, выделением тепла и испусканием флуоресценции хлорофилла и, следовательно, предоставляет ценную информацию о состоянии здоровья растений. Активная визуализация с использованием, например, УФ источника возбуждающего света может применяться для скрининга на близком расстоянии или дистанционно зондирования в контексте точного земледелия и в смежных областях.

Операции блок-схем описаны со ссылками на системы/аппараты, показанные на блок-схемах. Однако следует понимать, что операции блок-схем могут быть выполнены вариантами осуществления систем и аппаратов, отличными от тех, которые обсуждаются со ссылкой на блок-схемы, и варианты осуществления, обсуждаемые со ссылкой на системы/аппараты, могут выполнять операции, отличные от тех, которые обсуждаются со ссылкой на блок-схемы.

Ввиду широкого разнообразия вариантов осуществления описанных здесь вариантов, данное подробное описание предназначено только для иллюстрации и не должно рассматриваться как ограничивающее объем изобретения. Таким образом, в качестве изобретения заявлены все модификации, которые могут входить в объем следующей формулы изобретения и ее эквивалентов. Поэтому спецификацию и чертежи следует рассматривать в иллюстративном, а не ограничительном смысле.

Краткое описание чертежей

Далее более подробно описаны только примерные формы изобретения со ссылкой на чертежи, в которых они содержатся. Они показывают:

фиг. 1А блок-схема системы, используемой для создания модели машинного обучения, которая научилась маркировать RGB-изображения;

фиг. 1В автоматически промаркированное гиперспектральное обучающее изображение;

фиг. 2 блок-схема вычислительной системы, используемой для прогнозирования маркировок для тестового RGB-изображения с помощью обученной модели машинного обучения;

фиг. 3 тестовое RGB-изображение, которое было автоматически промаркировано обученной моделью, и гиперспектральное изображение, которое было автоматически промаркировано на основе его спектральных сигнатур;

фиг. 4 структурная схема способа предложения обученной модели машинного обучения, приспособленной для автоматической маркировки изображений, полученных с помощью первого метода получения изображений;

фиг. 5 структурная схема способа использования обученной модели машинного обучения для автоматической маркировки изображений, полученных с помощью первого метода получения изображений;

и

фиг. 6 участок с двумя спектральными сигнатурами.

Подробное описание

На фиг. 1А показана блок-схема системы 100, используемой для создания модели 132 машинного обучения, которая научилась маркировать RGB-изображения. Создаваемая модель должна быть способна автоматически идентифицировать и маркировать растения сахарной свеклы, инфицированные определенной болезнью или паразитом, например, Церкоспорой, на основе RGB-изображений, которые можно легко получить с помощью стандартных камер. Церкоспора - это род грибов-аскомицетов. Большин-

ство видов этого рода вызывают заболевания растений и образуют пятна на листьях.

Система включает в себя вычислительную систему 120, например, стандартную настольную вычислительную систему, одну или несколько RGB-камер 104, приспособленных для получения цифровых RGB-изображений тестового поля с растениями сахарной свеклы, инфицированными Церкоспорой, и одну или несколько гиперспектральных камер 102, приспособленных для получения цифровых гиперспектральных изображений этого тестового поля. Использование RGB-камеры 104 обозначается как "первый метод получения изображений", а использование гиперспектральной камеры 102 обозначается как "второй метод получения изображений".

Гиперспектральная камера 102 и RGB-камера 104 расположены в непосредственной пространственной близости друг от друга таким образом, что обе изображают тестовое поле практически с одинакового расстояния и под одинаковым углом. Альтернативно, два типа камер 102, 104 располагаются на одном и том же месте и используются последовательно для получения изображений.

В одном варианте осуществления, HySpex Mjolnir была использована в качестве гиперспектральной камеры 102, и Sony Alpha 7rII была использована в качестве RGB-камеры 104. Беспилотный летательный аппарат (БПЛА), например, дрон, был оснащен обеими камерами 102 104.

Гиперспектральные изображения 106, полученные гиперспектральной камерой 102, и RGB-изображения 205, полученные RGB-камерой, были индивидуально географически привязаны на основе высокоточного инерциального измерительного блока с поддержкой ГНСС (где ГНСС означает глобальную навигационную спутниковую систему). Инерциальный измерительный блок - это электронное устройство, которое измеряет и сообщает об удельной силе объекта, угловой скорости, и иногда об ориентации тела, используя комбинацию акселерометров, гироскопов и иногда магнитометров. Использование GPS-устройств с инерциальными измерительными блоками может позволить GPS-приемнику работать в условиях отсутствия GPS-сигналов, например, при наличии электронных помех.

Полученные изображения 106, 205 передаются в вычислительную систему 120 и сохраняются на носителе 121 информации. Носитель 121 информации предпочтительно представляет собой энергонезависимый носитель информации, например, электромагнитный или оптический носитель информации, например, жесткий диск, DVD или тому подобное. Передача может осуществляться через мобильную телекоммуникационную связь во время полета БПЛА над полем. Альтернативно, передача может быть выполнена после приземления БПЛА, например, путем передачи SD-карты, USB-накопителя или другого типа портативного устройства хранения данных БПЛА вручну в вычислительную систему 120. Гиперспектральные изображения 106 используются как вторые обучающие изображения, и переданные RGB-изображения 205 используются как первые обучающие изображения во время обучения модели машинного обучения.

Вычислительная система 120 включает в себя один или несколько процессоров 112, настроенных на инстанцирование и запуск одного или нескольких программных обеспечений или модулей 114, 118, 122, 126, участвующих в создании обученной модели 132.

Например, модуль 114 извлечения признаков настроен на извлечение признаков изображения, называемых здесь вторыми признаками 116, из каждого пикселя каждого второго обучающего изображения 106. Второй признак предпочтительно состоит из или включает в себя спектральную сигнатуру. Например, спектральная сигнатура может быть кривой, указывающей на интенсивность света, наблюдаемую в континууме длин волн спектра, охватываемого гиперспектральным датчиком.

Модули 118 прогнозирования маркировок настроены на прием извлеченных вторых признаков в качестве входных данных и вычисление одной или нескольких маркировок для каждого второго обучающего изображения 106. Например, модуль 118 прогнозирования маркировок может включать в себя хранилище, содержащее множество эталонных спектральных сигнатур. Каждая эталонная спектральная сигнатура является описанием спектральной сигнатуры, характерной для определенного типа объекта. Например, хранилище может содержать эталонную гиперспектральную сигнатуру, характерную для обычной почвы, эталонную гиперспектральную сигнатуру, характерную для здоровых растений сахарной свеклы, эталонную гиперспектральную сигнатуру, характерную для растений сахарной свеклы, инфицированных Церкоспорой, эталонную гиперспектральную сигнатуру, характерную для смеси 50:50 здоровых и инфицированных Церкоспорой растений сахарной свеклы и т.д. Сравнивая эталонную спектральную сигнатуру, хранящуюся в хранилище модуля 118, со спектральными сигнатурами объектов в каждом втором обучающем изображении, модуль 118 может определить, какая из эталонных спектральных сигнатур наиболее похожа на спектральную сигнатуру соответствующего пикселя. Этому пикселю присваивается имя класса "наиболее похожей эталонной спектральной сигнатуры" пикселя на втором обучающем изображении. Альтернативно, числовое значение, указывающее на вероятность того, что пиксель на втором обучающем изображении изображает тип объектов, представленных "наиболее похожей эталонной спектральной сигнатурой", присваивается в качестве маркировки пикселю второго обучающего изображения.

Модуль 118 прогнозирования маркировок выводит промаркированное второе обучающее изображение 110 для каждого из вторых обучающих изображений 106.

Модуль 122 совмещения настроен на пространственное совмещение первых и вторых обучающих

изображений, изображающих один и тот же или практически один и тот же мотив. Например, совмещение может быть выполнено на основе GPS-координат, присвоенных изображениям камерами 102, 104, или может быть основано на известных параметрах камеры, таких как известное, фиксированное позиционирование камеры относительно мотива и/или относительно камеры другого типа. Кроме того, или альтернативно, может быть вычислен индекс зеленого цвета, который используется в качестве основы для совмещения первого и второго обучающих изображений. Модуль 118 прогнозирования маркировок может вычислить и присвоить по меньшей мере одну маркировку каждому из вторых обучающих изображений (или их суб-области, например, блоку пикселей или отдельному пикселю) до или после того, как модуль совмещения выполнит совмещение изображений.

Согласно вариантам осуществления, в которых маркировки присваиваются отдельным пикселям или блокам пикселей, модуль совмещения по своей сути также пространственно совмещает маркировки, которые присвоены или будут присвоены пикселям или областям пикселей вторых обучающих изображений, с соответствующими пикселями или областями пикселей первых обучающих изображений.

Совмещенные маркировки 124, т.е. содержание маркировок, а также указание одного или нескольких пикселей первого обучающего изображения, с которыми совмещена маркировка, вводятся вместе с первым обучающим изображением 205, с которыми были совмещены маркировки, в программное обеспечение 126, настроенное для обучения модели машинного обучения. Например, программное обеспечение 126 может включать в себя модуль 128, содержащий множество алгоритмов для извлечения признаков 130 из каждого из первых обучающих изображений. Кроме того, программное обеспечение 126 может включать в себя дополнительные алгоритмы и модули, необходимые в процессе обучения. Например, программное обеспечение 126 может включать в себя функцию потерь, которая настроена на сравнение маркировок, спрогнозированных модулем 132 машинного обучения на основе извлеченных первых признаков 130 во время обучения, с маркировками 124, предложенными в качестве обучающих данных во время обучения, и на адаптацию модели 132 таким образом, чтобы минимизировать отклонение спрогнозированных первых маркировок и предложенных "истинных" маркировок 124. Например, программное обеспечение DeepLabv3 может быть использовано в качестве обучающего программного обеспечения. DeepLabv3 - это современное программное обеспечение для глубокого обучения, определяющее модель глубокого обучения для семантической сегментации изображений, где целью является присвоение семантических маркировок, указывающих, например, на принадлежность к классу каждого пикселя на входном изображении. DeepLabv3 включает в себя несколько алгоритмов извлечения признаков изображения и включает в себя дополнительные модули, приспособленные для обучения модели машинного обучения на основе извлеченных первых признаков и дополнительных обучающих данных, предложенных пользователем.

Предпочтительно, обучающие данные, используемые для обучения модели 132 машинного обучения, включают в себя несколько сотен или предпочтительно несколько тысяч первых обучающих изображений и соответствующее количество вторых обучающих изображений, которые совмещены друг с другом и образуют несколько сотен или предпочтительно несколько тысяч пар совмещенных обучающих изображений.

На фиг. 1В более подробно показано автоматически промаркированное гиперспектральное обучающее изображение, созданное системой в соответствии с вариантами осуществления изобретения. Первоначально модуль 118 прогнозирования маркировок присваивает маркировку каждому отдельному пикселю второго обучающего изображения 106. В изображенном примере используются только три различные маркировки: маркировка 150, обозначающая почву, маркировка 152, обозначающая здоровые растения сахарной свеклы, и маркировка 154, обозначающая растения сахарной свеклы, инфицированные Церкоспорой. После того, как модуль 122 совмещения выполнил совмещение изображений, промаркированное второе обучающее изображение или комбинация только маркировок и информации о положении маркировок может быть предоставлена в качестве входных данных для обучающего программного обеспечения 126 машинного обучения.

На фиг. 1В показано графическое представление промаркированного второго обучающего изображения, в котором различные суб-области изображения были определены путем применения алгоритма сегментации, который группирует пиксели с одинаковыми или похожими маркировками в один и тот же сегмент. Например, алгоритм сегментации определил области 150 изображения, соответственно изображающие почву, большую область 152 изображения, изображающую здоровые растения сахарной свеклы, и множество участков 154 изображения, соответственно изображающих растения сахарной свеклы, инфицированные Церкоспорой. Применение алгоритма сегментации изображения и представление различных сегментов разными цветами или штриховкой может быть выгодным, поскольку такое графическое представление облегчает интерпретацию прогнозов маркировок человеком. Например, промаркированное и сегментированное изображение 110 может быть выведено пользователю на экран или распечатано.

Фиг. 2 - блок-схема вычислительной системы 120, используемой для прогнозирования маркировок 150, 152, 154 для тестового RGB-изображения 108 с помощью обученной модели 132 машинного обучения.

Вычислительная система 120 может быть той же самой вычислительной системой, которая исполь-

зуется для выполнения обучения. Альтернативно, вычислительная система может быть любой другой вычислительной системой, например, облачной вычислительной системой или настольной вычислительной системой, на которую была перенесена обученная модель машинного обучения.

Вычислительная система, используемая для применения обученной модели машинного обучения во время тестирования, включает в себя носитель 121 информации и один или несколько процессоров 112, которые идентичны или функционально эквивалентны носителю информации и процессорам, уже описанным со ссылкой на фиг. 1А. Вычислительная система 120 включает в себя программное обеспечение 202 для прогнозирования с модулем 128 извлечения признаков и обученной моделью 132 машинного обучения. Модуль извлечения признаков настроен на извлечение тех же типов признаков изображения, которые были извлечены как "первые признаки" во время обучения модели машинного обучения. Модуль 128 извлечения признаков может быть составной частью программного обеспечения 202 для прогнозирования или может быть отдельным программным приложением или модулем, настроенным на предварительную обработку любого полученного тестового изображения 108 для извлечения первых признаков 204 и предложения первых признаков в качестве входных данных для программного обеспечения 202 для прогнозирования.

Носитель информации содержит одно или несколько тестовых изображений 108, соответственно полученных с помощью первого метода получения изображений. В примерах, изображенных на фигурах 1 и 2, первый метод получения изображений представляет собой метод получения RGB-изображений. Тестовые изображения могут быть получены с другого компьютера по сети, могут быть считаны с локального или удаленного носителя информации, например, с USB-накопителя, и/или могут быть получены непосредственно с RGB-камеры 104. RGB-камера 104 может быть отличной от RGB-камеры, изображенной на фиг. 1А, и одинаковые ссылочные позиции лишь указывают на функциональную эквивалентность.

Каждое тестовое RGB-изображение 108 предлагается в качестве входных данных для программного обеспечения 202 для прогнозирования. Модуль 128 извлечения признаков извлекает множество первых признаков 204 из каждого тестового RGB-изображения. Например, первые признаки 204 изображения могут включать в себя градиенты интенсивности, текстуры и другие узоры, значения интенсивности, значения цвета, градиенты цвета, значения контраста и т.д. Извлеченные первые признаки 204 предлагаются в качестве входных данных для обученной модели 132 машинного обучения. В процессе обучения модель изучила пространственные взаимосвязи между маркировками и первыми признаками изображения, извлеченными из обучающих RGB-изображений. Таким образом, на основе первых признаков 204, предложенных модулем 128 извлечения признаков, обученная модель 132 машинного обучения способна спрогнозировать по меньшей мере одну маркировку и соответствующее положение маркировки для каждого тестового RGB-изображения 108. Например, в некоторых вариантах осуществления, прогнозируется только одна маркировка для каждого изображения. Предпочтительно, маркировки прогнозируются для каждого пикселя тестового RGB-изображения.

На промаркированном тестовом изображении 206 изображены сегменты изображения, полученные путем сегментирования тестового изображения 206 на основе пиксельных маркировок, спрогнозированных программным обеспечением 202. Промаркированное и сегментированное тестовое изображение 206 содержит несколько суб-областей, обозначенных белым цветом, которым присвоена маркировка 250, обозначающая почву. Изображение 206 также содержит большую область, обозначенную первой штриховкой, которой присвоена маркировка 252, обозначающая здоровые растения сахарной свеклы, и множество мелких участков изображения, обозначенных второй, темной штриховкой, которым присвоена маркировка 254, обозначающая растения сахарной свеклы, инфицированные Церкоспорой.

На фиг. 3 более подробно показано тестовое RGB-изображение 206, которое было автоматически промаркировано обученной моделью, при этом различные сегменты изображения, которым присвоены различные маркировки, представлены разными цветами, а не разными штриховками.

Чтобы проиллюстрировать точность предлагаемого подхода к прогнозированию маркировок, в нижней части фиг. 3 показаны маркировки, полученные для одного и того же тестового поля с помощью гиперспектральной камеры и программного обеспечения для прогнозирования маркировок, которое использует гиперспектральные сигнатуры для прогнозирования маркировок. Гиперспектральная камера 102 используется для получения гиперспектрального изображения 302, на котором изображен тот же сельскохозяйственный участок, что и на тестовом изображении 108. Сравнение тестового RGB-изображения 108 и гиперспектрального тестового изображения 302 показывает, что на обоих изображениях изображен один и тот же сельскохозяйственный участок. Конечно, спектральная информация за пределами видимого спектрального диапазона, которая содержится в гиперспектральном изображении 302, не может быть проиллюстрирована здесь. Применяя модуль 114 извлечения признаков, извлекающий вторые признаки 116 в виде спектральных сигнатур и сравнивая извлеченные спектральные сигнатуры каждого пикселя с соответствующими эталонными спектральными сигнатурами, конкретные маркировки пикселей могут быть вычислены модулем 118 прогнозирования маркировок, как описано ранее. В результате выполнения этапа сегментации изображения на основе указанных маркировок создается промаркированное и сегментированное гиперспектральное изображение 304. Сравнение двух промарки-

рованных изображений 206, 304 показывает, что обученная модель машинного обучения способна спрогнозировать тип и положение маркировок практически с той же точностью, что и модуль 118 прогнозирования маркировок, использующий в качестве входных данных гиперспектральные данные. Таким образом, несмотря на то, что RGB-камера, используемая для получения первого тестового изображения, охватывает меньший спектральный диапазон, обученная программа машинного обучения способна точно прогнозировать местоположение и тип маркировок. Таким образом, способ автоматической маркировки тестовых изображений, полученных с помощью первого метода получения изображений, с использованием модели машинного обучения, обученной на автоматически созданных маркировках гиперспектральных изображений, объединяет преимущества RGB и гиперспектральных способов визуализации: гиперспектральные изображения очень гибкие и позволяют автоматически идентифицировать практически любой объект на основе спектральных сигнатур, содержащих большое количество информации. RGB-изображения могут быть получены с помощью стандартных дешевых RGB-камер. Благодаря использованию гиперспектральных изображений только во время обучения, но использованию RGB-изображений для автоматической маркировки во время тестирования, затраты и усилия, связанные с использованием гиперспектральных камер, возникают только на этапе обучения, а не на этапе тестирования.

На фиг. 4 показана структурная схема способа предложения обученной модели машинного обучения, которая приспособлена для автоматической маркировки изображений, полученных с помощью первого метода получения изображений, например, RGB-съемки.

Например, метод может быть выполнен системой, изображенной на фиг. 1А.

Сначала, на этапе 402, метод включает в себя получение множества вторых обучающих изображений 106 с помощью второго метода получения изображений, например, гиперспектральной камеры 102. Кроме того, второй метод получения изображений может быть использован для получения эталонных спектральных сигнатур объектов одного или нескольких различных интересующих классов объектов. Например, могут быть получены эталонные гиперспектральные сигнатуры почвы, здоровых растений сахарной свеклы и растений сахарной свеклы, инфицированных Церкоспорой.

Далее на этапе 404 для каждого из вторых обучающих изображений 106 вычисляется по меньшей мере одна маркировка. Например, модуль 114 извлечения признаков извлекает спектральную сигнатуру для каждого пикселя в каждом из вторых обучающих изображений и использует их в качестве вторых признаков 116. Извлеченные спектральные сигнатуры сравниваются с эталонными спектральными сигнатурами для определения одной из эталонных спектральных сигнатур, наиболее похожей на спектральную сигнатуру текущего исследуемого пикселя. Класс объектов, представленный идентифицированной наиболее похожей эталонной сигнатурой, присваивается в виде по меньшей мере одной маркировки каждому из вторых обучающих изображений. Например, маркировка может быть присвоена каждому пикселю каждого второго обучающего изображения.

Согласно одному варианту осуществления, каждое из вторых обучающих гиперспектральных изображений сравнивалось с вышеупомянутыми эталонными гиперспектральными сигнатурами для расчета попиксельного значения сходства для спектров почвы, здоровых растений и растений, инфицированных Церкоспорой, с использованием алгоритма отображения спектрального угла. Согласно вариантам осуществления, эталонные спектральные сигнатуры для вышеупомянутых трех классов были получены эмпирически, кроме того, еще 13 классов, представляющих смеси почвы, здоровых растений и растений, инфицированных Церкоспорой с шагом 25%, были получены вычислительным путем при объединении вышеупомянутых "чистых" эталонных спектров.

Алгоритм отображения спектрального угла - это алгоритм, адаптированный для измерения спектрального сходства между двумя спектрами. Спектральное сходство можно получить, рассматривая каждый спектр как вектор в q -мерном пространстве, где q - количество полос, и сравнивая два вектора. Полученные значения сходства (указывающие на сходство, например, с эталонными спектрами для "почвы" или "здоровых растений сахарной свеклы" и т.д.) использовались в качестве маркировок в соответствии с одним вариантом осуществления изобретения, таким образом, получая изображения с низким разрешением, где значения представляют собой пиксельные маркировки.

Варианты осуществления изобретения могут быть особенно полезны в контексте точного земледелия, контроля качества для селекционных компаний и в смежных технических областях. Почти каждый класс объектов, связанных с растениями (растения определенной группы или вида, поля, заросшие сорняками, растения, инфицированные определенной болезнью, растения с дефицитом питательных веществ и т.д.), характеризуется определенным физиологическим состоянием или изменением состояния, которое влияет на отражающие свойства объекта. Здоровая культура и культура, пораженная болезнью, по-разному отражают солнечный свет. С помощью гиперспектральной съемки можно обнаружить очень небольшие изменения в физиологии растения и соотнести их со спектром отраженного света для автоматической маркировки большого количества гиперспектральных обучающих изображений.

Кроме того, на этапе 406 одно или несколько первых обучающих изображений 205 получены с помощью первого метода получения изображений, например, с помощью RGB-камеры 104. Этап 402 и этап 406 могут выполняться одновременно или последовательно. В любом случае, этапы 402 и 406 должны

быть выполнены таким образом, чтобы пары первых и вторых обучающих изображений в основном изображали один и тот же мотив и, следовательно, могли быть пространственно совмещены друг с другом. Изображение в основном одного и того же мотива в контексте настоящего документа означает, что относительное положение (расстояние и угол) между камерой, используемой для получения изображений, и мотивом, а также предпочтительно условия окружающей среды (интенсивность света, положение источника света, температура, спектральный состав света, излучаемого источником света) одинаковы или приблизительно одинаковы.

Далее на этапе 408 каждое первое обучающее изображение пространственно совмещается с одним из вторых обучающих изображений, изображающих тот же мотив.

Согласно вариантам осуществления, совмещение изображений выполняется следующим образом: RGB-представление гиперспектрального изображения, используемого в качестве второго обучающего изображения 106, рассчитывается путем усреднения соответствующих спектральных полос. Соответствующий индекс зеленого цвета рассчитывается как на основе "реального" RGB-изображения 205, полученного в качестве одного из первых обучающих изображений, так и на основе "вычисленного" RGB-изображения, которое является производной одного из вторых обучающих изображений 106. Индексы зеленого цвета сравниваются друг с другом для вычисления и оценки поля смещения. Например, это можно вычислить с помощью функции MATLAB "imregdemons".

Использование индекса зеленого цвета (или любого другого признака, определяемого мотивом, отличие которого между двумя совмещенными изображениями минимизируется во время совмещения) имеет то преимущество, что растения или части растений, которые расположены в немного разных позициях на первом и втором изображении, могут быть правильно совмещены. Например, такие факторы, как ветер, временная задержка в несколько часов между получением первого и второго изображения одного и того же мотива, использование разных дронов для получения первого и второго изображений и/или использование дронов, имеющих немного разные траектории, могут привести к позиционному смещению изображенного мотива на первом и втором изображениях.

Согласно вариантам осуществления, первая система получения изображений, используемая для получения первых обучающих изображений, и вторая система получения изображений, используемая для получения вторых обучающих изображений, установлены на одной и той же несущей системе, например, на дроне. Это может гарантировать, что изображенные мотивы в парах первых и вторых обучающих изображений, изображающих один и тот же мотив, имеют лишь небольшое пространственное смещение в несколько пикселей.

Согласно другим вариантам осуществления, первые обучающие изображения получены первым датчиком, установленным на первой несущей системе, а вторые обучающие изображения получены вторым датчиком, установленным на второй несущей системе, причем вторая несущая система отличается от первой несущей системы или является первой несущей системой, используемой несколько раз для получения первых и вторых обучающих изображений последовательно в ходе нескольких различных полетов. Например, первая и вторая несущие системы могут быть разными дронами или могут быть одним и тем же дроном, используемым для последовательного получения первых и вторых обучающих изображений во время нескольких разных полетов.

Например, первые обучающие изображения могут быть получены в одном или нескольких полетах первой несущей системы, а вторые обучающие изображения могут быть получены в одном или нескольких полетах второй несущей системы. Полеты первой и второй несущих систем выполняются в разное время, в частности, с межполетным интервалом по меньшей мере 5 минут, или даже несколько часов. За этот интервал времени положение растений могло немного измениться, например, из-за ветра, или из-за движения или переориентации растения или частей растения в направлении света.

Согласно некоторым вариантам осуществления, которые особенно полезны, если первые и вторые изображения получены в ходе нескольких последовательных полетов одной и той же или разных несущих систем, первые и вторые изображения являются географически привязанными изображениями, т.е. изображениями с заданной информацией о местоположении, в частности, координатами географически привязанной системы координат. Например, несущая система, используемая для размещения первого и/или второго датчиков, может включать в себя датчик инерциального измерительного блока, в частности, датчик инерциального измерительного блока с поддержкой ГНСС.

Инерциальный измерительный блок - это датчик, включающий в себя, например, датчики движения (акселерометры) и/или датчики вращения (гироскопы) для непрерывного вычисления положения, ориентации и скорости (направления и скорости движения) движущегося объекта без необходимости использования внешних ссылок. Часто инерционные датчики дополняются барометрическим высотомером и иногда магнитными датчиками (магнитометрами) и/или устройствами измерения скорости.

В частности, датчик инерциального измерительного блока может быть датчиком инерциального измерительного блока с поддержкой ГНСС. Термин "ГНСС" (глобальная навигационная спутниковая система) - это навигационная система с глобальным покрытием, использующая спутники для обеспечения автономного геопространственного позиционирования. Она позволяет небольшим электронным приемникам определять свое местоположение (долготу, широту и высоту/высоту над уровнем моря) с высо-

кой точностью (в пределах от нескольких сантиметров до метров), используя сигналы времени, передаваемые вдоль линии прямой видимости по радио со спутников. Система может использоваться для определения местоположения, навигации или для отслеживания положения чего-либо, оснащенного приемником (спутниковое слежение). По состоянию на сентябрь 2020 года Глобальная система позиционирования США (GPS), Российская глобальная навигационная спутниковая система (ГЛОНАСС), Китайская навигационная спутниковая система BeiDou (BDS) https://en.wikipedia.org/wiki/Satellite_navigation - cite_note-autogenerated1-1 и Galileo Европейского союза являются полностью действующими ГНСС. Японская квази-зенитная спутниковая система (КЗСС) - это спутниковая система дополнения GPS (США) для повышения точности GPS, причем спутниковая навигация, независимая от GPS, запланирована на 2023 год. Индийская региональная навигационная спутниковая система (ИРНСС) в перспективе планирует расширяться до глобальной версии. Геопозиция несущей системы в момент получения первого или второго обучающих изображений сохраняется совместно с соответствующим обучающим изображением для последующего использования при совмещении изображений.

Использование датчика инерциального измерительного блока с поддержкой ГНСС для определения положения несущей системы во время получения первых и вторых обучающих изображений позволяет разместить первый и второй датчики получения изображений на разных несущих системах и/или получить первые и вторые обучающие изображения последовательно.

Согласно вариантам осуществления, совмещение первого и второго изображений каждой из пар включает в себя совмещение первого и второго изображений, изображающих один и тот же мотив, на основе их соответствующих геопозиций, тем самым обеспечивая приблизительно совмещенную пару изображений; и затем уточнение совмещения в зависимости от интенсивности пикселей и/или цветового сходства (например, на основе индекса зеленого цвета) для обеспечения совмещения первого и второго изображения пары.

Далее на этапе 410 промаркированные вторые обучающие изображения (или просто их маркировки), совмещенные с RGB-изображением, были введены в программу машинного обучения, используемую для обучения модели. Например, можно использовать глубокую нейронную сеть семантической сегментации DeepLabv3+, которая уже поставляется с множеством алгоритмов извлечения признаков. Таким образом, совмещенные первые изображения могут быть введены в DeepLabv3+ до начала процесса извлечения первых признаков. Затем DeepLabv3+ автоматически выполняет извлечение первых признаков и обучение модели машинного обучения.

Согласно другому варианту осуществления, первые обучающие изображения были обработаны для извлечения первых признаков изображения, и извлеченные первые признаки и первые обучающие изображения предоставляются программному обеспечению машинного обучения.

Независимо от того, сама программа машинного обучения или модуль предварительной обработки выполняет извлечение первых признаков изображения, пространственное совмещение маркировок и первых признаков изображения может позволить модели машинного обучения, например, глубокой нейронной сети семантической сегментации, изучить пространственные взаимосвязи между маркировками и первыми признаками в процессе обучения.

В результате обучения предлагается обученная модель машинного обучения, которая изучила взаимосвязи между первыми признаками, извлеченными из обучающих RGB-изображений, и маркировками, пространственно совмещенными с первыми обучающими изображениями и первыми признаками изображений. Обученная модель машинного обучения способна прогнозировать маркировки изображений для любого входного изображения, полученного с помощью первого метода получения изображений и изображающего мотив, связанный с растениями, аналогичный мотиву, изображенному на обучающих изображениях.

На этапе 412 предлагается обученная модель машинного обучения. Например, обучающее программное обеспечение 126 или его части могут быть переданы на другой компьютер через сетевое соединение или с помощью переносного носителя информации и использованы на другом компьютере для автоматической маркировки тестовых RGB-изображений. Присвоенные маркировки указывают на тип объекта, изображенного пикселями тестового изображения, которым присвоены маркировки. Классы - это те же классы, которые использовались на этапе обучения для маркировки вторых обучающих изображений. Как показано на фиг. 3, обученная программа машинного обучения точно выдает результаты классификации, которые визуально похожи на эталонные данные. Другими словами, обученная программа машинного обучения может быть использована в соответствии с вариантами осуществления в качестве классификатора, приспособленного для точного прогнозирования маркировок RGB-изображений высокого разрешения, хотя в процессе обучения использовались маркировки гиперспектральных изображений. Создание обучающих данных 110, 205 было выполнено полностью автоматически или полуавтоматически и не зависело от аннотирования человеком.

На фиг. 5 представлена структурная схема способа использования обученной модели 132 машинного обучения для автоматической маркировки изображений, полученных с помощью первого метода получения изображений.

На первом этапе 502 предлагается обученная модель 132 машинного обучения. Например, модель и,

если требуется, дополнительные модули программного обеспечения, например, модуль 128 извлечения признаков, хранятся в вычислительной системе 120, содержащей или настроенной для приема одного или нескольких тестовых изображений 108.

Далее на этапе 503 одно или несколько тестовых изображений получают с помощью первого метода получения изображений, в частности, метода получения RGB-изображений. На каждом из тестовых изображений изображен мотив, связанный с растениями, например, сельскохозяйственный участок, растение, растительный продукт или их часть. Мотив, связанный с растениями, на тестовом изображении похож на мотивы, связанные с растениями, на первых и вторых обучающих изображениях, использованных для обучения модели машинного обучения. Этап 503 может быть выполнен перед этапом 502.

Далее на этапе 504 обученная модель машинного обучения применяется к каждому из тестовых изображений. Таким образом, из каждого тестового изображения извлекаются первые признаки. Например, программное обеспечение 202 для прогнозирования может быть в основном идентично обучающему программному обеспечению 126, используемому для обучения модели, и может включать в себя модуль 128 извлечения признаков, содержащий множество алгоритмов для извлечения различных признаков изображения из RGB-изображения. Признаки 204 изображения, извлеченные из тестового изображения, используются обученной моделью машинного обучения для прогнозирования одной или нескольких маркировок и присвоения маркировок тестовому изображению.

Далее на этапе 506 происходит вывод спрогнозированных маркировок. Например, спрогнозированные маркировки могут быть использованы на этапе сегментации для вычисления сегментированного изображения, которое показывается пользователю на экране или распечатывается.

На фиг. 6 показан участок, содержащий первую эталонную спектральную сигнатуру 602, характерную для почвы, и вторую эталонную спектральную сигнатуру 604, характерную для воды. Сравнивая эталонные спектральные сигнатуры 602, 604 со спектральными сигнатурами каждого пикселя на вторых обучающих изображениях, можно вычислить маркировки, указывающие на тип объекта, изображенного на изображении или в области изображения, или указывающие на вероятность изображения объекта этого класса.

Список ссылочных позиций

- 100 система,
- 102 гиперспектральная камера,
- 104 RGB-камера,
- 106 второе обучающее изображение, полученное с помощью второго метода получения изображений,
- 108 первое обучающее изображение, полученное с помощью первого метода получения изображений,
- 110 маркированное второе обучающее изображение,
- 112 процессор(ы),
- 114 модуль извлечения признаков,
- 116 извлеченные вторые признаки,
- 118 модули прогнозирования маркировок,
- 120 вычислительная система,
- 121 носитель информации,
- 122 модуль совмещения,
- 124 совмещенные маркировки,
- 126 обучающее программное обеспечение для машинного обучения,
- 128 модуль извлечения признаков,
- 130 извлеченные первые признаки,
- 132 модель машинного обучения,
- 150 штриховка, используемая в качестве маркировки: почва,
- 152 штриховка, используемая в качестве маркировки: здоровые растения,
- 154 штриховка, используемая в качестве маркировки: растения, инфицированные Церкоспорой (ЦР),
- 200 система,
- 202 программное обеспечение для прогнозирования,
- 204 первые признаки, извлеченные из тестового изображения,
- 205 тестовое изображение, полученное с помощью первого метода получения изображений,
- 206 промаркированное изображение, созданное из тестового изображения, программным обеспечением,
- 202 для прогнозирования,
- 250 штриховка, используемая в качестве маркировки: почва,
- 252 штриховка, используемая в качестве маркировки: здоровые растения,
- 254 штриховка, используемая в качестве маркировки: растения, инфицированные Церкоспорой,
- 302 гиперспектральное изображение,

304 маркировки, спрогнозированные на основе гиперспектрального изображения,
402-412 этапы,
502-506 этапы,
602 спектральная сигнатура,
604 спектральная сигнатура.

ФОРМУЛА ИЗОБРЕТЕНИЯ

1. Реализуемый компьютером способ распознавания и автоматической маркировки макроструктур, включающий

получение (406) первых обучающих изображений (108) с помощью первого метода (104) получения изображений, при этом каждое первое обучающее изображение содержит мотив, связанный с растениями, при этом мотив, связанный с растениями, выбран из группы, включающей: закрытый или открытый сельскохозяйственный участок, растение, растительный продукт, часть растения, часть растительного продукта;

получение (402) вторых обучающих изображений (106) с использованием второго метода (102) получения изображений, при этом каждое второе обучающее изображение изображает мотив, изображенный на соответствующем одном из первых обучающих изображений;

автоматическое присвоение (404), по меньшей мере, одной маркировки (150, 152, 154) каждому из полученных вторых обучающих изображений;

пространственное совмещение (408) первого и второго обучающих изображений, на которых изображен один и тот же мотив, в пару совмещенных обучающих изображений;

обучение (410) модели (132) машинного обучения в зависимости от совмещенных пар обучающих изображений и маркировок, при этом в процессе обучения модель (132) машинного обучения учится автоматически присваивать одну или несколько маркировок (250, 252, 254) любому тестовому изображению (205), полученному с помощью первого метода получения изображений, которое изображает мотив, связанный с растениями; и

предложение (412) обученной модели (132) машинного обучения.

2. Реализуемый компьютером способ по п.1, в котором мотив, связанный с растениями, является макроскопическим мотивом размером, по меньшей мере, 1 мм.

3. Реализуемый компьютером способ по любому из предыдущих пунктов, дополнительно включающий извлечение первых признаков (130) из каждого из первых обучающих изображений; при этом обучение выполняется таким образом, что модель машинного обучения изучает пространственную взаимосвязь первых признаков и маркировок на основе пространственной взаимосвязи первых признаков и маркировок в каждой из совмещенных пар первых и вторых обучающих изображений.

4. Реализуемый компьютером способ по любому из предыдущих пунктов, дополнительно включающий извлечение (114) вторых признаков (116) из каждого из вторых обучающих изображений (106); при этом автоматическое присвоение, по меньшей мере, одной маркировки каждому из полученных вторых обучающих изображений включает анализ вторых признаков, извлеченных из второго обучающего изображения, для прогнозирования (118), по меньшей мере, одной маркировки второго обучающего изображения в зависимости от вторых признаков, извлеченных из второго обучающего изображения.

5. Реализуемый компьютером способ по любому из предыдущих пунктов, в котором первый и второй методы получения изображений представляют собой методы получения изображений, соответственно выбранные из группы, включающей

получение гиперспектрального изображения (102);

получение RGB-изображения (104);

получение монохроматического изображения;

получение активного изображения с помощью источника возбуждающего света;

получение мультиспектрального изображения; и

получение ИК-изображения.

6. Реализуемый компьютером способ по любому из предыдущих пунктов, в котором автоматическое присвоение маркировок пикселям или областям каждого из вторых обучающих изображений включает для каждого из заранее определенного набора классов мотивов, получение эталонной спектральной сигнатуры от физического эталонного мотива, принадлежащего к этому классу мотивов;

сравнение эталонной спектральной сигнатуры со вторыми обучающими изображениями для выявления спектрального сходства между пикселями или областями вторых обучающих изображений и эталонными спектральными сигнатурами; и

присвоение каждому пикселю или области каждого из вторых обучающих изображений маркировки, указывающей на один из классов мотивов, спектрально наиболее схожих с этим пикселем или областью.

7. Реализуемый компьютером способ по любому из предыдущих пунктов, в котором второй метод получения изображений представляет собой получение гиперспектрального изображения с помощью

гиперспектрального датчика.

8. Реализуемый компьютером способ по любому из предыдущих пунктов, в котором второй метод получения изображений охватывает большую часть всего электромагнитного спектра по сравнению с первым методом получения изображений; или в котором второй метод получения изображений охватывает другую часть всего электромагнитного спектра по сравнению с первым методом получения изображений.

9. Реализуемый компьютером способ по любому из предыдущих пунктов, в котором первый метод получения изображений имеет более высокое пространственное разрешение по сравнению со вторым методом получения изображений.

10. Реализуемый компьютером метод по любому из предыдущих пунктов, в котором пространственное совмещение первого и второго обучающих изображений каждой из пар включает в себя совмещение первого и второго изображений, изображающих один и тот же мотив, на основе их соответствующих геопозиций, тем самым обеспечивая приблизительно совмещенную пару изображений, и затем уточнение совмещения в зависимости от интенсивности пикселей и/или цветового сходства таким образом, чтобы разница в интенсивности и/или цветовые различия между первым и вторым изображениями были минимальными для обеспечения совмещения первого и второго изображения пары.

11. Реализуемый компьютером способ по любому из предыдущих пунктов, в котором первые обучающие изображения являются RGB-изображениями, а вторые обучающие изображения являются гиперспектральными изображениями, при этом пространственное совмещение первого и второго обучающих изображений каждой из пар включает для каждого пикселя второго обучающего изображения вычисление значения интенсивности красного, зеленого и синего цветов путем усреднения значений спектральной интенсивности соответственно видимых красных, зеленых и синих спектральных полос, охватываемых вторым обучающим изображением;

создание RGB-представления второго обучающего изображения в зависимости от вычисленных значений интенсивности красного, зеленого и синего цветов;

вычисление первого изображения зеленого цвета, при этом интенсивность каждого пикселя первого изображения зеленого цвета представляет собой индекс зеленого цвета, вычисленный как функция значений интенсивности красного, зеленого и синего цветов первого обучающего изображения;

вычисление второго изображения зеленого цвета, при этом интенсивность каждого пикселя второго изображения зеленого цвета представляет собой индекс зеленого цвета, вычисленный как функция значений интенсивности красного, зеленого и синего цветов RGB-представления второго обучающего изображения;

автоматическое выполнение совмещения первого и второго обучающих изображений таким образом, что разница индексов зеленого цвета первого и второго изображений сводится к минимуму.

12. Реализуемый компьютером способ по любому из предыдущих пунктов, в котором обученная модель (132, 202) машинного обучения настроена на

присвоение одной или нескольких маркировок (250, 252, 254) тестовому изображению (205) таким образом, что, по меньшей мере, одна из указанных маркировок присваивается каждому пикселю тестового изображения; и

семантическую сегментацию тестового изображения (205) путем группировки пикселей тестового изображения, имеющих одну и ту же маркировку или достаточно схожую маркировку, в один и тот же сегмент.

13. Реализуемый компьютером способ по любому из предыдущих пунктов, в котором мотивы, изображенные на обучающих и тестовых изображениях, связанных с растениями, представляют собой закрытые и/или открытые сельскохозяйственные участки, и в котором маркировки выбраны из группы заранее определенных классов мотивов, включающей

участок, покрытый здоровыми растениями;

участок, покрытый растениями, инфицированными определенной болезнью и/или паразитом;

участок, покрытый растениями определенного вида;

участок, покрытый растениями определенного сорта;

участок, покрытый растениями, обработанными определенным веществом, в частности фунгицидом, пестицидом, гербицидом и/или удобрением;

участок, покрытый растениями, обработанными в соответствии с определенной схемой орошения;

участок, не покрытый какими-либо растениями;

участок, покрытый определенным типом почвы;

участок, покрытый комбинацией заранее определенных частей двух или более вышеупомянутых типов покрытия.

14. Реализуемый компьютером способ по любому из пп.1-12, в котором мотивы, изображенные на обучающих и тестовых изображениях, связанных с растениями, представляют собой растения, растительные продукты и/или части растения или растительного продукта, и в котором маркировки выбраны из группы заранее определенных классов мотивов, включающей

участок поверхности растения или продукта или части этого растения, при этом участок поверхно-

сти является здоровым;

участок поверхности растения или продукта или части этого растения, при этом на участке поверхности появляются симптомы, связанные с инфицированием этого участка определенным заболеванием;

участок поверхности растения или продукта или части этого растения, при этом участок поверхности свидетельствует об инфицировании этого участка определенным паразитом;

участок поверхности растения или продукта или части этого растения, при этом на участке поверхности видна клеточная структура или органелла в заранее определенном диапазоне количества;

участок поверхности растения или продукта или части этого растения, при этом на участке поверхности видна клеточная структура или органелла в заранее определенном состоянии;

участок поверхности растения или продукта или части этого растения, при этом на участке поверхности наблюдаются морфологические изменения, вызванные местным применением определенного вещества;

участок поверхности, покрытый комбинацией заранее определенных частей двух или более из вышеупомянутых типов участков поверхности.

15. Реализуемый компьютером способ по любому из предыдущих пунктов, в котором мотив, связанный с растениями, представляет собой закрытый или открытый сельскохозяйственный участок с множеством растений, растением, растительным продуктом, частью растения, частью растительного продукта, при этом ни одно из растений или растительных продуктов не было модифицировано, химически обработано и/или окрашено для обеспечения маркировки или для облегчения маркирования.

16. Реализуемый компьютером способ по любому из предыдущих пунктов,

в котором первые обучающие изображения получены первым датчиком, установленным на первой несущей системе, а вторые обучающие изображения получены вторым датчиком, установленным на второй несущей системе, и

в котором вторая несущая система отличается от первой несущей системы.

17. Реализуемый компьютером способ по любому из предыдущих пунктов,

в котором первые обучающие изображения получены первым датчиком, установленным на первой несущей системе, а вторые обучающие изображения получены вторым датчиком, установленным на второй несущей системе, идентичной первой несущей системе или отличной от нее; и

в котором первые обучающие изображения получены в одном или нескольких полетах первой несущей системы, вторые обучающие изображения получены в одном или нескольких полетах второй несущей системы, при этом полеты первой и второй несущих систем выполняются в разное время, в частности, с межполетным интервалом не менее 5 минут.

18. Реализуемый компьютером способ автоматического присвоения одной или нескольких маркировок (250, 252, 254) тестовому изображению (205), полученному с помощью первого метода получения изображений (104), при этом тестовое изображение изображает мотив, связанный с растениями, при этом способ включает

предложение (502) обученной модели (132) машинного обучения, при этом обученная модель машинного обучения приспособлена для автоматического прогнозирования одной или нескольких маркировок (250, 252, 154), которые будут присвоены любому входному изображению, полученному с помощью первого метода получения изображений и изображающему мотив, связанный с растениями,

использование (504) обученной модели машинного обучения для прогнозирования одной или нескольких маркировок (250, 252, 254) тестового изображения; и

вывод (506) спрогнозированных маркировок тестового изображения (206).

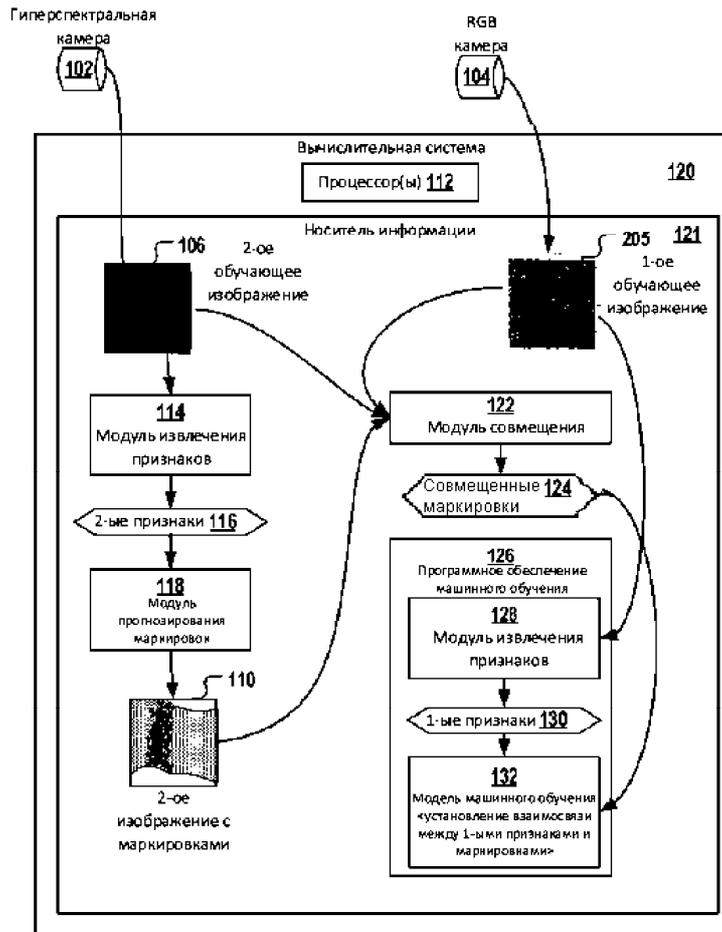
19. Реализуемый компьютером способ по п.18, в котором обученная модель машинного обучения приспособлена для автоматического прогнозирования одной или нескольких маркировок (250, 252, 254) на основе изученной пространственной взаимосвязи первых признаков (130) первых обучающих изображений (108), полученных с помощью первого метода получения изображений, и маркировок (150, 152, 154), присвоенных вторым обучающим изображениям (106), при этом вторые обучающие изображения содержат те же мотивы, что и первые обучающие изображения, и пространственно совмещены с первыми обучающими изображениями.

20. Реализуемый компьютером способ по любому из пп.18, 19, дополнительно включающий создание обученной модели (132) машинного обучения в соответствии со способом по любому из пп.1-17.

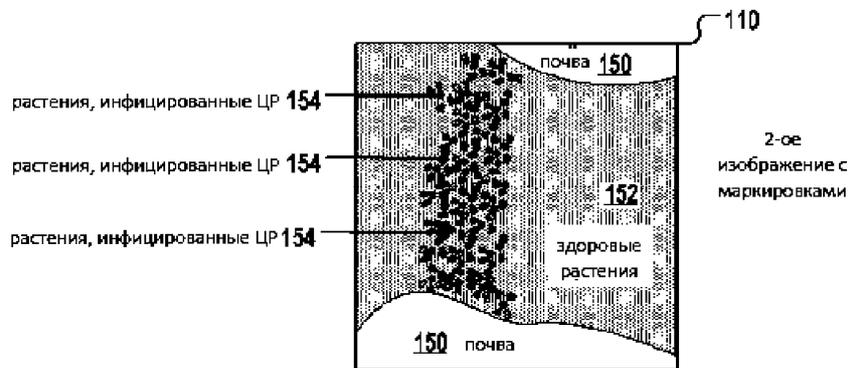
21. Система (120) распознавания и автоматической маркировки макроструктур, включающая

по меньшей мере, один процессор (112);

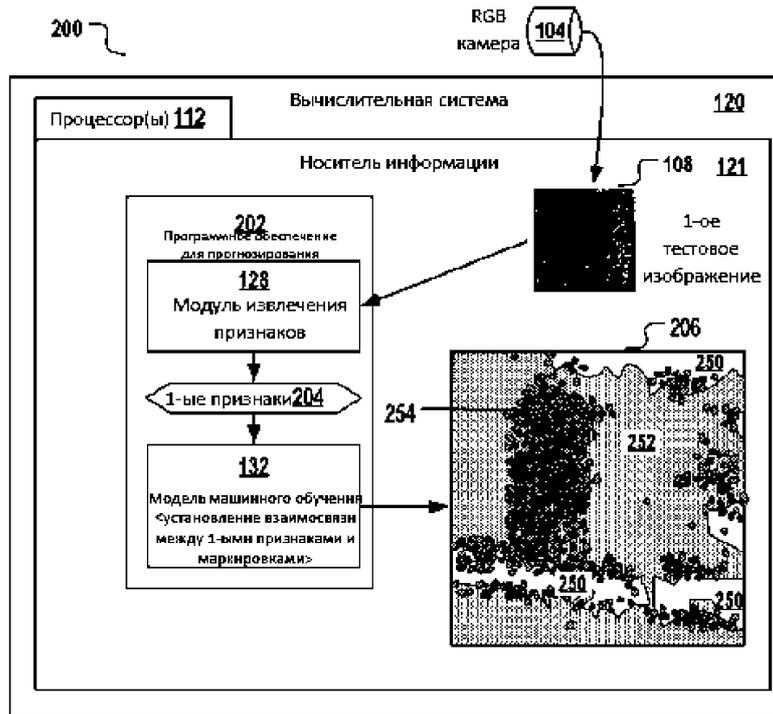
носитель (121) информации, включающий интерпретируемые компьютером инструкции, которые при выполнении, по меньшей мере, одним процессором заставляют процессор выполнять реализуемый компьютером способ по любому из пп.1-20.



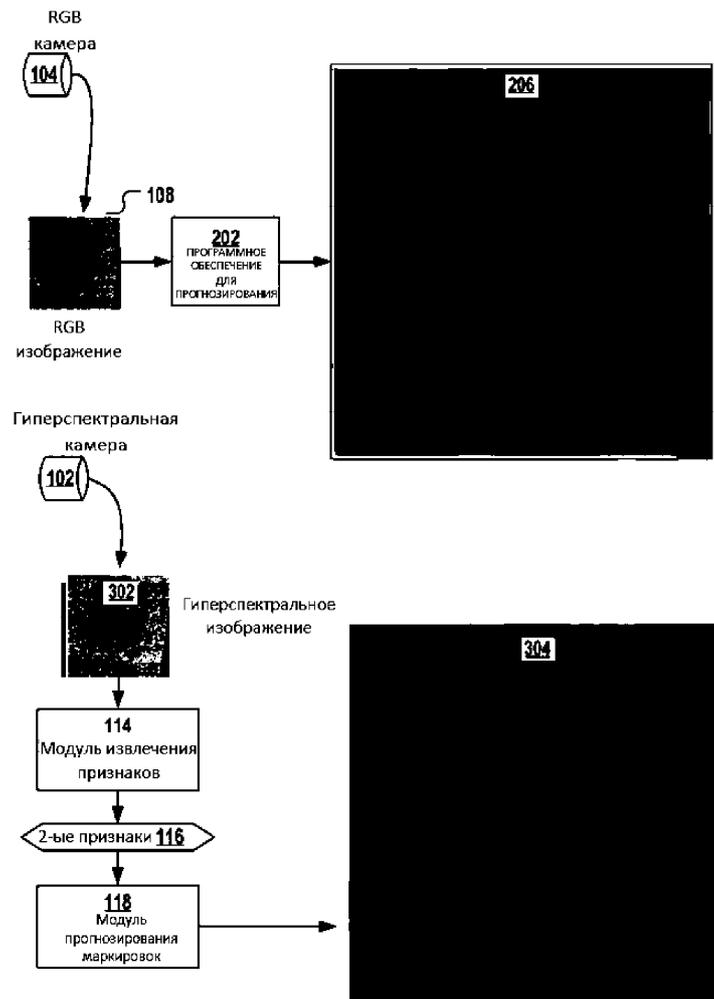
Фиг. 1А



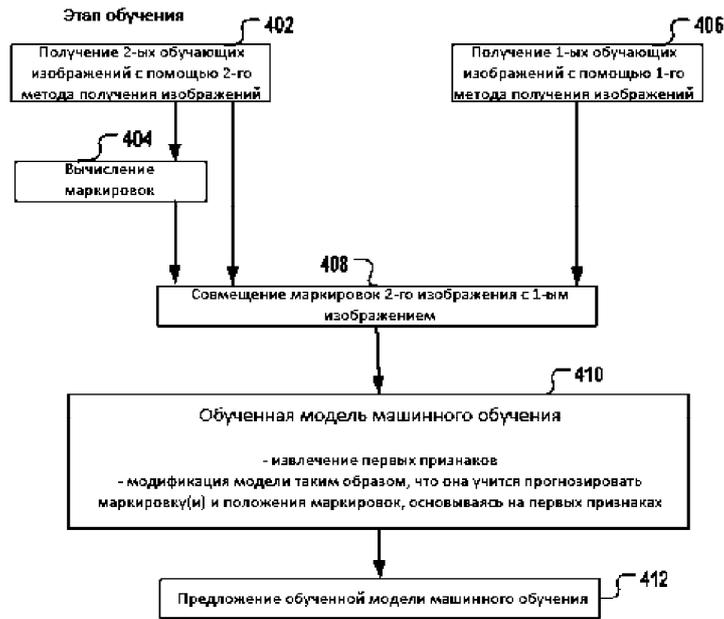
Фиг. 1В



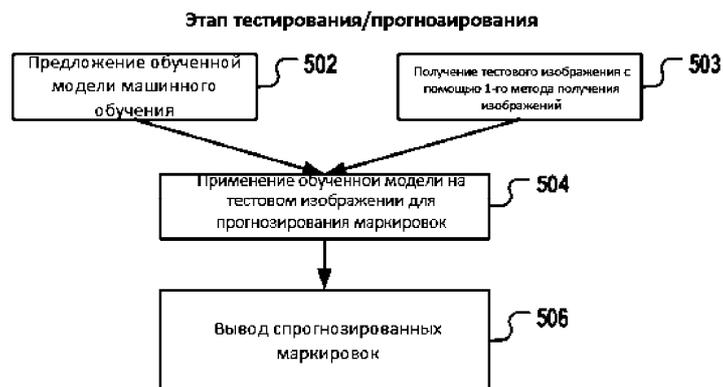
Фиг. 2



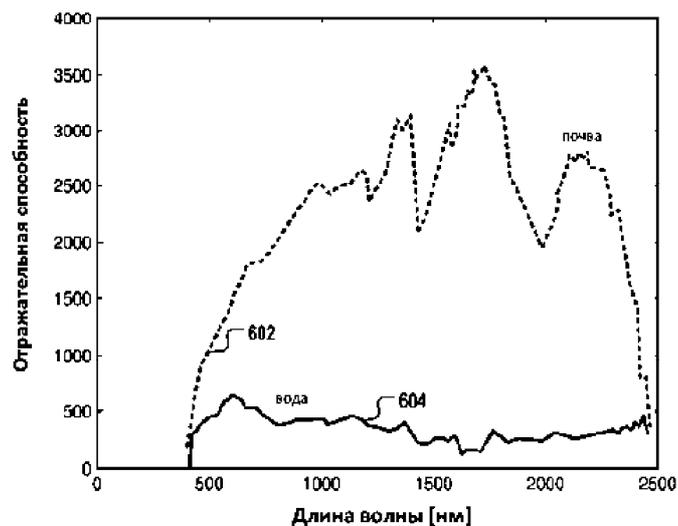
Фиг. 3



Фиг. 4



Фиг. 5



Фиг. 6

