

Аннотация.

Чрезмерное применение гербицидов оказывает негативное влияние на здоровье человека, окружающую среду и конкурентоспособность сельского хозяйства. В связи с тем что разработка автономных систем обнаружения сорняков – это сложный и дорогой процесс, целью данной работы является изучение возможности использования датчиков для определения вегетационного индекса NDVI (Normalized Difference Vegetation Index), уже имеющих коммерческое применение для внесения удобрений, в качестве средства обнаружения сорняков, а также для борьбы с сорняками на участках, где они являются единственной растительностью (тротуары, городские районы и т.д.). Была протестирована возможность использования метода опорных векторов SVM (Support Vector Machine), и максимальная достигнутая точность прогноза составила 78% (20% участков с сорняками не были обнаружены). Данный метод также имеет возможность различать всходы высокой и низкой плотности с точностью до 70%, с сорняками и без. С заданной плотностью всходов точность прогноза составила 80%, и только 10% участков с сорняками не были прогнозированы.

Данное исследование показывает, что точный датчик способен обнаруживать сорняки среди культур с использованием гораздо более простой системы, чем уже существующие.

ANN Artificial Neural Networks (искусственные нейронные сети)

Dif Difference between two consecutive NDVI values (разница между двумя последовательными значениями NDVI)

FSA Feature Selection Algorithm (алгоритм выбора функций)

KS Kernel Scale

HM Harmonic Mean (среднее гармоническое)

ML Machine Learning (машинное обучение)

MM Moving Mean (скользящее среднее)

MMED Moving Median (скользящая медиана)

MSD Moving standard Deviation (скользящее стандартное отклонение)

NDVI Normalized Vegetation Index (вегетационный индекс)

NIR Near Infra Ref (ближняя инфракрасная область)

RGB Red Green Blue (КЗС, красный зеленый синий)

SVM Support Vector Machine (метод опорных векторов)

VIS Visible Radiation (видимое излучение)

Введение.

Сорные растения, или сорняки – нежелательная растительность на посевных полях из-за их влияния на возделывание: неконтролируемое распространение сорняков обычно снижает урожайность на 10-95%, что делает пропалывание необходимым условием для продуктивности и конкурентоспособности сельскохозяйственных культур. Борьба с сорняками может быть осуществлена с помощью химикатов, обработкой гербицидами или механически: обрезанием сорняков или боронованием.

Распыление гербицидов может применяться на всей площади поля (что неэффективно в том случае, если сорняки растут не повсеместно) или только там, где есть сорняки, так называемая после всходов обработка гербицидами (опрыскивание только на тех участках поля, где плотность или покрытие сорняков выше заданного порогового значения). Данный метод имеет негативный эффект, поскольку сорняки начинают развивать толерантность к гербициду и оказывают неблагоприятное воздействие как на окружающую среду, так и на здоровье

человека. В Дании в 2009 году было распылено 2807 тонн гербицидов, что оказало серьезное влияние на экономику, конкурентоспособность, здоровье и окружающую среду.

Боронование производится только на участках, где есть сорняки, однако данный метод нарушает почвенный покров, создавая возможность прорастания еще большего количества сорняков (некоторые семена, находящиеся под землей, попадают на поверхность, получая солнечный свет, необходимый для прорастания), а также может повредить урожай. Поэтому, чтобы рыхление было эффективным, необходим точный инструмент для удаления сорняков, для которого требуется метод их идентификации (Nøtremark, 2010).

Согласно Nøtremark (2010), есть три ключевых элемента борьбы с сорняками:

- Сенсорные системы: идентификация, локализация и измерение параметров сельскохозяйственных культур и сорняков.
- Модели борьбы с сорняками: применение информации о конкуренции культурных и сорных растений, популяционной динамике, биологическая эффективность методов контроля и алгоритмов принятия решений, а также оптимизация обработки растений в соответствии с плотностью и видовым составом сорняков, экономическими целями и экологическими ограничениями.
- Точный инструмент для борьбы с сорняками, например, междурядный культиватор или опрыскиватель с отдельно управляемыми секциями штанги или системой управляемых форсунок, которые обеспечивают возможность варьирования траектории внесения гербицидов.

Данная работа сосредоточена на первом элементе, так как было проведено много исследований, но до сих пор ни одно из них не было достаточным для коммерческого использования, поскольку сенсорные системы не могут справиться с естественными изменениями спектральных или морфологических характеристик и затенением между растениями. Таким образом, борьба с сорняками на отдельных участках имеет существенные преимущества, и существует множество способов прицельного контроля роста сорных растений, но для их автоматизации и эффективности необходима надежная система обнаружения сорняков.



Рис. 1.1 Слева трактор, опрыскивающий поле, использующий отдельную управляемую секцию штанги, чтобы опрыскивать ряд с сорняками, справа - трактор с рыхлительным оборудованием, которое может подниматься или опускаться системой управления. Система обнаружения сорняков может запрограммировать его автоматически опускаться только при наличии сорняков.

1.1.1 Обзор литературы

1.1.2 Обнаружение сорняков в посевах.

Система обнаружения сорняков включает в себя датчики для обнаружения мишени (обычно используются гиперспектральные датчики), системы обработки данных и принятия решений, датчики изображения, спектрометры, устройства дистанционного зондирования, термографы и лазерные датчики (Hong et al., 2012). При обработке данных в качестве функций обычно используют формы на изображениях, цветовые индексы, вегетационные индексы или их комбинации.

В компьютерном зрении есть два основных тренда, направленных на обнаружение сорняков: первый пытается классифицировать каждое растение как культурное или сорное, второй пытается распознать паттерн в ряду растущих культур и на участках с сорняками (De Rainville et al., 2012).

Swain et al., 2011 использует концепцию «активной модели формы» для обнаружения сорняков и сельскохозяйственных культур на основе их морфологии, достигая 90% точности. Активная модель формы – это алгоритм, при котором задается форма листа, который необходимо обнаружить, а также ряд вариаций данной формы для обучения модели.

Сегментация, в данном случае с использованием вегетационного индекса ExG (Excess Green Index), применяется, чтобы выделить лист на фоне почвы. Несмотря на высокую точность, она воспроизводима только в идеальных условиях, когда вид сорного растения известен и находится на определенной стадии роста. Ahmed et al. (2012) использует метод опорных векторов (Support Vector Machine – SVM) – алгоритм машинного обучения для классификации сорняков и сельскохозяйственных культур. Были протестированы четырнадцать функций, чтобы найти наивысший уровень классификации; из них были выбраны девять: твердость (solidity), удлиненность (elongatedness), среднее значение и стандартное отклонение красного компонента КЗС (красный зеленый синий), среднее значение и стандартное отклонение синего компонента и три инварианта моментов (более подробное объяснение см. Ahmed et al. (2012)). Ahmed et al. (2012) достигли точности 97% без ошибочной классификации. Несмотря на высокую точность, SVM требует также высокой вычислительной мощности для обучения, поэтому его было бы целесообразно использовать только в неизменных условиях, когда сорняки одного и того же вида и размера, в противном случае его придется регулярно обучать.

Во втором тренде используется stop geometry (форма пространства доступного для отдельных растений). В Guerrero et al. (2012) обнаружение ряда с сорняками выполняется без сегментации (т.е. нет фильтрации изображения, чтобы увеличить контраст между растительностью и фоном или изолировать растительность), как альтернатива, так как сегментация требует больших ресурсов. Вместо этого делают разделение изображения в градациях серого на горизонтальные линии, ставя точки в наивысших значениях шкалы, затем с помощью преобразования Хафа точки соединяются в линии, которые принимаются за полосу растительности. Алгоритм был тем успешнее, чем больше рядов охватывала камера, и имел некоторые проблемы при появлении участков с сорняками. В Tellaiche et al. (2011) выполняется сегментация и бинаризация изображений (т.е. пиксели в изображении принимают только два значения, черное или белое). Когда почва отделена от растительности, применяется преобразование Хафа обнаружения полос растительности. Затем проводится разделение на ячейки с извлечением функций, представляющих из себя соотношение площадей белого цвета в левой и правой части ячейки, и площадей белого цвета, которые находятся отдельно. Эти функции обрабатываются, а затем используются для обучения SVM. Данная система была в состоянии определить участки для опрыскивания с точностью от 60 до 86%.

В De Rainville et al. (2012) наивный байесовский классификатор используется для распознавания сорняков среди культур, основываясь на статистике, полученной после анализа листьев в рядах и междурядьях. Он обнаруживает ряды, используя преобразование Хафа, а

затем применяет алгоритм обучения без учителя – модель гауссовых смесей – чтобы извлечь характеристики сорняков. Эта система имеет два преимущества: нет необходимости обучать алгоритм и не требуются предварительные знания о культурах и видах сорняков. Данная система имела точность 90-95% для различных плотностей всходов (исследуемые культуры - кукуруза и соя) и 70-90% при классификации сорняков. Однако она также требует большой вычислительной мощности, что делает ее дорогой и медленной.

Все предыдущие исследования основаны на компьютерном зрении, в Ali et al. (2014) использует кривые индукции флуоресценции хлорофилла с помощью нейронной сети для классификации сорняков и культур с точностью от 86 до 96,1%. Индукция флуоресценции означает изменение свечения хлорофилла, наблюдаемое в листьях растений при внезапном включении света после его длительного отсутствия. Данный метод имеет недостаток – необходимость записи на видео, поскольку важно регистрировать изменения.

1.1.3 NDVI

Нормализованный относительный вегетационный индекс представляет собой индекс, который измеряет количество фотосинтетически активной биомассы. Его значения изменяются от -1 до 1, но на практике значения варьируют от 0 до 1: отсутствие растительности означает 0, полное покрытие площади живой растительностью – 1. NDVI рассчитывается на основе двух измерений: ближнего инфракрасного излучения (NIR) и видимого излучения (VIS) в красном участке спектра, и вычисляется по следующей формуле Weier et al. (2006):

$$NDVI = \frac{NIR - VIS}{NIR + VIS}$$

Машинное обучение при работе с данными NDVI и Single Sensor.

Было проведено исследование, в котором SVM использовался вместе с NDVI. NDVI является одним из показателей спутниковой системы Landsat NASA. В Zheng et al. (2015) SVM используется для классификации видов культур в Центральной Аризоне в Соединенных Штатах с использованием временных рядов NDVI Landsat. Измерялись отклонения NDVI в течение года в зависимости от местоположения. Однако несмотря на то, что в статье фигурирует NDVI, этот тип исследования отличается от задачи данной работы, так как представлен совершенно другой масштаб. Также отличаются особенности SVM, так как в Zheng et al. (2015) измеряются географические и еженедельные вариации NDVI, а в настоящем исследовании рассмотрены локальные изменения на небольшой площади и вариации в десятые доли секунды.

Другая особенность данного исследования заключается в том, что оно основано на использовании единственного датчика, поэтому для обучения SVM требуется извлечь максимально возможное количество функций. В Ruiz-gonzalez et al. (2014) SVM получает данные от одноосного акселерометра, чтобы обнаружить аномалии в промышленном харвестере. Были смоделированы распространенные проблемы, чтобы проверить, может ли SVM их обнаружить. Данные с акселерометра были обработаны, и было получено 12 функций: среднее значение, медиана, стандартное отклонение, асимметрия, крест-фактор и т.д. (подробнее см. Ruiz-gonzalez et al. 2014). Затем с помощью метода исчерпывающего поиска (метода “грубой силы”) производился выбор лучшего набора функций.

В Terzic et al. (2010) для измерения топлива в топливном баке автомобиля используется ультразвуковой датчик. Функции, извлеченные из сигнала датчика, это скользящее среднее, скользящая медиана и вейвлет-фильтр, однако отбор функций не проводился.

В Rajab et al. (2016) изучалось использование одноэлементного пьезоэлектрического датчика на полосе движения для определения типа транспортных средств. Для выбора функции использовалось количество импульсов, соотношение между длительностью и продолжительностью импульса, а также метод главных компонент.

Таким образом, даже несмотря на то, что нет литературы, описывающей локальный датчик NDVI с использованием SVM, можно предположить, что извлечение функций, использованное в упомянутых исследованиях, может быть применено для извлечения максимума информации из одного датчика NDVI вместо использования первичных данных.

1.2 Машина опорных векторов

1.2.1 Машина опорных векторов в сравнении с другими алгоритмами машинного обучения

Существует много алгоритмов классификации и параметров, лежащих в основе выбора каждого алгоритма, таких как размер данных, размер маркированных данных, количество функций, разреженность, баланс классов (если классы имеют одинаковое количество образцов), требуемая точность, вычислительная мощность и время.

Несмотря на то, что размер данных и выбор классификатора остаются предметом частых обсуждений, многие исследования показали, что нейронные сети, деревья решений и SVM часто способны классифицировать набор данных с большей точностью, чем стандартные статистические классификаторы. (Foody and Mathur, 2004)

Преимущество SVM заключается в том, что он не требует большого набора данных, поскольку только элементы данных на границе (т.е. элементы данных, которые находятся ближе всего к гиперплоскости, разделяющей классы) используются для определения опорных векторов. Количество опорных векторов определяется тем, насколько легко можно разделить классы, что дает SVM способность к обобщению с относительно небольшим количеством тренировочных данных, а также отсутствием локальных минимумов и разреженным приближением решения. (Ahmed et al., 2012)

Краткое объяснение наиболее популярных алгоритмов классификации необходимо для понимания сравнений, сделанных для принятия решения о выборе SVM; будут представлены только контролируемые алгоритмы обучения. Более подробное объяснение SVM будет дано в следующей главе.

Для обучения алгоритмов существуют две модели: дискриминативная и генеративная. В дискриминативных моделях алгоритмы используют условное распределение вероятностей, то есть вероятность Y с заданным X . Наиболее популярными дискриминативными моделями являются машины опорных векторов, нейронные сети и “случайный лес” (random forest). В генеративных моделях на основе внесенных данных случайным образом генерируются значения новых данных из совместного распределения вероятностей. Наиболее популярной из подобных моделей является наивный байесовский классификатор.

Наивный байесовский классификатор довольно популярен для классификации текста, определяя категорию текста с частотой встречаемости слов. В De Rainville et al. (2012) наивный байесовский классификатор используется для того, чтобы отличить посеы от сорняков на основе статистических данных, рассчитанных по рядам и междурядьям. Одним из самых больших преимуществ данного классификатора является то, что он обучается очень быстро, а добавление элемента данных просто обновляет вероятности функций. Еще одним преимуществом является то, что это интерпретируемая модель, поскольку вероятности

определены, а также его можно проверить, чтобы увидеть, какие функции оказывают большее влияние на разделение классов и существуют ли функции, которые не зависят от класса. SVM, напротив, является методом черного ящика, то есть не совсем понятно, как классификатор получил те или иные результаты. Основным недостатком наивного байесовского классификатора является то, что он не учитывает комбинацию признаков, поэтому вероятности всегда представляют собой вероятности независимых событий. Случайный лес или дерево принятия решений – это классификатор, который наилучшим образом разделяет данные. У алгоритма случайного леса есть большое преимущество – его очень легко интерпретировать, поскольку он создает дерево, где каждый узел – это решение, принятое для выбора определенного класса. Одним из недостатков случайного леса является то, что он является линейным классификатором, поэтому, если функция не линейна, он не сможет правильно предсказать класс.

Искусственные нейронные сети (Artificial Neuron Network, ANN) – это алгоритм, который пытается имитировать нейронную сеть мозга, где каждый нейрон имеет вес, который корректируется в процессе обучения нейронной сети. Преимущество ANN заключается в возможности обрабатывать сложные нелинейные функции, которые могут находить зависимости между различными входными данными (там, где наивный байесовский классификатор не может этого сделать) и возможности инкрементного обучения (т.е. при обучении нет необходимости анализировать данные полностью каждый раз как становятся доступными новые входные данные). Есть два недостатка, один из которых состоит в том, что, так же как SVM, ANN является методом черного ящика, поэтому не всегда возможно или даже невозможно понять, как алгоритм получил результаты. Другая причина состоит в том, что ANN имеет проблему локальных минимумов, в то время как решение SVM является глобальным и уникальным. Также одна из причин, почему SVM часто превосходят ANN на практике, заключается в том, что нейронные сети сталкиваются большой проблемой машинного обучения – переобучением. SVM менее подвержены переобучению, чем ANN.

Таким образом, SVM соответствует требованиям данной задачи, при этом не требуя больших вычислительных мощностей, однако выбор алгоритма – это только первый шаг для создания классификатора, за которым следует подготовка данных для обучения, что так же или даже более важно, чем выбор классификатора. Как сказано в Foody and Mathur (2004), «Особое значение имеют факторы, связанные с этапом обучения классификации. Действительно, обучение может оказывать большее влияние на точность классификации, чем используемый метод классификации».

1.2.2 Машина опорных векторов.

SVM – это обучающая модель, которая создает гиперплоскость – подпространство с размерностью, на единицу меньшей, чем объемлющее пространство – которая разделяет классы (которые будут называться положительными и отрицательными) с максимально возможным зазором.

На рис. 1.2 показано два класса и гиперплоскость, разделяющая их. Закрашенные фигуры – это опорные векторы, расположенные на зазоре и определяющие гиперплоскость. Версия Matlab использованная для данного исследования имеет реализованные функции SVM, поэтому для обучения SVM нужно только вызывать функции и вводить данные и параметры. Математическая процедура взята из MIT OpenCourseWare (2014). Она будет продемонстрирована в следующем разделе, чтобы лучше понять функции и работу классификатора и наилучшим образом использовать его.




Рис. 1.2: Иллюстрация SVM с двумя классами.

Математическое объяснение

Точки (x^+, y) , (x^-, y) , ..., (x^-, y) – заданные тренировочные данные, где y равно 1 для положительного класса и -1 для отрицательного класса, чтобы указать, к какому классу принадлежит точка. Уравнение гиперплоскости имеет вид:

$$\vec{w} \cdot \vec{x} - b = 0,$$

где \vec{w} – вектор нормали к гиперплоскости, а b/w – смещение вектора по отношению к началу координат (на рис.1.2 гиперплоскость – пунктирная линия). Это приводит к правилу принятия решений:

$$\vec{w} \cdot \vec{x}_+ + b \geq 1$$

где x_+ принадлежит положительному классу

$$\vec{w} \cdot \vec{x}_- + b \leq -1$$

и x_- принадлежит отрицательному классу.

Если это уравнение умножить на y (1 для + и -1 для -), то результат:

$$y (\vec{w} \cdot \vec{x}_+ + b) \geq 1$$

$$y (\vec{w} \cdot \vec{x}_- + b) \geq 1$$

Они равны, так что только можно записать только одно уравнение:

$$y (\vec{w} \cdot \vec{x} + b) - 1 \geq 0 \quad (1.7)$$

Расстояние между двумя зазорами:

$$(\vec{x}_+ - \vec{x}_-) \cdot \vec{w} / \|\vec{w}\|$$

Если x заменить уравнениями 1.5 и 1.6,

$$(1 - b + 1 + b) / \|\vec{w}\| = 2 / \|\vec{w}\|$$

Как было сказано ранее, цель состоит в том, чтобы получить максимально возможный зазор, и это происходит путем минимизации $\|\vec{w}\|$, или минимизации $\|\vec{w}\|^2/2$, что более удобно для последующих процедур.

Чтобы минимизировать $\|\vec{w}\|^2/2$, который имеет ограничения, можно использовать метод множителей Лагранжа, что приводит к следующему уравнению:

$$L = \|\vec{w}\|^2 / 2 - \sum \alpha_i [y_i (\vec{w} \cdot \vec{x}_i + b) - 1] \quad (1.10)$$

Производная уравнения:

$$\partial L / \partial \vec{w} = 0 \quad (\Rightarrow) \quad \vec{w} - \sum \alpha_i y_i \vec{x}_i = 0 \quad \vec{w} = \sum \alpha_i y_i \vec{x}_i \quad (1.11)$$

$$\partial L / \partial b = - \sum \alpha_i y_i = 0 \quad (1.12)$$

Применяя 1.11 и 1.12 в 1.10:

$$L = 1/2 (\sum \alpha_i y_i \vec{x}_i) (\sum \alpha_j y_j \vec{x}_j) - (\sum \alpha_i y_i \vec{x}_i) \cdot (\sum \alpha_j y_j \vec{x}_j) - b \sum \alpha_i y_i + \sum \alpha_i$$

$$L = \sum \alpha_i 1/2 \sum \alpha_j y_i y_j \vec{x}_i \cdot \vec{x}_j$$

С решением данного уравнения становятся известны w и b , которые определяют гиперплоскость.

Важно отметить, что функция зависит только от векторов, которые являются опорными векторами.

Ядерный метод




Рис. 1.3 Иллюстрация функции ядра.

Как было показано, гиперплоскость зависит от $x_i \cdot x_o$, но что происходит, когда классы не отделимы друг от друга гиперплоскостью?

Особенностью SVM является ядерный метод, который обеспечивает SVM большую гибкость, снимая ограничение линейности.

“Ядерный трюк” – изменение системы координат пространственного вектора x_i с применением функции $\Phi(x_i)$, то же самое для $\Phi(x_j)$. На рис.1.3 (а) видно, что классы не разделяются линейной плоскостью, поэтому новое пространство определяется функцией ядра, и обычно называется характерным пространством. Функция ядра определяется как:

$$K(x_i, x_j) = \Phi(x_i) \cdot \Phi(x_j) \quad (1.15)$$

Существуют различные функции ядра. В табл.1.1 представлены три наиболее распространенных ядра, использованные в данном исследовании. Используемый полином имеет второй порядок ($n = 2$) и третий порядок ($n = 3$).

Табл. 1.1 Функции ядра

Название	Функция
Gaussian or Radial Basis Function	$\exp -2 x^{\vec{}} - x^{\vec{}} ^2$
Linear	$w^{\vec{}} \cdot x^{\vec{}}_i$
Polynomial	$w^{\vec{}} \cdot x^{\vec{}}^n_i$




Рис. 1.4 SVM с неразделимыми классами

Жесткий и мягкий зазоры.

В предыдущих разделах предполагалось, что классы могут быть полностью разделимыми, это то, что называется жесткой границей (т.е. все точки, принадлежащие классу, находятся на стороне, принадлежащей соответствующему классу, рис.1.2 является иллюстрацией необходимости жесткого зазора). Это оптимальные ситуации, но в случае, когда они не возможны, используется мягкий зазор (рис. 1.4 является иллюстрацией необходимости мягкого зазора).

В уравнении 1.10 цель состоит в том, чтобы минимизировать $\|\vec{w}\|/2$, к уравнению 1.7 добавляется переменная ξ :

$$y(\vec{w} \cdot \vec{x} + b) - 1 + \xi \geq 0 \quad (1.16)$$

ξ – допустимый предел зазора. Если значение ξ очень велико, уравнение 1.16 всегда будет выполнено.

Таким образом, константа C добавляется в случае, если значение ξ очень велико:

$$\|\vec{w}\|^2 / 2 + C \sum \xi \quad (1.17)$$

Таким образом, C контролирует количество точек, которые находятся не с той стороны гиперплоскости. Если значение C очень маленькое, определено много опорных векторов, что означает, что алгоритм не является обобщающим (то есть, если большое количество точек являются опорными векторами, это означает, что большинство точек способствуют принятию решения). Если C слишком велик, то он может столкнуться с проблемой переобучения (overfitting). Чтобы найти оптимальный баланс:

$$\min[\|\vec{w}\|^2 / 2 + C \sum \xi] \quad (1.18)$$

Таким образом, первый член максимизирует зазор между классами, вторая часть контролирует точки, которые находятся на неправильной стороне, а C балансирует две части (Foody и Mathur, 2004).

Множественные классы SVM.

В объяснении выше было только два класса, и SVM является бинарный классификатором, но его можно применить к задаче множественных классов, разделив их на множество двоичных задач классификации. Есть два способа сделать это, «один против одного» или «один против всех». В «один против одного» классы спарены, и есть классификатор для каждой пары классов. Выбирается класс, у которого больше побед, т.е. который предсказан большее количество раз. В «один против всех» каждый класс отличается от всех остальных,

классификатор прогнозирует, принадлежит ли выборка классу или нет, и выбирается наилучший прогноз. В этом исследовании для нескольких классов используется “один против одного”.

Выбор функции.

При выборе функции выбирается набор функций, которые лучше всего отображают данные и дают наилучшую классификацию. Это важный шаг в процессе классификации, так как он снижает потребность в обработке, уменьшает шумные функции (функции, которые не зависят от классов), максимизирует производительность алгоритмов и упрощает использование и обновление алгоритмов (Salappa et al. 2017). В Salappa et al. (2017) проводится анализ алгоритмов выбора функций (feature selection algorithm – FSA). FSA имеет различные способы выбора подходящих функций на основе дисперсии классов. Процесс прямого отбора начинается без функций, и функции добавляются по мере того как он совершенствуется; при обратном исключении он начинает со всех функций и исключает их по мере совершенствования. Они комбинируются, затем происходит случайный выбор. Далее он сравнивает различные FSA, а затем сравнивает точность алгоритмов с выбранными функциями с полным набором функций. С SVM точность в среднем на 6% выше с выбранными функциями, чем с полным набором функций.

1.3 Цели

Как было показано в предыдущих разделах, системы обнаружения сорняков, которые были описаны, эффективны только в идеальных и специфических условиях и требуют определенного оборудования в целях использования исключительно как системы обнаружения сорняков, что требует первоначальных инвестиций.

В данной магистерской диссертации будет изучена возможность использования датчика нормализованного разностного вегетационного (NDVI) для обнаружения участков с сорняками.

Датчики NDVI широко используются в сельском хозяйстве для контроля за внесением удобрений (Samborski et al. 2015), так что они надежны и доступны. Создание подобных датчиков, даст возможность иметь автоматизированную систему обнаружения сорняков, которая будет проще и надежнее тех, которые имеются на данный момент, что позволит значительно сократить использование гербицидов, делая сельское хозяйство более экономичным, устойчивым, эффективным и экологичным.

Основными целями магистерской работы являются:

1. Проверить возможность обнаружения сорняков с помощью сенсора NDVI.
2. Изучить лучшие функции NDVI для обнаружения сорняков.

1.3.1 Ограничения

Это магистерская работа, поэтому есть ограничения. Ограничение по времени довольно значительное, так как это должно быть сделано в течение семестра. Поскольку это экспериментальная работа, в одном семестре количество тестов ограничено, и, поскольку оно зависит от роста урожая, число возможных повторений сводится к единице. Прохождение с измерительными приборами в посевах не может быть повторено много раз, так как колесо смещает некоторую часть почвы, после прохождения с квадроциклом некоторые растения попадают под почву. Также требовались определенные погодные условия, так как во время дождя при прохождении квадроцикл может покрыть растения грязью.

Этот отчет должен быть сдан в марте, и получилось, что посевы выросли так, чтобы их можно было измерить только в конце января, что ограничило время обработки данных, обработки и применения алгоритмов. Что касается ресурсов, то использовались те инструменты, которые

были доступны, что не соответствовало требуемому уровню техники. Другим ограничением измерений был источник питания измерительных приборов, которые питались от батареи квадроцикла, и были некоторые моменты, когда измерения были прерваны из-за инструментов, не получая достаточно энергии.

Chapter 2. Experimental Set Up.




Рис. 2.1 Схема датчика NDVI и камеры.

Сбор данных был произведен в Исследовательском центре Follum в Выборге, Орхусском университете, 26 января 2017 года. Измерения проводились на озимой пшенице и двух различных видах листовых сорняков, которые были высажены на специально отведенной площади в целях эксперимента. Схема поля показана на рис. 2.2(с). Ширина междурядья составляет 0,2 метра. Измерения проводились на различных участках: участки, где урожай был более плотным с сорняками и без, участки с менее плотным с сорняками и без, участки, где полосы растительности были прорежены, участки с всходами между рядами растущих культур. В конце каждого участка измерения помещается белая доска, служащая эталоном в измерениях, поскольку NDVI опускается до нуля, когда достигает белой доски.

В качестве датчика NDVI использовался GreenSeeker® RT100 от Trimble, который выполнял 10 измерений в секунду в пределах линии шириной 60 см, перпендикулярной ряду посаженных культур (рис.2.2а). Металлическая рама была прикреплена к квадроциклу достаточно высоко, на расстоянии 0,8 м от земли, чтобы камера полностью улавливала все измерения NDVI, что было подтверждено с помощью красного света, испускаемого GreenSeeker (приложение А.2, GreenSeeker должен быть от 0,8 до 1,22 м, согласно инструкции). Была использована камера Marlin F-033, которая регистрировала цветные изображения размером 640x460 пикселей. Объектив камеры покрывал участки размером 45x60 см на поверхности почвы. Программное обеспечение AVT Firepackage Smart View V2.3.1 получало изображения.


И GreenSeeker, и камера были напрямую подключены к ноутбуку, который записывал данные. Установка была помещена на квадроцикл, который питался от батареи. На 2.2 (а) и (b) показано изображение квадроцикла с GreenSeeker, камерой и ноутбуком. Квадроцикл ехал со скоростью примерно 0,8 м/с.

Каждый участок земли измерялся 3 раза в обе стороны.

Вся обработка данных проводилась в автономном режиме с использованием образовательного программного обеспечения MATLAB 2016a. Обработка данных будет рассмотрена в следующей главе.

Табл. 2.1 Характеристики камеры

Camera	Marlin F033
Sensor:	Sony ICX414, progressive scan CCD progressive scan
Resolution:	656x949
Max f.p.s:	73



(a)

(b)




Рисунок 2.2: 2.2a - Система измерений, камера и датчик NDVI с белой доской перед квадроциклом. 2.2b - GreenSeeker (белый датчик) и камера (красная), а также ноутбук сзади. В 2.2c - схема поля, где проводились измерения.

Chapter 3. Processing the Data.

3.1 Обработка данных

В этой главе будет объяснена классификация, обработка данных и выбор функций.

3.1.1 Классификация

К изображениям были применены три схемы классификации, даже несмотря на то, что цель состоит в том, чтобы просто обнаружить участки с сорняками. Существуют подходы, при которых классификатор способен разделять данные на подмножества, а затем снова делить подмножество, это – иерархическое обучение. Оно дает преимущество, заключающееся в том, что классификатору может быть проще разделить данные на два подмножества, а затем разделить их снова, чем разделять все одновременно. Также он обладает большей гибкостью,

поскольку функции, которые использовались для первой классификации, могут отличаться от тех, которые используются для второй и т.д. В данном случае схема классификации будет называться “НС” для классификации между всходами высокой и низкой плотности и “второй уровень” для классификации культур или сорняков, для как густых, так и редких всходов.

Три классификационные схемы:

- Наличие/отсутствие сорняков (BC)
 - Культурные растения (crop – c)
 - Культурные растения с наличием сорняков (crop with weed patch – c wp)
- Наличие сорняков с учетом плотности всходов (MC)
 - Низкая плотность всходов (Low crop - lc)
 - Низкая плотность всходов с наличием сорняков (Low crop with weed patch - lc wp)
 - Высокая плотность всходов (High crop - hc)
 - Высокая плотность всходов с наличием сорняков (High crop with weed patch - hc wp)
- Иерархическое обучение (НС)
 - Низкая плотность всходов (Low crop - lc)
 - * Культурные растения (c)
 - * Культурные растения с наличием сорняков (cwp)
 - Высокая плотность всходов (Highcrop - hc)
 - * Культурные растения (Crop - c)
 - * Культурные растения с наличием сорняков (Crop with weed patch - cwp)

Классификация изображений была сделана вручную индивидуально для каждого изображения (приложении В.2). В таблице 3.1 указано количество классифицированных изображений для каждого класса. Классификация, зависящая только от наличия сорняков (BC) была гораздо проще остальных. В MC и НС используется одна и та же классификация, разделенная на разные классы, а изображение, которое было классифицировано в MC и НС, также включается в соответствующий класс в BC. Обратное неверно, что объясняет разницу в количестве классифицированных изображений для каждой схемы: например, культура может иметь высокую плотность в одном ряду, но отсутствовать или иметь низкую плотность в других. Примеры изображений из классов можно увидеть на рис.3.1.

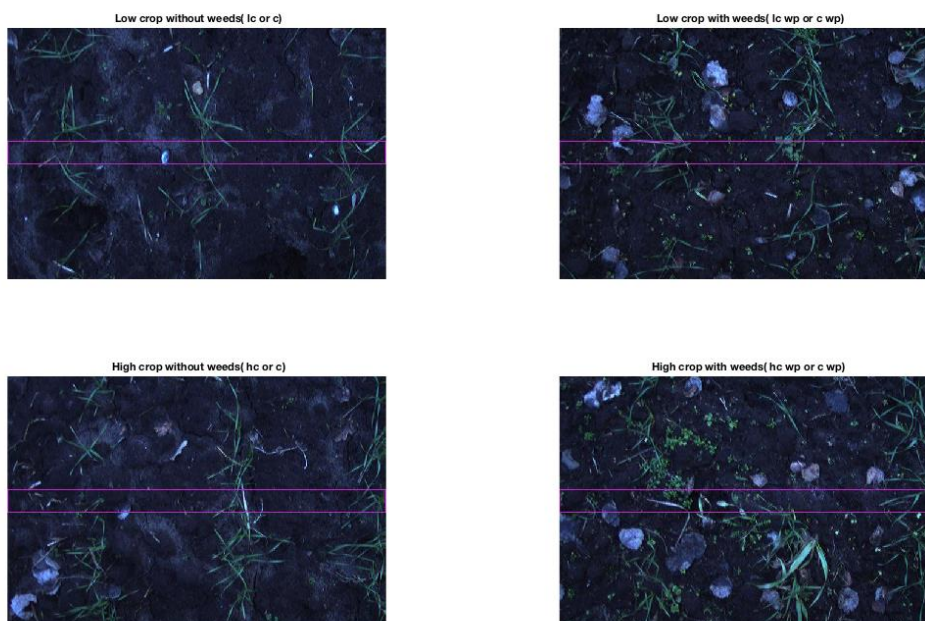


Рисунок 3.1: Изображения с камеры каждого класса, прямоугольник в середине был добавлен для справки (место, где измерялся NDVI)

3.1.2 Синхронизация данных

Данные из NDVI были сохранены на жестком диске ноутбука в текстовом формате CSV. Снимки с камеры были сохранены в формате JPG. Данные с двух датчиков должны были быть синхронизированы, и поскольку они регистрировались независимо друг от друга, в каждый протокол ставилась временная метка. Как было сказано в предыдущей главе, были некоторые ограничения (как энергопотребление, так и сохранение данных на компьютер не всегда шли непрерывно), которые имели влияние на данные. Кроме того, временная метка измеряется в секундах, и даже несмотря на то, что NDVI и камера записывали через 0,1 сек и 0,75 сек соответственно, доли секунд были добавлены позже. Таким образом, с временной меткой необходимо было провести некоторые манипуляции для синхронизации между изображениями и измерениями NDVI.

Table 3.1: Количество образцов в каждом классе.

Crop Spots	BC C CWP	MC LC LCWP HC HCWP	HC
			C CWP C CWP
			LC
			HC
Plot 1	199 9	88 9 37 0	88 9 37 0
Plot 2	252 411	110 181 93 225	110 181 93 225
Plot 3	114 38	34 33 60 0	34 33 60 0
Plot 4	15 4	13 0 02 2	13 0 02 2
Plot 5	575 28	151 15 194 9	151 15 194 9
Total per Class	962 481	395 237 286 236	396 237 286 236

Синхронизация необходима, так как классификация была применена к изображениям, но цель работы состоит в том, чтобы применить к ее NDVI. Для синхронизации использовался цветовой индекс, чтобы проверить его изменение в соответствии с измерениями и сравнить с изменением NDVI. Было использовано пять цветowych индексов, таких же, как у Guerrero et al. (2012) и дополнительный цветовой индекс, разработанный специально для данного исследования. Цветовой индекс, созданный для данного исследования, показал наилучшую корреляцию (рис. 3.2). Верхний график – это цветовой индекс для всего изображения (сумма всех значений пикселей), а нижний – только участок, где измеряется NDVI (красная полоса на рис.2.2(b)). Более подробное объяснение цветowych индексов можно прочитать в приложении A.2.1.

На рис. 3.2, чтобы компенсировать разницу в частоте измерений NDVI и съемки изображений, классификация, примененная к изображению, была применена к NDVI измеренному с разницей $\pm 0,1$ сек от времени съемки изображения, то есть для каждых 3 снятых изображений было измерено 4 значения NDVI. Таким образом, классификация i-го изображения была передана приблизительно i-му ± 1 измерению NDVI, поскольку классификация была сделана для изображений, и изображения перекрываются.

На рис. 3.3 и 3.4 можно сравнить два способа передачи классификации NDVI, в данном случае временная метка является непрерывной, что не всегда возможно – в таких случаях данные были исключены (для дополнительной информации см. приложение B.2). Также

важно отметить, что различия между графиками увеличиваются с левой стороны, что показывает, что данные протокола не всегда были постоянны во времени.

Исходя из рисунка 3.3, можно сделать предположение, что цветовой индекс классифицированных изображений выше для классов участков с сорняками (Weed Patches Classes), что подтверждает классификацию изображений. Это не всегда верно для NDVI, но также меньше подвержено изменениям.

Будут использоваться только классификации, синхронизированные во времени.




Рисунок 3.2: Верхний график - от всего изображения, нижний график – это только область, где измеряется NDVI.

3.1.3 Функции.

Как видно из предыдущей главы, выбор функций является важной частью обучения классификатора. Посмотрев на рис.3.6, можно увидеть помеченные значения NDVI, а также некоторые тренды в каждом классе, такие как среднее значение, вариация, пики, которые будут использоваться в качестве функций. Также будут использоваться некоторые функции из Ruiz-gonzalez et al. (2014). Список функций находится в конце раздела. Некоторые функции зависят от соседних значений. Так, например, скользящее среднее – это среднее от n_i до n_i , этот интервал является постоянным для одного и того же набора признаков, размер интервала будет рассмотрен в следующем разделе.





Рисунок 3.3: Данные, собранные на графике 5, в верхней части NDVI, классифицированные по порядку ведения протокола. Внизу цветовой индекс.





Рисунок 3.4: Те же данные, что и на рис. 3.3, но с временной меткой в качестве горизонтальной оси




Рисунок 3.5: Примеры маркированных значений NDVI.

- NDVI value
- См. пункт 1.1

- Скользящее среднее (Moving Mean - MM)

$$\frac{NDVI_{-i} + \dots + NDVI_i}{N}$$

- Сумма значений NDVI, разделенных на N (количество значений).

- Скользящее среднее гармоническое (Moving Harmonic Man - MHM)

$$\frac{NIR - VIS}{\frac{1}{NDVI_{-i}} + \dots + \frac{1}{NDVI_i}}$$

- Количество значений, разделенных на противоположные значения NDVI

- Скользящее стандартное отклонение (Moving Standard Deviation - MSD)

$$\sqrt{\frac{1}{N-1} \sum |NDVI - mean|^2}$$

- Стандартное отклонение — квадратный корень дисперсии.

- Диапазон (Range)

$$max(NDVI) - min(NDVI)$$

- разница между максимальным и минимальным значениями интервала

- Скользящая медиана (Moving Median - MMED)

- NDVI разделяет интервалы на две части.

- Разница (Difference - Dif)

$$NDVI_i - NDVI_{i-1}$$

- Разница между двумя последовательными значениями NDVI

3.1.4 Выбор функции.

Чтобы подтвердить размер используемого интервала, запускаются модели с полным набором функций для трех схем и рассчитывается точность. Начинают с 3 выборок, вычисляется точность, затем добавляется одна выборка и снова вычисляется точность. Так повторяется до тех пор, пока интервал не будет состоять из 30 значений. Точность рассчитывается с использованием 10-кратной перекрестной проверки (см. Приложение А.1). На рис. 3.6 показана нормализованная вариация точности для трех схем, а для мультиклассификации максимальная точность равна 6 значениям NDVI, но имеет другой пик с почти такой же точностью с 11 значениями. При двоичной классификации максимум составляет 12 и 13 значений, иерархической классификации - 11. Для стандартизации интервала, поскольку различия очень малы, выбранный размер – это 12 измерений для всех трех. Для выбора функций используется исчерпывающий поиск (Salappa et al. 2017) с 10-кратной перекрестной проверкой. В табл. 3.2 показаны подмножества функций, которые получили наилучший результат для каждой схемы классификации. Точность только с NDVI и точность с использованием всех функций показана для сравнения.

Как видно, значения не сильно меняются, поскольку все функции получены из одного NDVI. Также важно отметить, что проценты между схемами классификации не могут сравниваться, так как двоичная классификация имеет гораздо больше выборок.

Надлежащее сравнение между схемами будет сделано в следующей главе.

Использоваться будут функции, которые получили наивысшую точность: для двоичной классификации это скользящее среднее и скользящее стандартное отклонение, для множественной классификации – скользящее среднее, скользящая медиана, диапазон и скользящее стандартное отклонение. Для иерархической классификации – скользящая медиана, диапазон и разность, для классификации между плотным и низким урожаем. Преимущество иерархической классификации заключается в том, что разные функции можно использовать для разных уровней иерархии, а также для разных ветвей одного уровня.

Таблица 3.2: Точность подмножеств, которые получили наилучшие результаты, в процентах. * Подмножество с NM, MMED, Range, Dif получило тот же результат в MC, ** подмножество MMED, Range, MST получило тот же результат в HC

Subsets of Features	NDVI	MM,MMED,Range,MSD*	MM,MSD	MMED,Range,Dif**	All
Binary Classification	74.36	78.19	79.81	77.94	77.76
Multi Classification	44.36	51.05	50.15	50.25	50.85
HC between hc-lc	59.58	61.69	59.58	63.79	60.88




Рисунок 3.6: Вариации нормализованной точности с изменением количества выборок, используемых для расчета функций.

Таблица 3.3: Точность в процентах для второго иерархического уровня

Sub Set of Features	NDVI	MM,Range,MST	NDVI,MM,MED,Dif	All
Low Crop	69.53	75.32	72,75	72.96
Dense Crop	77.21	79.85	84.18	81.73

Глава 4. Результаты эксперимента

SVM может быть обучен с использованием всех выбранных функций. Как объяснено в предыдущей главе, в двоичной классификации больше выборок, поэтому в первом разделе данной главы двоичный классификатор будет обучаться с использованием того же размера выборки, что и другие, для сравнения, а в следующем разделе – со всеми доступными образцами.

4.1 Значения параметров

Можно откорректировать значения параметров, описанные в разделе 1.2.2, используя выбранные функции. Параметры были найдены с помощью случайного поиска, который представляет собой численный метод оптимизации, который выбирает случайную точку в пределах указанного радиуса и сохраняет ее, а затем поиск продолжается снова с выбранной точки. В данном исследовании было проведено 30 итераций этой процедуры. Высокие значения говорят о том, что данные разделимы. Значения, равные 1, объясняются тем, что для оптимизации для мультикласса SVM требовалась большая вычислительная мощность, поэтому использовалось значение по умолчанию. Низкие значения указывают на то, что данные не могут быть разделены.

4.2 Сравнение всех схем классификации

В табл. 4.2 показана точность для 4 протестированных ядер. Ядро с наибольшей точностью – это ядро Гаусса. SVM имеет самую высокую точность для того, чтобы отличить участок с культурными или сорными растениями, когда плотность всходов задана; линейное ядро имеет точность 83%.

В табл.4.4 результаты взяты из бинарной классификации со всеми образцами, но разница не очень большая, по сравнению с ограниченным набором, что согласуется с тем, что было сказано в разделе 1.2.1: SVM имеет хорошую способность к обобщению.

Таблица 4.2: Точность в процентах для разных ядер.

Kernel Functions	Linear	2nd order Polynomial	3rd order Polynomial	Gaussian
Binary Classification	77.6	59.0	57.25	78.4
Multi Classification	53.4	56.2	67.8	67.8
Hierarchical Classification	63.2	62.6	49.5	65.9

Таблица 4.3: Точность в процентах для иерархии второго уровня

Kernel Functions	Linear	2nd order Polynomial	3rd order Polynomial	Gaussian
Low Crop	74.5	74.5	62.9	80.3
Dense Crop	83.6	82.1	81.7	80.4

Таблица 4.4: Точность в процентах двоичного класса для всех выборок

Kernel Functions	Linear	2nd order polynomial	3rd order polynomial	Gaussian
Binary Class	79.6	76	58.7	79.8

4.3 Матрицы путаницы

Матрица путаницы – это очень простой и понятный способ оценить, насколько хорошо и точно модель может классифицировать каждый класс. Матрица путаницы строится с использованием перекрестной проверки, столбцы – это значения, которые используются для проверки и распределены в столбце класса, который предсказывала модель. Строки соответствуют истинным значениям. Таким образом, лучшие классификаторы имеют значения по диагонали, то есть, когда столбец прогнозируемого класса пересекается с соответствующей строкой класса True. Например, сравнивая двоичную классификацию (рис.4.1a) с иерархической классификацией (рис.4.1b), можно увидеть, что ВС получил более высокие значения, чем НС по диагонали, и в табл.4.2 видно, что ВС получил наилучшую точность.

Из матрицы путаницы может быть получено больше информации, например, в данном исследовании гораздо важнее, чтобы SVM не пропускал участок с сорняками, чем если бы он перепутал участок с сорными и культурными растениями, так как в первом случае он позволяет сорнякам расти, а во втором он срезает посеы или распыляет на них гербицид. Таким образом, чтобы выбрать схему классификации, которая больше подходит для обнаружения сорняков, следует искать столбцы прогнозируемых культур без сорняков и строки с истинными значениями участков с сорняками.

Глава 5. Итоги и рекомендации для будущей работы.

5.1 Обсуждение

5.1.1 Функции

Все схемы классификации выдали различные наборы функций. Точность с разными наборами различалась не сильно ($\pm 1\%$), и поскольку она также является оценкой из перекрестной проверки, выбор функции гарантирует, что SVM будет обучаться с некоторыми согласующимися функциями, но одновременно не позволяет лучше понять, что может определять каждый класс. Также интересно, что скользящее среднее – это функция, присутствующая в всех подмножествах, за исключением первого иерархического уровня, который должен различать всходы высокой и низкой плотности.

Разница между использованием только одной функции (NDVI) и использованием всех функций также невелика (7% на втором уровне иерархии с низкой плотностью всходов). Подмножество для обнаружения сорняков с низкой плотностью посевов (второй уровень иерархии) включает в себя диапазон, скользящее среднее и стандартное отклонение. Это может объясняться тем, что при низкой плотности всходов возможны ситуации, когда NDVI измеряет только почву и имеет очень низкое значение (поскольку ряды всходов прорежены, см. рис. 3.1), а затем может идти распознавание растений, чему соответствует высокое значение. Все вышесказанное может послужить причиной того, что диапазон является хорошей характеристикой для данной классификации.

Размер интервала, который определяет функции, также интересен, поскольку все схемы получили аналогичный размер. Так как это имеет отношение к скорости квадратоцикла, было бы интересно понять, насколько оно будет изменяться при другой скорости. Таким образом, можно сделать вывод, что, хотя результаты не будут существенно отличаться, если не будет сделан выбор функций, FSA выберет лучшее подмножество, улучшая классификаторы.

5.1.2 Схемы классификации

К сожалению, SVM – это метод черного ящика, поэтому не ясно, какие «решения» принял SVM, даже несмотря на то, что из результатов можно извлечь много информации.

Двоичная классификация получила наилучшие результаты. Интересно то, что обучение с полными наборами образцов только добавило 1,4% к ядру Гаусса; большая разница была для полинома 2-го порядка, который прибавил 17%.

Поскольку одна выборка вдвое больше другой (1443–632), это вполне согласуется с тем фактом, что SVM может обобщать небольшие наборы данных.

Множественная классификация получила некоторые плохие результаты, но можно предположить, что класс с наименьшим значением NDVI – это всходы низкой плотности, а с наивысшим – всходы высокой плотности с сорняками, так что остальные значения должны быть в середине, и это, вероятно, причина низких баллов. Он классифицировал 24% *lc-wr* как участки без сорняков, и 9% *hc wr* как участки без сорняков. Эти значения были бы наиболее важными в том случае, если бы это была реальная задача по обнаружению сорняков. Данная классификационная схема была предназначена для того, чтобы увидеть, существует ли тенденция в распознавании сорняков и плотности всходов. У всех классов, кроме *lc wr*, было больше несоответствий классификации плотности (т.е. истинный *lc* имел больше предсказанных значений *hc*, чем *lc wr* и *hc wr*, и истинный *hc* имел больше предсказанных значений *lc*, чем значения *s wr*, и истинный *hc wr* имел больше предсказанных значений *lc wr*, чем *lc* или *hc*). Это означает, что у SVM больше проблем с распознаванием плотностей посевов, чем с разделением посевов и сорняков. Это проясняется в иерархической классификации. Иерархический классификатор получил некоторые интересные результаты на втором уровне, когда он фактически должен был обнаружить участки с сорняками, являясь классификатором высочайшей точности.

Однако он получил очень плохие результаты при распознавании плотности посевов, но это также может быть связано с тем, что классификация проводилась вручную, поэтому значения из одного и того же класса могут сильно колебаться. Это также единственная классификация, в которой линейное ядро работает лучше, чем гауссовское.

Интересно, что на втором уровне иерархии были достигнуты высокие значения, которые говорят о том, что при более точном считывании плотности всходов может иметь место четкая тенденция в значениях с сорняками и без сорняков, на чем и сфокусировано данное исследование.

В целом достигнутая точность последовательна и алгоритмы были применены должным образом.

5.2 Заключение

Результат этого эксперимента с учетом ограничений довольно положительный. С единственным датчиком была возможность обнаружить сорняки с точностью до 78% (бинарный классификатор предсказал, что всего лишь 20% образцов с сорняками не было обнаружено), что является многообещающим числом, учитывая преимущества по сравнению с другими решениями (в основном с использованием компьютерного зрения, см. главу 1). В работе Guerrero et al. (2012) была достигнута точность 93%, в Те Илаш и др. составлял от 60 до 85%, а у De Rainville et al. (2012) от 85% до 95%, все с компьютерным зрением и вычислительными алгоритмами.

Ядро Гаусса было безусловно самой точной функцией ядра, это означает, что Линейные классификаторы не выгодны. Выбор SVM с различными ядрами дал возможность убедиться в этом.

SVM был более чем в состоянии выполнить задачу, так как было видно, что в двоичной классификации число образцов удвоилось, при этом точность повысилась только на 1%. Исходя из этого, можно предположить, что на другие схемы классификации количество выборок не сильно повлияло.

Однако даже при том, что количество выборок было достаточным, их качество, вероятно, оказало большее влияние на точность классификации. Поскольку классификация проводилась в течение определенного времени и не для конкретных выборок, это могло бы добавить некоторый шум к данным.

В целом, выбор функций, тестирование различных ядер и различных схем классификации дали новое представление о возможности обнаружения сорняков с помощью только датчика NDVI.

5.3 Рекомендации по дальнейшей работе

Исследование для NDVI как датчика обнаружения сорняков имеет большой потенциал, например, есть некоторые идеи, которые стоит рассмотреть:

- Параллельные измерения, сбор данных от двух датчиков одновременно. Например, два датчика NDVI установлены на балке трактора, один из датчиков проходит через участок с сорняками, а другой нет. Сможет ли алгоритм ML обнаружить разницу в измерениях?
- Влияние скорости транспортного средства, которое несет датчик. Функции в данном исследовании зависели от интервала измерений, однако скорость, с которой датчик проходит по рядам, могла бы дать лучшее понимание эффектов, которые имеет участок с сорняками при измерениях.
- Точное измерение. Самым большим ограничением в этом исследовании была недостаточная точность синхронизации между изображениями и NDVI, классификация NDVI проводилась по интервалам, а не по конкретным значениям. Тот факт, что было невозможно точно определить, что NDVI считывает конкретный образец не позволил глубоко изучить разницу между значениями из участка с сорными и культурными растениями (то есть разница между

определением того, что эти образцы из данного интервала, когда он считывает сорняк, и определением значения от X до Y при считывании сорняков). Было бы интересно изучить функции каждого образца.

Итоги.

В целом SVM был более чем успешным алгоритмом для обработки данных с такого датчика, как NDVI. Он получил очень разумные результаты, близкие к результатам компьютерного зрения, при этом данный алгоритм обучается в автономном режиме, и ему не нужно сохранять старые данные, хотя он и не реализует новые данные для изучения. Он может применяться в датчике, например GreenSeeker, для обнаружения сорняков. Хотя необходимо провести дополнительные исследования, чтобы проверить, можно ли достичь более высокой точности.

Приложение

A.1 Перекрестная проверка

Перекрестная проверка – это метод проверки, очень распространенной в статистике, который используется в машинном обучении для проверки точности классификатора. В перекрестной проверке набор данных разделяется на подмножества (обычно называемые блоками), а затем подмножество используется для обучения модели, в то время как другое дается модели как новые данные, которые модель затем прогнозирует. Далее проверяется, как модель вела себя с новыми данными, так как эти данные были фактически уже классифицированы. Точность – это доля правильно классифицированных выборок.

Концепция проста, но необходимо учитывать способ разделения набора данных, так как возможно выбрать подмножество, которое не очень хорошо отображает данные, а также если подмножество, выбранное для обучения модели, слишком мало, модель может быть не в состоянии его обобщить.

Из всех типов перекрестной проверки наиболее распространенными являются три. Leave-p-out, где наблюдения p набора данных выбираются для проверки, а остальное выбирается для обучения модели. Это повторяется до тех пор, пока все образцы не станут частью подмножества проверки. Есть еще один тип, который является частным случаем leave-p-out – leave one out, когда один образец используется для проверки, а остальные - для обучения, и это повторяется по количеству образцов.

Другой тип K-блок (K-fold), где данные делятся k раз, и только одна часть используется в качестве проверки, и так повторяется k раз; если k равно количеству выборок, это то же самое, что leave one out.

Точность

Точность A классификатора определяется как:

$$A = \frac{N_{correct}}{N_{total}}$$

При перекрестной проверке точность – это среднее значение точности для каждого подмножества.

A.2 Цветовой индекс

A.2.1 Matlab Созданный Цветовой Индекс

Цветовой индекс, который был создан для этого исследования, использовал и настраивал распределение YCBCR (для данного случая), а затем автоматически генерировал код. Код, созданный приложением, можно прочитать далее.

```

function [BW,maskedRGBImage] = weedfilter1 (RGB)
%createMask Threshold RGB image using auto-generated code from colorThresholder app. %
[BW,MASKEDRGBIMAGE] = createMask(RGB) thresholds image RGB using
% auto-generated code from the colorThresholder App. The colorspace and
% minimum/maximum values for each channel of the colorspace were set in the
% App and result in a binary mask BW and a composite image maskedRGBImage,
% which shows the original RGB image values under the mask BW.

% Auto-generated by colorThresholder app on 14-Feb-2017
%-----

% Convert RGB image to chosen color space I = rgb2ycbcr(RGB);

% Define thresholds for channel 1 based on histogram settings channel1Min = 67.000;
channel1Max = 87.000;

% Define thresholds for channel 2 based on histogram settings channel2Min = 120.000;
channel2Max = 140.000;

% Define thresholds for channel 3 based on histogram settings

channel3Min = 102.000;

channel3Max = 120.000;

% Create mask based on chosen histogram thresholds
sliderBW = (I(:,,1) >= channel1Min ) & (I(:,,1) <= channel1Max) & ...

(I(:,,2) >= channel2Min ) & (I(:,,2) <= channel2Max) & ...

(I(:,,3) >= channel3Min ) & (I(:,,3) <= channel3Max); BW = sliderBW;

% Initialize output masked image based on input image. maskedRGBImage = RGB;

% Set background pixels where BW is false to zero . maskedRGBImage(repmat(~BW,[1 1 3])) = 0;

end

```

A.2.2 Цветовые индексы

Используемые цветовые индексы были такими же, что и в машинах опорных векторов для идентификации культур/сорняков на полях кукурузы. В изображении RGB каждый пиксель состоит из трех компонентов: красного (R), зеленого (G) и синего (B), которые варьируются от 0 до 255. Итак, сначала три компонента нормализуются.

Избыток зеленого (ExG):

Цветовой индекс экстракции растительности (C I V E):

Комбинации из трех (COM):

A.2.3 Красная линия, излучаемая датчиком NDVI

GreenSeeker испустил красный свет, который является видимым красным светом, VIS в уравнении 1.1. Этот свет позволял убедиться, что камера была направлена туда же, куда и NDVI. На рис.А.2

Рисунок А.2: Красный луч, излучаемый GreenSeeker

Приложение Б

Б.1 Синхронизация данных

Рисунок В.1: Скриншот программы для синхронизации изображений с NDVI

На рис. В.2 скриншот программы для синхронизации изображений и NDVI. Программа была создана специально для данного исследования. В тот момент, когда NDVI начинает проходить белую доску, которая будет отображаться на графике в нижней части графического интерфейса, пользователь нажимает кнопку «Start NDVI», а когда изображение «покидает» белую доску, пользователь нажимает кнопку «Start Image», и то же самое для кнопок End. Кнопка «cycle» предназначена для ситуации, когда измерения проведены и квадроцикл вращается или останавливается. График ниже изображения является суммой зеленых значений каждого столбца пикселей.

В.2 Классификация изображений

На рис. В.3 скриншот программы, используемой для классификации изображений.

Приложение было разработано специально для данного исследования. В зависимости от показанного изображения пользователь нажимает одну из кнопок «С»: С1 для низкой плотности всходов, С2 для низкой плотности всходов с сорняками, С3 для высокой плотности всходов и С4 для высокой плотности всходов с сорняками. «No weeds» или «Weeds» для случаев, когда было неясно, были ли это всходы высокой или низкой плотности.

Рисунок В.2: Экран печати приложения для синхронизации изображений с NDVI

В.3 Пример проблемы с отметкой времени

Иногда камера не сохраняла изображения с регулярным интервале, создавая большой интервал в временной метке, вызывая перекрытие секунд при добавлении доли секунд. Даже если учесть, что классификация синхронизируется со временем, этого не произойдет в порядке регистрации.

Рисунок В.3: Ошибка метки времени в секундах с 22 по 24, вверху - NDVI по порядку логов, в середине это измерения на графике 5