

## МЕТОД ГАУССОВА ОБУЧЕНИЯ НЕЙРОННОЙ СЕТИ ДЛЯ РЕШЕНИЯ ЗАДАЧИ РАСПОЗНАВАНИЯ МНОГОСПЕКТРАЛЬНЫХ СПУТНИКОВЫХ ИЗОБРАЖЕНИЙ

С.Х.П. Кобеняя

joanpa13.cc@gmail.com

РУДН, Москва, Российская Федерация

### Аннотация

Рассмотрено различие в использовании методов компьютерного зрения по Гауссу и машинного обучения, применяемых для обработки многоспектральных спутниковых снимков при обнаружении и распознавании объектов исследования — банановых плантаций в районе Эль-Порвенир на побережье Эквадора. С учетом методов компьютерного зрения, машинного обучения, обработки многоспектральных спутниковых изображений и косвенных данных растров после расчета индексов вегетации NDVI и NDWI выполнена классификация растительности и водных объектов. Проведение анализа данных многоспектральных спутниковых изображений осложняет наличие облачности и растров. Метод машинного обучения при маркировке данных с валидацией по показателям вегетации применяется при сегментации классов, не участвующих в анализе компьютерного зрения при обнаружении и распознавании объекта исследования. Вероятность приведенных положительных экспериментальных результатов составляет ~ 96 %. Предлагаемые методы обнаружения и распознавания объектов на многоспектральных спутниковых изображениях могут быть внедрены в сельскохозяйственные системы для улучшения, анализа и оценки потребностей в сельскохозяйственных культурах, являющихся частью сельского хозяйства как первичного сектора экономики, для удовлетворения потребностей производства продуктов питания и сырьевых материалов. Таким образом, в условиях повышенного спроса на сельскохозяйственную продукцию необходимо внедрение технологий, гарантирующих качество и высокую производительность сельскохозяйственной техники

### Ключевые слова

*Разность Гаусса, распознавание многоспектральных спутниковых изображений, машинное обучение, линейная регрессия, вегетационные индексы*

Поступила 21.04.2020  
Принята 03.09.2020  
© Автор(ы), 2021

**Введение.** Использование машинного обучения и дескрипторов изображений демонстрирует преимущества обнаружения рассеянного множества точек. Таким образом, использование оператора разности Гаусса (Difference-of-Gaussians, DoG) можно считать аппроксимацией оператора Лапласа. Общие [1] результаты масштабирования конечных результатов стандартизированной функции Лапласа в компьютерном зрении [2] — это метод обнаружения точек или областей до распознавания объекта, так как он показывает обобщенные пространственные точки интереса в более высокой пропорции корректных совпадений и более низкой пропорции вторичных совпадений.

*Цель работы* — показать производительность при сравнении аналогичных функций масштабирования на изображении, используя обобщенный кадр для выделения особых точек к функциям масштабирования. Оператор DoG — это полосный фильтр, который отбрасывает все пространственные частоты, за исключением некоторых, присутствующих на исходном изображении. Он также используется для улучшения видимости деталей и краев, присутствующих на изображении со случайными шумами высокой пространственной частоты [3].

Схематическое представление [4] таких изображений, как границы, столбики и края определяются от нулевых пересечений. Аппроксимация нулевых пересечений в DoG может привести к «ложным краям». Гауссово сглаживание изменяет значения интенсивности локальных характеристик изображения, поэтому в данном подходе [5] связывание конечных точек с уровнями серого считается примитивным пространственным эскизом. Экспериментально показано, что полученный первичный масштабно-пространственный эскиз позволяет извлекать растровые структуры в виде выступающих пятен, а также масштабировать уровни для их обработки вверх. Для сегментации изображения использовалась связь [6] компонентов изображения с градиентом над масштабным пространством.

Общая идея [7, 8] осуществления масштабного выбора и определения характеристик изображения путем вычисления локальных максимумов относительно пространства и масштаба стандартизованных производных приводит к теоретически доказуемой масштабной инвариантности. При выборе масштаба все визуальные модули преобразуются в переменные, что позволяет автоматически адаптировать и обрабатывать изображения разных размеров. Обнаружение особенностей изображения [9] в пространственном масштабе сочетается с последующим расчетом фоновых матриц для формирования локальной поверхности с помощью градиентов формы и текстуры. При данных подходах к распознаванию инвариантность

свойств системы распознавания во многом зависит от свойств точек интереса, в которых вычисляются дескрипторы изображений.

Что касается области совпадения изображений и распознавания объектов [10], то начаты исследования методов распознавания на основе гистограмм, показывающих, как можно получить рациональную производительность схемы распознавания объектов путем сравнения цветовых RGB-гистограмм. Комбинация [11] дескрипторов изображений на основе признаков и гистограмм определила масштабно-инвариантное преобразование признаков, интегрирующее накопление статистики направления локальных градиентов масштабируемых точек с информацией о пространственной планировке. Подобные дескрипторы [12] объединяют пространственные моменты с RGB-информацией и чувствительностью различных цветовых пространств нулевого порядка для распознавания гистограмм [13]. Набор инвариантов дифференциального цвета [14], инвариантных к освещению, основанный на модели отражения и цветовой модели Гаусса [15], рассчитывает частичные производные необязательных цветовых каналов. Общие теоретические основы [16] откликов локального приемного поля и его расширений или аналогов на цветные изображения и данные пространственно-временных изображений могут быть положены в основу расчета свойств объектов, поддерживающих инвариантное распознавание в естественных преобразованиях изображений.

Модель обнаружения и распознавания культур структурирована под автоматическое изучение и распознавание регионов, особенно в светлых областях на темном фоне или в темных областях на светлом фоне. Исходным алгоритмом, реализованным для детектирования сюжета, является разность по Гауссу.

Используя модели машинного обучения [17] в сельскохозяйственных системах, с помощью таких данных, как температура воздуха, относительная влажность воздуха и скорость ветра прогнозируют условия окружающей среды для обнаружения и профилактики распространения вредителей.

Разновременные изображения, широко используемые для оценки и мониторинга состояния растительного покрова на глобальном, региональном, национальном и местном уровнях, предоставляются спутниково-выми системами Земли, например системами серии LANDSAT, для оценки и рационального использования природных ресурсов растительного покрова. Сочетание спутниковых изображений позволяет анализировать конкретные элементы земной поверхности в соответствии с их эмиссионным спектром. Благодаря различным многоспектральным полосам работы спутников можно интерпретировать такие аспекты, как расти-

тельность, землепользование или водные объекты. В результате стремительной эволюции вычислительных парадигм [18] разработка [19] систем мониторинга в моделях точного земледелия выявляет температуру, относительную влажность и другие факторы для обеспечения надлежащего управления сельскохозяйственными ресурсами. Сельское хозяйство использует для этой цели технологии спутникового или воздушного дистанционного зондирования, ставя на службу космическую технику, а методы дистанционного зондирования [20], применяемые в сельском хозяйстве, способствуют повышению урожайности органического земледелия. Внедрение этой технологии обеспечивает рациональное использование сельскохозяйственных ресурсов, поскольку в связи с ростом численности населения и растущим спросом на продовольствие сельское хозяйство вынуждено развиваться и использовать технологии, связанные со спутниковыми снимками.

**Постановка задачи.** Распознавание объектов регионов на многоспектральных спутниковых изображениях вычислительным методом линейной регрессии с использованием среднеквадратической погрешности на этапе предварительной обработки становится более точным:

$$\frac{1}{N} \sum_{i=1}^N |y_i - \mu|,$$

где  $y_i$  — метка для экземпляра;  $N$  — номер экземпляра;  $\mu$  — среднее задаваемое значение.

Компиляция информации используется для разделения данных с помощью энтропии и вычисляется как уменьшение энтропии после разделения набора данных на атрибуты:

$$\text{Компиляция}(T, X) = \text{Энтропия}(T) - \text{Энтропия}(T, X),$$

где  $T$  — целевая переменная;  $X$  — классификационная характеристика;  $\text{Энтропия}(T, X)$  — энтропия, вычисленная после разделения данных на признаки  $X$ .

Для каждого дерева решений вычисляют значение узлов, предполагая только два дочерних узла (двоичное дерево):

$$ni_j = w_j C_j - w_{left(j)} C_{left(j)} - w_{right(j)} C_{right(j)},$$

где  $ni_j$  — значение узла  $j$ ;  $w_j$  — взвешенное число образцов, достигающих узла  $j$ ;  $C_j$  — количество примесей в узле  $j$ ;  $left(j)$  и  $right(j)$  — дочерние узлы, разделенные слева и справа на узлы  $j$ .

Значение каждого элемента дерева решений вычисляется как

$$f_i = \frac{\sum_j n_{ij}}{\sum_k n_{ik}},$$

где  $f_i$  — значимость по признаку  $i$ ;  $n_{ij}$  — значимость по узлу  $j$ .

Затем эти значения подлежат нормализации по значению между нулем и единицей. Разделив их на сумму всех значений признака по значимости, получим

$$\text{norm } f_i = \frac{f_i}{\sum_j f_j}.$$

Выходной признак по значимости — это среднее значение всех деревьев решений. Сумма значений признаков по значимости на каждом дереве вычисляется и делится на общее число деревьев:

$$RF f_i = \frac{\sum_j \text{norm } f_{ij}}{T},$$

где  $RF f_i$  — значимость признака  $i$ , вычисленного из всех деревьев решений в модели;  $\text{norm } f_{ij}$  — нормализованная значимость признака для  $i$  в дереве  $j$ ;  $T$  — общее число деревьев.

Используемый набор данных многоспектральных спутниковых изображений показывает элементы исследования в зависимости от конкретных комбинаций их спектральных диапазонов. Для этого спутниковая информация, получаемая с помощью многодиапазонного изображения, должна быть разбита по категориям и сгруппирована так, чтобы можно было отличить область с определенными характеристиками от других. Одним из способов выражения этой классификации или группировки является разработка вегетационных индексов. Эти показатели используются для улучшения разграничения между почвой и растительностью, уменьшая влияние рельефа на спектральную характеристику различных покрытий.

В настоящей работе использованы изображения со спутника LANDSAT 8, который переснимает одну и ту же точку на поверхности Земли каждые 16 дней. Его датчики OLI (оперативный землеустроитель) и TIRS (тепловой ИК-датчик) обеспечивают доступ к 9 спектральным полосам, которые покрывают спектр от 0,433 до 1,390 мкм и от 10,30 до 12,50 мкм с разрешением 30 мкм (табл. 1).

Таблица 1

**Характеристики диапазонов спектра спутников LANDSAT 8**

Полосы LANDSAT 8		Длина волны, мкм	Разрешение, м
2	Синяя	0,452–0,512	30
3	Зеленая	0,533–0,590	
4	Красная	0,636–0,673	
5	Ближняя инфракрасная (NIR)	0,851–0,879	

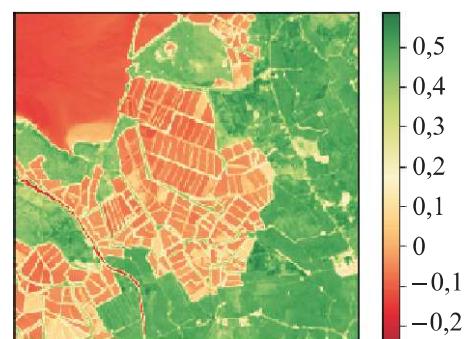
Геопространственные растровые данные многоспектральных спутниковых изображений считывались, обрабатывались и визуализировались с помощью библиотеки Rasterio от Python для расчета нормализованного относительного индекса растительности NDVI (Normalized Difference Vegetation Index), который используется для минимизации топографических эффектов и получения линейной шкалы измерений [21]:

$$\text{NDVI} = \frac{X_{\text{NIR}} - X_{\text{red}}}{X_{\text{NIR}} + X_{\text{red}}}.$$

Шкала колеблется от  $-1$  до  $1$  с нулевым значением, представляющим собой приблизительное значение, где начинается отсутствие растительности.

Отрицательные значения представляют районы без растительности. Нормализация, которую он выполняет, снижает эффект от калибровки датчиков и влияния атмосферных эффектов. Низкие значения NDVI до  $0,1$  соответствуют каменистым, песчаным или снежным районам, от  $0,1$  до  $0,2$  могут соответствовать районам с бедной растительностью — естественные кустарники или пастбища (рис. 1).

Из этих значений получаем уровни, соответствующие лугам, сельскохозяйственным культурам, лесам в зависимости от достигнутого значения.



**Рис. 1.** Визуализация расчета индекса NDVI на многоспектральном спутниковом изображении банановой плантации (кантона Эль-Гуабо, Эквадор, 2019)

При использовании NDVI спутниковое многоспектральное изображение рассчитывается пиксель за пикселием от отражения длин видимых красных и ближних ИК-волн. В результате этого процесса формируется изображение, показывающее относительную биомассу. Поглощение хлоро-

филла в красной полосе и относительно высокая отражательная способность растительности в ближней ИК-полосе (NIR) также используются для расчета этого показателя. Данный нормализованный разностный водный индекс NDWI (Normalized Difference Water Index) [22] дифференцирует вегетативные зоны, которые затем используются для классификации пикселей на плантациях,

$$NDWI = \frac{X_{\text{green}} - X_{\text{NIR}}}{X_{\text{green}} + X_{\text{NIR}}}.$$

Индекс NDWI используется для измерения количества воды растительности или уровня насыщенности влагой почвы (рис. 2).

Значение отражательности для каждого пикселя представляет собой среднее отражение покрытия всех типов внутри этого пикселя, поэтому изображения предварительно обрабатываются с помощью растровых функций. Функция NDVI идентифицирует зоны со здоровой растительностью, а NDWI — водоемы или почвы, насыщенные влагой.

В настоящей работе выполнена маскировка водных объектов на динамических изображениях дистанционного зондирования, реализованная в моделях линейной регрессии для подтверждения индексом NDWI полученных данных векторного признака, являющегося атрибутом, который представляет собой объект исследования. Чем больше векторов у признака, тем проще процесс классификации. Эти функциональные векторы сочетаются с весами для построения прогностической функции. Отраженная яркость объекта, захваченного на снимке дистанционного зондирования, зависит от величины электромагнитного излучения, поглощаемого объектом, т. е. чем больше он поглощает, тем меньше отражает. Вода больше поглощает в ИК-области, поэтому отраженный блик воды в ИК-диапазоне и коротковолновом ИК-диапазоне меньше, чем блик других объектов, таких как растительность, здания, голая почва, дороги и др. Модель выбирает число пикселей в зависимости от областей, где  $NDWI < 0,3$  или  $NDWI \geq 0,3$  для каждого раstra (рис. 3).

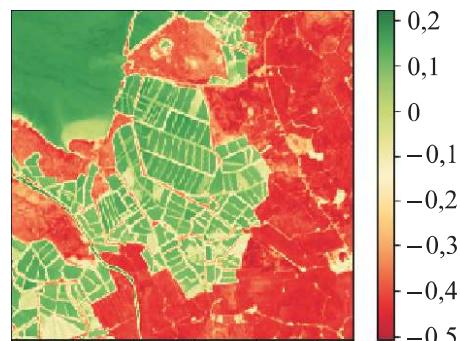


Рис. 2. Визуализация расчета индекса NDWI на многоспектральном спутниковом изображении банановой плантации

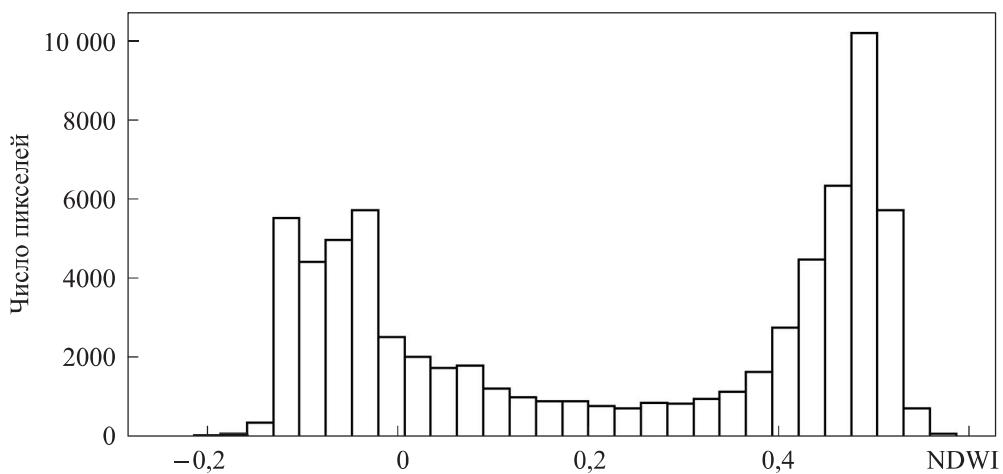


Рис. 3. Гистограмма индекса NDWI на многоспектральном спутниковом изображении банановой плантации

Многоспектральные спутниковые изображения соответствуют банановым культурам, поскольку производство бананов является наиболее значительным видом деятельности в Республике Эквадор. В провинции Эль-Оро расположено наибольшее число ферм в стране: из 5737 ферм 2375 зарегистрированы в Департаменте торговли Министерства сельского хозяйства Эквадора, т. е. 41,39 %. Эквадор укрепил свои позиции в качестве основного экспортёра бананов в мировом масштабе, на долю которого приходится 30 % международных поставок. Один из основных районов возделывания находится в кантоне Эль-Гуабо, провинция Эль-Оро, координаты изучаемой зоны приведены в табл. 2.

Таблица 2

#### Параметры области изучения

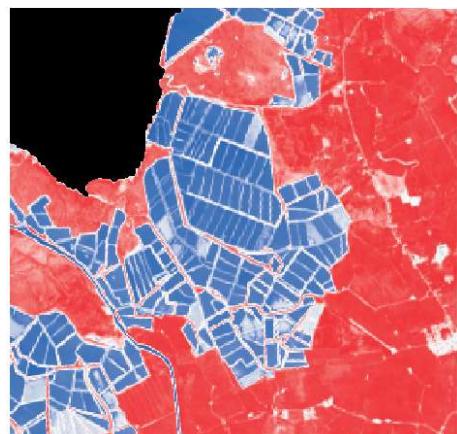
Площадь поверхности	32,84 км <sup>2</sup>
Координаты поверхности	-3,17163° ю. ш.; -79,89206° з. д.
Полигон	[-79,899273; -3,207876]; [-79,900818; -3,193136]; [-79,908543; -3,187994]; [-79,916782; -3,175139]; [-79,925194; -3,170168]; [-79,928455; -3,159199]; [-79,917812; -3,166398]; [-79,914036; -3,163827]; [-79,909573; -3,164512]; [-79,906311; -3,157142]; [-79,905796; -3,153885]; [-79,902363; -3,147372]; [-79,903221; -3,144287]; [-79,891891; -3,135374]; [-79,908543; -3,187994]; [-79,916782; -3,175139]; [-79,925194; -3,170168]; [-79,928455; -3,159199];

Окончание табл. 2

Полигон	$[-79,917812; -3,166398]; [-79,914036; -3,163827];$ $[-79,909573; -3,164512]; [-79,906311; -3,157142];$ $[-79,905796; -3,153885]; [-79,902363; -3,147372];$ $[-79,903221; -3,144287]; [-79,891891; -3,135374];$ $[-79,888458; -3,137259]; [-79,886742; -3,137088];$ $[-79,881077; -3,146515]; [-79,879532; -3,144973];$ $[-79,875927; -3,144287]; [-79,873180; -3,140859];$ $[-79,872665; -3,146172]; [-79,872837; -3,152343];$ $[-79,868031; -3,161256]; [-79,865112; -3,167255];$ $[-79,855671; -3,185251]; [-79,856186; -3,186623];$ $[-79,863052; -3,189708]; [-79,860992; -3,191079];$ $[-79,866142; -3,193650]; [-79,877644; -3,194507];$ $[-79,877300; -3,197078]; [-79,874554; -3,197078];$ $[-79,874897; -3,199820]; [-79,899273; -3,207876]$
---------	---

Интересующие пиксели принадлежат  $X_t \in \mathbb{R}(p \times B)$ , где  $p$  — число пикселей и  $B$  — число полос, и входному набору  $X = [X_t, X_{t-1}, X_{t-2}, X_{t-3}]$ ,  $X \in \mathbb{R}(p \times 4B)$ , где  $j(X_{t-j})$  определяется как пиксель перед  $t$  (без водоемов, рис. 4).

**Рис. 4.** Маскировка водного объекта с помощью индекса NDWI на многоспектральном спутниковом изображении банановой плантации

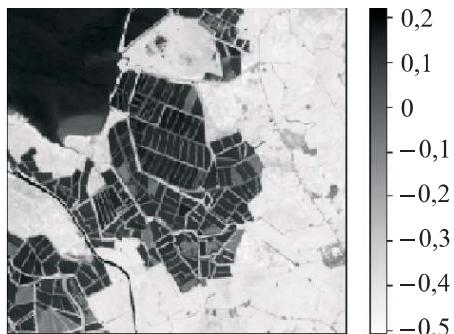


Маскировка позволяет изолировать водные объекты так, что на предварительно обработанном изображении присутствуют только пиксели с коэффициентом  $NDVI > 0,1$  для классификации пикселей в градации серого (рис. 5), и вычислить число плантаций с помощью метода разности Гаусса в качестве аппроксимации стандартной шкалы Лапласа:

$$\frac{1}{2} \nabla^2 L(x; t) = \partial_t L(x; t) \approx \frac{L(x; t + \Delta t) - L(x; t)}{\Delta t} = \frac{DoG(x; t, \Delta t)}{\Delta t}$$

с подобной себе  $\Delta t = (k^2 - 1)t$  выборкой по шкале  $\sigma_{i+1} = k\sigma_i$ , соответствующей  $t_{i+1} = k^2t_i$  и подразумевающей, что

$$\text{DoG}(x, y; t) \approx \frac{(k^2 - 1)}{2} \nabla_{\text{norm}}^2 L(x, y; t).$$

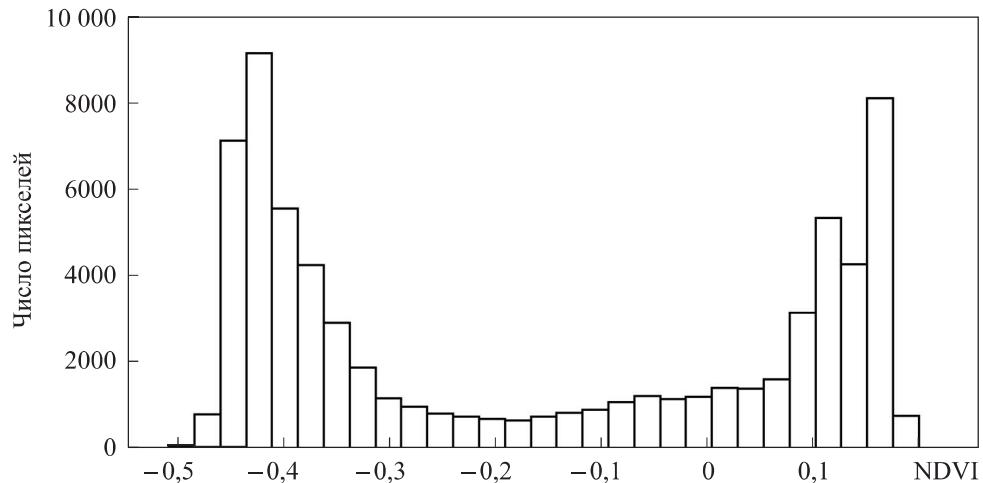


**Рис. 5.** Обработка многоспектрального спутникового изображения банановой плантации с помощью индекса NDVI

Процентные точки, полученные из масштабируемого пространства экстремума разности Гаусса, рассматриваются как аппроксимации процентных точек, полученных из масштабно-пространственных экстремумов Лапласа. Для каждого пикселя, определенного как плантация, метод дает его координаты и стандартное отклонение гауссова ядра, обнаруженного как плантация. Абсолютный нижний предел для максимумов пространства мас-

штаба уменьшается для обнаружения пикселей с меньшей интенсивностью.

**Результаты эксперимента.** Методология составления информации для классификации пикселей с использованием индекса NDVI в качестве метода валидации в зависимости от уровня растительности (рис. 6) показала, что процент растительности, существующий на плантациях, эквивалентен числу пикселей  $\text{NDVI} > 0,3$ .



**Рис. 6.** Гистограмма индекса NDVI на многоспектральном спутниковом изображении банановой плантации

Предварительно обработанное изображение приведено на рис. 7, а, где использована семантическая сегментация данных индекса NDVI на многоспектральном спутниковом изображении банановой плантации, позволяющая строить карту с изображением контуров банановых плантаций, на основе входных данных [23].

Алгоритм разности Гаусса в полутонах изображениях распознал в среднем 247 плантаций в исследуемой области (рис. 7, б).

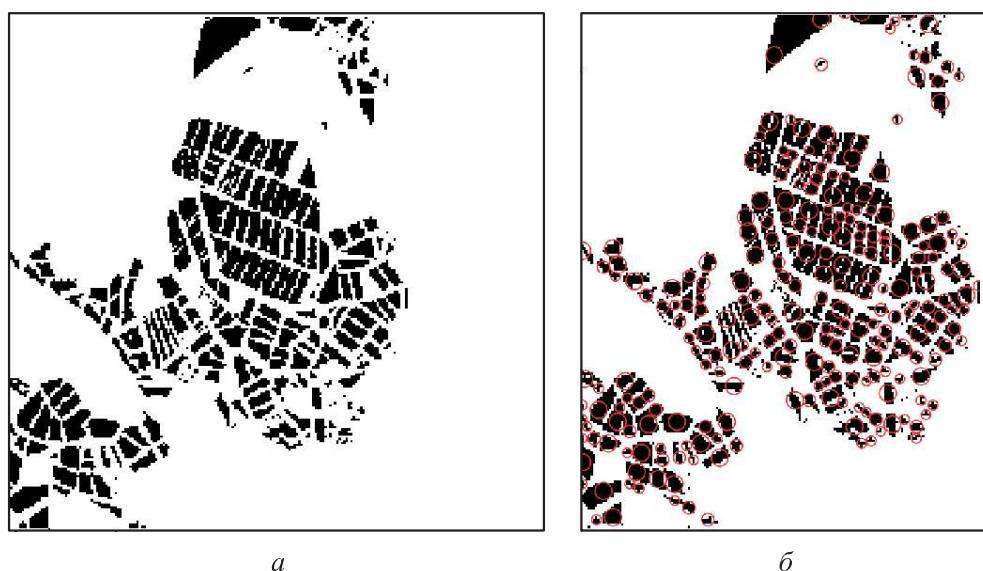


Рис. 7. Предварительно обработанное (а) и полутонаовое (б) многоспектральные спутниковые изображения банановой плантации с индексом NDVI > 0,3 (кантоны Эль-Губабо, Эквадор, 2019)

**Заключение.** Для классификации массива данных расчетных значений NDVI по многоспектральным спутниковым изображениям LANDSAT 8 спроектировано использование компиляции информации, значение NDVI, отраженное на банановых плантациях, равно 0,3.

Для предварительной обработки многоспектрального спутникового изображения водных объектов использовалась их маскировка, рассчитанная с помощью индекса NDWI, для исключения этих объектов и получения качественного набора данных.

Использование разности Гаусса позволило получить средний прогноз при распознавании банановых плантаций, равный 96 %. Для уменьшения погрешности сгенерирована группировка пикселей, ранее обработанных с помощью NDVI, для валидации набора данных по банановым культурам в районе Эль-Порвенира с помощью двух многоспектральных спутниковых изображений LANDSAT 8 при уровне облачности менее 10 %.

## ЛИТЕРАТУРА

- [1] Lindeberg T. Scale selection properties of generalized scale-space interest point detectors. *J. Math. Imaging Vis.*, 2013, vol. 46, no. 2, pp. 177–210.  
DOI: <https://doi.org/10.1007/s10851-012-0378-3>
- [2] Lindeberg T. Feature detection with automatic scale selection. *Int. J. Comput. Vis.*, 1998, vol. 30, no. 2, pp. 77–116. DOI: <https://doi.org/10.1023/A:1008045108935>
- [3] Смирнов К.А., Волков В.А. Автоматизированный метод обнаружения арктических айсбергов на спутниковых снимках. 14 Всерос. открытая конф. «Современные проблемы дистанционного зондирования Земли из космоса». М., ИКИ РАН, 2016, с. 50.
- [4] Marr D., Hildreth E. Theory of edge detection. *Proc. Royal Soc. Lond.*, 1980, vol. 207, no. 1167, pp. 187–217. DOI: <https://doi.org/10.1098/rspb.1980.0020>
- [5] Lindeberg T. Detecting salient blob-like image structures and their scales with a scale-space primal sketch: a method for focus-of-attention. *Int. J. Comput. Vis.*, 1993, vol. 11, no. 3, pp. 283–318. DOI: <https://doi.org/10.1007/BF01469346>
- [6] Olsen O.F. Multi-scale watershed segmentation. In: Gaussian scale-space theory. New York, Springer, 1997, pp. 191–200.
- [7] Lindeberg T. On scale selection for differential operators. *Proc. 8th SCIA*, 1993, pp. 857–866.
- [8] Lindeberg T. Edge detection and ridge detection with automatic scale selection. *Int. J. Comput. Vis.*, 1998, vol. 30, no. 2, pp. 117–154.  
DOI: <https://doi.org/10.1023/A:1008097225773>
- [9] Lindeberg T., Garding J. Shape from texture from a multi-scale perspective. *Proc. ICCV*, 1993, pp. 683–691. DOI: <https://doi.org/10.1109/ICCV.1993.378146>
- [10] Swain M., Ballard D. Color indexing. *Int. J. Comput. Vis.*, 1991, vol. 7, no. 1, pp. 11–32. DOI: <https://doi.org/10.1007/BF00130487>
- [11] Lowe D. Distinctive image features from scale-invariant keypoints. *Int. J. Comput. Vis.*, 2004, vol. 60, no. 2, pp. 91–110.  
DOI: <https://doi.org/10.1023/B:VISI.0000029664.99615.94>
- [12] Slater D., Healey G. Combining colour and geometric information for illumination invariant recognition of 3D objects. *Proc. ICCV*, 1995, pp. 563–568.  
DOI: <https://doi.org/10.1109/ICCV.1995.466889>
- [13] Gevers T., Smeulders A.W.M. Color-based object recognition. *Pattern Recognit.*, 1999, vol. 32, no. 3, pp. 453–464. DOI: [https://doi.org/10.1016/S0031-3203\(98\)00036-3](https://doi.org/10.1016/S0031-3203(98)00036-3)
- [14] Geusebroek J.M., van den Boomgaard R., Smeulders A.W.M., et al. Color invariance. *IEEE Trans. Pattern Anal. Mach. Intell.*, 2001, vol. 23, no. 12, pp. 1338–1350.  
DOI: <https://doi.org/10.1109/34.977559>
- [15] Hall D., de Verdiere V., Crowley J. Object recognition using coloured receptive fields. *Proc. ECCV*, pp. 164–177. DOI: [https://doi.org/10.1007/3-540-45054-8\\_11](https://doi.org/10.1007/3-540-45054-8_11)
- [16] Lindeberg T. A computational theory of visual receptive fields. *Biol. Cybern.*, 2013, vol. 107, no. 6, pp. 589–635. DOI: <https://doi.org/10.1007/s00422-013-0569-z>

- [17] Truong T., Dinh A., Wahid K. An IoT environmental data collection system for fungal detection in crop fields. *Proc. IEEE 30th CCECE*, 2017.  
DOI: <https://doi.org/10.1109/CCECE.2017.7946787>
- [18] Wolfert S., Ge L., Verdouw C., et al. Big data in smart farming a review. *Agric. Syst.*, 2017, vol. 153, pp. 69–80. DOI: <https://doi.org/10.1016/j.agrsy.2017.01.023>
- [19] Patil S.S., Thorat S.A. Early detection of grapes diseases using machine learning and IoT. *Proc. 2nd Int. Conf. CCIP*, 2016.  
DOI: <https://doi.org/10.1109/CCIP.2016.7802887>
- [20] Pallavi S., Mallapur J.D., Bendigeri K.Y. Remote sensing and controlling of green-house agriculture parameters based on IoT. *Proc. Int. Conf. BID*, 2017, pp. 44–48.  
DOI: <https://doi.org/10.1109/BID.2017.8336571>
- [21] Campbell J.B., Wynne R.H. Introduction to remote sensing. New York, The Guilford Press, 2011.
- [22] Gao B. NDWI — a normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sens. Environ.*, 1996, vol. 58, no. 3, pp. 257–266.  
DOI: [https://doi.org/10.1016/S0034-4257\(96\)00067-3](https://doi.org/10.1016/S0034-4257(96)00067-3)
- [23] Друки А.А., Спицын В.Г., Болотова Ю.А. и др. Семантическая сегментация данных дистанционного зондирования Земли при помощи нейросетевых алгоритмов. *Известия ТПУ. Инженеринг георесурсов*, 2018, т. 329, № 1, с. 59–68.

**Кобенъя Севальос Хоан Патрисио** — аспирант департамента механики и процессов управления Инженерной академии РУДН (Российская Федерация, 117198, Москва, ул. Миклухо-Маклая, д. 6).

**Просьба ссылаться на эту статью следующим образом:**

Кобенъя С.Х.П. Метод гауссова обучения нейронной сети для решения задачи распознавания многоспектральных спутниковых изображений. *Вестник МГТУ им. Н.Э. Баумана. Сер. Приборостроение*, 2021, № 4 (137), с. 59–74.  
DOI: <https://doi.org/10.18698/0236-3933-2021-4-59-74>

## GAUSSIAN NEURAL NETWORK TRAINING METHOD FOR SOLVING THE PROBLEM OF MULTISPECTRAL SATELLITE IMAGES RECOGNITION

C.J.P. Cobeña

joanpa13.cc@gmail.com

RUDN University, Moscow, Russian Federation

---

### Abstract

The methods of Gaussian computer vision and machine learning used to process multispectral satellite images in the detection and recognition of research objects — banana plantations in the area of El Porvenir on the

### Keywords

Difference of Gaussian, recognition of multispectral satellite images, machine learning, linear regression, vegetation indices

coast of Ecuador — are considered. Using computer vision and machine learning techniques, processing of multispectral satellite images and indirect raster data after calculating NDVI and NDWI vegetation indices, classification of vegetation and water objects was performed. The analysis of multispectral satellite image data is complicated by the presence of clouds and rasters that do not contain data other than the object of study. The machine learning method when labeling data with validation by vegetation indices is used in segmentation of classes that do not participate in the computer vision analysis in the detection and recognition of the research object. The probability of the given positive experimental results is ~ 96 %. The proposed methods of objects detection and recognition on multispectral satellite images can be implemented in agricultural systems to improve, analyze and assess the needs of crops, which are part of agriculture as the primary sector of the economy, to meet the needs of food and raw materials production. Thus, with the increased demand for agricultural products, it is necessary to introduce technologies that guarantee the quality and high productivity of agricultural machinery

Received 21.04.2020

Accepted 03.09.2020

© Author(s), 2021

## REFERENCES

- [1] Lindeberg T. Scale selection properties of generalized scale-space interest point detectors. *J. Math. Imaging Vis.*, 2013, vol. 46, no. 2, pp. 177–210.  
DOI: <https://doi.org/10.1007/s10851-012-0378-3>
- [2] Lindeberg T. Feature detection with automatic scale selection. *Int. J. Comput. Vis.*, 1998, vol. 30, no. 2, pp. 77–116. DOI: <https://doi.org/10.1023/A:1008045108935>
- [3] Smirnov K.A., Volkov V.A. [Automated method for detection of arctic icebergs on satellite images]. *14 Vseros. otkrytaya konf. “Sovremennye problemy distantsionnogo zondirovaniya Zemli iz kosmosa”* [14th Russ. Open Conf. “Modern Issues of Earth Remote Sensing from Space”]. Moscow, IKI RAS Publ., 2016, p. 50 (in Russ.).
- [4] Marr D., Hildreth E. Theory of edge detection. *Proc. Royal Soc. Lond.*, 1980, vol. 207, no. 1167, pp. 187–217. DOI: <https://doi.org/10.1098/rspb.1980.0020>
- [5] Lindeberg T. Detecting salient blob-like image structures and their scales with a scale-space primal sketch: a method for focus-of-attention. *Int. J. Comput. Vis.*, 1993, vol. 11, no. 3, pp. 283–318. DOI: <https://doi.org/10.1007/BF01469346>
- [6] Olsen O.F. Multi-scale watershed segmentation. In: Gaussian scale-space theory. New York, Springer, 1997, pp. 191–200.
- [7] Lindeberg T. On scale selection for differential operators. *Proc. 8th SCIA*, 1993, pp. 857–866.

- [8] Lindeberg T. Edge detection and ridge detection with automatic scale selection. *Int. J. Comput. Vis.*, 1998, vol. 30, no. 2, pp. 117–154.  
DOI: <https://doi.org/10.1023/A:1008097225773>
- [9] Lindeberg T., Garding J. Shape from texture from a multi-scale perspective. *Proc. ICCV*, 1993, pp. 683–691. DOI: <https://doi.org/10.1109/ICCV.1993.378146>
- [10] Swain M., Ballard D. Color indexing. *Int. J. Comput. Vis.*, 1991, vol. 7, no. 1, pp. 11–32. DOI: <https://doi.org/10.1007/BF00130487>
- [11] Lowe D. Distinctive image features from scale-invariant keypoints. *Int. J. Comput. Vis.*, 2004, vol. 60, no. 2, pp. 91–110.  
DOI: <https://doi.org/10.1023/B:VISI.0000029664.99615.94>
- [12] Slater D., Healey G. Combining colour and geometric information for illumination invariant recognition of 3D objects. *Proc. ICCV*, 1995, pp. 563–568.  
DOI: <https://doi.org/10.1109/ICCV.1995.466889>
- [13] Gevers T., Smeulders A.W.M. Color-based object recognition. *Pattern Recognit.*, 1999, vol. 32, no. 3, pp. 453–464.  
DOI: [https://doi.org/10.1016/S0031-3203\(98\)00036-3](https://doi.org/10.1016/S0031-3203(98)00036-3)
- [14] Geusebroek J.M., van den Boomgaard R., Smeulders A.W.M., et al. Color invariance. *IEEE Trans. Pattern Anal. Mach. Intell.*, 2001, vol. 23, no. 12, pp. 1338–1350.  
DOI: <https://doi.org/10.1109/34.977559>
- [15] Hall D., de Verdiere V., Crowley J. Object recognition using coloured receptive fields. *Proc. ECCV*, pp. 164–177. DOI: [https://doi.org/10.1007/3-540-45054-8\\_11](https://doi.org/10.1007/3-540-45054-8_11)
- [16] Lindeberg T. A computational theory of visual receptive fields. *Biol. Cybern.*, 2013, vol. 107, no. 6, pp. 589–635. DOI: <https://doi.org/10.1007/s00422-013-0569-z>
- [17] Truong T., Dinh A., Wahid K. An IoT environmental data collection system for fungal detection in crop fields. *Proc. IEEE 30th CCECE*, 2017.  
DOI: <https://doi.org/10.1109/CCECE.2017.7946787>
- [18] Wolfert S., Ge L., Verdouw C., et al. Big data in smart farming a review. *Agric. Syst.*, 2017, vol. 153, pp. 69–80. DOI: <https://doi.org/10.1016/j.aggsy.2017.01.023>
- [19] Patil S.S., Thorat S.A. Early detection of grapes diseases using machine learning and IoT. *Proc. 2nd Int. Conf. CCIP*, 2016.  
DOI: <https://doi.org/10.1109/CCIP.2016.7802887>
- [20] Pallavi S., Mallapur J.D., Bendigeri K.Y. Remote sensing and controlling of greenhouse agriculture parameters based on IoT. *Proc. Int. Conf. BID*, 2017, pp. 44–48.  
DOI: <https://doi.org/10.1109/BID.2017.8336571>
- [21] Campbell J.B., Wynne R.H. Introduction to remote sensing. New York, The Guilford Press, 2011.
- [22] Gao B. NDWI — a normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sens. Environ.*, 1996, vol. 58, no. 3, pp. 257–266.  
DOI: [https://doi.org/10.1016/S0034-4257\(96\)00067-3](https://doi.org/10.1016/S0034-4257(96)00067-3)

- 
- [23] Druki A.A., Spitsyn V.G., Bolotova Yu.A., et al. Semantic segmentation of Earth scanning images using neural network algorithms. *Izvestiya TPU. Inzhiniring georesursov* [Bulletin of the Tomsk Polytechnic University. Geo Assets Engineering], 2018, vol. 329, no. 1, pp. 59–68 (in Russ.).

**Cobeña C.J.P.** — Post-Graduate Student, Department of Mechanics and Mechatronics, Academy of Engineering, RUDN University (Miklukho-Maklaya ul. 6, Moscow, 117198 Russian Federation).

**Please cite this article in English as:**

Cobeña C.J.P. Gaussian neural network training method for solving the problem of multi-spectral satellite images recognition. *Herald of the Bauman Moscow State Technical University, Series Instrument Engineering*, 2021, no. 4 (137), pp. 59–74 (in Russ.).  
DOI: <https://doi.org/10.18698/0236-3933-2021-4-59-74>