

## Сравнение байесовского классификатора и метода на основе вычисления оценок для распознавания видов с/х культур по космическим снимкам Terra/MODIS

Н.С. Воробьева<sup>1</sup>, А.В. Чернов<sup>1,2</sup>

<sup>1</sup>Самарский национальный исследовательский университет им. академика С.П. Королева, Московское шоссе 34А, Самара, Россия, 443086

<sup>2</sup>Институт систем обработки изображений РАН – филиал ФНИЦ «Кристаллография и фотоника» РАН, Молодогвардейская 151, Самара, Россия, 443001

**Аннотация.** Рассматриваются два метода распознавания видов сельскохозяйственных культур по космическим снимкам: байесовский классификатор и метод распознавания, основанный на алгоритме вычисления оценок (АВО). В качестве признаков используются значения временных рядов, рассчитанных по последовательности космических снимков низкого пространственного разрешения 250 м со спутника Terra/MODIS. Отличительная особенность и несомненное преимущество АВО – использование временных рядов даже с пропусками значений, тогда как для применения байесовского классификатора требуется предварительная процедура восстановления пропущенных значений временных рядов. Приводятся численные оценки сравнения двух методов на протяжении всего сезона вегетации сельскохозяйственных культур для разной длины временных рядов, полученных по космическим снимкам территории Самарской области за 2014-2016 годы.

### 1. Введение

Распознавание типов посевов по данным дистанционного зондирования Земли (ДЗЗ) является актуальной задачей мониторинга земель сельскохозяйственного (далее – с/х) назначения [1, 2]. Результаты распознавания применяются для контроля и учета земель, выявления неиспользуемых земель в течение ряда лет, контроля использования субсидий, выделяемых с/х производителям [3]. Особенно важны результаты так называемого раннего распознавания, проводимого как можно раньше от начала сева культур – это позволит провести оперативные мероприятия по контролю использования с/х земель [4]. В данной работе будем говорить о раннем распознавании на территориях большой площади, сравнимых с размерами регионов России. Для распознавания на таких территориях обычно применяются методы, основанные на использовании временных рядов вегетационных индексов, позволяющие наблюдать за динамикой развития с/х культур в течение длительного промежутка времени (посевного сезона или его части) [5, 6]. В [4] была предложена информационная технология для раннего распознавания типов посевов (видов с/х культур) по временным рядам вегетационных индексов, рассчитанных по сезонной последовательности космических снимков. Технология позволяет провести распознавание с/х культур на полях в ситуации, когда данных текущего года недостаточно для настройки метода распознавания. В ней используются данные прошлых лет и информация о посеянных культурах на небольшом количестве так называемых опорных

полей текущего года. Информационная технология включает в себя два этапа, каждый из которых состоит из ряда блоков. Для непосредственного распознавания с/х культур в информационной технологии предлагается использовать метод, основанный на алгоритме вычисления оценок (далее – АВО).

Цель данной работы – сравнить метод распознавания с/х культур, используемый в [4] для распознавания с/х культур и основанный на алгоритме вычисления оценок, с некоторым другим методом распознавания, и оценить целесообразность его применения для раннего распознавания видов с/х культур.

Для сравнения был выбран байесовский классификатор для нормально распределенных векторов признаков.

## 2. Исходные данные

В работе для распознавания рассматривались следующие классы с/х культур (типы посевов)  $\Omega_l, l = \overline{1,5}$ :

- многолетние травы и неиспользуемые земли (МТ и НЗ);
- озимые;
- пар;
- ранние яровые;
- поздние яровые.

Для экспериментальных исследований были использованы наземные данные (векторные границы полей, данные о посеянных на полях культурах) и космические снимки, полученные для территории Самарской области за 2014-2016 годы. По совокупности природно-экономических условий, по особенностям климата и почв территория Самарской области делится на три агроклиматические зоны (далее – зоны): северную, центральную и южную [7]. В таблице 1 для наземных данных приведено количество полей каждого вида (класса) с/х культуры в каждой агроклиматической зоне в соответствующем году, выбранных для исследования.

**Таблица 1.** Статистика наземных данных о полях.

Год	Зона	МТ и НЗ	Озимые	Пар	Ранние яровые	Поздние яровые
2014	Север	289	210	291	334	217
	Центр	530	357	408	472	549
	Юг	164	526	598	507	971
2015	Север	304	243	220	296	225
	Центр	498	368	486	436	525
	Юг	111	265	620	626	982
2016	Север	252	220	214	235	207
	Центр	461	302	330	362	397
	Юг	134	384	520	457	927

Для каждого поля, выбранного для исследований, по набору космических снимков за соответствующий год был рассчитан временной ряд вегетационного индекса NDVI. NDVI (Normalized Difference Vegetation Index) – нормализованный разностный вегетационный индекс, значение которого вычисляется по формуле:

$$NDVI = \frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + \rho_{RED}}, \quad (1)$$

где  $\rho_{NIR}, \rho_{RED}$  – значения отраженного (регистрируемого спутником) излучения в ближней инфракрасной и красной зонах спектра, соответственно. NDVI – самый популярный индекс, используемый в методах распознавания с/х культур, а также других методах изучения состояния растительности по космическим снимкам [2, 5, 8 – 12].

Для расчета временных рядов в работе использовались снимки с космического аппарата Terra/MODIS, обработанные до уровня продукта MOD09GQ (250м), представляющего собой оценку отраженного спектрального излучения, как если бы оно было измерено у поверхности земли в отсутствии влияния рассеяния и поглощения в атмосфере, абсорбции, атмосферных газов, аэрозолей и тонких перистых облаков. Продукт MOD09GQ прошел радиометрическую, атмосферную коррекцию, имеет географическую привязку и представляет собой минимальный уровень комбинирования ежедневных данных разрешения 250 м [13]. Каждый снимок использовался совместно с маской облачности, позволяющей исключить неинформативные пиксели из расчетов, поэтому различные наборы временных рядов получаются «с пропусками». Полученный набор временных рядов далее был использован для формирования эталонных/обучающих данных и данных для распознавания для проведения серии экспериментов по сравнению качества распознавания с/х культур метода распознавания на основе АВО с байесовским классификатором.

В связи с делением Самарской области на три агроклиматические зоны и целесообразностью проведения распознавания с/х культур в каждой зоне выбранного года отдельно [10], серия экспериментов по сравнению качества распознавания методом на основе АВО и байесовским классификатором проводилась для каждой зоны отдельно. Для каждой зоны в каждом году были сформированы собственные наборы обучающих/эталонных данных и распознаваемых объектов, каждый из которых состоял из временных рядов пяти классов с/х культур.

### 2.1. Эталонные/обучающие данные

В информационной технологии раннего распознавания [4] было предложено заменить зашумленные временные ряды, используемые в качестве эталонных/обучающих данных на их модели в виде гладких кривых, описывающие только полезный сигнал. Будем называть такие кривые, описывающие неискаженные шумами значения временного ряда, *идеальными*.

В [14, 15] показано, что для описания идеальных кривых наилучшим образом подходит кубический сплайн. Также в [14, 15] приведен способ генерации таких кривых. Генерация выполнялась из предположения, что коэффициенты сплайнов, аппроксимирующих временные ряды, рассчитанные для некоторого набора полей одного вида с/х культур (заданных года и зоны), представляют собой случайную величину с многомерным нормальным законом распределения. Поэтому в данной работе набор реальных зашумленных временных рядов в каждом классе был заменен на набор идеальных сгенерированных кривых. Для каждого года, зоны и класса с/х культур использовались собственные параметры генерации (а именно – ковариационная матрица и математическое ожидание многомерного нормального закона распределения параметров сплайна) и было сгенерировано по 2000 идеальных кривых. Под реальными зашумленными временными рядами (или *реальными данными*) будем понимать временные ряды, построенные по последовательности космических снимков за соответствующий год для полей из таблицы 1.

### 2.2. Распознаваемые объекты

В качестве распознаваемых объектов также использовались сгенерированные временные ряды. Для генерации использовалась математическая модель параметризованного временного ряда, описывающая зависимость от времени зашумленных значений индекса NDVI (далее – модель зашумленного временного ряда). Модель зашумленного временного ряда – это идеальная кривая с наложенным шумом и исключенными точками в результате влияния облачности.

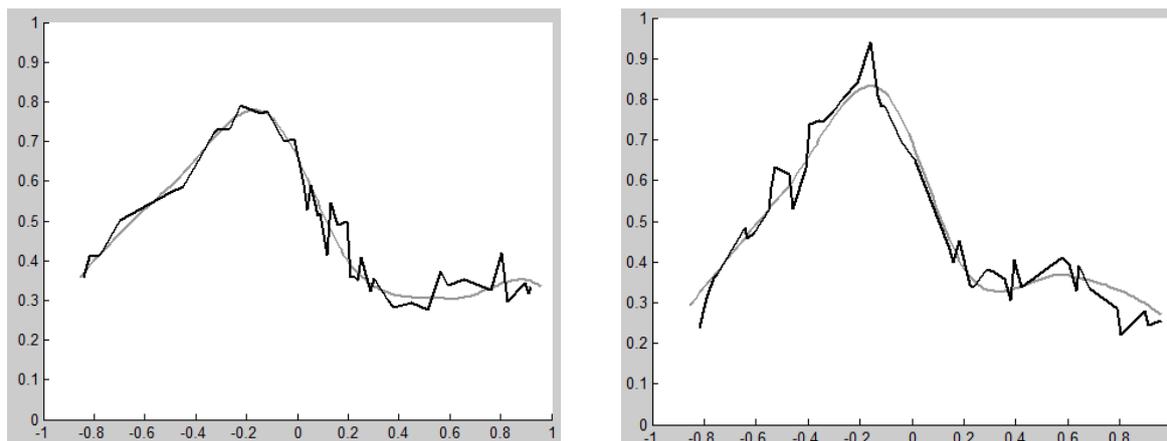
Пусть  $\tilde{y}_k, k = \overline{1, K}$  – значения идеальной кривой с шагом в один день. Генерация зашумленного временного ряда включает два этапа:

- зашумление идеальных значений  $\tilde{y}_k, k = \overline{1, K}$  аддитивным шумом:  $y_k = \tilde{y}_k + v_k$ , где  $v_k$  – некоррелированный шум, имеющий нормальный закон распределения,  $y_k$  – зашумленные значения временного ряда,

- исключение части точек из ряда случайным образом. Среднее количество исключаемых точек соответствует среднему количеству облачных дней.

Для каждого года, зоны и класса с/х культур использовались собственные параметры генерации, и было сгенерировано по 1000 зашумленных кривых.

На рисунке 1 приведены примеры идеальных кривых и соответствующих им зашумленных временных рядов, сгенерированных с использованием рассмотренной модели. По оси абсцисс отложена дата, по оси ординат – значение индекса NDVI. В приведенном примере даты были пересчитаны в диапазон [-1,1].



**Рисунок 1.** Примеры идеальных кривых (серая кривая) и построенных на их основе зашумленных кривых (черная кривая) для класса «Озимые» в южной зоне в 2015 году.

### 3. Методы распознавания

В проведенных экспериментах признаками для распознавания являлись значения временных рядов (число признаков совпадало с количеством дней наблюдения временных рядов). Критерием качества распознавания являлась общая вероятность верной классификации, рассчитываемая по формуле:

$$Q = \frac{m}{M}, \quad (2)$$

где  $m$  – число верно распознанных объектов,  $M$  – общее число объектов для распознавания.

Далее рассматриваются выбранные для сравнения алгоритмы, а также приводятся результаты проведенных экспериментов.

#### 3.1. Метод распознавания на основе вычисления оценок

Класс алгоритмов распознавания, основанных на вычислении оценок, был предложен Журавлевым Ю.И. [16]. Принцип действия АВО состоит в вычислении некоторых оценок сходства, которые характеризуют близость исследуемого (распознаваемого) и эталонного объектов. Для каждого класса задан собственный набор эталонных объектов. На основании оценок сходства исследуемого и эталонных объектов из одного класса формируется единая оценка, характеризующая близость исследуемого объекта к этому классу. Далее сравниваются оценки близости, полученные для всех классов, и принимается окончательное решение о классификации.

Класс алгоритмов распознавания, основанных на вычислении оценок – это не заранее заданный алгоритм, а модель распознающего алгоритма. И в каждом конкретном случае эту модель надо конкретизировать. Подробное описание конкретизации модели АВО для распознавания с использованием временных рядов приведено в [4]. В данной работе приведено сокращенное описание метода.

Метод имеет один параметр  $T$  – пороговое значение близости. Признаками являются значения временного ряда. Система опорных множеств признаков состоит из единственного

множества, включающего в себя все признаки. Функция близости  $\rho(x)$  исследуемого  $x$  и эталонного  $x^*$  объектов рассчитывается по формуле:

$$\rho(x) = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - x_i^*)^2}$$

где  $x_i, x_i^*, i = \overline{1, n}$  – признаки объектов  $x$  и  $x^*$ , соответственно. Функция близости вычисляется только по тем дням  $i$ , в которые у обоих объектов имеются значения временных рядов.

Значение функции близости  $\rho(x)$  вычисляется так:

$$f(\rho(x)) = \begin{cases} 1, & \rho(x) \leq T \\ 0, & \rho(x) > T \end{cases}$$

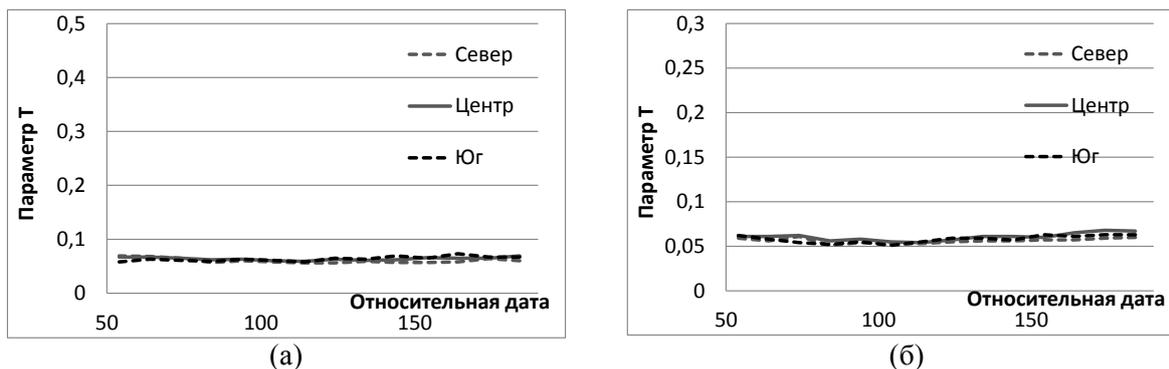
Оценка  $\Gamma(\Omega_i)$  близости объекта  $x$  к некоторому классу  $\Omega_i$  вычисляется по формуле:

$$\Gamma(\Omega_i) = \sum_{x \in \Omega_i} f(\rho(x))$$

Классификация объекта  $x$  будет произведена в класс  $\Omega_k$  в соответствии с решающим правилом:  $k = \arg \max_{l=1, L} \Gamma(\Omega_l)$ .

В данной работе было проведено исследование динамики значений параметра  $T$ , обеспечивающих наилучшее качество распознавания для разной длины временных рядов. В результате проведенных экспериментов с шагом изменения длины временных рядов в 10 дней (в этом пункте и далее), было установлено, что значения параметра  $T$  слабо меняются при изменении длины. Поэтому для конкретной зоны и года предлагается использовать единственное усредненное значение параметра  $T_{cp}$  при распознавании для разной длины временных рядов. Обозначим  $Q(T_{cp})$  качество распознавания, получаемое при использовании усредненного параметра  $T_{cp}$ .

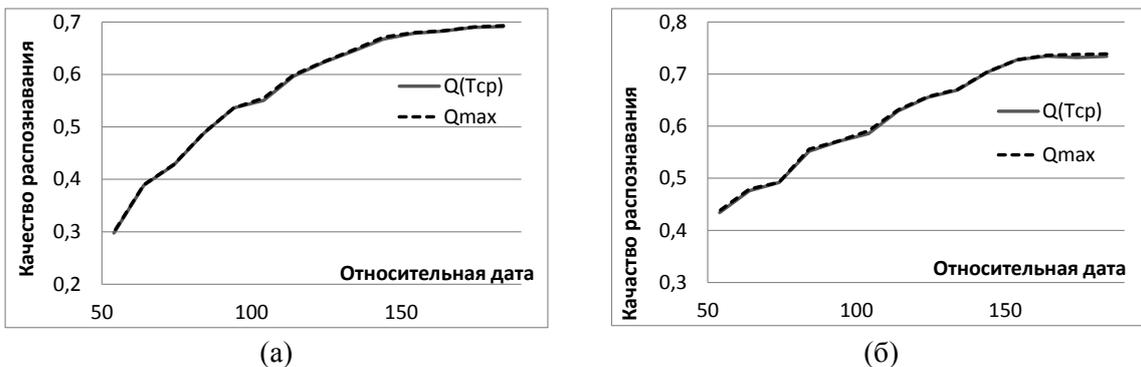
На рисунке 2 приведены графики значений параметра  $T$ , рассчитанные для разной длины временных рядов для северной, центральной и южной зон в 2015 (а) и 2016 (б) году.



**Рисунок 2.** Динамика значений параметра  $T$  для разной длины временных рядов для северной, центральной и южной зон в 2015 (а) и 2016 (б) году.

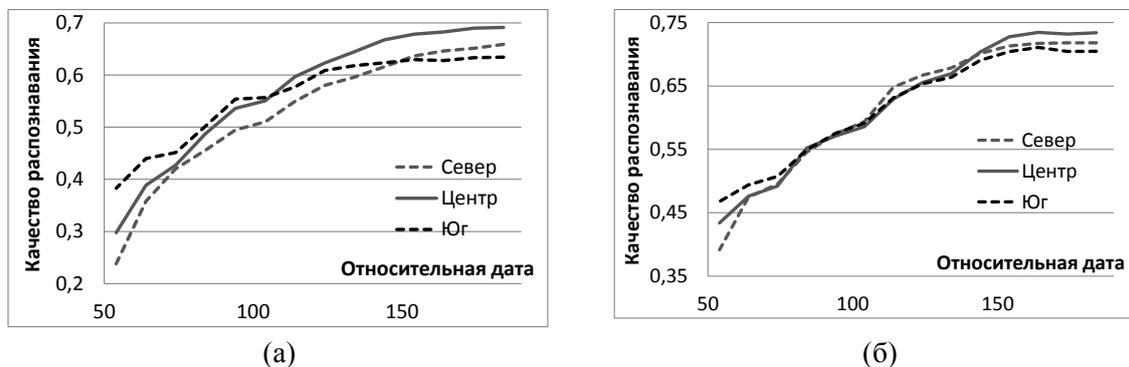
Приведенные на графиках значения параметра  $T$  обеспечивали наилучшее качество классификации (обозначим его  $Q_{max}$ ). На графиках по оси абсцисс отложена относительная дата окончания временных рядов, рассчитываемая от 1 марта, по оси ординат – значение  $T$ . По графикам, приведенным на рисунке 2 видно, что параметр  $T$  слабо меняется в зависимости от изменения длины временных рядов.

На рисунке 3 приведены графики зависимостей качества распознавания  $Q_{\max}$  и  $Q(T_{\text{cp}})$  от относительной даты окончания временных рядов для центральной зоны в 2015 (а) и 2016 (б) году. Графики демонстрируют близость значений  $Q_{\max}$  и  $Q(T_{\text{cp}})$  практически для любой даты окончания временных рядов. В среднем,  $Q(T_{\text{cp}})$  отклоняется от  $Q_{\max}$  не более, чем на 0,5%.



**Рисунок 3.** Сравнение качества распознавания максимального  $Q_{\max}$  и достигаемого при усредненном значении  $T_{\text{cp}}$  для центральной зоны в 2015 (а) и 2016 (б) году.

На рисунке 4 приведены графики зависимости  $Q(T_{\text{cp}})$  для разной длины временных рядов для северной, центральной и южной зон в 2015 (а) и 2016 (б) году. По графикам видно, что качество распознавания значительно меняется в зависимости от года и зоны.



**Рисунок 4.** Качество распознавания  $Q(T_{\text{cp}})$  для разной длины временных рядов для северной, центральной и южной зон в 2015 (а) и 2016 (б) году.

### 3.2. Байесовский классификатор

Для распознавания применялся байесовский классификатор для нормально распределенных векторов признаков [17]. Будем считать, что наблюдаемые вектора признаков  $\mathbf{x} = (x_1, \dots, x_n)^T$  в каждом из классов  $\Omega_l, l = \overline{1, 5}$  имеют многомерный нормальный закон распределения с плотностью вероятностей такого вида:

$$f(\mathbf{x} / \Omega_l) = \frac{1}{(2\pi)^{n/2} \sqrt{|B_l|}} \exp\left(-\frac{1}{2}(\mathbf{x} - \mathbf{M}_l)^T B_l^{-1} (\mathbf{x} - \mathbf{M}_l)\right), l = \overline{1, L} \tag{3}$$

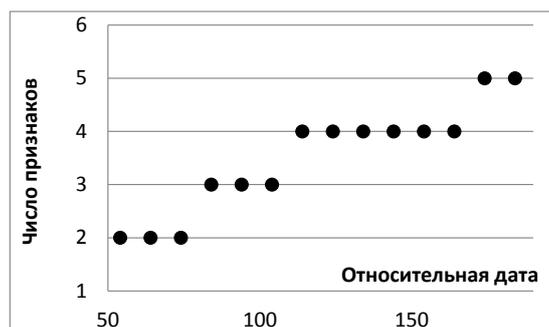
где  $B_l, \mathbf{M}_l$  – ковариационная матрица и математическое ожидание вектора признаков из класса  $\Omega_l$ , соответственно. Для указанного классификатора дискриминантные функции  $d_l(\mathbf{x})$  вектора признаков  $\mathbf{x}$  имеют следующий вид:

$$d_l(\mathbf{x}) = \ln P(\Omega_l) - \ln \sqrt{|B_l|} - \frac{1}{2}(\mathbf{x} - \mathbf{M}_l)^T B_l^{-1}(\mathbf{x} - \mathbf{M}_l), l = \overline{1, L} \quad (4)$$

где  $P(\Omega_l)$  – априорная вероятность появления объектов класса  $\Omega_l$ . Решение о классификации вектора признаков  $\mathbf{x}$  принимается в тот класс, которому соответствует наибольшее значение дискриминантной функции.

Предварительный анализ значений признаков объектов (эталонных/обучающих и распознаваемых) показал их линейную зависимость. Для снижения размерности пространства признаков применялся метод главных компонент. Число компонент выбиралось при условии, что доля объясняемой дисперсии, соответствующая выбранным компонентам, составляет 0,99. Для разной длины временных рядов варьировалось число выбранных компонент, а, соответственно, и число используемых для распознавания признаков. Для всех эталонных/обучающих и распознаваемых объектов (заданной зоны, года и даты окончания временных рядов) вне зависимости от класса выполнялось снижение пространства признаков одним и тем же оператором. В полученном новом подпространстве признаков меньшей размерности выполнялось распознавание объектов по эталонным/обучающим данным с использованием байесовского классификатора для нормально распределенных векторов признаков.

На рисунке 5 приведена зависимость числа признаков, использованных для распознавания, от относительной даты окончания временных рядов в 2016 году (число признаков не менялось от зоны к зоне).

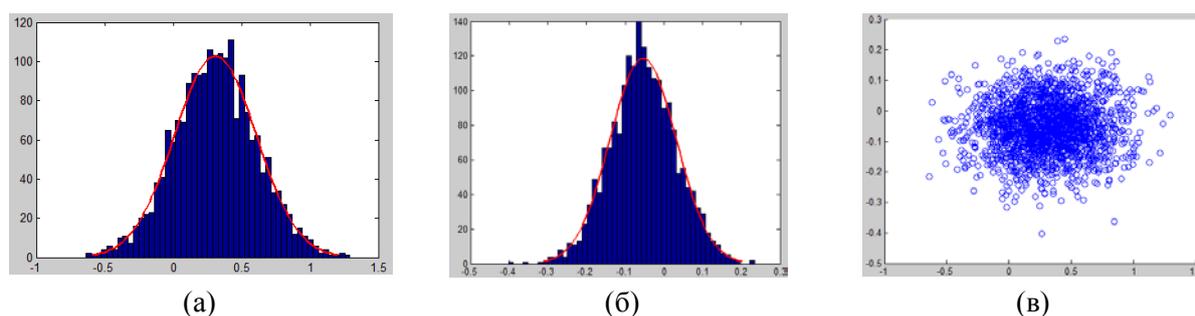


**Рисунок 5.** Число признаков для разной длины временных рядов в 2016 году.

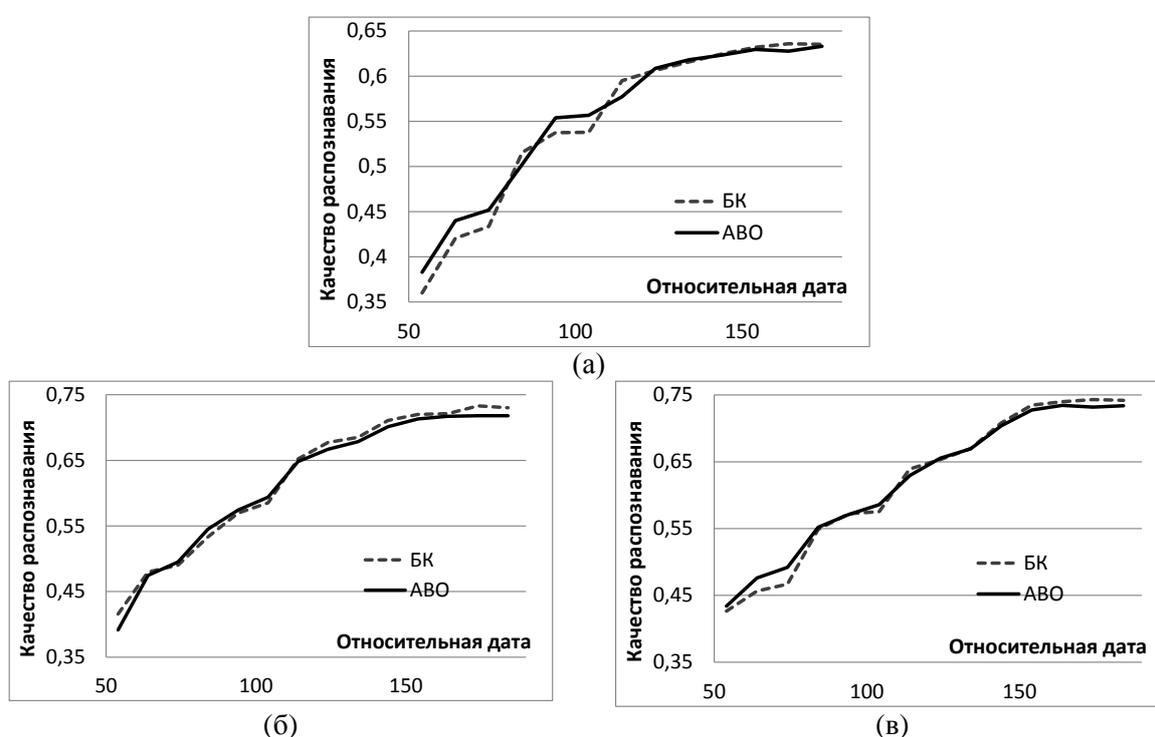
На рисунке 6 приведены гистограммы значений первого (а) и второго (б) признаков и диаграмма их рассеяния (в) для объектов из класса «Многолетние травы и неиспользуемые земли» из южной зоны 2015 года с относительной датой окончания временных рядов равной 54 в новом сокращенном пространстве признаков. Приведенные гистограммы и диаграмма рассеяния демонстрируют близость распределения признаков к нормальному закону.

### 3.3. Сравнение методов распознавания

Проведенная серия экспериментов показала, что качество распознавания, получаемое с использованием метода на основе вычисления оценок  $Q_{ABO}$  близко в качеству байесовского классификатора  $Q_{БК}$ . На рисунке 7 приведены графики зависимостей качества распознавания  $Q_{БК}$  и  $Q_{ABO}$  от относительной даты окончания временных рядов для южной зоны 2015 года (а), северной (б) и центральной (в) зон 2016 года. Среднее отклонение  $Q_{БК}$  от  $Q_{ABO}$  составляет 1,6%. В большинстве случаев в первой половине посевного сезона качество распознавания с использованием метода на основе АВО  $Q_{ABO}$  выше качества, получаемого байесовским классификатором  $Q_{БК}$ , что позволяет сделать вывод о целесообразности использования метода на основе вычисления оценок для раннего распознавания видов с/х культур.



**Рисунок 6.** Гистограммы значений первого (б) и второго (в) признаков и диаграмма их рассеяния (а) в сокращенном пространстве признаков (класс «многолетние травы и неиспользуемые земли», южная зона, 2015 год).



**Рисунок 7.** Качество распознавания байесовским классификатором (БК) и методом на основе вычисления оценок (АВО) для разной длины временных рядов для южной зоны 2015 года (а), северной (б) и центральной (в) зон 2016 года.

#### 4. Заключение

В работе рассматривался метод распознавания на основе алгоритма вычисления оценок, применяемый в информационной технологии раннего распознавания видов с/х культур, и проводилось его сравнение с байесовским классификатором для нормально распределенных векторов признаков. Было установлено, что качество распознавания обоих классификаторов близко, однако в первой половине сезона метод на основе АВО дает (в большинстве случаев) лучшее качество распознавания при значительно лучшей адаптации и меньших требованиях к исходным данным, что говорит о целесообразности его применения в технологии раннего распознавания видов с/х культур.

#### 5. Благодарности

Работа выполнена в рамках госзадания ФАНО России, проект №0026-2018-0106, а также при поддержке РФФИ: грант № 16-29-09494 офи\_м «Методы компьютерной обработки

мультиспектральных данных дистанционного зондирования Земли для определения ареалов растений в специальных криминалистических экспертизах», грант № 18-07-00748 А «Методы комплексирования и калибровки разнородных источников данных ДЗЗ в задачах тематической классификации объектов земной поверхности».

## 6. Литература

- [1] Abade, N.A. Comparative Analysis of MODIS Time-Series Classification Using Support Vector Machines and Methods Based upon Distance and Similarity Measures in the Brazilian Cerrado-Caatinga Boundary / N.A. Abade, O.A. Júnior, R.F. Guimarães, S.N. Oliveira // *Remote Sens.* – 2015. – Vol. 7(9). – P. 12160-12191. DOI: 10.3390/rs70912160.
- [2] Masialei, I. Assessment of time-series MODIS data for cropland mapping in the U.S. Central Great Plains: PhD Dissertation, Department of Geography / I. Masialei // Lawrence: University of Kansas, 2008. – 180 p.
- [3] Schmedtmann, J. Reliable Crop Identification with Satellite Imagery in the Context of Common Agriculture Policy Subsidy Control / J. Schmedtmann, M.L. Campagnolo // *Remote Sensing of Environment.* – 2015. – Vol. 7(7). – P. 9325-9346. DOI: 10.3390/rs70709325.
- [4] Воробьева, Н.С. Информационная технология раннего распознавания видов сельскохозяйственных культур по космическим снимкам / Н.С. Воробьева, В.В. Сергеев, А.В. Чернов // *Компьютерная оптика.* – 2016. – Т. 40, № 6. – С. 929-938. DOI: 10.18287/2412-6179-2016-40-6-929-938.
- [5] Victoria, D.C. Cropland area estimates using Modis NDVI time series in the state of Mato Grosso / D.C. Victoria, A.R. Paz, A.C. Coutinho, J.C. Brown // *Brazil. Pesq. agropec. bras.* – 2012. – Vol. 47(9). – P. 1270–1278. DOI: 10.1590/S0100-204X2012000900012.
- [6] Плотников, Д.Е. Экспериментальная оценка распознаваемости агрокультур по данным сезонных спутниковых измерений спектральной яркости / Д.Е. Плотников, С.А. Барталев, В.О. Жарко, В.В. Михайлов, О.И. Просянникова // *Современные проблемы дистанционного зондирования Земли из космоса.* – 2011. – Т. 8, № 1. – С. 199-208.
- [7] Васин, А.В. Формирование высокопродуктивных поливидовых агрофитоценозов кормовых культур в Среднем Поволжье: дис. ... д-ра с.-х. наук: 06.01.09 / А.В. Васин // Кинель: Самарская гос. с.-х. акад, 2006. – 513 с.
- [8] Терехин, Э.А. Сезонная динамика NDVI многолетних трав и ее использование для типизации их посевов на территории Белгородской области / Э.А. Терехин // *Современные проблемы дистанционного зондирования Земли из космоса.* – 2015. – Т. 12, № 1. – С. 9-17.
- [9] Калинин, Н.А. Технология комплексной оценки фитомассы сельскохозяйственных культур по данным дистанционного зондирования Земли / Н.А. Калинин, С.В. Пьянков, Е.М. Связов, А.А. Смирнова // *Вестник Удмуртского университета. Серия «Биология. Науки о Земле».* – 2010. – Т. 4. – С. 3-10.
- [10] Wardlow, B.D. Analysis of time-series MODIS 250 m vegetation index data for crop classification in the U.S. Central Great Plains / B.D. Wardlow, S.L. Egbert, J.H. Kastens // *Remote Sensing of Environment.* – 2007. – Vol. 108(3). – P. 290-310.
- [11] Wardlow, B.D. Large-area crop mapping using time-series MODIS 250 m NDVI data: An assessment for the U.S. Central Great Plains / B.D. Wardlow, S.L. Egbert // *Remote sensing of environment.* – 2008. – Vol. 112(3). – P. 1096-1116. DOI: 10.1016/j.rse.2007.07.019.
- [12] Lui, M.W. Crop Type Classification by Simultaneous Use of Satellite Images of Different Resolutions / M.W. Liu, M. Ozdogan, X. Zhu // *IEEE Transactions on geoscience and remote sensing.* – 2014. – Vol. 52(6). – P.3637-3649.
- [13] Justice, C.O. An overview of MODIS Land data processing and product status / C.O. Justice, J.R.G. Townshend, E.F. Vermote // *Remote Sensing of Environment* – 2002. – Vol. 83(1). – P. 3-15.
- [14] Воробьева, Н.С. Аппроксимация временных рядов NDVI в задаче раннего распознавания видов сельскохозяйственных культур по космическим снимкам / Н.С. Воробьева, А.В. Чернов // *Сборник трудов III Международной конференции и молодежной школы*

- «Информационные технологии и нанотехнологии (ИТНТ-2017)», Самара, 2017. – С. 390-399.
- [15] Vorobiova, N. Curve fitting of MODIS NDVI time series in the task of early crops identification by satellite images / N. Vorobiova, A. Chernov // *Procedia Engineering*. – 2017. – Vol. 201. – P. 184-195. DOI: 10.1016/j.proeng.2017.09.596.
- [16] Журавлев, Ю.И. Алгоритмы вычисления оценок и их применение / Ю.И. Журавлев, М.М. Камиллов, Ш.Е. Туляганов. – Ташкент: Фан, 1974. – 114 с.
- [17] Дуда Р. Распознавание образов и анализ сцен / Р. Дуда, П. Харт. – Москва: “Мир”, 1976. – 511 с.

## Comparing Bayesian classifier and a method based on algorithm for calculating estimates for crop identification by time-series Terra/MODIS 250 m

N.S. Vorobiova<sup>1</sup>, A.V. Chernov<sup>1,2</sup>

<sup>1</sup>Samara National Research University, Moskovskoe Shosse 34A, Samara, Russia, 443086

<sup>2</sup>Image Processing Systems Institute of RAS - Branch of the FSRC "Crystallography and Photonics" RAS, Molodogvardejskaya street 151, Samara, Russia, 443001

**Abstract.** Two methods for crops identification by satellite images are studied in this research: the Bayesian classifier and a method based on the algorithm for calculating estimates (ACE). Time-series values calculated by a set of low-resolution Terra/MODIS 250m imagery are the features for classification. The main advantage of the method based on the algorithm for calculating estimates is the use of time series even with missing values. Whereas the Bayesian classifier requires a preliminary procedure for reconstructing missing values of time series. Comparison of two methods is carried out during the entire growing season for the different length of time series.

**Keywords:** time-series, Terra/MODIS, crops identification, Bayesian classifier, the algorithm for calculating estimates.