

# Трехмерная реконструкция плоских граней прозрачных минералов по набору изображений с микроскопа

Виктор Гаганов\*, Алексей Игнатенко\*\*

\* Институт прикладной математики им. М.В. Келдыша РАН

\*\* ВМиК МГУ им. М.В. Ломоносова

[vgaganov@graphics.cs.msu.ru](mailto:vgaganov@graphics.cs.msu.ru), [ignatenko@graphics.cs.msu.ru](mailto:ignatenko@graphics.cs.msu.ru)

## Аннотация

В данной работе рассматривается задача реконструкции плоских граней прозрачных минералов по набору изображений, полученных с помощью оптического микроскопа. Особенностью таких изображений является то, что на них четко виден только небольшой слой наблюдаемой сцены, находящийся в пределах глубины резкости. Это позволяет для текстурированных областей сцены найти их примерное положение в пространстве. В работе предлагается метод, использующий машинное обучение, который позволяет для каждого участка сцены определить, можно ли точно оценить его положение в пространстве с помощью фокусировки. Также в статье предлагается метод на основе теории статистической проверки гипотез, позволяющий установить, можно ли по набору точек в трехмерном пространстве надежно построить плоскость. В работе представлены эксперименты, подтверждающие высокую точность построения плоскостей граней прозрачных минералов с помощью предлагаемого метода.

**Ключевые слова:** 3D реконструкция, реконструкция по фокусу, подгонка плоскости, робастная оценка, машинное обучение.

## 1. ВВЕДЕНИЕ

В статье рассматривается задача автоматической реконструкции плоских граней по фотографиям, возникающая в процессе оцифровки формы трехмерного объекта. Мы рассматриваем эту задачу в применении к общей задаче реконструкции и анализа формы образцов прозрачных минералов. Необходимость построения компьютерной модели минерала (см. рис. 1) вместе с внутренними включениями и неоднородностями возникает на производстве (контроль качества продукции), в науке (анализ материалов) и т.п. На данный момент для построения моделей включений (дефектов) и неоднородностей внутри минерала широко используется следующий метод: оператор с помощью микроскопа через специально отшлифованные «окна» (крупные плоские грани) на поверхности камня просматривает его внутренность и задает положения включений тем или иным способом. Из-за высокого коэффициента преломления оптической среды минерала, методы построения включения оказываются крайне чувствительны к точности построенной плоскости «окна» для поиска дефектов. В работе предлагается метод высокоточного построения плоскости для граней минерала, работающий на основе реконструкции по фокусу с учетом особенностей прозрачных оптических сред.

Более формально задачу можно поставить следующим образом. Пусть у нас имеется микроскоп, под который

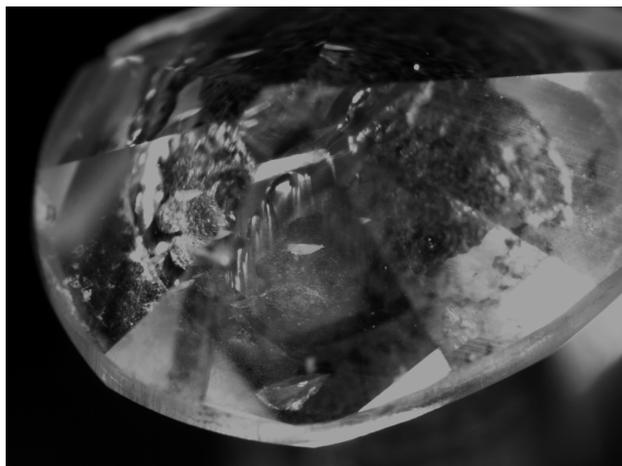


Рис. 1. Изображение прозрачного минерала с множеством плоских граней

установлен образец, для которого нужно найти положение и ориентацию наиболее крупных граней. Предполагается, что имеется возможность программно управлять фокусировкой микроскопа. Перед определением положения и ориентации конкретной грани, пользователь поворачивает образец под микроскопом таким образом, чтобы грань была в области видимости камеры. Также предполагается, что пользователь вручную приблизительно сфокусировался на грани. После этого требуется вычислить положение и ориентацию грани, и единственные данные, которые можно использовать, это фотографии образца, с фиксированной ориентацией, полученные с разными положениями по фокусу.

Предлагаемый в данной работе метод базируется на идее алгоритмов трехмерной реконструкции семейства *shape from focus* [1] (далее SFF). Как известно, при фотосъемке объектов только часть реальной сцены, которая лежит в пределах глубины резкости, оказывается на фотографии четкой, а та часть сцены, которая лежит вне глубины резкости, оказывается размыта (см. рис. 2). Тем самым, если в какой-то области изображения мы видим резкие детали, мы можем с точностью до глубины резкости сказать, на каком расстоянии от камеры лежит эта область, если известно фокусное расстояние. Все известные нам методы SFF [1,2,3] работают примерно следующим образом (рис. 3). Они снимают набор фотографий сцены с разным положением глубины резкости, причем обычно это делается с постоянным шагом. После этого полученные изображения разбиваются регулярной сеткой на набор областей и по всем областям, для всех фотографий считается значение некоторой меры резкости [1]. При этом так как фотографии отличаются друг от друга

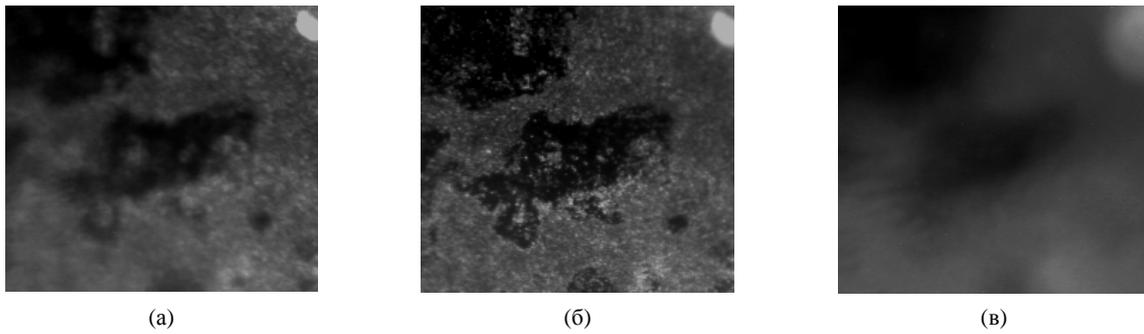


Рис. 2 На рисунке (а) поверхность объекта находится немного дальше, чем фокусное расстояние. На рисунке (б) поверхность объекта находится приблизительно в глубине резкости. На рисунке (в) поверхность объекта находится значительно ближе, чем фокусное расстояние

только положением глубины резкости, области  $(i, j)$  на одном изображении соответствует область  $(i, j)$  на любом другом изображении из набора. Далее, для каждой области ищется фотография, на которой мера резкости максимальна, и фокусное расстояние для этой фотографии принимается за оценку глубины по этой области. После этого, по данным, которые выдают алгоритмы SFF, можно оценить положение плоскости грани с помощью методов математической статистики.

К сожалению, при отсутствии на поверхности сканируемого объекта видимой текстуры методы SFF дают ошибочную оценку глубины, так как даже когда поверхность находится в резкости на фотографии, из-за отсутствия текстуры на поверхности объекта, на изображении ничего резкого нет. В работе [3] для решения этой проблемы предлагается отбрасывать те области, для которых на всех фотографиях максимальное среднеквадратичное отклонение цвета меньше заданного порога. В нашей задаче сканируемые объекты прозрачны, на них обычно очень много областей без текстуры. Единственные детали поверхности плоских граней

образца это дефекты полировки и осевшая на гранях пыль. На таких данных методы SFF, которые не отбрасывают области без текстуры, дают вплоть до 95% выбросов. В связи с этим мы уделили особое внимание проблеме обнаружения областей без текстуры и предлагаем для их обработки новый подход на основе методов машинного обучения. Эта проблема рассматривается в разделе 2.

Если полировка плоской грани близка к идеальной и на ее поверхности отсутствует пыль и следы грязи, то невозможно надежно построить плоскость грани по изображениям и такие ситуации необходимо обрабатывать. Только с помощью локальных методов, которые отбрасывают области без текстуры, сделать это нельзя, в связи с тем, что эти методы неизбежно будут допускать ошибки. Поэтому в данной работе предлагается метод на основе теории статистической проверки гипотез [4], который по полученной оценке плоскости определяет, насколько вероятно то, что построенная оценка является исключительно результатом случайных ошибок в измерениях. Данный метод будет описан в разделе 3.

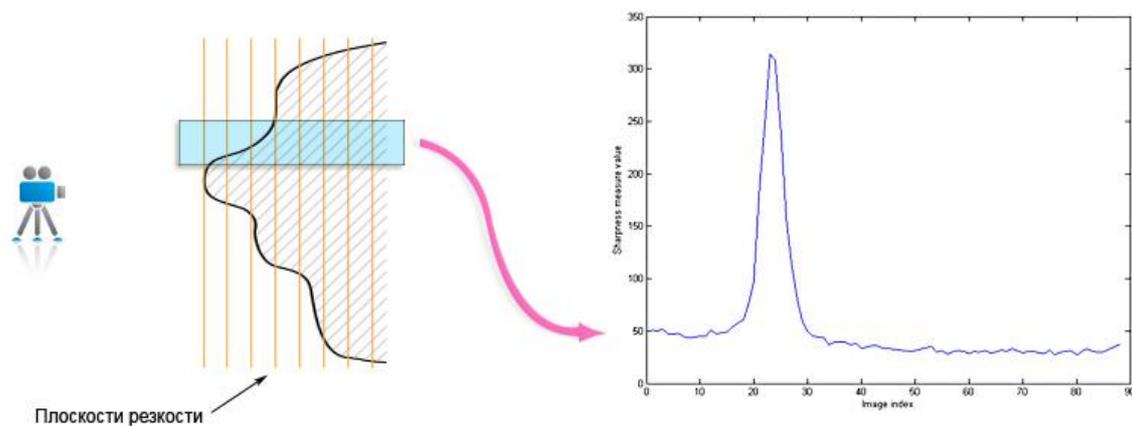


Рис. 3 Схематичная иллюстрация принципа работы алгоритмов семейства shape from focus. На графике справа горизонтальная ось соответствует номеру картинке, а вертикальная — значению меры резкости

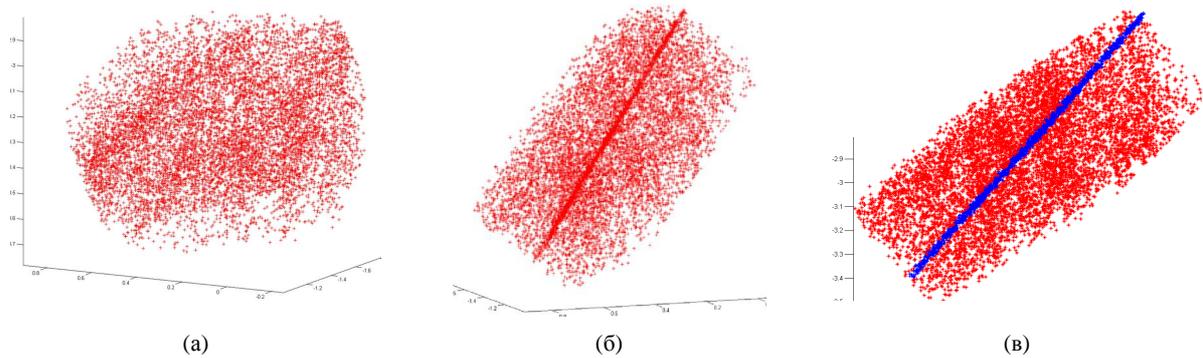


Рис. 4. На рисунке изображены примеры замеров по глубине, получаемые методом SFF для плоской грани. На рисунке (а) изображено облако точек с произвольного ракурса. На рисунке (б) облако точек повернуто таким образом, чтобы плоскость грани была видна сбоку. На рисунке (в) выделены точки, которые принадлежат плоскости

## 2. ОБРАБОТКА НЕНАДЕЖНЫХ ЗАМЕРОВ

### 2.1 Получение замеров по глубине

Пусть пользователь позиционировал объект под микроскопом таким образом, что грань, для которой надо оценить положение и ориентацию находится в кадре и положение фокуса микроскопа расположено недалеко от грани. Тогда изображения, которые будут использованы для оценки положения грани, снимаются в некоторой окрестности от текущего положения микроскопа с постоянным шагом по фокусу. Перемещение глубины резкости микроскопа в нашем приложении достигается за счет движения оптики микроскопа и камеры на механической подвижке. Величину шага между последующими изображениями следует выбирать не больше, чем глубина резкости микроскопа, иначе существует возможность того, что некоторые детали текстуры поверхности ни на одном изображении в наборе не будут в резкости.

Будем обозначать снятые таким образом изображения  $I_i, i = \overline{1, n}$ , и будем считать, что изображения представлены в градациях серого. Все изображения считаются зарегистрированными относительно глобальной системы координат микроскопа и для каждого изображения считается известной и одинаковой глубина резкости  $d$ . Обозначим как  $o = o(x, y, i)$  точку в трехмерном пространстве, которая является пересечением луча, выпущенного из точки  $(x, y)$  на  $i$ -том изображении в направлении обзора и области резкости этого изображения. Все параметры, необходимые для вычисления  $o$  по  $(x, y, i)$ , считаются известными для каждого изображения.

По аналогии с [2] каждое входное изображение  $I_i$  разбивается регулярной сеткой на квадратные окна, с центрами в  $(\hat{x}_p, \hat{y}_k)$  где  $p = \overline{1, c_1}$ , а  $k = \overline{1, c_2}$ . В каждом пикселе изображений из  $I$  вычисляется значение меры резкости и по каждому изображению формируется карта резкости  $S_i = F(I_i)$ . В качестве меры резкости мы использовали оператор Лапласа, как одну из лучших мер резкости в соответствии со сравнением в [5]:

$$L(I) = \frac{\partial^2 I}{\partial x^2} + \frac{\partial^2 I}{\partial y^2}$$

После этого значения меры резкости суммируются по каждому из окон регулярной сетки, описанной ранее. Сумму по окну  $(p, k)$  для изображения  $i$  будем обозначать как  $s_i(p, k)$ . Из сумм мер резкости по соответствующим окнам на разных изображениях образуется так называемые профили меры резкости  $\hat{s}(p, k) = [s_1(p, k), \dots, s_n(p, k)]$ . Тогда для каждого окна  $(p, k)$  в качестве оценки положения участка сцены, который на него проецируется, выбирается  $u(p, k) = o(x_p, y_k, \arg \max(\hat{s}_i(p, k)))$ .

### 2.2 Оценка надежности замеров

На рис 4 изображен пример замеров положения точек плоской грани образца полученных с помощью описанной схемы. В данных можно заметить присутствие плоскостной структуры, но также в них присутствует большое количество выбросов, т.е. абсолютно неверных замеров. Зачастую количество выбросов может достигать 90-95%, что делает построение плоскости по таким данным традиционными методами математической статистики, такими как метод наименьших квадратов, невозможным. Для построения плоскости по таким данным можно использовать только робастные методы математической статистики.

Из существующих робастных методов, с количеством выбросов больше 50% в состоянии справиться только схемы на базе случайных выборок (RANSAC) [6] и методы на основе голосования [7], примером которых является преобразование Хафа. Недостатком методов семейства RANSAC является их рандомизированность. Результаты работы метода на одних и тех же данных могут отличаться от запуска к запуску и при каждом запуске с некоторой вероятностью метод может не найти правильное решение. Схемы на основе голосования являются детерминированными, но они дискретизируют пространство решений и осуществляют в нем перебор, что не эффективно при размерности пространства поиска более двух и для больших объемов входных данных.

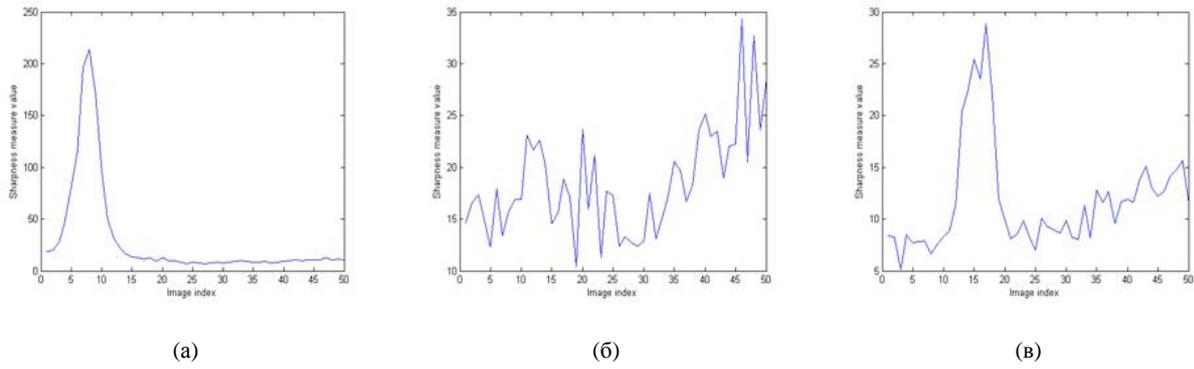


Рис 5. На рисунке изображены примеры профилей меры резкости. На рисунке (а) изображен надежный профиль. На рисунке (б) находится пример ненадежного профиля с большим количеством локальных максимумов, найти по которому наиболее резкое положение надежно не представляется возможным. На (в) изображен еще один пример профиля, по которому можно надежно определить положение

Так как подавляющее большинство выбросов возникает из-за отсутствия текстуры на поверхности объекта в рассматриваемой области, можно отбросить существенную часть выбросов путем обнаружения таких областей. В отличие от [3] мы предлагаем схему для определения надежности оценки глубины по окну на основе формы профиля меры резкости. На рис. 5 приведены примеры профилей меры резкости для различных областей. Понятно, что профиль, который соответствует достаточно текстурной области, а следовательно надежной области, имеет один главный пик и возможно несколько существенно более слабых пиков (рис. 5(а) и (в)), в то время как профиль ненадежной области имеет более случайную структуру и несколько сильных пиков, из которых затруднительно выбрать один главный (рис. 5(б)). В связи с тем, что сформулировать четкое правило, которое по профилю меры резкости решает надежный он или не надежный, в явном виде затруднительно, предлагается для этой цели использовать методы машинного обучения.

При составлении тренировочной базы для обучения мы использовали порядка 20 различных наборов фотографий граней прозрачных образцов. В каждом наборе было от 40 до 100 фотографий. По каждому набору строилось множество замеров глубины, по схеме, описанной в разделе 2.1. После чего, по множеству замеров оценивалось положение плоскости с помощью метода RANSAC. При этом вручную проверялось, насколько точно построилась плоскость для того, чтобы избежать добавления в базу неверных прецедентов из-за рандомизированности RANSAC.

В качестве классификатора мы использовали Gentle AdaBoost [8], с порогом в роли базового классификатора. Из-за того, что количество ненадежных замеров на наших данных существенно превышает количество надежных, количество примеров разных классов в тренировочной базе существенно отличалось. Несбалансированность классов негативно сказывается на качестве классификации методом Gentle AdaBoost и для решения этой проблемы мы использовали метод random undersampling [9]. В качестве признаков для классификации, наряду с максимальным среднеквадратичным отклонением цвета по окрестности [3], мы использовали различные характеристики поведения одномерного сигнала профиля меры резкости  $\hat{s}$ , приведенные в таблице 1. Для перечисления признаков, которые мы использовали,

обозначим как  $\hat{i}^{\max} = \{i_1^{\max}, \dots, i_w^{\max}\}$  индексы локальных минимумов сигнала, упорядоченных от самого сильного к самому слабому.

Номер	Формула
1	$length(\hat{i}^{\max})$
2	$length(\hat{i}^{\max}) / n$
3	$\hat{s}(i_1^{\max}) / \hat{s}(i_2^{\max})$
4	$ i_1^{\max} - i_2^{\max} $
5	$ i_1^{\max} - i_2^{\max}  / n$
6	$\hat{s}(i_1^{\max}) / \max(\hat{s})$
7	$ \arg \max(\hat{s}) - i_1^{\max} $
8	$ \arg \max(\hat{s}) - i_1^{\max}  / n$

Таблица 1. Список признаков, использованных для классификации профилей меры резкости на надежные и ненадежные

Для того, чтобы снизить влияние шума в профиле меры резкости на признаки, каждый из перечисленных признаков вычислялся на нескольких уровнях гауссовского размытия сигнала. То есть, если обозначить признаки, перечисленные в таблице 1 как  $f = f(\hat{s})$ , то итоговый вектор признаков сигнала получается как  $F = [f(\hat{s} * G(d_1)), \dots, f(\hat{s} * G(d_v))]$ , где  $*$  обозначает свертку, а  $G(\cdot)$  обозначает гауссовское ядро свертки.

Для итогового классификатора мы подобрали порог классификации таким образом, чтобы ошибка второго рода (принять ненадежный замер за надежный) на контрольной выборке равнялась 2%. На рис. 6 приведен пример фильтрации замеров с помощью описанного классификатора. Более подробную информацию о качестве работы классификатора можно найти в разделе 4.

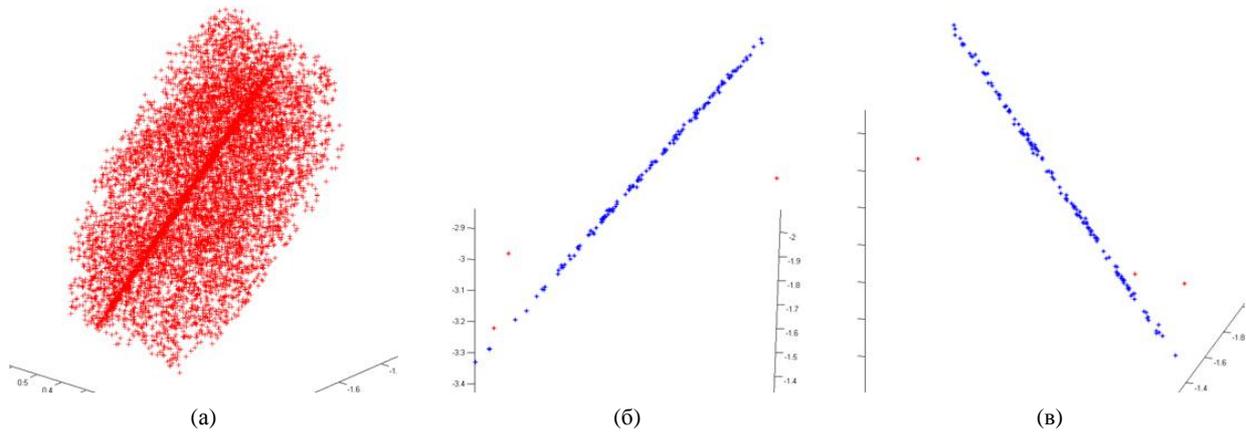


Рис. 6 Иллюстрирует работу алгоритма отсева ненадежных замеров. На рисунке (а) изображены изначальные неотфильтрованные замеры. На рисунках (б) и (в) изображены замеры после фильтрации. Ракурс на этих рисунках выбран так, чтобы плоскость была видна сбоку

### 3. ОЦЕНКА ПОЛОЖЕНИЯ ПЛОСКОСТИ

#### 3.1 Вычисление положения и точности оценки

После отброса ложных замеров методом, описанным в прошлом разделе, количество выбросов во входных данных существенно падает. Стоит заметить, что полностью устранить выбросы только этим методом не представляется возможным, так как построенный классификатор неизбежно будет допускать ошибки. Поэтому для оценки положения плоскости по отфильтрованным данным по-прежнему необходимо использовать методы робастной статистики. Из-за того, что на наших входных данных количество выбросов обычно очень велико, после отброса ненадежных замеров размерность входных данных существенно падает. На наших данных после фильтрации обычно остается не более 100-200 точек, поэтому для устойчивой оценки плоскости по этим данным мы использовали адаптивное преобразование Хафа [7]. После оценки плоскости с помощью преобразования Хафа, все точки, которые лежат от полученной плоскости на

расстоянии большем, чем половина глубины резкости  $\frac{d}{2}$ , принимаются за выбросы и отфильтровываются.

Преобразование Хафа не позволяет оценить точность построения плоскости, и для получения оценки точности построения мы использовали метод [10]. После отброса всех оставшихся выбросов с помощью преобразования Хафа, положение плоскости повторно оценивается по всем оставшимся точкам методом наименьших квадратов и вычисляется матрица ковариации параметров плоскости как в [10], с использованием стандартного закона распространения ошибок. Предполагается, что ошибка в каждой конкретной, оставшейся после отсева выбросов, точке, имеет нормальное

распределение с дисперсией равной  $(\frac{d}{6})^2$  и нулевым математическим ожиданием. В случае, если оценка точности построения превышает некоторый порог (в нашем случае был установлен порог в пять градусов на максимальную угловую ошибку), то полученная оценка плоскости считается ненадежной.

#### 3.2 Оценка надежности полученной плоскости

Надо заметить, что с помощью метода описанного в разделе 3.1 можно построить наилучшую плоскость по абсолютно любому набору входных данных. Даже если данные полностью случайны, и реально не представляют собой плоскость, предложенный метод успешно проведет через них лучшую плоскость и вычислит оценку точности ее построения.

В нашем приложении возможна ситуация, когда грань образца абсолютно прозрачна и не содержит каких-либо видимых деталей. Тогда все точки, которые пройдут фильтрацию, описанную в разделе 2.2, будут исключительно результатами ошибки классификации, и построенная по ним плоскость не будет иметь ничего общего с реальной плоскостью грани образца. Именно поэтому для обнаружения таких ситуаций мы предлагаем использовать схему, основанную на теории статистической проверки гипотез.

Пусть у нас есть набор точек  $P = \{p_i, i = 1, m\}$  в трехмерном пространстве. Будем считать, что все точки из этого набора представляют собой случайные ошибки измерения т.е. что эти точки являются выбросами. Традиционно для моделирования поведения выбросов используется равномерное распределение [11], таким образом  $p_i \sim U(\Omega)$ , где  $\Omega$  это область пространства, в которой расположены точки  $P$ . В нашем случае в качестве  $\Omega$  разумно взять прямоугольник, ограничивающий все точки из  $P$ . Теперь зафиксируем в пространстве плоскость  $l$ , которая проходит через область  $\Omega$  и обозначим через  $\Omega_0$  множество точек  $\Omega$ , которые лежат от зафиксированной плоскости на расстоянии не большем некоторого заданного порога. Т.е.  $\Omega_0 = \{p \mid p \in \Omega, dist(p, l) < t\}$ , где  $t$  - это величина порога. Тогда понятно, что каждая конкретная точка из  $P$  принадлежит области  $\Omega_0$  с вероятностью

$$\Pr(p_i \in \Omega_0) = \frac{|\Omega_0|}{|\Omega|}$$
 и таким образом количество выбросов, попавших в плоскость, подчиняется

биномиальному закону  $c \sim B\left(\frac{|\Omega_0|}{|\Omega|}, m\right)$ . Тогда если

использовать в качестве основной гипотезы  $H_0$  тот факт, что точки из  $P$  распределены равномерно, а в качестве критической статистики использовать  $c$ , то можно построить тест, проверяющий надежность плоскости, следующим образом. Найдем количество точек  $c_0$  такое, что вероятность того, что  $c_0$  точек или более принадлежат зафиксированной плоскости при условии  $H_0$  равно  $\alpha$  и положим  $\alpha$  достаточно маленьким, например равным 0.01. Тогда если количество точек, которые попали в плоскость, превосходит  $c_0$  то можно утверждать, что с большой вероятностью гипотеза  $H_0$  неверна и наблюдаемые точки имеют неравномерное распределение.

Эту идею мы применяем для оценки надежности плоскости. После построения итоговой оценки плоскости мы вычисляем количество точек  $\hat{c}$  из изначального неотфильтрованного набора, которые лежат на расстоянии не большем чем половина глубины резкости  $\frac{d}{2}$  от этой плоскости, и сравниваем это количество точек с  $c_0$ , которое посчитано описанным выше методом. Если  $\hat{c} > c_0$  то построенная плоскость считается надежной.

#### 4. ЭКСПЕРИМЕНТЫ

Для тестирования предложенные методы были реализованы в среде MATLAB и было поставлено три эксперимента. Для экспериментов мы использовали микроскоп Leica Z6 APOA с установленной на него черно-белой камерой разрешения 1280x1024. Для того, чтобы обеспечить максимальную точность все тестовые изображения снимались с минимальной возможной глубиной резкости, что для нашего микроскопа составляет порядка 15 микрон. Для получения тестовых изображений мы использовали набор из нескольких прозрачных минералов, на каждом из которых присутствуют плоские полированные грани.

В первом эксперименте мы оценивали качество определения надежности замеров предложенным методом с машинным обучением. Для этого мы на нашей тренировочной базе обучили 2 классификатора. Первый классификатор использовал для классификации замеров на надежные и ненадежные только признак предложенный в [3]

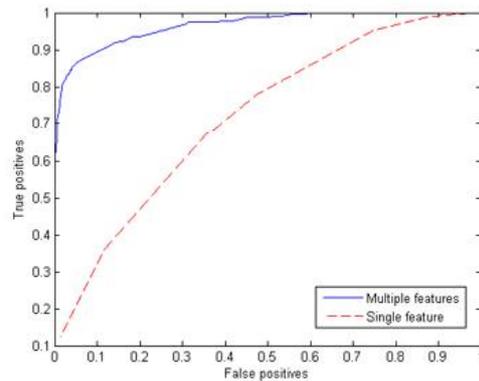


Рис. 7 ROC-кривые для пары классификаторов из эксперимента 1. Пунктиром отмечена ROC-кривая для классификатора использующего только признак из [3]. Сплошной линией отмечена кривая классификатора использующего признаки предложенные в данной работе

(максимальное среднеквадратичное отклонение цвета в окне) а второй классификатор в дополнение к этому признаку использовал еще признаки предложенные в разделе 2.2. На рис. 7 приведены ROC-кривые [12] для обоих классификаторов. Оценка ошибок классификации осуществлялась методом скользящего контроля. Видно, что использование дополнительных признаков, характеризующих поведения профиля резкости, позволяет добиться более качественной классификации.

Во втором эксперименте мы попытались оценить реальную точность построения плоскости предложенным методом. Для оценки точности мы сканировали одну и ту же грань минерала с разных направлений и с разными параметрами освещения. Если грани были достаточно большими мы также пытались для чистоты эксперимента сканировать разные участки грани. По каждому из полученных наборов оценивалось положение и ориентация плоскости грани. Результаты построения по всем наборам усреднялись и считался разброс оценок плоскости относительно этого среднего. Результаты данного эксперимента для нескольких граней приведены в таблице 2. В таблице приведен разброс оценок по углу нормали, так как это наиболее важный показатель точности построения плоскости. Также в таблице приведена статистика среднего количества выбросов в замерах до и после фильтрации.

В третьем эксперименте мы оценили качество работы предложенного теста для определения надежности плоскости. Мы сняли несколько наборов фотографий, на которых грани минерала достаточно грязные и детали хотя бы на части их поверхности различимы на глаз. Также мы сняли некоторое количество наборов фотографий, на которых грань практически не видна и оценили на всех наборах положение плоскости и ее надежность. В дополнение к этому мы на части первого набора фотографий, где грани хотя бы

Количество наборов	Средняя ошибка по углу	Максимальная ошибка по углу	Средины % выбросов до фильтрации	Средний % выбросов после фильтрации
8	0.12 градуса	0.24 градуса	85%	12%
8	0.16 градуса	0.22 градуса	76%	3%
7	0.2 градуса	0.31 градуса	87%	10%
8	0.15 градусов	0.22 градуса	89%	2%

Таблица 2. Иллюстрирует статистику точности работы методов построения плоскости и фильтрации замеров. Каждая строка таблицы соответствует одной грани, которая сканировалась с разных направлений и при разных условиях освещенности

частично видны, выделили участки где отсутствует текстура и оценили положение граней по ним. Результат работы алгоритма оценки положения для каждого набора анализировался и вручную определялось, удалось ли корректно построить грань по этому набору. Статистика демонстрирующая согласованность результатов ручной пометки и результатов работы теста на надежность приведена в таблице 3. Как можно заметить, предложенный тест успешно обнаруживает ситуации, когда грани на изображениях видны слишком плохо, но при этом иногда он отбрасывает грани, по которым можно построить плоскость надежно.

	Общее количество	Ошибки
Надежные	36	3
Ненадежные	29	0

Таблица 3. В первой колонке приведено общее количество надежно/ненадежно построенных граней, участвовавших в эксперименте. Во второй приведено количество ошибок определения надежности

## 5. ЗАКЛЮЧЕНИЕ

В этой статье была рассмотрена задача трехмерной реконструкции плоскостей граней прозрачных минералов по изображениям с микроскопа. В работе был предложен новый метод для определения того, можно ли считать замер положения для участка сцены по фокусу надежным. Применение этого метода не ограничивается описанным приложением. Авторы надеются в дальнейшей работе применить этот метод для реконструкции по фокусу поверхностей произвольной формы. Также был предложен метод, позволяющий определить то, можно ли по набору трехмерных точек, содержащему выбросы, надежно построить плоскость. Приведенные в работе эксперименты подтверждают высокое качество и точность работы предложенных методов.

## 6. СПИСОК ЛИТЕРАТУРЫ

- [1] Nayar, S.K. Nakagawa, Y. Shape from Focus, PAMI, pp. 824-831, 1994.
- [2] Darrel, T. Wohn, K. Pyramid based depth from focus, In Proc. of CVPR, pp. 504-509, 1988.
- [3] Nair, H.N. Stewart, C.V. Robust focus ranging, CVPR, pp. 309-314, 1992.
- [4] Айвазян, С.А. Енюков, И.С. Мешалкин, Л.Д. Основы моделирования и первичная обработка данных, Финансы и статистика, 1983.
- [5] Groen, F.C. Young, I. T. , Lighthart, G. A comparison of different focus functions for use in autofocus algorithms, Cytometry, pp. 81-91, 1985.
- [6] Fischler, A. Bolles, C. Random Sample Consensus: A Paradigm for Model Fitting with Applications to Image Analysis and Automated Cartography, SACM, pp. 381-395, 1981.
- [7] Ecabert, O. Thiran, J.-P. Adaptive Hough transform for the detection of natural shapes under weak affine transformations, Pattern Recognition Letters, pp. 1411-1419, 2004.

[8] Friedman, J., Hastie, T., Tibshirani, R. Additive Logistic Regression: a Statistical View of Boosting, Stanford University Tech. Report, 1998.

[9] Japkowicz, N. Stephen, S. The class imbalance problem: a systematic study. IDAJ, pp. 429-450, 2002.

[10] Weingarten, J.W. Gruener, G. Siegart, R. Probabilistic plane fitting in 3D and an application to robotic mapping, ICRA, pp. 927-932, 2004.

[11] Torr, P.H.S. Zisserman, A. MLESAC: A new robust estimator with application to estimating image geometry, CVIU, pp. 138-156, 1996.

[12] Вежневцев В. Оценка качества работы классификаторов. <http://cgm.graphicon.ru/content/view/106/66/>, 08.04.2008

## 3D reconstruction of planar facets of transparent objects from microscopic images

### Abstract

In this paper the problem of 3D reconstruction of planar facets of transparent objects from microscopic images is studied. We present a novel method based on machine learning, that allows to determine if a surface patch is textured enough for its position to be precisely estimated using a shape from focus method. In this work we also address the problem of plane estimate reliability and suggest a statistical test that assesses if a plane has enough support for estimate to be considered confident. In addition, experimental results are presented, demonstrating that proposed methods allow to locate planar facets of transparent objects reliably and with high accuracy.

### About the authors

Victor Gaganov is a PhD student at Keldysh Institute of Applied Mathematics of Russian Academy of Science. His research interests include computer vision, 3D reconstruction and adjacent fields. His contact e-mail is [ygaganov@graphics.cs.msu.ru](mailto:ygaganov@graphics.cs.msu.ru).

Alexey Ignatenko is a researcher at Computational Mathematics and Cybernetics department of Moscow State University. His research interests include photorealistic 3D rendering, 3D modelling and reconstruction, image-based rendering and adjacent fields. His contact e-mail is [ignatenko@graphics.cs.msu.ru](mailto:ignatenko@graphics.cs.msu.ru).