

# Прикладные аспекты распознавания объектов по аэрокосмическим изображениям земной поверхности

**В.В.Козодеров<sup>1</sup>,**

**Е.В.Дмитриев<sup>2</sup>**

*<sup>1</sup>Московский  
государственный  
университет*

*имени*

*М.В.Ломоносова,*

*<sup>2</sup>Институт  
вычислительной  
математики РАН*



## **Содержание доклада**


- Современные подходы к распознаванию образов объектов на фото-, многоспектральных (до десятка каналов) и гиперспектральных (сотни каналов) изображениях: искусственные нейронные сети, кластеризация данных в многомерном признаковом пространстве, линейный и нелинейный дискриминантный анализ, байесовский классификатор (вычислительная процедура) с обучением по тестовой выборке.**
- Особенности распознавания выбранных классов природно-техногенных объектов по спектральным признакам и контекстуального распознавания текстур лесной растительности разного породного состава и возраста по данным гиперспектрального аэрокосмического зондирования.**
- Примеры реализации предлагаемых подходов в рамках создаваемой аппаратно-программной системы обработки гиперспектральных изображений для тестовой территории совместно с данными ее наземных лесотаксационных обследований.**

# Исходные положения

- **Распознавание образов – обширный раздел прикладной математики при разработке математических моделей, которые стремятся построить по принципу организации сетей нервных клеток живых организмов (головного мозга).**
- **Президент Б.Обама в обращении к Конгрессу США в феврале 2013 года обозначил необходимость базовых исследований работы головного мозга приоритетным направлением: «Настало время выйти на уровень научных исследований и разработок, не виданный с момента пика космической гонки» (цитируется в переводе из сетевого издания rtrf.ru).**
- **В России идут по пути объединения разработок в области нано-, био-, информационных, когнитивных и даже социогуманитарных исследований (НБИКС, Национальный исследовательский центр «Курчатовский институт»).**  
**Когнитивные технологии составляют основу распознавания образов (pattern recognition).**

# Существующие подходы к распознаванию образов

- Искусственные нейронные сети (ИНС) – математические модели функционирования нервных клеток, модели можно подвергнуть обучению, что при наличии узлов (вход, выход, скрытые слои) позволяет решать задачи распознавания образов. ИНС – это система взаимодействующих между собой простых процессоров (искусственных нейронов), каждый процессор имеет дело с сигналами.



- С точки зрения машинного обучения ИНС представляют частный случай методов распознавания образов, дискриминантного анализа, методов кластеризации и др. Распознавание образов включает процесс классификации объектов и их последующей идентификации. Дискриминантный анализ – раздел вычислительной математики, связанный со статистическими методами разделения имеющихся наборов данных на группы. Кластерный анализ – это многомерная статистическая процедура упорядочения объектов в сравнительно однородные классы (классификатор без обучения).

# Процедуры обучения

- С математической точки зрения обучение нейронных сетей – это многопараметрическая задача нелинейной оптимизации. Возможность обучения – одно из главных преимуществ ИНС перед традиционными вычислительными алгоритмами. Обучение – это нахождение коэффициентов связи между нейронами в процессе выявления сложных зависимостей между входными и выходными данными, включая искаженные («зашумленные») данные.
- Суть моделей ИНС в определении класса функций  $f : X \rightarrow Y$  при наличии распределений  $X$  и  $Y$ . В реальности функция  $f(x)$  определяется как комбинация функций  $g_i(x)$ , которые могут быть комбинациями других функций. Наиболее часто используется нелинейная сумма синаптических весов  $w_i$ , так что  $f(x) = K(\sum_i w_i g_i(x))$ , где  $K$  – так называемая функция активации (часто используется гиперболический тангенс). Для заданного класса функций  $F$  обучение означает использование множества наблюдений для нахождения оптимальной функции  $f^* \in F$ .
- В процедурах обучения с учителем речь идет о том, чтобы на основе множества пар прецедентов  $(x, y)$ ,  $x \in X$ ,  $y \in Y$  найти функцию  $f : X \rightarrow Y$  соответствия этих множеств в смысле минимизации среднеквадратической ошибки между выходной функцией сети  $f(x)$  и некоторым эталонным значением  $y$  соответствующих пар прецедентов.




## **Основа критики концепции ИНС – затрачиваются слишком большие вычислительные ресурсы**

- **Несмотря на наличие успешных примеров решения ряда прикладных задач и в отличие от головного мозга, который обрабатывает сигналы посредством графа нейронов (идет параллельная обработка сигналов), технологии реализации ИНС на обычном компьютере требуют многих миллионов баз данных для соответствующих соединений, т.е. огромной оперативной и дисковой памяти.**
- **Технологии параллельных вычислений и машинно-обучающих алгоритмов приближают создание экспертных систем искусственного интеллекта.**
- **Вывод: для решения прикладных задач обработки гиперспектральных аэрокосмических изображений надо искать другие подходы – кластеризация спектров в многомерном признаковом пространстве, дискриминантный анализ, распознавание с обучением (supervised learning).**

# Множества и метки в многомерном признаковом пространстве.

## Дискриминатный анализ

- В случае двух классов объектов имеется два множества (каждый спектр – это точка в указанном пространстве):  $X$  – множество спектров или их некоторых характеристик (признаки),  $Y$  – множество наименований объектов. Необходимо построить отображение  $X \rightarrow Y$ , которое каждому элементу  $x \in X$  ставит в соответствие элемент  $y \in Y$ .
- В случае отсутствия априорной информации говорят о классификации без обучения: множество  $Y$  изначально не определено, элементы множества  $X$  группируются на основе предполагаемой меры близости. Итог группировки – построение множества  $Y$ . Оптимизация такой задачи состоит в поиске максимального количества минимально перекрывающихся групп (кластеров). Разбиение проводится оптимальным образом с помощью поверхности (кривой), называемой дискриминантной поверхностью.
- Справа: примеры построения дискриминантной поверхности (два канала  $R_1, R_2$ ): *a* – линейный дискриминант для бинарной классификации, *б* – линейный дискриминант для случая многих классов, *в* – нелинейный дискриминант для случая многих классов.



# **Распознавание объектов на гиперспектральных изображениях**

- **Распознавание по спектральным признакам основывается на вычислительных процедурах разделения классов в многомерном признаковом пространстве. Возможно чисто геометрическое разделение выделенных кластеров в указанном пространстве, но возможны и статистические подходы к распознаванию на основе распределений вероятности: априорных знаний об объектах и правдоподобия этих знаний и текущих распределений обрабатываемых данных.**
- **Для изображений высокого пространственного разрешения требуется также контекстуальное распознавание текстур. Контекст характеризуется воздействием соседних пикселей: например, объект «лесная растительность определенного породного состава» относится к одному классу до тех пор, пока не появится граница с другим объектом; при массовой обработке «свечение» отдельных пикселей заданного класса может восприниматься как шум, учет контекста в этом случае приводит к повышению общей точности распознавания, но отдельно стоит задача обнаружения таких специфических объектов. Аналогично «всплески» в спектральном ходе отдельных пикселей (каждый спектр пикселя формируется с помощью весовых функций составных элементов соответствующих объектов – end-members) относительно окружающего фона могут использоваться для обнаружения объектов по спектральным признакам с учетом отношений «сигнал/шум» аппаратуры.**



# Подходы теории видения при обработке зашумленных (искаженных) аэрокосмических изображений

Рассматриваются участки (sites, множество  $S$ ) и метки классов (labels, множество  $L$ ). Отдельная метка – это событие, которое может произойти на выбранном участке. Множество  $f = \{f_1, \dots, f_m\}$

дает помеченные участки на множестве  $S$  в терминах меток на множестве  $L$ . Говорят об отображении (mapping) множества участков на множестве меток  $f : S \rightarrow L$ .

Примеры: (1-2 – регулярные участки и отдельные пиксели, 3-4 – нерегулярные участки и отдельные линии, контура и т.п.).

1. Множество  $S$  – все пиксели изображения, множество  $L$  – непрерывные изменения меток: вычислительные процедуры реставрации всего изображения при его искажениях за счет шума и других эффектов.
2. Сегментация отдельных классов, т.е. реставрация только внутри выделенных контуров объектов.
3. Появление смыслового группирования (perceptual grouping), когда участки с сегментированными признаками (точки, линии, «регионы») нерегулярно распределены и возникает проблема соответствия (matching) этих признаков – собственно распознавание.
4. Участок означает заданное соответствие, а метка представляет собой допустимую трансформацию (ортогональное, аффинное или другое преобразование).

## Совместные и условные распределения вероятностей

- Проблема контекста при обработке изображений определяется локально в терминах условных вероятностей  $P(f_i | \{f_{i'}\})$ , где  $\{f_{i'}\}$  означает множество меток для других пикселей  $i' \neq i$ . Общая вероятность  $P(f)$  при независимости меток друг от друга (отсутствие контекста) выражается через произведение локальных вероятностей

$$P(f) = \prod_{i \in S} P(f_i).$$

В этом случае условная вероятность приравнивается к общей вероятности

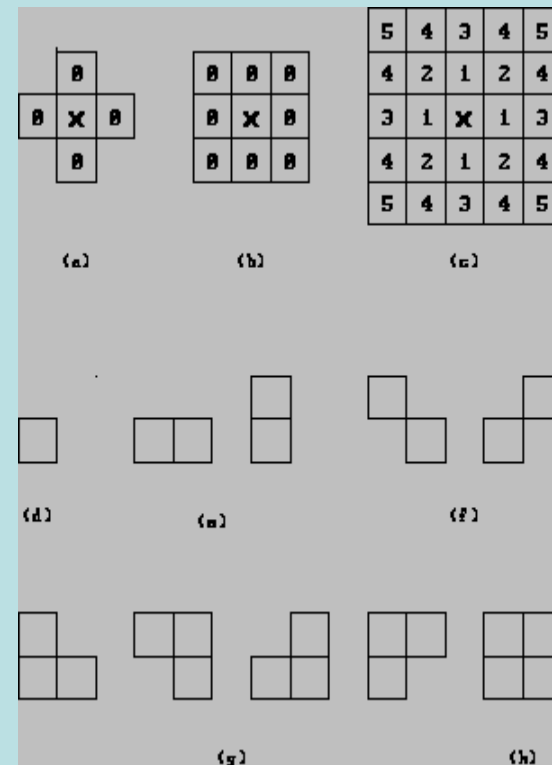
$$P(f_i | \{f_{i'}\}) = P(f), i' \neq i,$$

что означает: глобальное распределение меток можно рассчитать с помощью локальных меток.

- При наличии контекста (пространственного влияния разных пикселей) метки становятся взаимно зависимыми, а теория Марковских случайных полей обеспечивает математическую основу для решения возникающих задач.

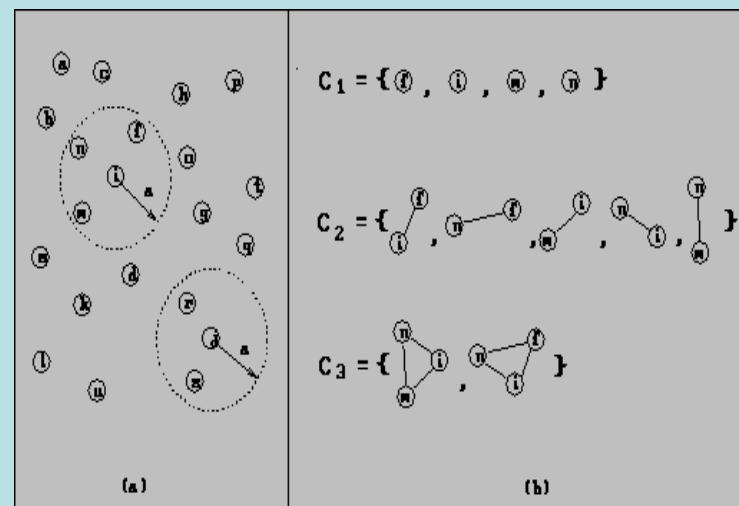
# Система соседей и связей (cliques) пикселей данного класса

- Пара множеств участков и  $N$  соседей символически записывается как граф:  $(S, N) \sim G$ , когда множество таких участков содержит узлы (nodes) и связи (links) для соседних элементов. Для такого графа вводится условие замыкания  $c$  (clique) как подмножество участков на множестве  $S$ . Это условие может относиться к отдельному участку  $c = \{i\}$ , к паре соседних участков  $c = \{i, i'\}$ , к триплету  $c = \{i, i', i''\}$  и т.д.
- Тип замыкания для графа  $(S, N)$  на регулярной решетке определяется его размером, формой и ориентацией. Вверху – система соседства



1-го порядка (a) и более высоких порядков (b, c) с разными уровнями замыкания (d-h).

Внизу – картина для нерегулярных участков, когда система замыканий (a, b) уже не имеет фиксированной формы и носит более усложненный характер.



# Вероятностный подход. Байесовский формализм и нахождение максимума апостериорной вероятности при распознавании объектов на оптических изображениях

- Если обозначить через  $d = \{d_1, \dots, d_n\}$  изображение из  $n$  пикселей как случайных полей и через  $f = \{f_1, \dots, f_n\}$  понимание того, к какому классу объектов  $f_i$  принадлежит каждый пиксель  $i$ , то известная Байесовская парадигма увязывает следующие условные вероятности:

$$P(f | d) P(d) = P(d | f) P(f).$$

- Типичным для такой классификации объектов является решение, основанное на нахождении максимума апостериорной вероятности (МАР):

$$f^* = \arg \max_f [P(d | f) P(f)].$$

Условная вероятность  $P(d | f)$  обычно моделируется в терминах Гауссовского распределения метода максимального правдоподобия, а априорная вероятность  $P(f)$  – с помощью Марковских случайных полей (MRF/МСП) с учетом влияния соседних пикселей для заданных классов объектов.

## Моделирование априорных вероятностей с помощью МСП

- Представим семейство  $F = \{F_1, \dots, F_m\}$  случайных переменных, определенных на множестве  $S$ ; в этом семействе каждая переменная  $F_i$  принимает значение  $f_i$  на множестве меток  $L$ . Семейство  $F$  называется случайным полем, а совместное распределение вероятности  $P(F=f) = P(F_1=f_1, \dots, F_m=f_m)$  обычно обозначается как  $P(f)$ .
- Говорят, что семейство  $F$  является Марковским случайным полем (МСП) на множестве  $S$  относительно системы соседей  $N$ , тогда и только тогда, если выполняются следующие два условия:

$$P(f) > 0 \text{ (положительность),}$$
$$P(f_i | f_{S-\{i\}}) = P(f_i | f_{N_i}) \text{ (марковость),}$$

где  $S-\{i\}$  - разность множеств,  $f_{S-\{i\}}$  - функция распределения этой разности множеств, а обозначение

$$f_{N_i} = \{f_{i'} | i' \in N_i\}$$

характеризует распределение множеств меток на участках, соседствующих с участком, проиндексированным как  $i$ .

# Эквивалентность локальной модели МСП и глобального распределения Гиббса

Вероятностное распределение Гиббса для набора случайных переменных  $f \in F$ :

$$P(f) = \exp[-U(f)/T] / Z, \text{ где } Z = \sum_{f \in F} \exp[-U(f)/T],$$

$$U(f) = \sum_{c \in C} V_c(f), \text{ } Z - \text{ константа нормализации,}$$


называемая функцией разделения, постоянная величина (температура, здесь равна 1),  $U(f)$  - функция энергии, равна сумме потенциалов замыкания  $V_c(f)$  на множестве  $C$ .

Модель МСП: выражение для априорной вероятности

$$P(f) = P(f_i / f_{S-\{i\}}) = P(f_i / f_{N_i}),$$

$f_{N_i}$  обозначает все локальные соседние пиксели относительно пикселя  $i$ ,

$S-\{i\}$  – разность множеств всех пикселей, за исключением  $i$ .



- Обладая анизотропными свойствами модель МСП играет важную роль в анализе текстур изображения (приведена модель соседства второго порядка).

## **Распределение меток (labeling) и процедура возможного сглаживания соседних пикселей как априорное предположение о слабом изменении свойств соседей**

- В терминах случайных полей проблема распределения меток (построение конфигураций) означает выбор пространственного распределения энергетической яркости или каких-то иных признаков, характеризующих соответствующий класс объектов.**
- Задание априорной вероятности  $P(f)$  определяет вероятность появления определенной конфигурации для функции  $f$ : более вероятные конфигурации – те, которые имеют более низкие энергии; температура  $T$  контролирует форму соответствующих распределений – когда значения  $T$  велики, конфигурации стремятся к равномерному распределению, при  $T \rightarrow 0$  распределения концентрируются вблизи глобального минимума энергии.**
- Порядок  $n$  производной функции распределения  $f^{(n)}(x)$  ( $x$  - пиксели для выбранных классов объектов) определяет число соседей:  $n = 1$  соответствует паре участков потенциала  $[f^{(n)}(x)]^2$  сглаживания и т.д.; разные порядки производной подразумевают разные классы сглаживания.**

## Проблема «MAP-MRF labeling» в фокусе аналитических свойств функции распределения $f(x)$ :

- Если эта функция (яркость объектов) постоянная для всех пикселей  $f(x) = a_0$  (говорят о плоской поверхности), т.е. производная  $f'(x) = 0$ , то имеем дело с априорной энергией струны (в двумерном случае мембраны)

$$U(f) = \int [f'(x)]^2 dx$$

(энергия имеет равный нулю минимум для такой упрощенной модели или положительна в противном случае), в дискретном случае

$$U(f) = \sum_i [f_i - f_{i-1}]^2.$$

- Возможно априорное предположение о постоянстве градиента яркостей для изображения или отдельных его сегментов

$$f(x) = a_0 + a_1 x, f''(x) = 0,$$

и получаем энергию стержня  $U(f) = \int [f''(x)]^2 dx$ .

- Возможно априорное предположение о постоянстве кривизны соответствующей поверхности  $f'''(x) = 0$ ,  $U(f) = \int [f'''(x)]^2 dx$  и т.д. Порядок производной определяет число соединяемых участков (например, при  $n = 1$  это пара соседних участков, хотя соседство пикселей может быть первого, второго и более высоких порядков).



# Гауссовская модель апостериорной энергии и

## регуляризация решения задачи ее минимизации

- Если для каждого пикселя  $i$  наблюдение есть «истина» плюс независимый гауссовский шум  $d_i = f_i + \varepsilon_i$ , где  $\varepsilon_i \sim N(0, \sigma_i^2)$ , то энергия правдоподобия есть

$$U(d | f) = \sum_{i=1}^m (f_i - d_i)^2 / (2\sigma_i^2),$$

а апостериорная энергия для модели плоской поверхности

$$E(f) \equiv U(f | d) = U(d | f) + U(f) = \sum_{i=1}^m (f_i - d_i)^2 / (2\sigma_i^2) + \sum_{i=1}^m (f_i - f_{i-1})^2.$$

- В общем случае регуляризованное решение, которое переводит некорректно поставленную задачу (решение может быть неединственным) в корректно поставленную задачу, получается путем минимизации энергии следующего типа:

$$E(f) = \sum_{i \in A} [f(x_i) - d(x_i)]^2 + \lambda \int_a^b [f^{(n)}(x)]^2 dx,$$

$A$  – множество индексов выборочных данных, локализация которых дается точками  $x_i$ ,  $\lambda \geq 0$  – весовой фактор при рассмотрении интеграла от квадрата производной указанной функции на интервале  $[a, b]$ ,  $n \geq 1$  - порядок производной. Первое слагаемое в правой части характеризует меру близости искомого решения и исходных данных обрабатываемого изображения. Второе слагаемое – собственно регуляризатор, который накладывает априори ограничение на решение по сглаживанию используемых при этом функций.

# Нахождение контуров границ объектов (edge detection) и распознавание текстур

- Выражение для апостериорной энергии в виде

$$E(f) = \sum_{i \in S} (f_i - d_i)^2 + \lambda \sum_{i \in S} \sum_{i' \in N_i} g(f_i - f_{i'}),$$

где на производную функции  $g$  накладывается ограничение

$$\lim_{\eta \rightarrow \infty} |g'(\eta)| = \text{const} < \infty,$$

приводит к прекращению сглаживания пикселей на границах объектов и маркировке этих границ.

- Усложнение гауссовской модели

$$d_i = \varphi(f_i) + \varepsilon_i$$

и функции потенциала правдоподобия до

$$V(d_i/f_i) = [\varphi(f_i) - d_i]^2 / (2\sigma_i^2)$$

позволяет строить модели текстур и их распознавания. При этом оптимальное распознавание соответствует поиску глобального минимума указанной целевой функции энергии.

# **Замечания по поводу компьютерной реализации моделей МСП**

- Открываются перспективы учета контекста для выбранных классов объектов на оптических изображениях при рассмотрении коррелированных признаков в терминах вероятностей.**
- Решаются проблемы нахождения оптимальных решений теории видения в процессе определения максимума апостериорных вероятностей байесовского классификатора.**
- Локальные свойства МСП приводят к тому, что в задачах контекстуального распознавания текстур становится возможным применение параллельных вычислений на суперкомпьютерах, т.е. могут быть задействовано большое число процессоров, выполняющих параллельные скоординированные вычисления.**
- Введение понятия энергии как целевой функции минимизации расхождений между регистрируемыми данными и свойствами распределений, аппроксимирующих эти данные, уточняет понятие классов на изображении (от однородных объектов до объектов с большим разнообразием регистрируемых яркостей), а возможное визуальное восприятия сглаживания пикселей дает основание это разнообразие для заданного класса объектов уменьшить.**

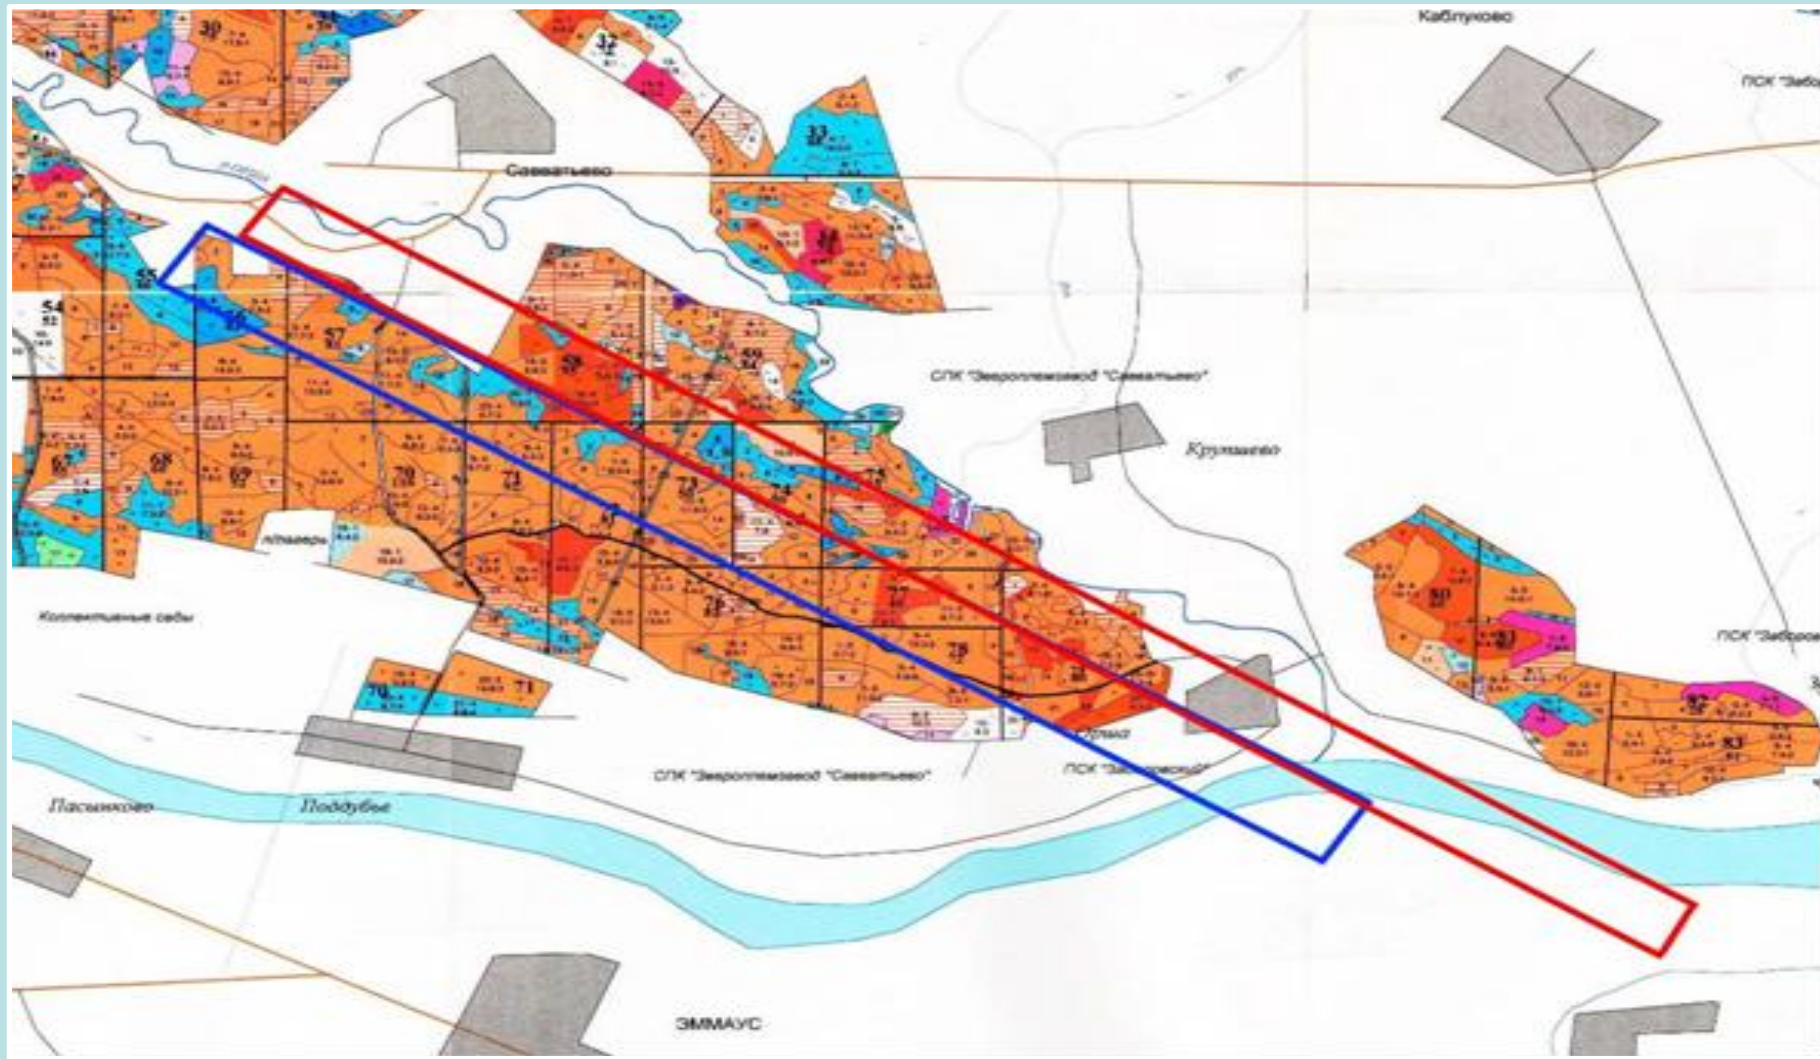
# Этапы обработки изображений

- 1. Нахождение контуров – границ между разными классами объектов. Разным классам соответствует неодинаковое число пикселей на обрабатываемом изображении.
- 2. Однотипные преобразования, допускающие распараллеливание вычислений в пределах каждого контура (класса) по минимизации энергии соответствующих сцен путем использования функций  $f$ , т.е. нахождение сглаженного решения задачи в функциональном пространстве Соболева  $W_2^n$ . Это пространство, каждая точка в котором есть функция  $f$ ,  $(n-1)$ -я производная которой  $f^{(n-1)}$  абсолютно непрерывна, а  $n$ -я производная  $f^{(n)}$  квадратично интегрируема.
- 3. На первых двух этапах реализуется распознавание объектов по текстурным признакам при использовании байесовского классификатора и локальных свойств МСП. Далее следует распознавание по спектральным признакам (определение более тонких нюансов свойств этих объектов; например, различение породного состава и возраста лесной растительности) с обучением по тестовой выборке.



# **Исходные данные обработки**

- Гиперспектральные изображения в около 200 спектральных каналах от 400 нм до 1000 нм с разрешением около 1 нм в коротковолновых каналах и 5-10 нм – в длинноволновых каналах. Высота полета 1.5-2 км, пространственное разрешение аппаратуры порядка 1 м.**
- Синхронные аэрофотоизображения зондируемой территории.**
- Картосхемы наземных лесотаксационных обследований территории в виде отдельных кварталов и выделов внутри них.**

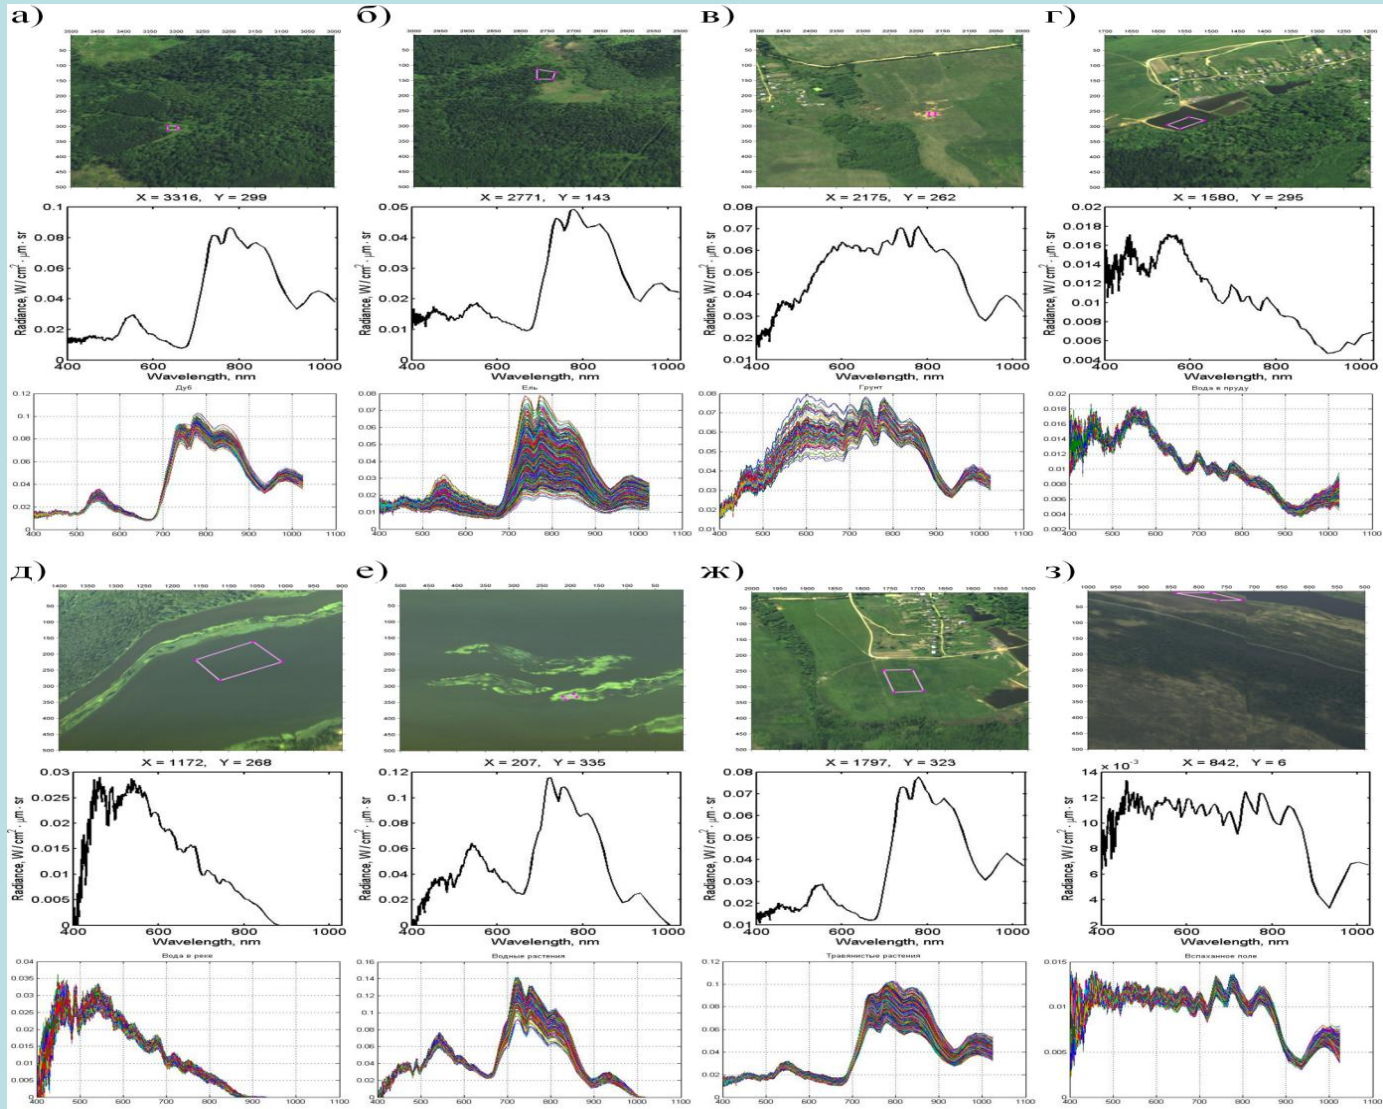
**Картосхема данных традиционных наземных лесотаксационных обследований выбранной территории в виде отдельных кварталов и выделов (цвета: оранжевый – сосняки, сине-голубой – березняки, фиолетовый – ельники; чем темнее цвет, тем больше возраст древостоев).  
Две отдельные полосы рамок красного и синего цветов соответствует двум маршрутам пролета самолета над тестовой территорией на дату съемки**



# RGB-синтезированные изображения двух участков: с преимущественно лесной растительностью (а) и с преимущественно открытой водной поверхностью (б)

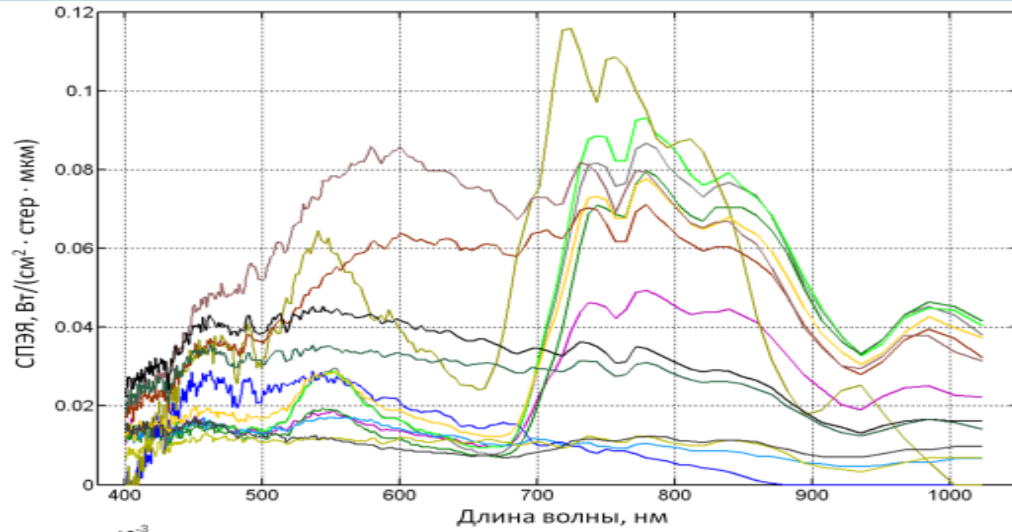


**Изображения частей самолетного треков, спектры отдельного пикселя из оконтуренной области и ансамбль спектров внутри этой области. Объекты: освещенная крона средневозрастного дуба (а); зрелая ель (б); песчаный карьер (в); водная поверхность пруда (г); водная поверхность реки Волга (д); водоросли (е); луговая трава (ж); распаханная почва (з).**

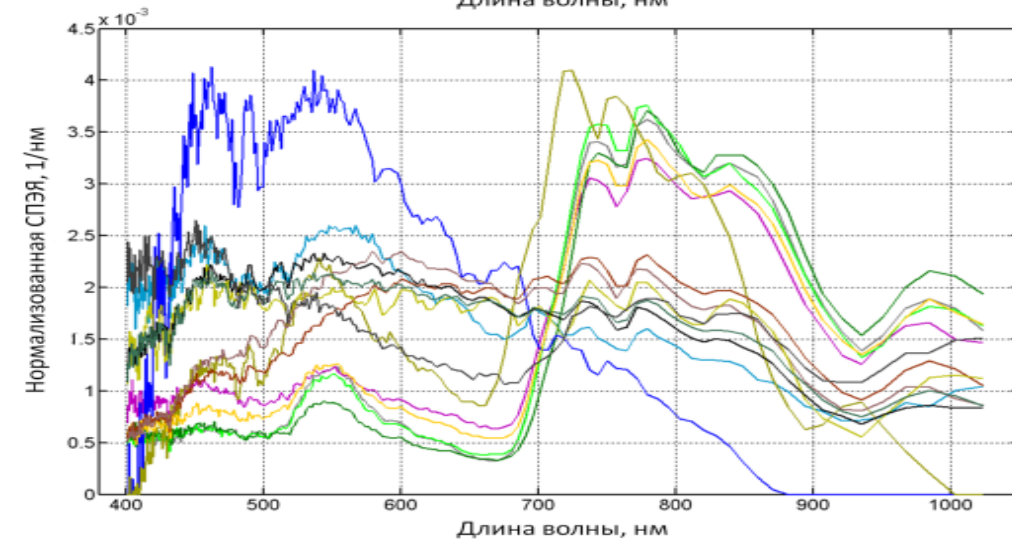




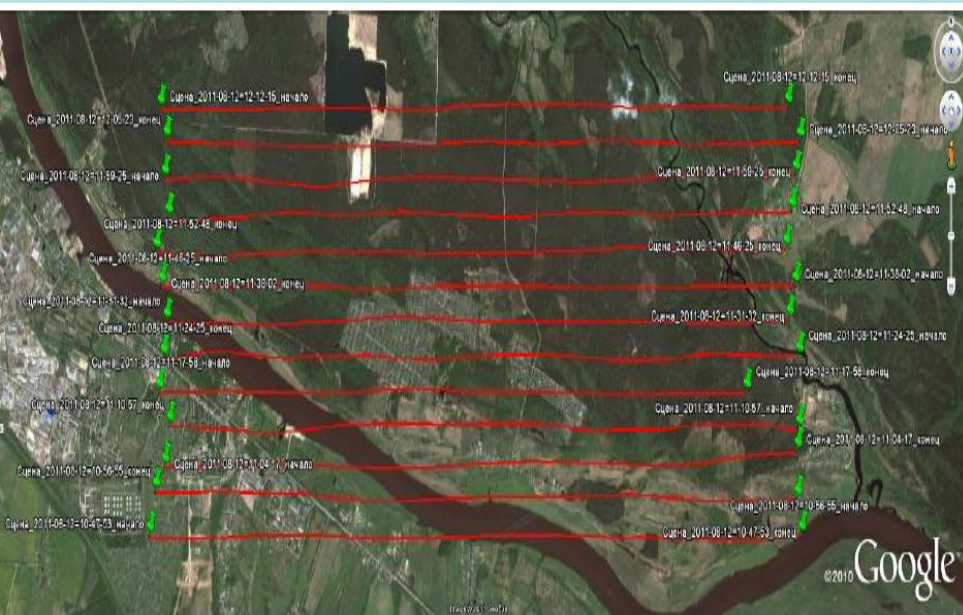
# Характерные распределения спектральных плотностей энергетической яркости (СПЭЯ) иллюстрируемых объектов; словесное описание 14 выбранных объектов рассматриваемых сцен; величины СПЭЯ для спектров, нормированных на их интегральные значения для соответствующих объектов



- Дуб
- Ель
- Широколиственные породы деревьев (липа, ясень)
- Широколиственные породы деревьев (клен, липа)
- Вода в пруду
- Вода в реке
- Водные растения
- Травянистые растения сухих местообитаний
- Грунт
- Грунтовая дорога
- вспаханное поле
- Городские строения
- Асфальтированная дорога
- Тень от объекта



**Отображение 13 самолетных треков еще одной тестовой территории (слева) и параметры ансамблей спектральных плотностей энергетических яркостей (СПЭЯ) для «чистых выделов» (сравнительно однородных древостоев – около 50 тыс. спектров) (справа). Общая зондируемая площадь около 4 км x 3 км, каждая из 13 полос - матрица около 2000 x 500 пикселей (размер каждого пикселя на местности порядка 2 м x 1 м).**





Порода	Возраст	Количество спектров	Наименование трека-источника
Сосна	13	1046	2011-08-12=11-10-57
	16	2428	2011-08-12=11-31-32
	26	2061	2011-08-12=12-05-23
	36	447	2011-08-12=11-10-57
	47	5025	2011-08-12=11-17-58
	56	1807	2011-08-12=11-46-25
	66	7551	2011-08-12=11-52-48
	76	1557	2011-08-12=11-52-48
	76	4019	2011-08-12=11-59-25
	86	2055	2011-08-12=11-46-25
	96	3156	2011-08-12=11-38-02
	106	2191	2011-08-12=11-59-25
	116	644	2011-08-12=11-24-25
126	1932	2011-08-12=11-04-17	
136	695	2011-08-12=11-46-25	
Береза	16	1729	2011-08-12=11-31-32
	51	1634	2011-08-12=11-38-02
	71	5656	2011-08-12=11-46-25
Осина	11	2545	2011-08-12=11-38-02
Вяз	–	534	2011-08-12=10-47-53

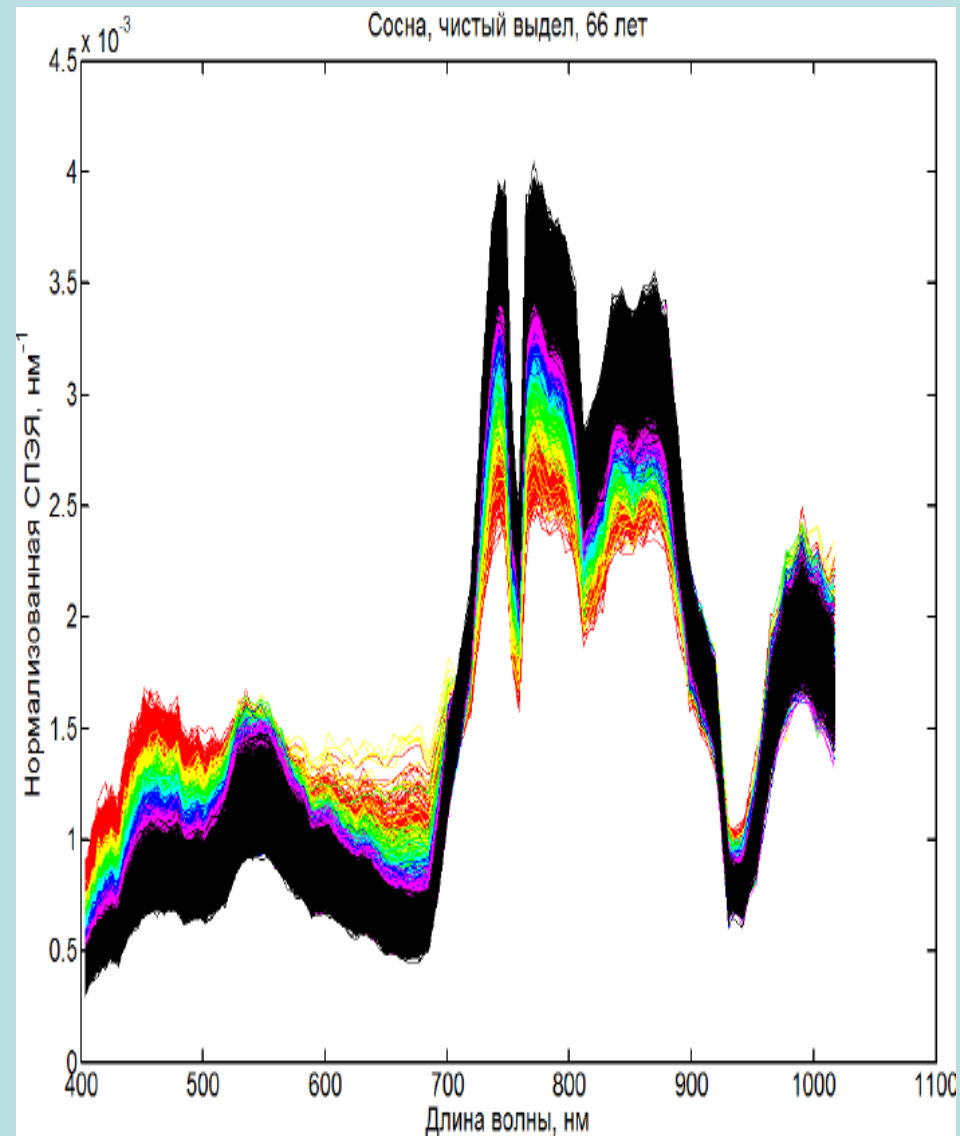
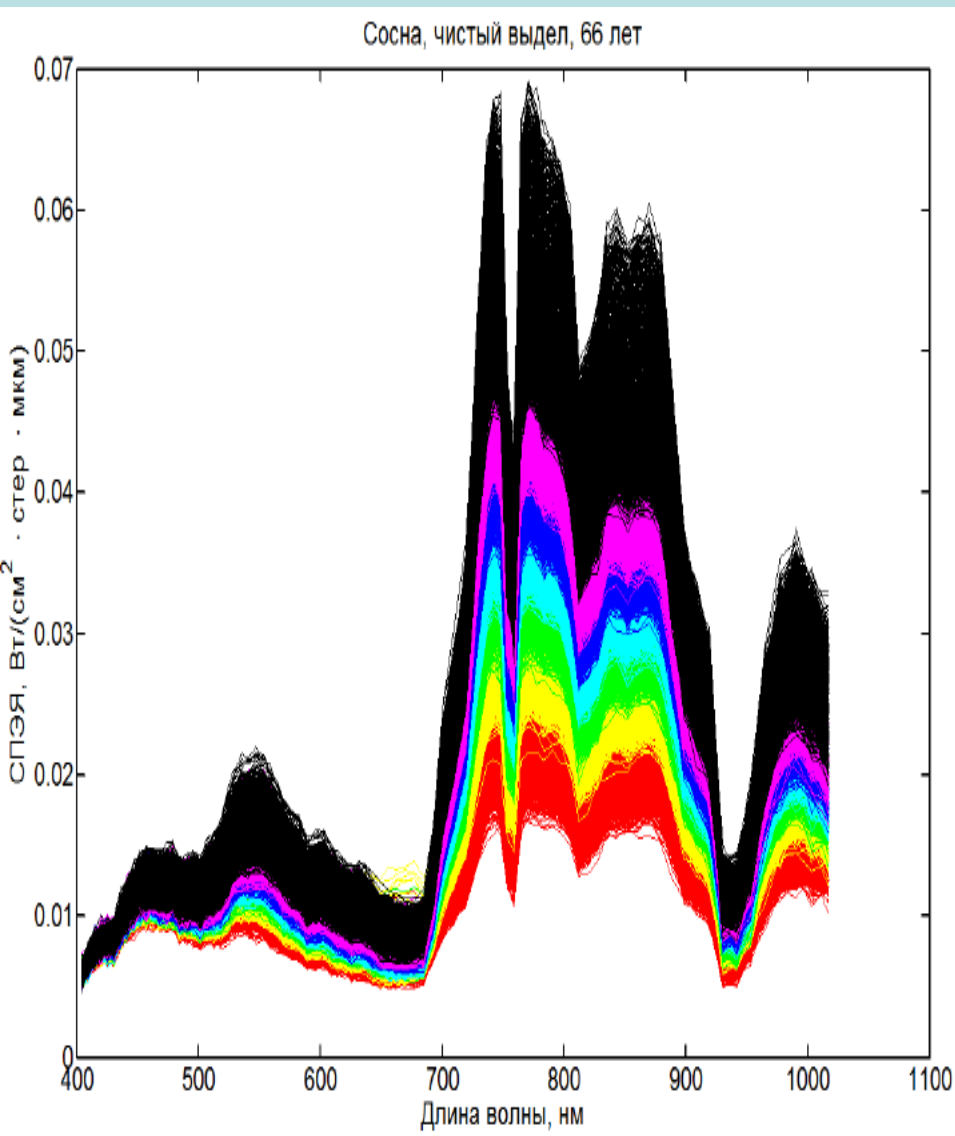
**Текстура лесного полога (перемежающиеся освещенные и затененные участки крон, а также межкроновые просветы) и интегральные яркости (СПЭЯ) для чистых выделов:**

- Значения СПЭЯ освещенных участков, для которых аппаратура обеспечивает достаточно высокие значения отношения «сигнал/шум», определяются в основном оптическими свойствами кроны, текущими атмосферными условиями и высотой Солнца.**
- При более низких значениях указанного отношения и увеличении шумовой составляющей для затененных участков кроны формирование СПЭЯ происходит за счет многократного рассеяния света внутри кроны и спектральных свойств подстилающей поверхности.**
- Для полученных обучающих выборок производится разделение пикселей освещенных и затененных участков кроны на 7 градаций по интегральной яркости (СПЭЯ интегрируются методом трапеций по всем центральным длинам волн гиперспектральной аппаратуры).**



**Распределение исходных значений СПЭЯ (слева) и нормированных на интегральную яркость (справа) значений СПЭЯ молодого соснового древостоя с однородным породным составом возрастом 13 лет (7 градаций соответствуют процентным интервалам от пикселей с затененной кроной – красный цвет до ярких пикселей с освещенной кроной – черный цвет)**





# Градации распределения исходных значений СПЭЯ (слева) и нормированных на интегральную яркость значений (справа) для приспевающего соснового древостоя возрастом 66 лет



**Три информационных слоя (красный цвет – полностью освещённая часть полога, синий – затененная часть, зеленый – промежуточная часть), сформированные по собранным ансамблям спектров в зависимости от возраста сосновых (слева) и берёзовых (справа) древостоев. Видно: для всех возрастов слой, соответствующий пикселям с полностью затенённой частью кроны, более выражен в видимом диапазоне и в каналах с длиной волны более 920 нм; для каналов 710 нм и 920 нм более выражен слой освещённой части полога; переходный слой заметен вблизи длины волны 910 нм.**




**Пример RGB-синтезированного изображения лесной растительности смешанного породного состава (слева): в центре видна заросшая осиной вырубка, внизу – территория садового товарищества. Картосхема лесотаксации верхней части территории (справа): синий цвет – преобладание березы, оранжевый – сосны, зеленый – осины.**









**RGB-синтезированное изображение гиперспектральных данных, нормированных на интегральную яркость (вверху слева); распознавание объектов с использованием объединенных каналов, обеспечивающих спектральное разрешение порядка 5 нм (вверху справа); то же самое с добавлением канала, в котором заметен эффект виньетирования (внизу слева); картосхема наземной лесотаксации (внизу справа). Слева на изображениях виден лесной покров (оранжевый цвет – сосняки, синий – березняки, горизонтальные полосы – бывшие вырубki), справа – песчаный карьер, частично заполненный водой (правый верхний угол)**





**Результаты распознавания породного состава древостоев по градациям интегральной яркости излучения, отраженного от лесного полога: 1– затененная часть кроны, 2 – полуосвещенная, 3 – освещенная. Видно, что водная поверхность отображается двумя разными классами объектов**



## **Валидация новой информационной продукции обработки гиперспектральных самолетных изображений**

- Суммарная вероятность ошибки классификации объектов – основная мера сравнения полученных данных с известными данными («эталонном») из других источников. Данные лесотаксации не могут служить таким эталоном, т.к. соответствующие картосхемы сами нуждаются в обновлении.**
- Более перспективно при рассмотрении вероятности ошибки распознавания использовать современные подходы (например, метод «кросс-валидации», когда всё множество пикселей при обучении используемого классификатора разбивается на какое-то их число, используемое для обучения, с повторным выбором других пикселей для обучения). Доказывается реальная точность, достоверность и вычислительная эффективность этих новых методов с учетом результатов предполетной калибровки аппаратуры, значений отношения «сигнал/шум», других особенностей спектрального и контекстуального распознавания объектов.**

**Матрицы ошибок определения возраста выбранных «чистых пород» лесной растительности (confusion matrices) для пикселей, соответствующих освещенным кронам сосняков (слева), и для таких же пикселей, соответствующих трем выбраным возрастам березняков и сосняков (справа) при использовании метода кросс-валидации. На главной диагонали – общие точности распознавания, вне диагонали – ошибки ложной тревоги и пропуска цели**



# Выводы

- **Использование концепции искусственных нейронных сетей может быть полезной процедурой вычислительных технологий, связанных с применением параллельных компьютеров, но требует дополнительных исследований при реализации прикладных задач распознавания природно-техногенных объектов на гиперспектральных аэрокосмических изображениях.**
- **Предлагаются усовершенствования байесовского классификатора, который позволяет повысить вычислительную эффективность методов распознавания объектов по спектральным и текстурным признакам на гиперспектральных изображениях и провести оптимизацию спектральных каналов, но требует развития новых подходов к кросс-валидации результатов распознавания при сравнении получаемой информационной продукции с данными наземной лесотаксации, нуждающихся в обновлении.**
- **Показано, что точность распознавания объектов лесного покрова разного породного состава и возраста повышается в процессе выделения для заданного класса объектов, по крайней мере, трех информационных слоев, ответственных за формирование пикселей, относящихся к полностью освещенным элементам кроны, полностью затененным элементам и промежуточным условиям регистрации спектров.**