САНКТ-ПЕТЕРБУРГСКИЙ ГОСУДАРСТВЕННЫЙ
МЕДИЦИНСКИЙ УНИВЕРСИТЕТ
ИМЕНИ АКАДЕМИКА И. П. ПАВЛОВА

Кафедра физики, математики и информатики

Методы «раскопки данных» - Data Mining

Авторы

Тишков Артем Валерьевич
Эюбова Наргиз Идаят кызы
Делакова Екатерина Александровна
Семенова Елена Михайловна

2013

Медицинские данные

Результаты медико-биологических исследований – большое количество данных различного характера

Результаты лабораторных исследований;

Социально-паспортные и антропометрические данные;

Факторы риска;

Данные медицинских приборно-компьютерных систем.

Анализ медицинских данных

- Статистические методы
- Методы, основанные на знаниях
  - «Раскопка данных» (Data Mining)
  - Экспертные системы

Data Mining «Раскопка данных»

–поиск (неочевидных) закономерностей в данных

–обнаружение скрытых знаний

Статистические методы

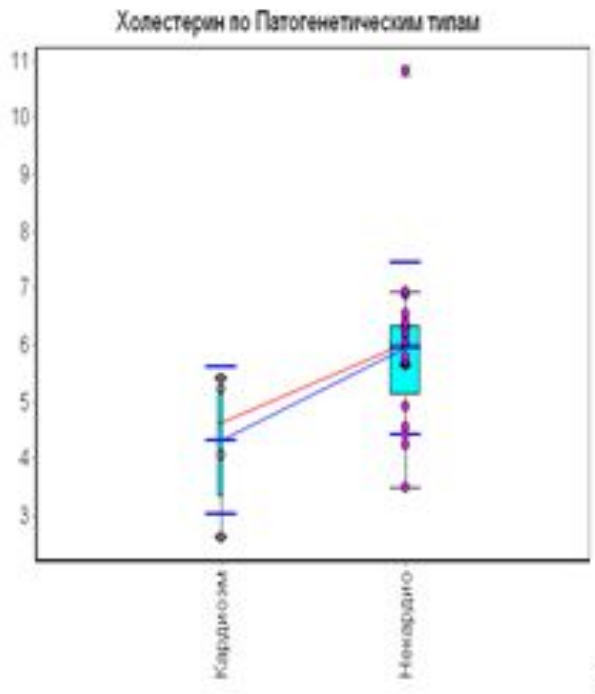

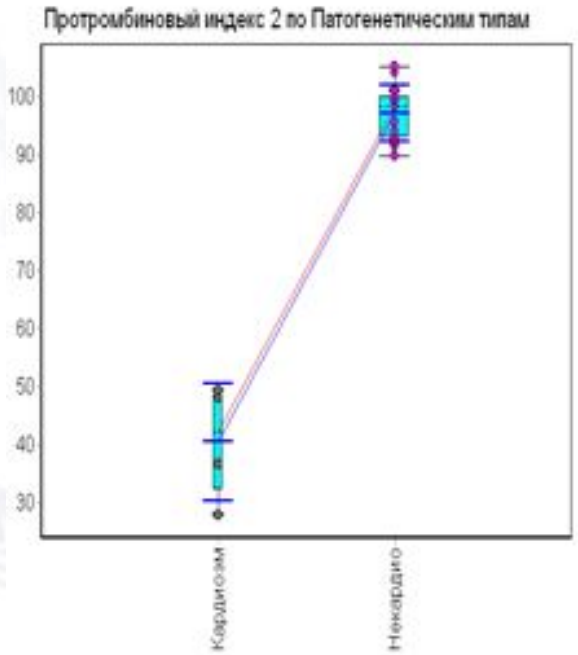

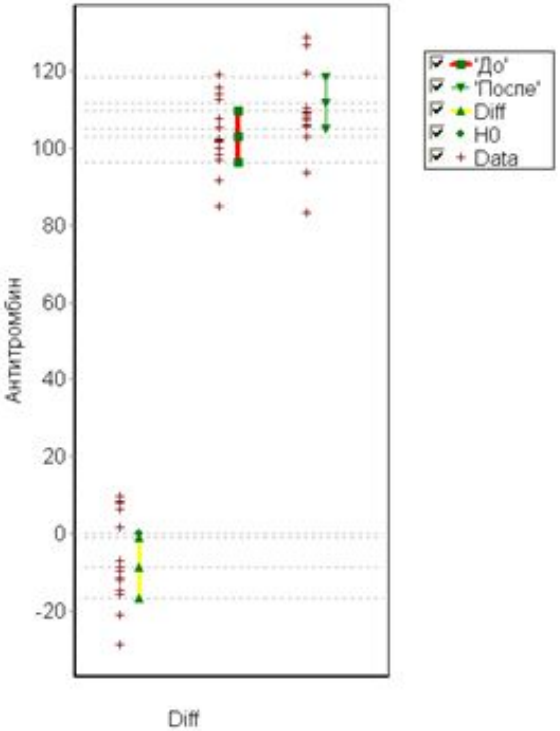

Согласованность с нормальным законом распределения

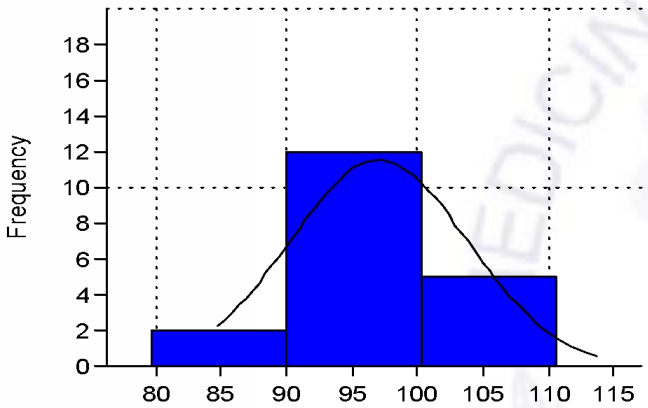

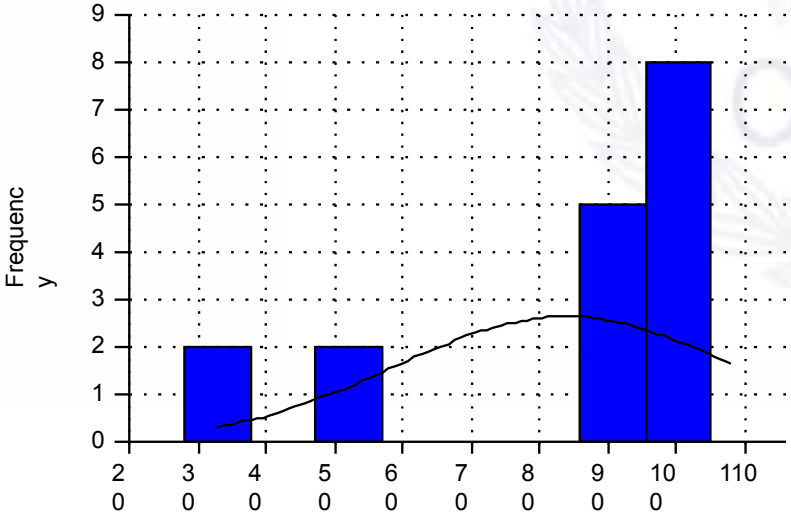

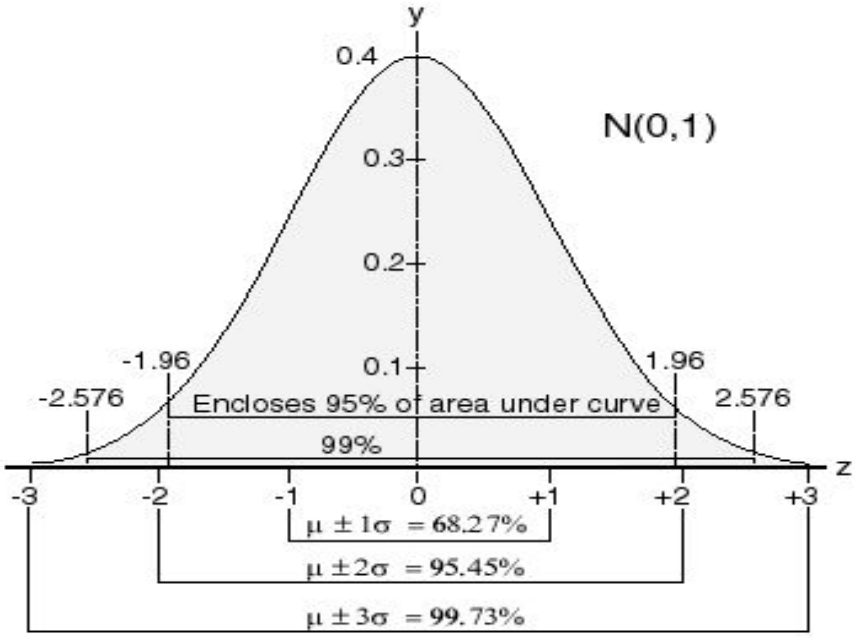

Корреляционный анализ

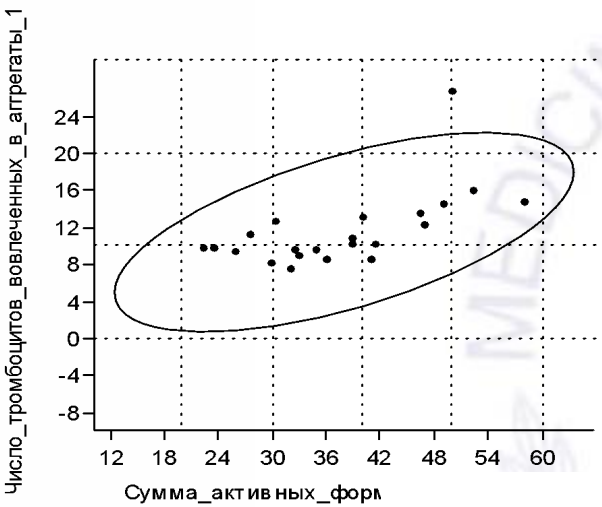

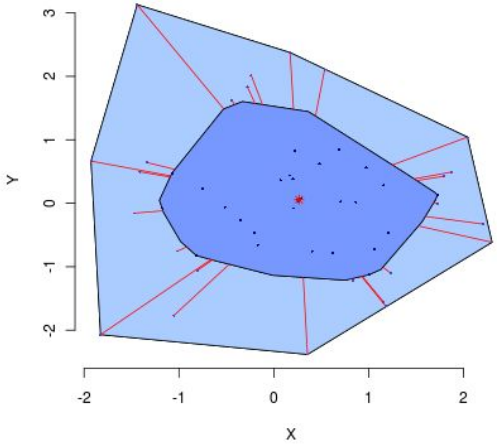

r-коэффициент корреляции

$$r_n = \frac{\sum_{i=1}^{n}(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^{n}(x_i - \bar{x})^2}\sqrt{\sum_{i=1}^{n}(y_i - \bar{y})^2}}.$$

Pearson

ранговые:

ρ Spearman

τ Kendall

Гармонизированный анализ

	Протромбиновое время 2		МНО 2		Протромбиновый индекс 2	
	Среднее	N	Среднее	N	Среднее	N
Кардиоэмболический тип	15,19; **27,42**; 39,65	4	1,44; **2,59**; 3,73	4	24,24; **40,41**; 57,57	4
Некардиоэмболический тип	10,52; **10,85**; 11,18	13	1,00; **1,03**; 1,07	13	94,03; **96,96**; 99,89	13
Критерий Стьюдента	8,34		8,37		15,74	
p-значение двустороннее	**5,08E-07**		**4,90E-07**		**9,80E-11**	
Размер эффекта ES, с (1 − α) × 95 %	2,64; **4,53**; 6,43		1,17; **1,56**; 1,94		48,9; **56,55**; 64,2	
Бейзов фактор BF_{JZS}	4.581506e-05		4.401148e-05		1.870535e-08	
Мощность критерия	**0.99**		0.83		**1,00**	
Размер выборки N (α = 0,01; 1 − β = 0,95)	10		34		8	
Предсказательный интервал для размера эффекта	[2,87; 6,17]		[0,98; 2,12]		[45.72; 67,38]	
Предсказательная вероятность для последующих экспериментов	**0,99; 0,99; 1,00**		**0,99; 0,99; 1,00**		**1,00; 1,00; 1,00**	
Критерий Уэлча	4,31		4,32		10,76	
p-значение двустороннее	0,02		0,02		0,00091	
Размер эффекта по Коэну	4,77		4,70		9,01	
Разница дисперсий SD	3,47		0,32		6,28	

Нестатистические методы: «раскопка данных»

эотаксин	эотаксин-2	интерлейкин-8	MIP-1alpha	MIP-1beta	RANTES	CCR1	CCR3	CCR5	CXCR1	CXCR2	result
6,7	13	113	13	33	23	126	99	63	113	86	y
5,1	9,8	89	29	15	23	102	27	32	49	74	y
27	11,4	48	73	36	61	116	118	118	114	85	y
9	20	44	14	11	52	111	102	101	101	84	y
7	3	16	49	49	61	79	58	39	109	111	y
13	10	11	28	10	15	100	91	102	76	66	y
1,2	0	1,2	0,8	1,6	1,4	140	96	158	96	122	n
1	0	0,8	0,1	0,06	10	165	88	66	1,8	73	n
0	3,2	26	0	0,1	0	94	104	74	27	54	n
0,5	1	7	0	4	18	146	81	112	27	90	n
1,5	4	10	0,7	1	43	145	103	127	36	103	n
1	20	33	0	0	98	152	122	140	50	103	n
3	0	17	0	0	39	128	103	18	35	74	n
0,4	2	29	0,3	0,06	32	112	98	96	36	79	n
0,3	0,6	34	0,6	0,3	6	108	112	92	34	98	n
0,3	2	9	0,3	0,2	1	121	114	105	8	120	n

Кластеризация (обучение без учителя)

Кластеризация предназначена для разбиения совокупности объектов на однородные группы —*кластеры*.

Цель *кластеризации* — построить оптимальное разбиение объектов на группы: разбить N объектов на k кластеров.

Характеристиками *кластера* можно назвать два признака:

- внутренняя однородность;
- внешняя изолированность.

Непересекающиеся и пересекающиеся кластеры

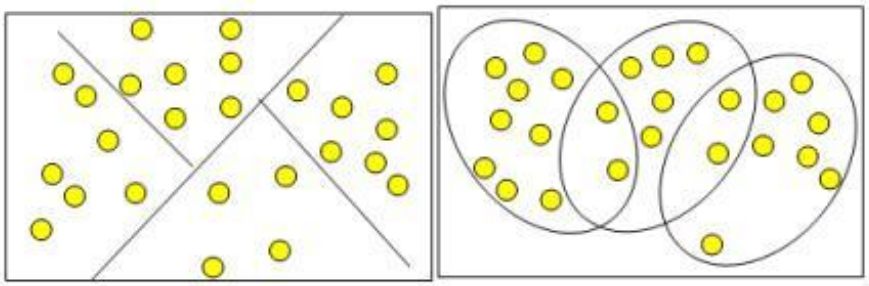

Кластеризация. K-means

- Разделить образцы на **k** групп (классов) автоматически, без информации о настоящем классе образца

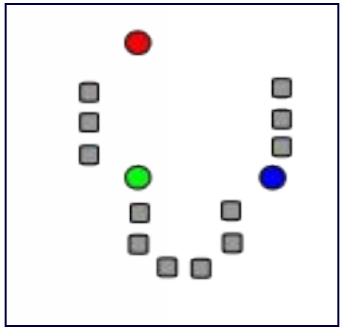

1. **Выбрать начальное положение центров классов**

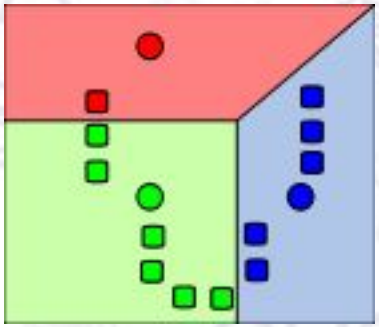

2. **Сгруппировать образцы по принципу близости к центрам**

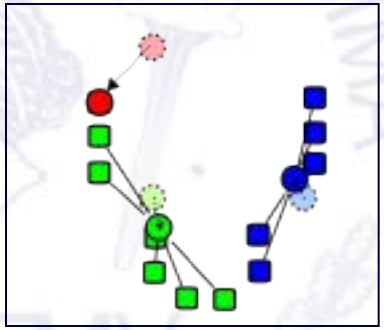

3. **Вычислить новые положения центров**

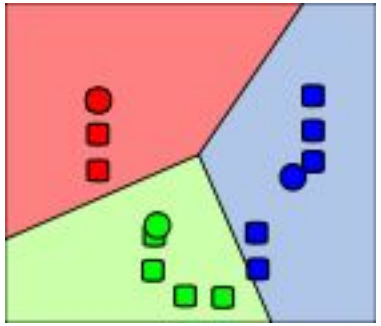

4. **Повторить шаги 2 и 3 до схождения алгоритма**

Классификация (обучение с учителем)

- Цель классификации:

отнести имеющиеся статические образцы (например, данные медосмотра) к определенному классу (например, диагнозу).

Методы:

- Классификатор Байеса
- Дерево решений
- Нейронная сеть
- Метод k ближайших соседей

Классификация

- 25 пациентов, перенесших ишемический инсульт; 44 показателя
- Факторы риска
  - ишемическая болезнь сердца
  - артериальная гипертензия
  - сахарный диабет
  - курение
  - …
- Классифицирующий признак: патогенетический тип инсульта
  - кардиоэмболический
  - некардиоэмболический (атеротромботический, лакунарный, криптогенный, гемореонологический)
- Другие признаки
  - применяемые препараты
  - шкала NIHSS (**National Institutes of Health Stroke Scale)**

Наивный классификатор Байеса

- Классификатор Байеса—вероятностный классификатор, основанный на применении Теоремы Байеса со строгими (наивными) предположениями о независимости.
- Достоинством данного классификатора является малое количество данных для обучения, необходимых для оценки параметров, требуемых для классификации.

accuracy: 93.33% +/- 13.33% (mikro: 92.00%)

	true Некардиоэмболический	true Кардиоэмболический	class precision
pred. Некардиоэмболический	20	2	90.91%
pred. Кардиоэмболический	0	3	100.00%
class recall	100.00%	60.00%	

Наивный классификатор Байеса

Формула Байеса для совместной вероятности

$$p(C|F_1,\ldots,F_n) = \frac{p(C)\ p(F_1,\ldots,F_n|C)}{p(F_1,\ldots,F_n)}$$

$$\begin{aligned}
&p(C, F_1,\ldots,F_n)\\
&\quad = p(C)\ p(F_1,\ldots,F_n|C)\\
&\quad = p(C)\ p(F_1|C)\ p(F_2,\ldots,F_n|C,F_1)\\
&\quad = p(C)\ p(F_1|C)\ p(F_2|C,F_1)\ p(F_3,\ldots,F_n|C,F_1,F_2)\\
&\quad = p(C)\ p(F_1|C)\ p(F_2|C,F_1)\ p(F_3|C,F_1,F_2)\ p(F_4,\ldots,F_n|C,F_1,F_2,F_3)
\end{aligned}$$

Наивное предположение: свойства F_i и F_j условно независимы

$$p(F_i|C,F_j) = p(F_i|C)$$

И тогда

$$p(C,F_1,\ldots,F_n) = p(C)\ p(F_1|C)\ p(F_2|C)\ p(F_3|C)\ \cdots\ = p(C)\prod_{i=1}^{n} p(F_i|C)$$

Нейронные сети

При обучении сети предлагаются различные образцы образов с указанием того, к какому классу они относятся. Образец, как правило, представляется как вектор значений признаков. При этом совокупность всех признаков должна однозначно определять класс, к которому относится образец

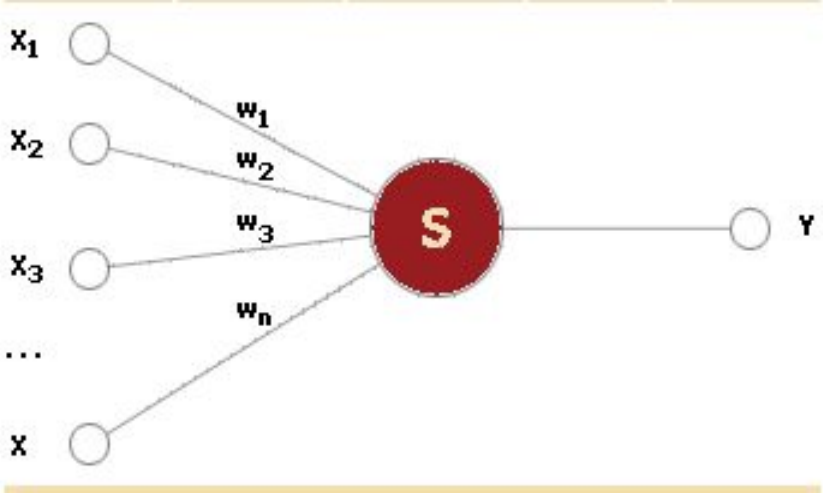

Table View Plot View

accuracy: 93.33% +/- 13.33% (mikro: 92.00%)

	true Некардиоэмболический	true Кардиоэмболический	class precision
pred. Некардиоэмболический	19	1	95.00%
pred. Кардиоэмболический	1	4	80.00%
class recall	95.00%	80.00%	

Нейронные сети

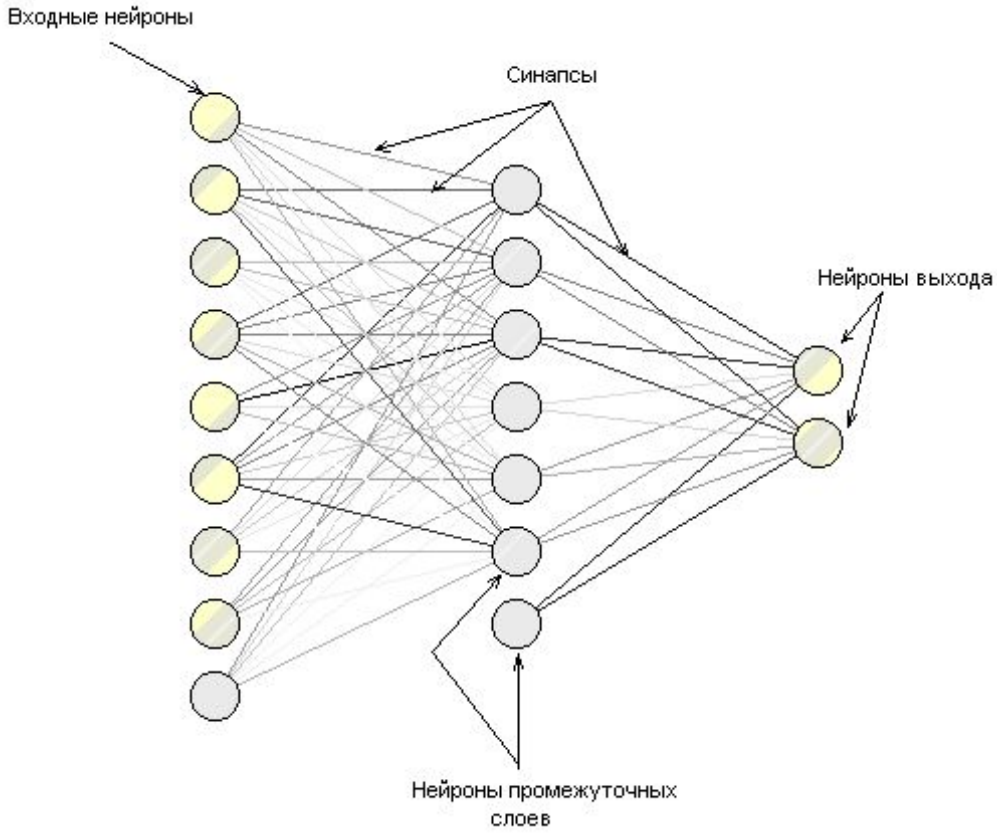

Чем сильнее связь между нейронами тем более четкой линией она отображается, чем слабее — тем линия прозрачнее

САНКТ-ПЕТЕРБУРГСКИЙ ГОСУДАРСТВЕННЫЙ
МЕДИЦИНСКИЙ УНИВЕРСИТЕТ
ИМЕНИ АКАДЕМИКА И. П. ПАВЛОВА

Кафедра физики, математики и информатики

Нейронные сети, изучение космических снимков

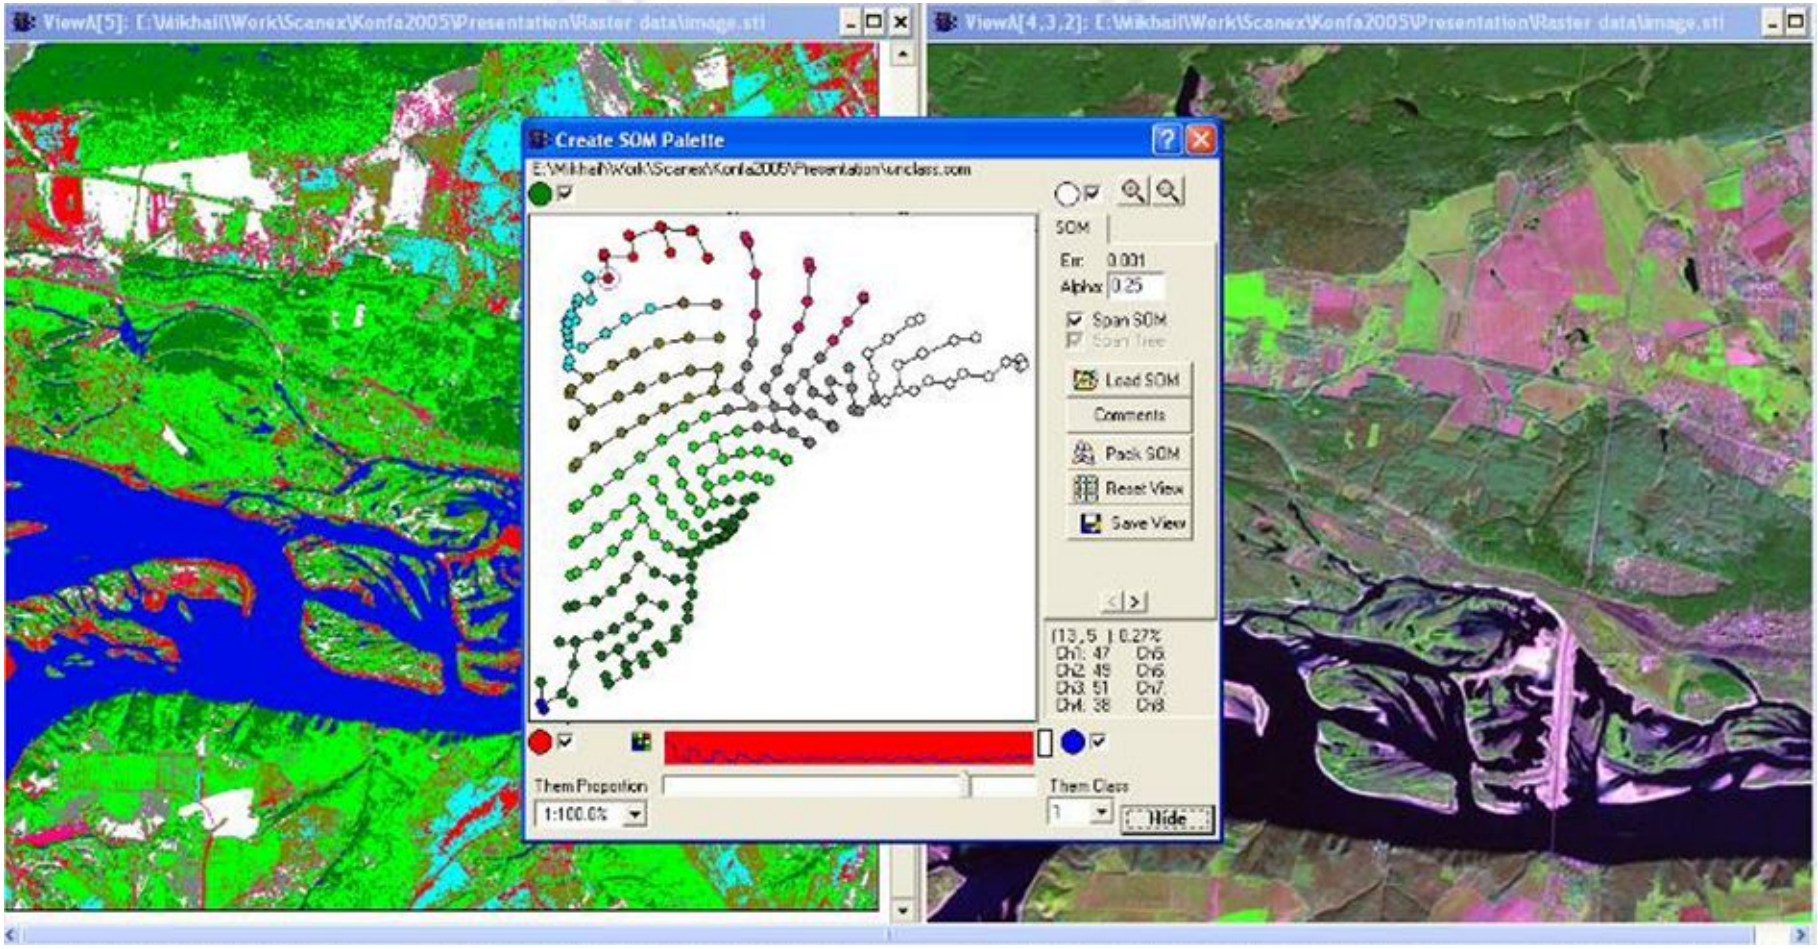

Дерево решений

Деревья принятия решений- это дерево, на ребрах которого записаны атрибуты, от которых зависит целевая функция, в листьях записаны значения целевой функции, а в остальных узлах — атрибуты, по которым различаются случаи.

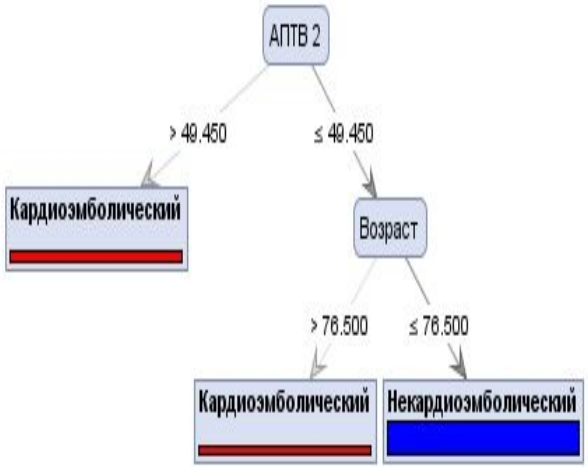

accuracy: 88.33% +/- 18.33% (mikro: 88.00%)

	true Некардиоэмболический	true Кардиоэмболический	class precision
pred. Некардиоэмболический	20	3	86.96%
pred. Кардиоэмболический	0	2	100.00%
class recall	100.00%	40.00%	

Метод k ближайших соседей

Метод k ближайших соседей (англ. *k-nearest neighbor algorithm*, kNN) - метод автоматической классификации объектов. Основным принципом **метода ближайших соседей** является то, что объект присваивается тому классу, который является наиболее распространённым среди соседей данного элемента.
Соседи берутся исходя из множества объектов, классы которых уже известны, и, исходя из ключевого для данного метода значения k высчитывается, какой класс наиболее многочислен среди них.

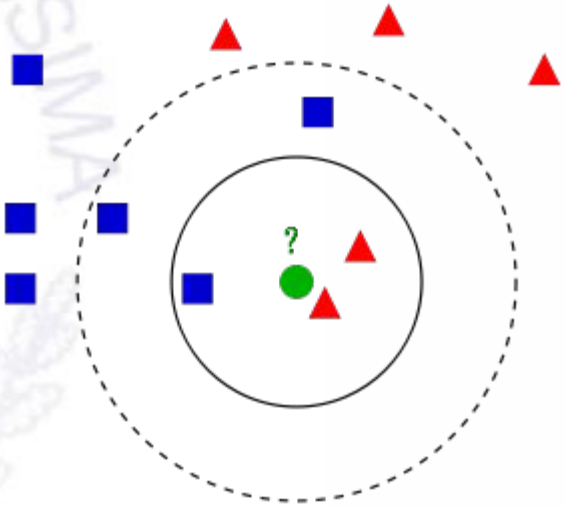

Сравнение классификации и кластеризации

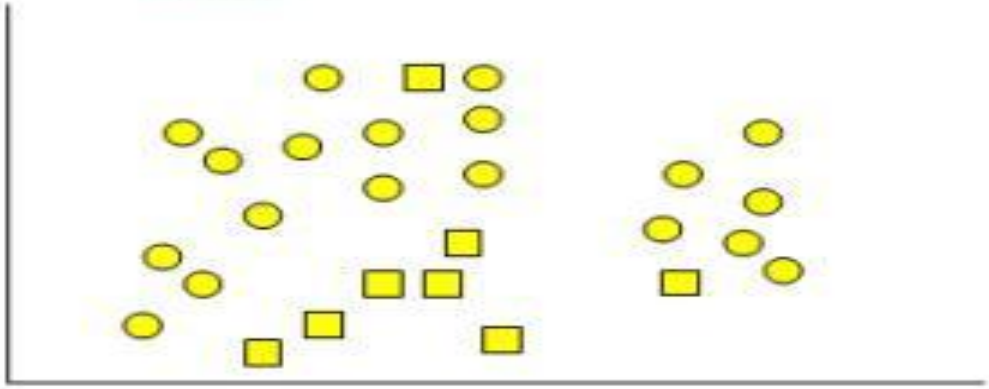

Классификация: классы предопределены изначально

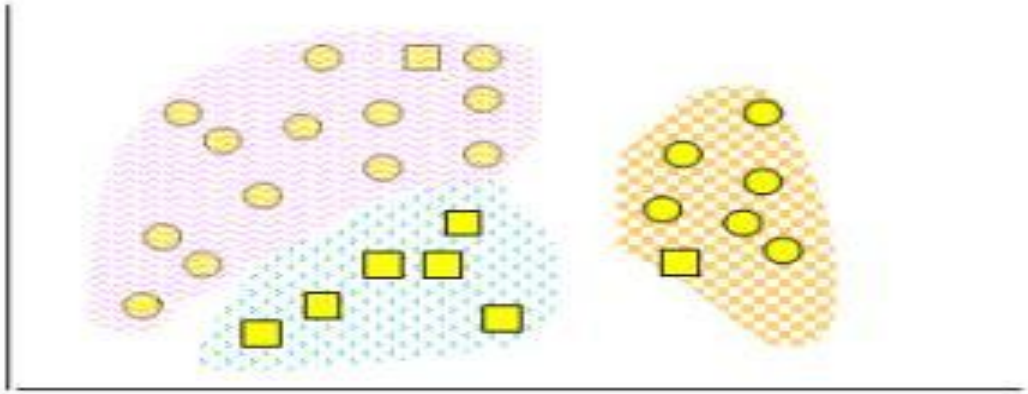

Кластеризация: классы не предопределены, осуществляется поиск наиболее похожих, однородных групп

Бесплатный Data Miner: RapidMiner

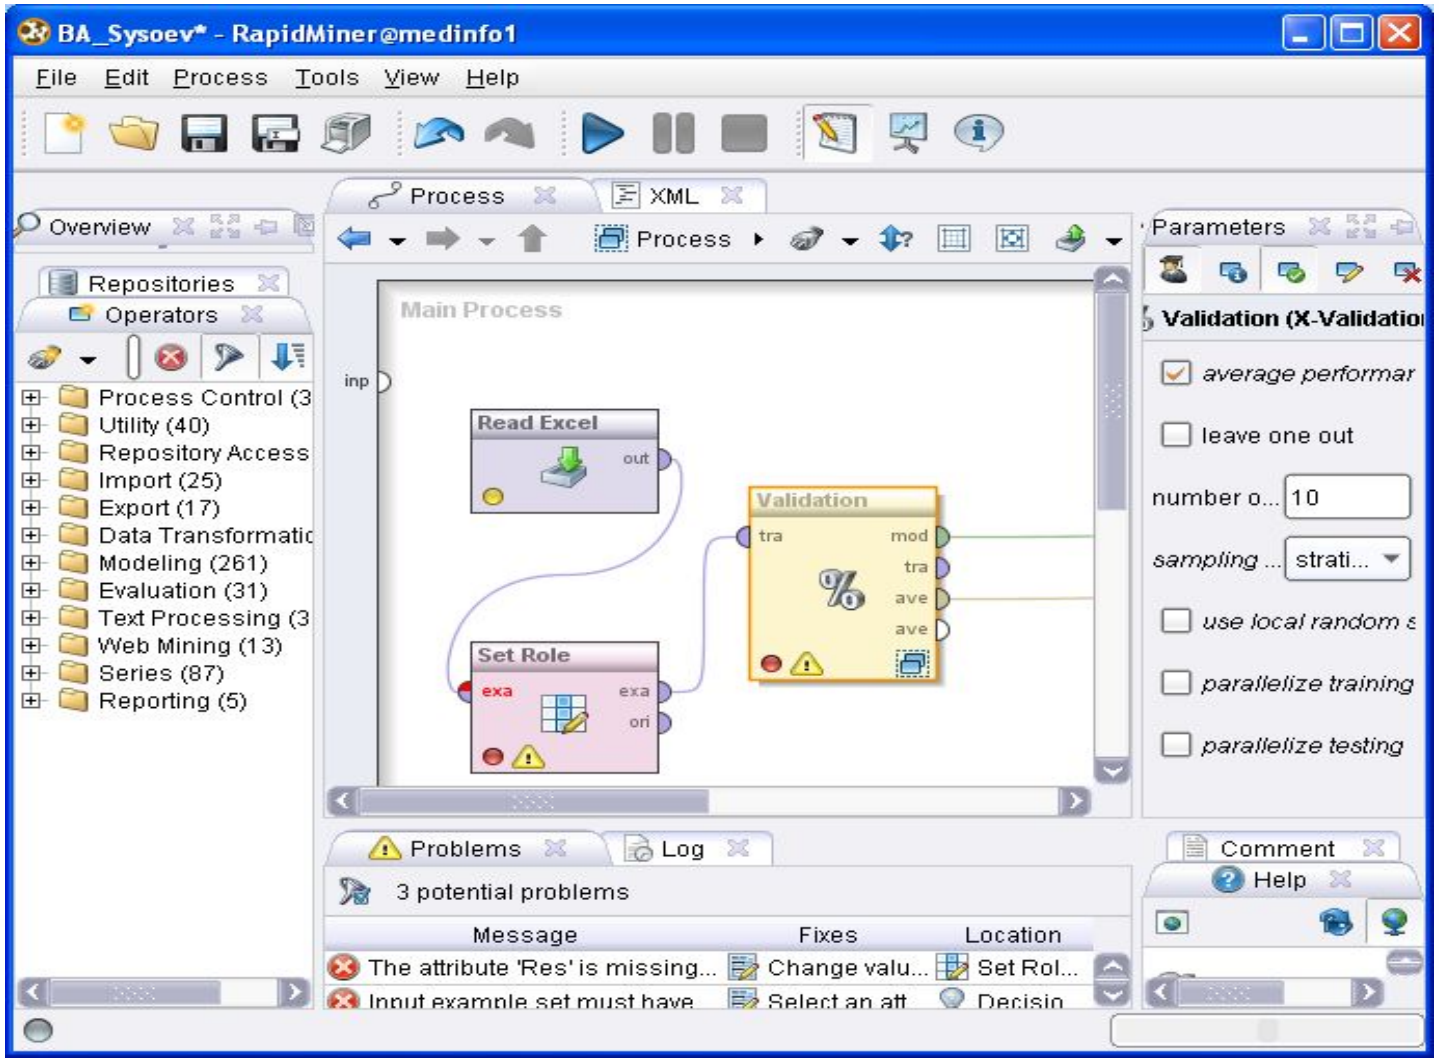

Репозиторий и загрузка данных

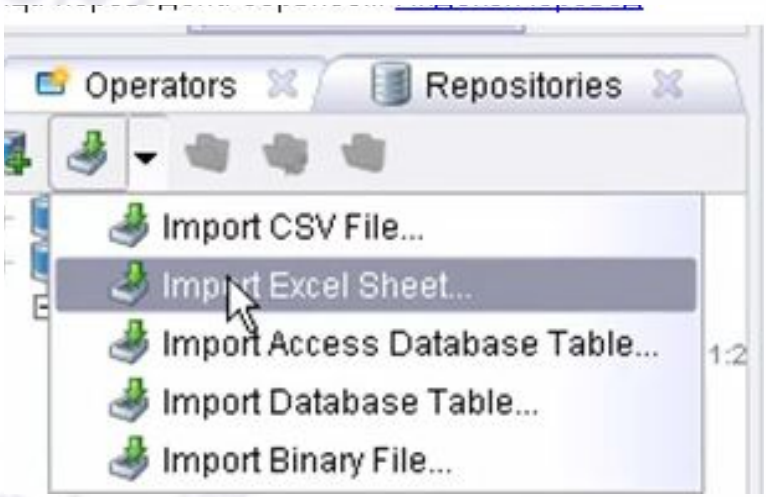

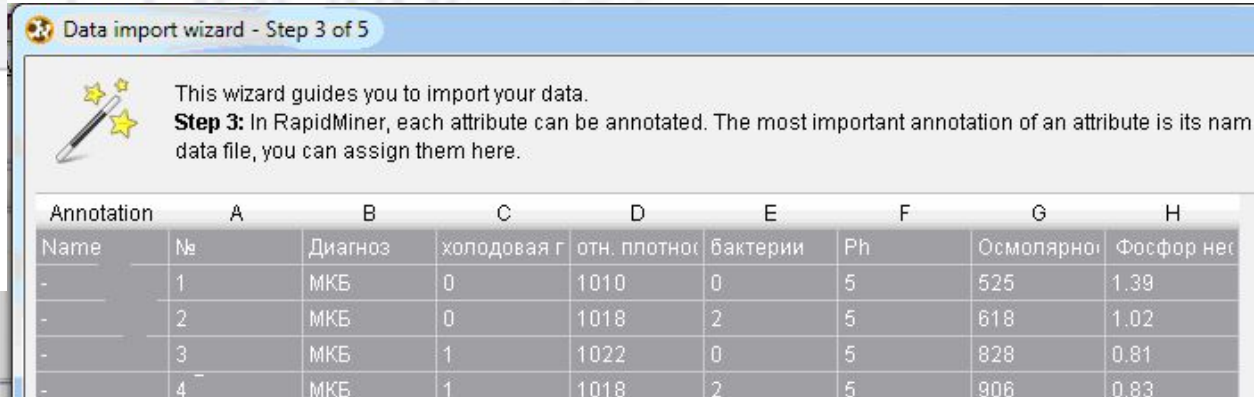

Annotation	A	B	C	D	E	F	G	H
Name	№	Диагноз	холодовая г	отн. плотнос	бактерии	Ph	Осмолярнос	Фосфор нес
-	1	МКБ	0	1010	0	5	525	1.39
-	2	МКБ	0	1018	2	5	618	1.02
-	3	МКБ	1	1022	0	5	828	0.81
-	4	МКБ	1	1018	2	5	906	0.83

Определение видов и типов данных

Data import wizard - Step 4 of 5

This wizard guides you to import your data.
Step 4: RapidMiner uses strongly typed attributes. In this step, you can define the data types of yo
attributes, defining what they can be used for by the individual operators. These roles can be also
them entirely.

Reload data | Guess value types | Preview uses only first 100 rows. | Date format

№	Диагноз	холодовая г	отн. плотно	бактерии	Ph	ни(500-900)	Фосфор не
integer	polyno...	nominal	integer	nominal	real	integer	real
id	label	attribute	attribute	attribute	attribute	attribute	attribute
1	МКБ	0	1010	0	5	525	1.390
2	МКБ	0	1018	2	5	618	1.020
3	МКБ	1	1022	0	5	828	0.810
4	МКБ	1	1018	2	5	906	0.830
5	МКБ	0	1010	1	5	472	1.170

Создание алгоритма анализа данных из блоков

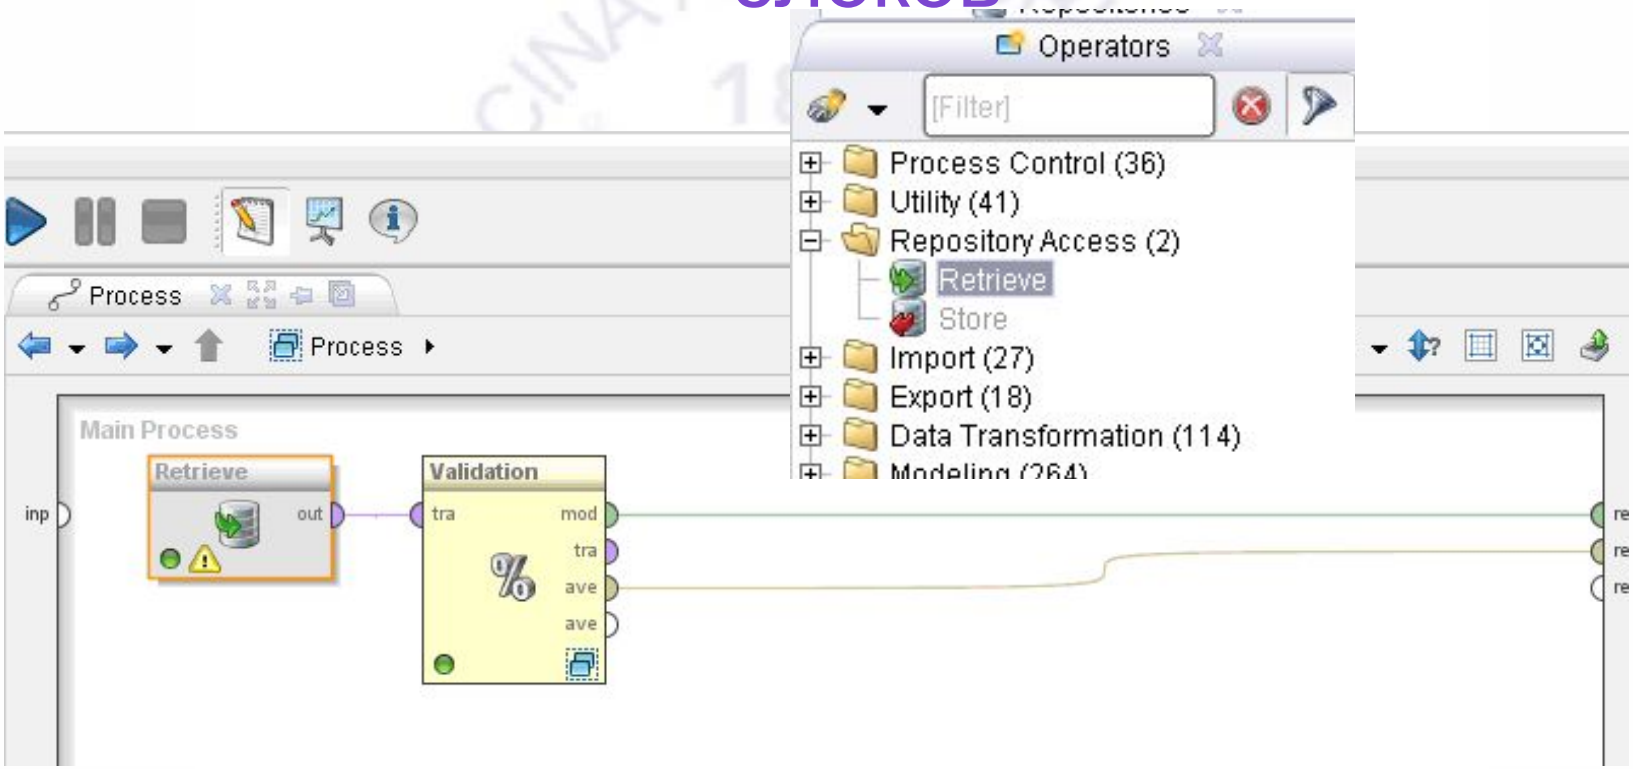

Построение и X-валидация

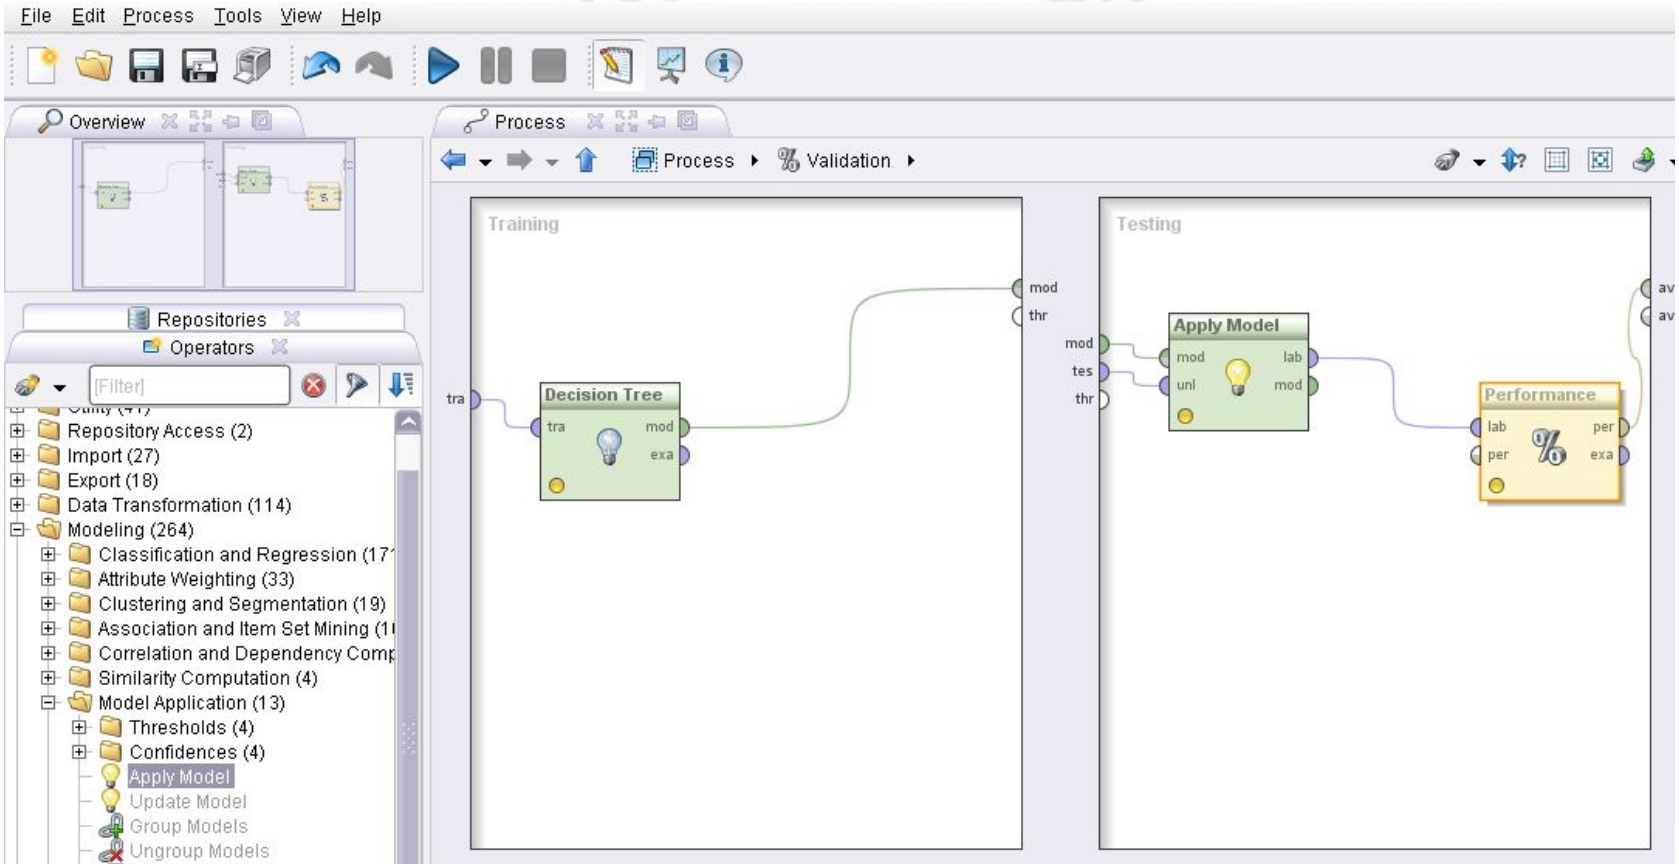

Результат – точность классификации

Result Overview | PerformanceVector (Performance) | Tree (Decision Tree)

Table / Plot View | Text View | Annotations

Criterion Selector
- accuracy
- kappa

Multiclass Classification Performance | Annotations

Table View | Plot View

accuracy: 61.67% +/- 23.63% (mikro: 62.07%)

	true МКБ	true варикоцеле	true пиелонефрит	class precision
pred. МКБ	15	6	1	68.18%
pred. варикоцеле	3	3	1	42.86%
pred. пиелонефрит	0	0	0	0.00%
class recall	83.33%	33.33%	0.00%	

Результат запуска: построенный классификатор

		true y	true n	class precision
accuracy: 82.64% +/- 8.25% (mikro: 82.76%)				
pred. y		61	6	91.04%
pred. n		9	11	55.00%
class recall		87.14%	64.71%	

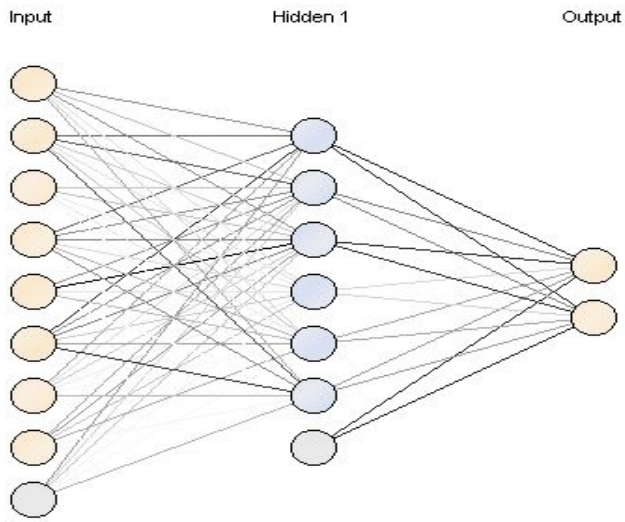

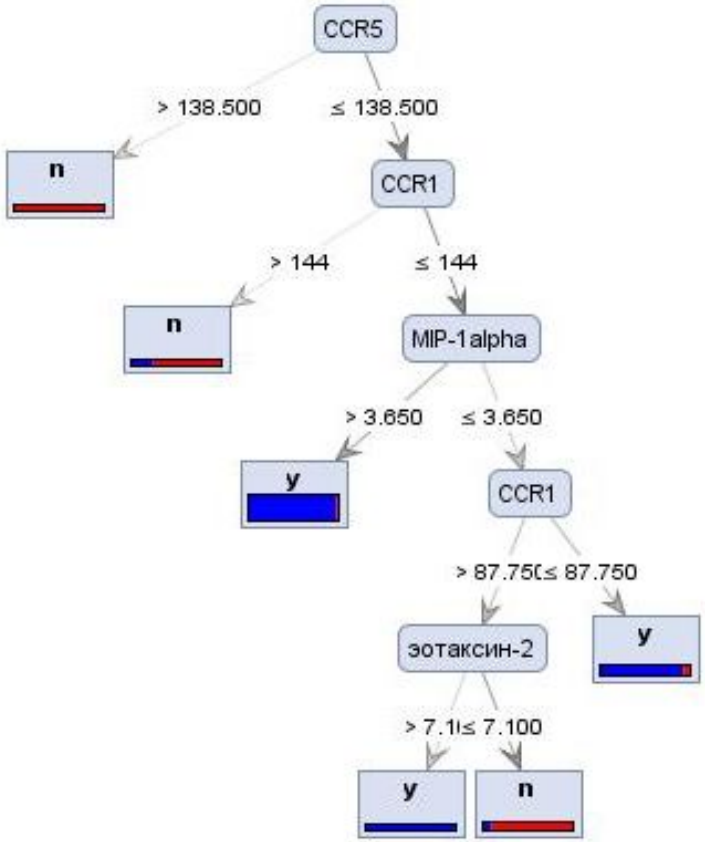

Экспертные системы

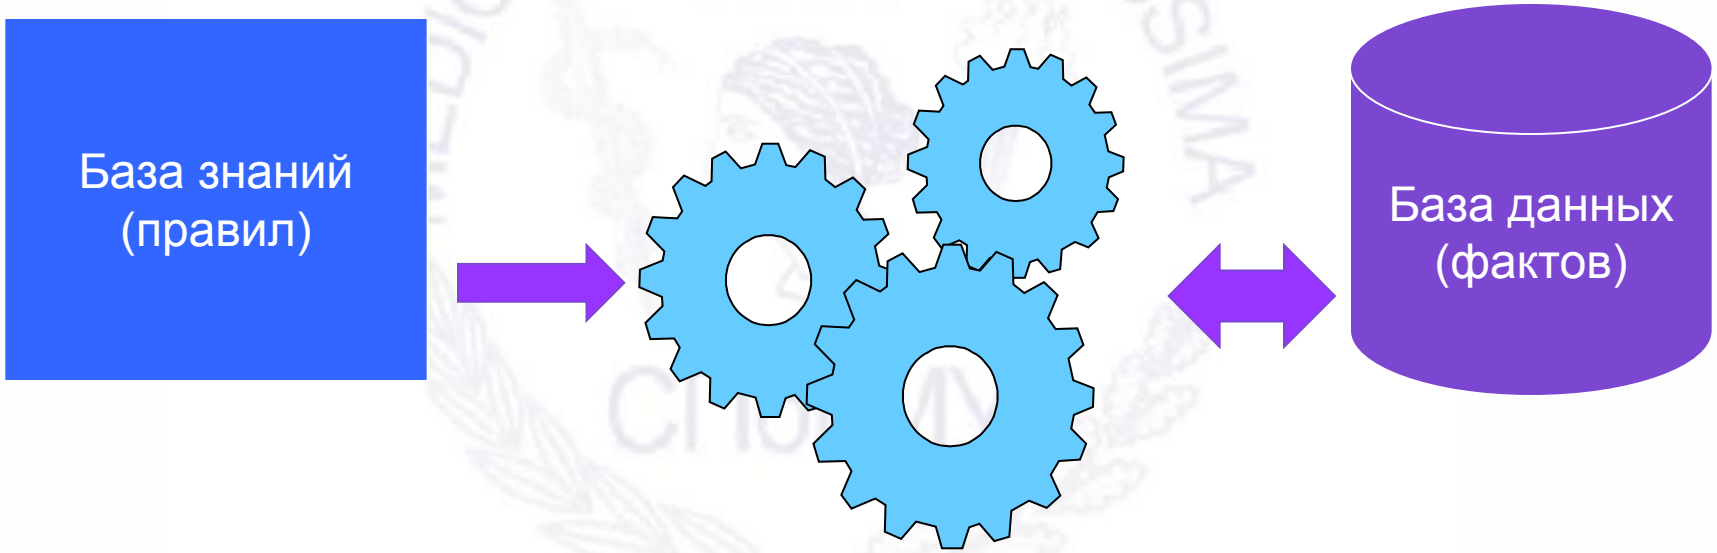

Интеллектуальная медицинская информационная система

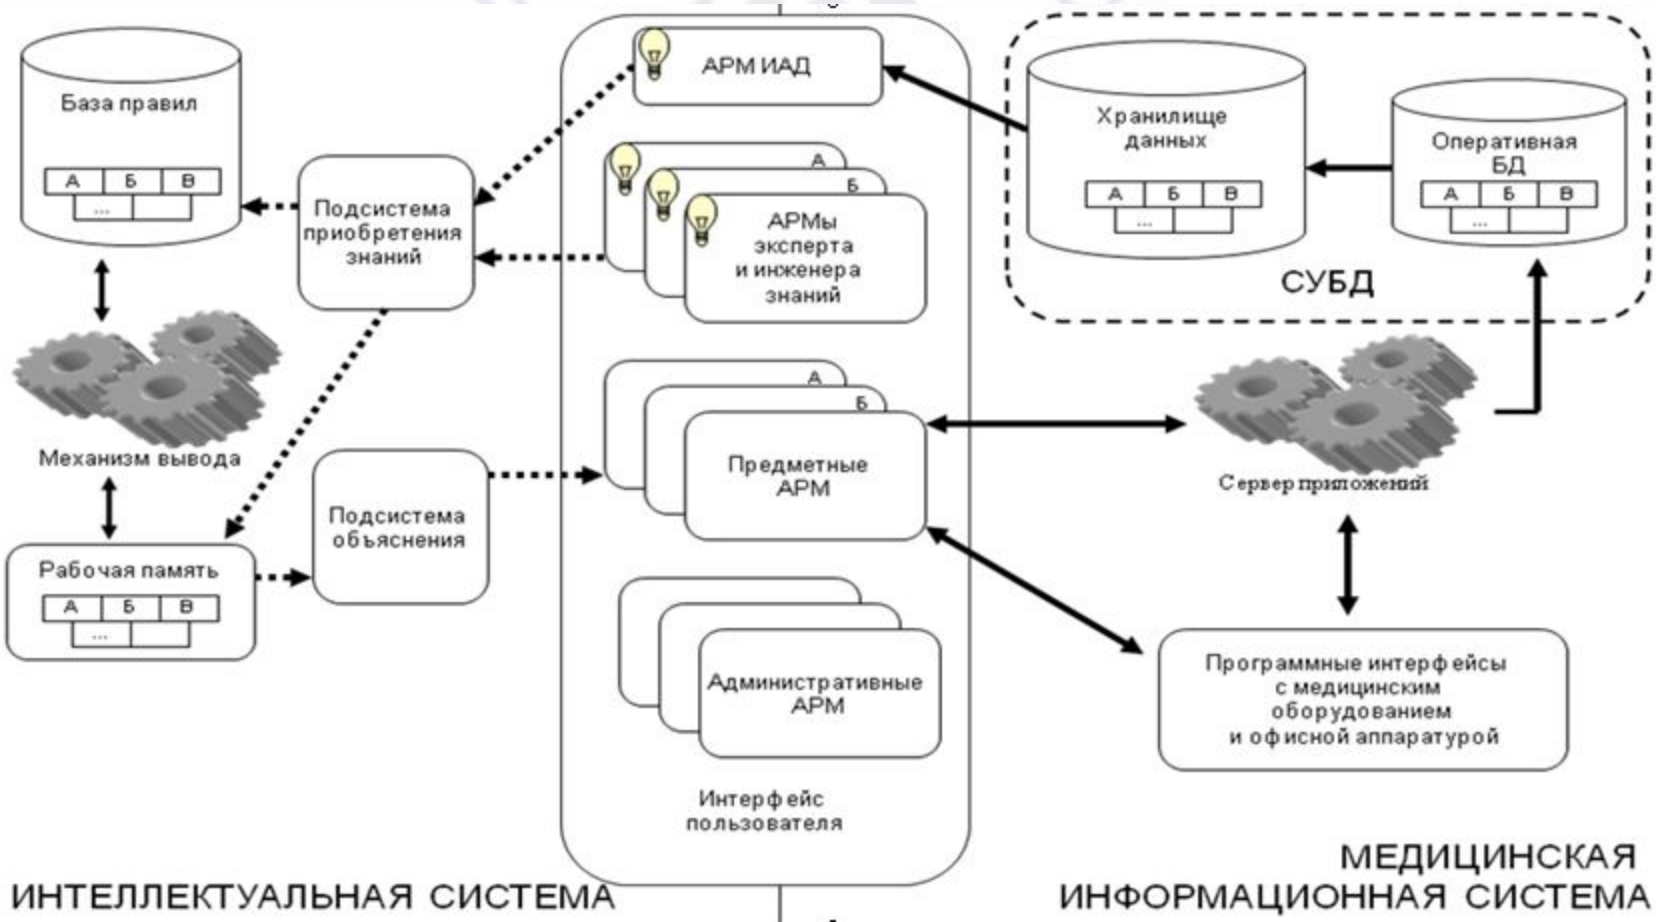

Диагностика мочекаменной болезни

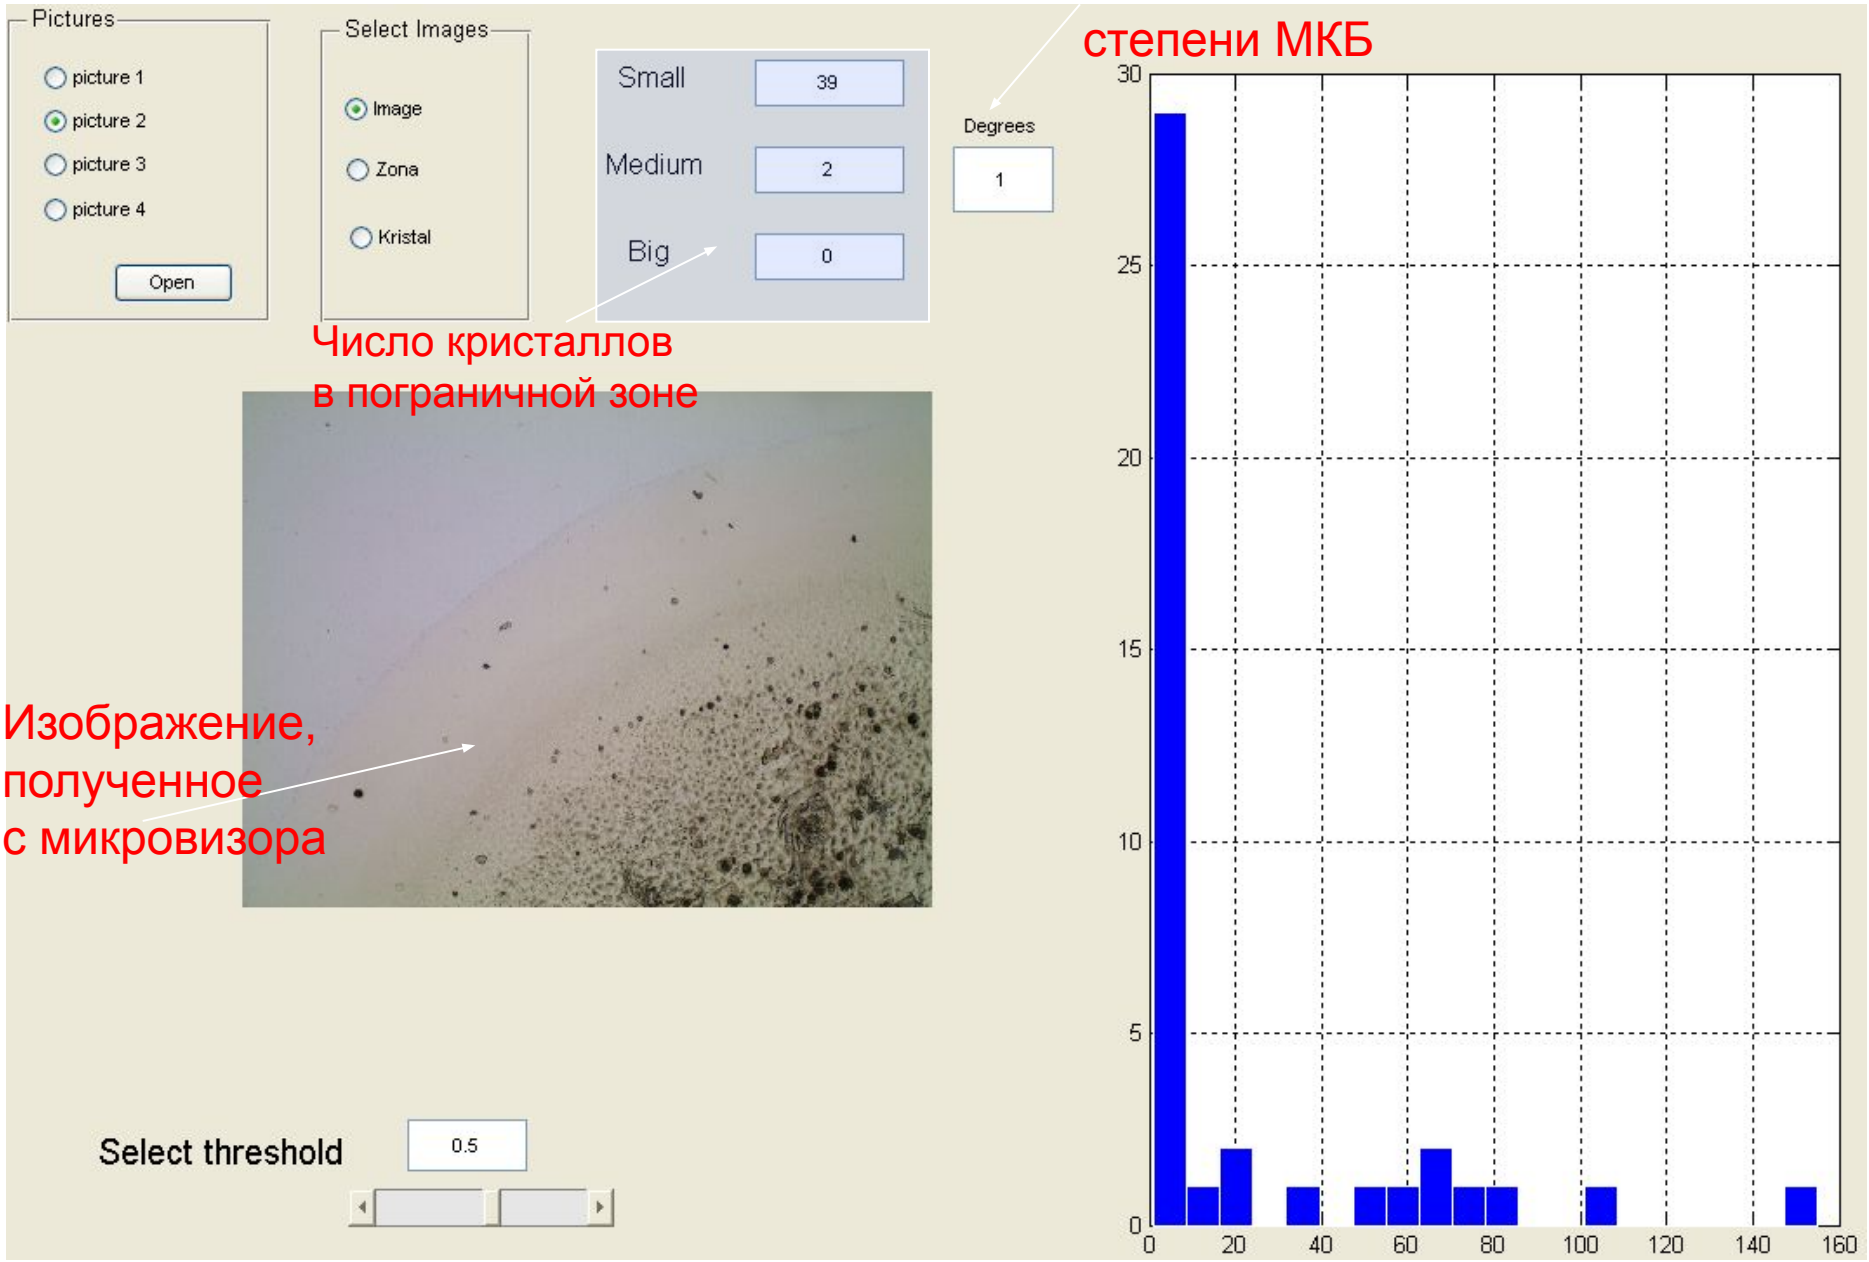
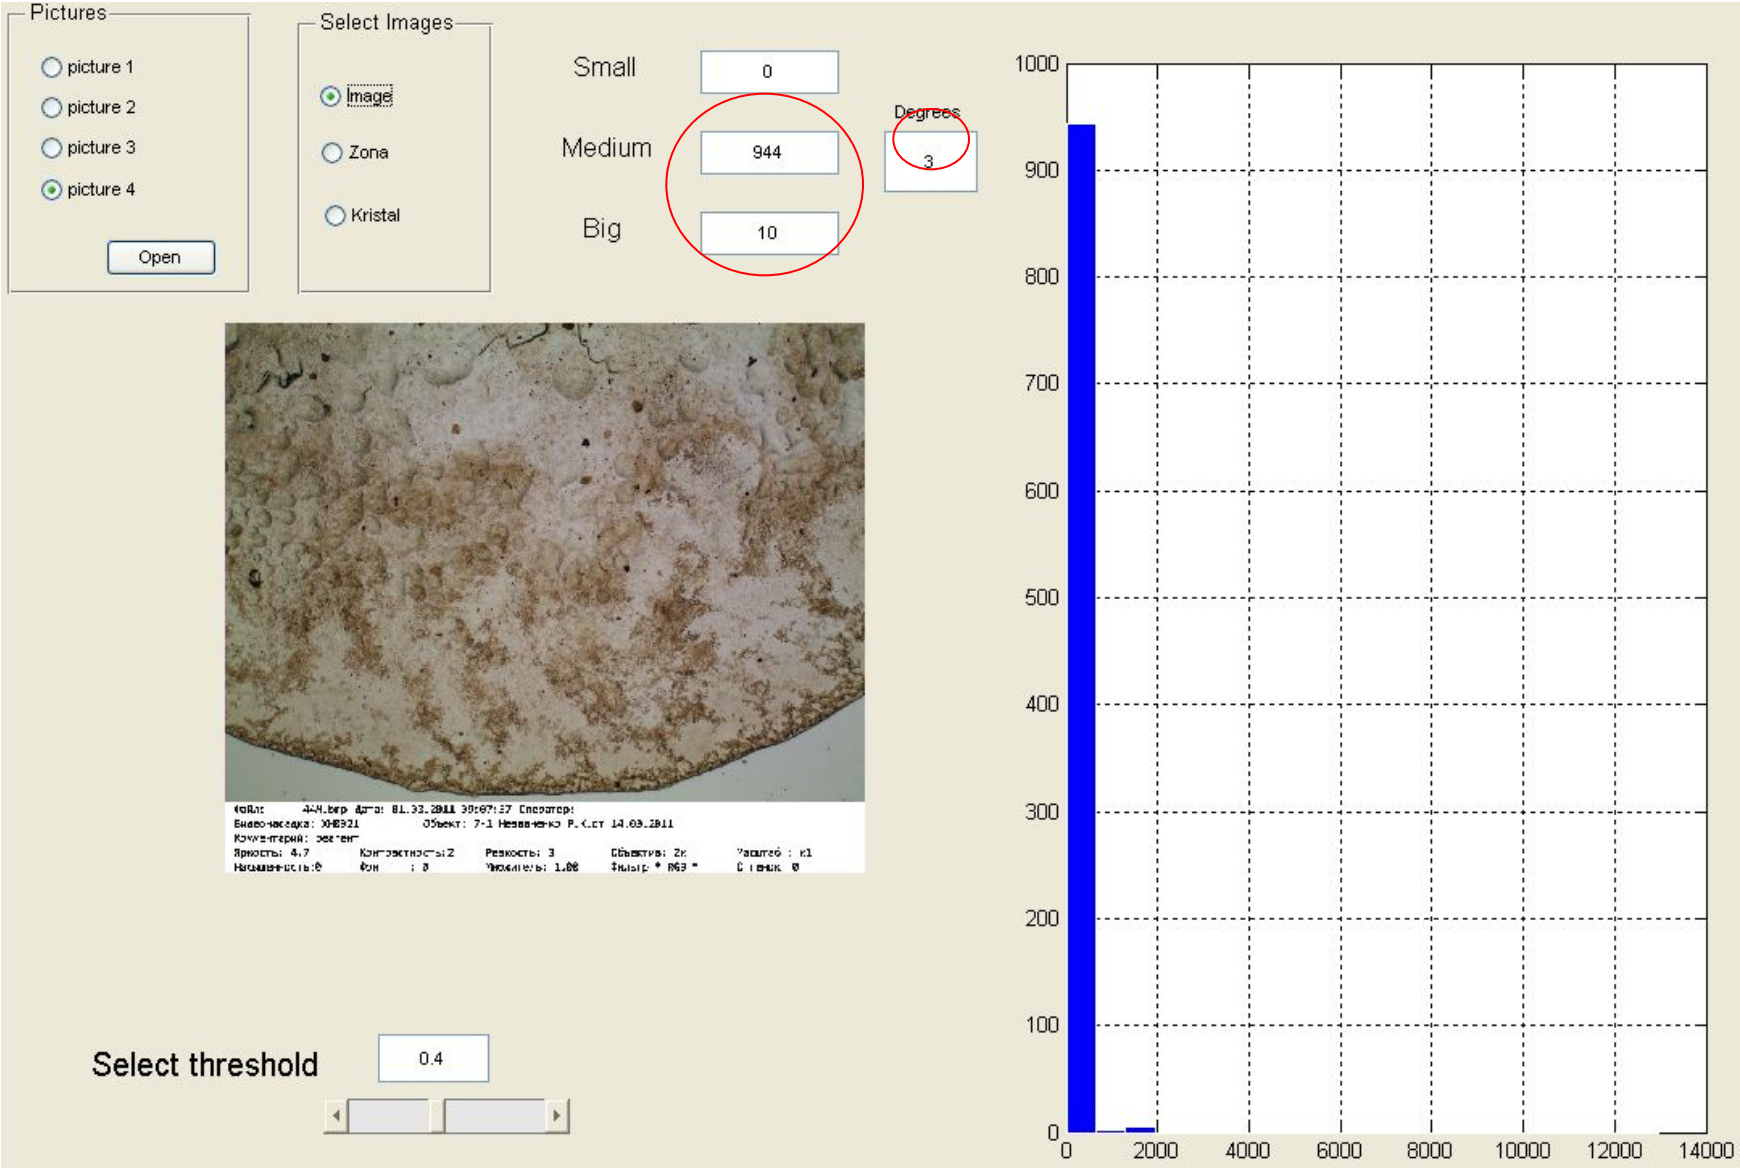
Диагностика мочекаменной болезни