

ОБ ОДНОМ МЕТОДЕ МУЛЬТИАЛГОРИТМИЧЕСКОЙ КЛАССИФИКАЦИИ

Сергей Львов, Владимир Рязанов

Аннотация: В работе рассматривается модель типа вычисления оценок, основанная на системах логических закономерностей для решения задачи классификации с учителем. Предлагается метод нахождения весовых коэффициентов решающего правила, а также два метода устранения отказов от классификации с помощью введения отрицаний дизъюнкции логических закономерностей и аппроксимации логических закономерностей сигмоидными функциями. Приводятся результаты численных экспериментов.

Ключевые слова: классификация, распознавание образов, вычисление оценок, мультиалгоритмический подход, логические закономерности

ACM Classification Keywords: I.2.4 Artificial Intelligence Knowledge Representation Formalisms and Methods – Predicate logic; I.5.1 Pattern Recognition Models – Deterministic, H.2.8 Database Applications, Data mining; I.5.3 Clustering.

Введение

В настоящее время для решения задачи распознавания по прецедентам (классификации с учителем) на основе дискретного анализа выборки прецедентов широкое распространение получили алгоритмы типа вычисления оценок. Их общая идея состоит в следующем. По выборке прецедентов вычисляется эвристическая степень близости $\Gamma_j(\mathbf{x})$, $j = 1, 2, \dots, l$ распознаваемого объекта (оценка) к каждому из конечного числа классов. Объект относится к тому классу, оценка для которого максимальна. В распространенных моделях распознавания оценки $\Gamma_j(\mathbf{x})$, $j = 1, 2, \dots, l$ являются линейными функциями от различных опорных множеств [Журавлев, 1978; Журавлев и др., 2006], тупиковых тестов [Дмитриев и др., 1966], представительных наборов [Баскакова и др., 1981], логических закономерностей [Рязанов, 2007]. Обычно оценки вычисляются как доля некоторых предикатов (функций близости, логических закономерностей), выполненных на распознаваемом объекте, поэтому данные алгоритмы распознавания имеют и другое название – „алгоритмы голосования”. Следует отметить, что целесообразным здесь представляется использование различных весовых коэффициентов.

В настоящей работе рассматривается новая модель типа вычисления оценок, основанная на системах логических закономерностей. Сначала, в результате анализа обучающей информации, для каждого класса находится система логических закономерностей (ЛЗ). Далее в процессе построения решающего правила (которое проводит классификацию произвольного нового объекта) находятся оптимальные весовые коэффициенты линейной формы от логических закономерностей. Весь процесс можно представить, как последовательное применение двух известных алгоритмов. Сначала находятся логические закономерности классов [Ковшов и др., 2008], а затем – оптимальная линейная разделяющая функция в некотором новом признаковом пространстве (применяя, например, алгоритм „метод опорных векторов”, „линейная машина” или „линейный дискриминант Фишера”). Поэтому данный подход можно считать мультиалгоритмический, в котором последовательно работают два алгоритма. Отметим, что другая распространенная мультиалгоритмическая классификация предполагает параллельное применение различных алгоритмов. Там конечное множество классификаторов строится независимо друг от друга на одной и той же обучающей выборке. При классификации нового объекта независимо применяется каждый из классификаторов. Далее вычисляется его окончательная классификация - „коллективное решение”. Представителями данного мультиалгоритмического подхода являются алгебраический подход [Журавлев, 1978], алгоритм ADABOOST [Freund et al, 1995], многие другие процедуры. Настоящая статья будет посвящена именно первому „последовательному” подходу.

Алгоритмы распознавания, основанные на голосовании по системам логических закономерностей

Будем рассматривать задачу распознавания (классификации с учителем) по прецедентам в следующей стандартной постановке [Журавлев, 1978]. Дано множество M объектов x , заданных своими признаковыми описаниями $x = \{x_1, x_2, \dots, x_n\}, x_i \in R$, причем

$M = \{x\} = \bigcup_{i=1}^l K_i, K_i \cap K_j = \emptyset, i, j = 1, 2, \dots, l, i \neq j$. Множества K_i называются классами. Дана

обучающая выборка $X = \{x\} \subseteq M$, содержащая хотя бы по одному представителю каждого класса. Требуется создать алгоритм A , который отнесет произвольный объект $x \in M$ к одному из классов.

Далее для простоты будем считать выражение вида $(a \leq x)$ равным единице при его выполнении и равным нулю в ином случае. Будем использовать следующее определение логической закономерности класса (ЛЗК) [Рязанов, 2007].

Определение 1. Предикат

$$P^{a,b,\Omega_1,\Omega_2}(\mathbf{x}) = \big\&_{i \in \Omega_1} (a_i \leq x_i) \big\&_{i \in \Omega_2} (x_i \leq b_i), |\Omega_1| = k_1, |\Omega_2| = k_2 \quad (1)$$

будем называть логической закономерностью класса (ЛЗК) $K_t, t = 1, 2, \dots, l$, если выполнены условия

1. $\exists \mathbf{x}_j \in X \cap K_t : P^{a,b,\Omega_1,\Omega_2}(\mathbf{x}_j) = 1$.
2. $\forall \mathbf{x}_j \notin X \cap K_t : P^{a,b,\Omega_1,\Omega_2}(\mathbf{x}_j) = 0$.
3. $F(P^{a,b,\Omega_1,\Omega_2}(\mathbf{x})) = \text{extr} F(P^{a^*,b^*,\Omega_1^*,\Omega_2^*}(\mathbf{x}))$, где $\mathbf{a}^*, \mathbf{b}^* \in R^n, \mathbf{a}^* \leq \mathbf{b}^*, \Omega_1^*, \Omega_2^* \subseteq \{1, 2, \dots, n\}$, F - некоторый критерий качества предиката.

Будем рассматривать задачу локальной максимизации функции $F(P^{a,b,\Omega_1,\Omega_2}(\mathbf{x})) = \left| \left\{ \mathbf{x}_j \in X \cap K_t : P^{a,b,\Omega_1,\Omega_2}(\mathbf{x}_j) = 1 \right\} \right|$. Две ЛЗ класса K_t мы будем называть

эквивалентными, если их значения на объектах обучающей выборки совпадают. Назовем минимальной логической закономерностью класса K_t ЛЗК следующего вида:

$$P^{a,b}(\mathbf{x}) = \big\&_{i \in \{1, 2, \dots, n\}} (a_i \leq x_i \leq b_i), \quad a_i = \min_j \{x_{ji} : P^{c,d,\Omega_1,\Omega_2}(\mathbf{x}_j) = 1\}, \quad b_i = \max_j \{x_{ji} : P^{c,d,\Omega_1,\Omega_2}(\mathbf{x}_j) = 1\},$$

$j = 1, 2, \dots, m$, где $P^{c,d,\Omega_1,\Omega_2}(\mathbf{x})$ - некоторая ЛЗК. Множество $N_\lambda = \{\mathbf{x} : P_\lambda^{a,b,\Omega_1,\Omega_2}(\mathbf{x}) = 1\}$ называется интервалом ЛЗК $P_\lambda^{a,b,\Omega_1,\Omega_2}(\mathbf{x})$. Можно показать, что для любого множества эквивалентных ЛЗК существует единственная минимальная ЛЗК. В работе [Ковшов и др., 2008] изложены различные приближенные и „точный” методы поиска ЛЗК.

Пусть по обучающей выборке X для каждого класса K_t найдено некоторое множество его ЛЗК: $\mathbf{P}_t = \{P_\lambda^{a,b,\Omega_1,\Omega_2}(\mathbf{x})\}$. Тогда в методе распознавания, основанном на голосовании по системам ЛЗК, оценка близости объекта \mathbf{x} к классу K_t вычисляется по формуле:

$$\Gamma_t(\mathbf{x}) = \sum_{P_\lambda \in \mathbf{P}_t} \gamma_\lambda P_\lambda(\mathbf{x}), \quad (2)$$

где коэффициенты $0 \leq \gamma_\lambda \leq 1$ находятся в результате решения оптимизационных задач (например, [Рязанов, 2007]) или вычисляются как $\gamma_\lambda = \frac{1}{|\mathbf{P}_t|}$.

Алгоритмы распознавания, основанные на взвешенном голосовании по системам логических закономерностей

Вычисление оценок степени близости к классам по формуле (2) в некоторых случаях может привести к неудовлетворительным результатам при распознавании новых объектов. На Рис. 1 приведен подобный простой пример. В данной задаче распознавания с двумя классами каждый класс описывается лишь одной закономерностью, интервалы закономерностей (области U и V) графически представлены на Рис. 1. Однако, при распознавании произвольного объекта, лежащего вне данных интервалов, будут вычислены нулевые значения оценок за оба класса. Подобный эффект можно устранить с помощью введения отрицаний ЛЗК (что эквивалентно использованию „антиблизостей”) и аппроксимации ЛЗК сигмоидными функциями. Далее будет рассматриваться случай двух классов.




Рис. 1. Пример „простой” задачи с двумя классами

Рассмотрим сначала вопрос модификации модели и вычисления оптимальных весовых коэффициентов. Модификация будет состоять в использовании вместо (2) выражения

$$f(\mathbf{x}) = \sum_{i=1,2,\dots,m(1)} \alpha_i^1 P_i^1(\mathbf{x}) + \alpha_0^1 \overline{\bigvee_{i=1,2,\dots,m(2)} P_i^2(\mathbf{x})} - \sum_{i=1,2,\dots,m(2)} \alpha_i^2 P_i^2(\mathbf{x}) - \alpha_0^2 \overline{\bigvee_{i=1,2,\dots,m(1)} P_i^1(\mathbf{x})}, \quad (3)$$

Здесь $P_i^1(\mathbf{x}), i = 1, 2, \dots, m(1)$ и $P_i^2(\mathbf{x}), i = 1, 2, \dots, m(2)$ - вычисленные ЛЗК первого и второго класса соответственно, $\alpha_0^1, \alpha_0^2, \alpha_i^1, \alpha_i^2$ - весовые коэффициенты. Объект \mathbf{x} будем относить к первому классу, если $f(\mathbf{x}) > 0$ и ко второму, если $f(\mathbf{x}) < 0$ (при $f(\mathbf{x}) = 0$ происходит отказ от распознавания или случайная классификация).

Построение функции $f(\mathbf{x})$ можно рассматривать как последовательное решение двух задач:

1. Вычисление ЛЗК $P_i^1(\mathbf{x}), i = 1, 2, \dots, m(1)$, $P_i^2(\mathbf{x}), i = 1, 2, \dots, m(2)$ и переход к новому $m(1) + m(2) + 2$ -мерному признаковому пространству их значений и отрицаний соответствующих дизъюнкций.
2. Поиск весовых коэффициентов посредством вычисления в новом признаковом пространстве разделяющей гиперплоскости, используя линейный метод, например, „метод опорных векторов”, „линейная машина” или „линейный дискриминант Фишера” [Duda et al, 2000].

Отметим, что в новом признаковом пространстве объектам первого класса обучающей выборки будут соответствовать векторы вида $\mathbf{y} = (\sigma_1, \sigma_2, \dots, \sigma_{m(1)}, 1, 0, 0, \dots, 0), \sigma_t \geq 0, \sum_{t=1}^{m(1)} \sigma_t > 0$, а объектам

второго – $\mathbf{z} = (0, 0, \dots, 0, \theta_1, \theta_2, \dots, \theta_{m(2)}, 1), \theta_t \geq 0, \sum_{t=1}^{m(2)} \theta_t > 0$, и, значит, классы будут линейно разделимы в данном пространстве.

Случай, когда число классов больше двух, разрешается следующим образом. Непосредственно распознавание новых объектов происходит линейным классификатором в новом признаковом пространстве, поэтому здесь возможно применение стандартных стратегий сведения многоклассовой классификации к двухклассовой. Например, при использовании „метода опорных векторов” часто используется стратегия „один против всех”.

Алгоритмы распознавания, основанные на взвешенном голосовании по системам логических закономерностей и их функциям с использованием сигмоидных аппроксимаций

Пусть имеется некоторая ЛЗК класса K_t вида (1). Мы хотим аппроксимировать ее гладкой функцией (произведением „сигмоид”).

Упростим данную задачу следующим образом:

1. $\alpha_i \equiv \beta_i = \alpha > 0$ в выражении

$$P^{a,b,\Omega_1,\Omega_2}(\mathbf{x}) \approx \Phi^{a,b,\Omega_1,\Omega_2}(\mathbf{x}) = \prod_{i \in \Omega_1} \frac{1}{(1 + \exp(-\alpha_i(x_i - a_i)))} \prod_{i \in \Omega_2} \frac{1}{(1 + \exp(\beta_i(x_i - b_i)))} \quad (4)$$

2. Поиск параметров α_i, β_i сведем к решению уравнения $\frac{1}{(1 + \exp(\alpha\sigma))^k} = 1 - \sigma$, где $0 < \sigma < 1$ - параметр алгоритма, который задает „граничную область” отдельного сомножителя и „максимум” функции $\Phi^{a,b,\Omega_1,\Omega_2}(\mathbf{x})$, $k = k_1 + k_2$. В результате, параметр

$\alpha \equiv \alpha_i \equiv \beta_i$ будет вычисляться по заданному σ по формуле $\alpha = \frac{\ln\left((1-\sigma)^{-\frac{1}{k}} - 1\right)}{\sigma}$.

Окончательно аппроксимация (4) для $P^{a,b,\Omega_1,\Omega_2}(\mathbf{x})$ будет вычисляться как

$$\Phi^{a,b,\Omega_1,\Omega_2}(\mathbf{x}) = \prod_{i \in \Omega_1} \frac{1}{(1 + \exp(-\alpha(x_i - a_i)))} \prod_{i \in \Omega_2} \frac{1}{(1 + \exp(\alpha(x_i - b_i)))} \quad (5)$$

Параметры a_i, b_i известны для каждой логической закономерности. В выражении (5) значения признаков и данные параметры ранее нормируются (например, путем деления на разброс признака по таблице).

Простой пример одномерной аппроксимации с параметром $\alpha = 1$ приведен на Рис. 2.




Рис. 2. Пример аппроксимации

Итак, если задано число $0 < \sigma < 1$, то для каждой ЛЗ $P^{a,b,\Omega_1,\Omega_2}(\mathbf{x})$ и объекта \mathbf{x} мы можем вычислить значение $\Phi^{a,b,\Omega_1,\Omega_2}(\mathbf{x})$. Распознавание объекта \mathbf{x} будем производить по формуле, аналогичной (3) (за исключением использования отрицаний дизъюнкций):

$$f(\mathbf{x}) = \sum_{i=1,2,\dots,m(1)} \alpha_i^1 \Phi_i^1(\mathbf{x}) - \sum_{i=1,2,\dots,m(2)} \alpha_i^2 \Phi_i^2(\mathbf{x}), \quad (6)$$

при этом объект будет отнесен к первому классу, если $f(\mathbf{x}) > 0$, ко второму, если $f(\mathbf{x}) < 0$. В случае $f(\mathbf{x}) = 0$ происходит отказ от распознавания или случайная классификация.

В данном случае построение функции $f(\mathbf{x})$ также можно рассматривать как выполнение двух последовательных шагов:

1. Вычисление аппроксимаций $\Phi_i^1(\mathbf{x}), \Phi_i^2(\mathbf{x})$ и переход к новому признаковому пространству размерности $m(1) + m(2)$.
2. Поиск весовых коэффициентов посредством вычисления в новом признаковом пространстве разделяющей гиперплоскости, используя линейный метод.

Отдельно отметим, что при использовании аппроксимации сигмоидами не утверждается о линейной разделимости классов в новом признаковом пространстве. Также стоит указать, что оригинальная модель вычисления оценок, основанная на системах ЛЗК, обладает следующим свойством. После построения модели, все объекты обучающей выборки будут распознаваться верно, т.к. всегда существует ЛЗК, внутри интервала которой лежит этот объект. Применение аппроксимации, вообще говоря, нарушает это свойство.

Результаты экспериментов на модельных и практических задачах

Предложенные в работе методы были протестированы на наборах модельных и практических данных. Во всех примерах для визуализации использовалась проекция многомерных данных на плоскость обобщенных признаков [Duda et al, 2000; Журавлев и др., 2006]. Во всех практических задачах пропуски данных заполнялись средним значением по признаку. В качестве модельных задач использовались выборки из смеси многомерных нормальных распределений. Математические ожидания и матрицы ковариации выбирались таким образом, чтобы классы не являлись линейно отделимыми. В дальнейшем конкретной „модельной задачей” является задача со следующими характеристиками: 2 класса, 3 признака, 240 объектов обучающей и 60 объектов контрольной выборки.

Практические данные представлены следующими задачами: „**breast**” [Mangasarian et al, 1990], „**credit**” [Bache et al., 2013], „**Image**” [Bache et al., 2013]. Характеристики данных приведены в Таблице 1.

Таблица 1. Характеристики практических задач

Задача	Число классов	Число признаков	Число объектов обучающей выборки	Число объектов контрольной выборки
„breast”	2	9	344	355
„credit”	2	15	342	348
„Image”	7	16	210	2100

На Рис. 3 - 5 показаны визуализации исходных обучающих данных модельной задачи и задач „breast” и „credit”. Визуализация задачи „Image” не приведена ввиду большого числа классов.

Для построения систем логических закономерностей использовались „точный” и „приближенный” методы [Ковшов и др., 2008]. Таким образом, по каждому из наборов данных строилось 4 новых набора: по „точным” и „приближенным” ЛЗК, с использованием отрицаний ЛЗК или сигмоидных аппроксимаций. Параметр алгоритма аппроксимации: $\sigma = 0.9$. Некоторые визуализации обучающих данных в новых признаковых пространствах приведены на Рис. 6 - 10.




Рис. 3. Модельная задача




Рис. 4. Задача „breast”




Рис. 5. Задача „credit”




Рис. 6. Модельная задача в новом признаковом пространстве, „точные” ЛЗ и их отрицания




Рис. 7. Задача „breast” в новом признаковом пространстве, „точные” ЛЗ и их отрицания




Рис 8. Задача „breast” в новом признаковом пространстве, „точные” ЛЗ с аппроксимацией




Рис. 9. Задача „credit” в новом признаковом пространстве, „приближенные” ЛЗ и их отрицания




Рис 10. Задача „credit” в новом признаковом пространстве, „приближенные” ЛЗ с аппроксимацией

По рисункам 6, 7, 9 видно, что в новом признаковом пространстве, построенном по ЛЗК и их отрицаниям отделимость классов на обучении становится существенно лучше.

Для сравнения результатов классификации в качестве линейного метода использовался „метод опорных векторов”. Результаты тестов при использовании „точных” ЛЗК приведены в Таблице 2, при использовании „приближенных” ЛЗК – в Таблице 3. Указан процент верных классификаций контрольных данных и, если были отказы от распознавания, процент отказов.

Таблица 2. Результаты тестов при использовании „точных” ЛЗ

Задача	Оригинальный метод	ЛЗ и их отрицания	Аппроксимация ЛЗ
Модельная	85% (3,3% отказов)	86,8%	88,3%
„breast”	94,6% (0,8% отказов)	95,8%	96,1%
„credit”	80,5% (4,3% отказов)	85,6%	84,5%
„Image”	68,8% (27,7% отказов)	73,8%	92% (0,6% отказов)

Таблица 3. Результаты тестов при использовании „приближенных” ЛЗ

Задача	Оригинальный метод	ЛЗ и их отрицания	Аппроксимация ЛЗ
Модельная	58,3% (25% отказов)	65%	80% (3,3% отказов)
„breast”	95,2% (1,1% отказов)	94,6%	96,3%
„credit”	76,1% (4,3% отказов)	83%	85,3%
„Image”	93,1%	93,8%	94,7% (0,4% отказов)

По результатам исследований можно утверждать, что использование представленного в данной работе метода построения решающего правила (как с отрицаниями дизъюнкций ЛЗК, так и с аппроксимацией их сигмоидами) позволяет повысить качество классификации по сравнению с исходным оригинальным методом. Также видно, что число отказов от распознавания значительно сократилось.

Метод, основанный на аппроксимации ЛЗК сигмоидами, почти на всех задачах показал лучшее качество распознавания, чем метод, использующий отрицания дизъюнкций ЛЗК, и значительно превзошел оригинальный метод, но не смог устранить все отказы от классификации.

Заключение

В настоящей работе предложен новый вид решающего правила и способ вычисления весовых коэффициентов для модели типа вычисления оценок, основанной на логических закономерностях. Также предложено два метода устранения отказов от классификации. Оба рассмотренных метода показали себя способными повысить качество распознавания и уменьшить число отказов от классификации. Их применение может привести к значительному росту числа искомых параметров, поэтому минимизация числа ЛЗК, предобработка множеств ЛЗК являются несомненным резервом, позволяющим еще более улучшить результаты классификации. По результатам проведенных экспериментов, метод, использующий сигмоидные аппроксимации логических закономерностей, представляется наиболее перспективным. Отдельный интерес составляют возможности модификации этого метода, которые позволили бы полностью устранить отказы от распознавания и сохранить свойство гарантированного

правильного распознавания объектов обучающей выборки. Данные вопросы будут рассмотрены в дальнейших исследованиях авторов.

Благодарности

Настоящая работа выполнена при поддержке Программы Президиума РАН №15 „Информационные, управляющие и интеллектуальные технологии и системы”, Программы №2 Отделения математических наук РАН, Проекты РФФИ № 14-01-90413 Укр_а, 14-01-90019 Бел_а, 14-01-00824 А, 13-01-12033 офи м, 13-01-90616 Арм_а, 12-01-00912-а.

Библиография

- [Bache et al., 2013] Bache, K. & Lichman, M. (2013). UCI Machine Learning Repository [<http://archive.ics.uci.edu/ml>]. Irvine, CA: University of California, School of Information and Computer Science.
- [Duda et al, 2000] Duda, R. O., Hart, P. E., and Stork, D. G. Pattern Classification. John Wiley and Sons, 2nd edition, 2000
- [Freund et al, 1995] Y. Freund, and R. Shapire, "A decision-theoretic generalization of on-line learning and an application to boosting", Proceedings of the Second European Conference on Computational Learning Theory, 1995, pp. 23 - 37
- [Mangasarian et al, 1990] Mangasarian O. L., Wolberg W.H.: "Cancer diagnosis via linear programming", SIAM News, Volume 23, Number 5, September 1990, pp 1 - 18.
- [Баскакова и др., 1981] Баскакова Л.В., Журавлев Ю.И. Модель распознающих алгоритмов с представительными наборами и системами опорных множеств //Журн. вычисл. матем. и матем. физики. 1981. Т.21, № 5. С.1264-1275.
- [Дмитриев и др., 1966] Дмитриев А.Н., Журавлев Ю.И., Кренделев Ф.П., О математических принципах классификации предметов и явлений. Сб. "Дискретный анализ". Вып. 7. Новосибирск, ИМ СО АН СССР. 1966. С. 3-11.
- [Журавлев и др., 2006] Ю.И.Журавлев, В.В.Рязанов, О.В.Сенько, РАСПОЗНАВАНИЕ. Математические методы. Программная система. Практические применения. Изд.во „ФАЗИС”, Москва, 2006, 178 стр.
- [Журавлев, 1978] Ю.И.Журавлев, Об алгебраическом подходе к решению задач распознавания или классификации. Проблемы кибернетики. М.: Наука, 1978. Вып.33. С.5-68.
- [Ковшов и др., 2008] Ковшов Н.В., Моисеев В.Л., Рязанов В.В. Алгоритмы поиска логических закономерностей в задачах распознавания. Журнал вычислительной математики и математической физики, М.: Наука. Т.48, 2008, N 2, стр. 329-344.


[Рязанов, 2007] Рязанов В.В. Логические закономерности в задачах распознавания (параметрический подход). Журнал вычислительной математики и математической физики, Т.47, №10, 2007, с.1793-1808

Информация об авторах



Sergei Lvov – *The fourth year student; Lomonosov Moscow State University; Faculty of Computational Mathematics and Cybernetics; Department of Mathematical Forecasting Methods, Russia, 119991, Moscow, GSP-1, Leninskie Gory, 1, p. 52; e-mail: sergei.lvov0@gmail.com*

Major Fields of Scientific Research: Pattern recognition, Data mining, Artificial Intelligence



Vladimir Ryazanov – *Head of Department; Institution of Russian Academy of Sciences Dorodnicyn Computing Centre of RAS, Russia, 119991 Moscow, Vavilov's street, 40; e-mail: rvv@ccas.ru*

Major Fields of Scientific Research: Pattern recognition, Data mining, Artificial Intelligence

On a method of multi-algorithmic classification

Sergei Lvov, Vladimir Ryazanov

Abstract: *In this paper the calculating estimates model, based on a system of logical regularities to solve the supervised classification problem is considered. A method of determining the weighting parameters of the decision rule, as well as two methods to eliminate bounce on the classification by introducing a logical disjunction of the negations of regularities and the approximation of regularities by sigmoid logic functions are proposed. The results of numerical experiments are presented.*

Keywords: *classification, pattern recognition, estimates calculation, multi-algorithmic approach, logical regularities*