

Опубликована: Сб. тр. X Науч.-техн. Всерос. Научн. Конф. “Нейроинформатика-2008” 24-28 января 2008г. Москва. Изд. М.: - МИФИ, 2008, Ч.1, с.230-242.

**А.Ю. Дорогов, М.Ю. Шестопалов**

Санкт-Петербургский государственный электротехнический университет  
«ЛЭТИ»

dorogov@lens.spb.ruT

## **АЛГОРИТМЫ СИНТЕЗА КОЛЛЕКТИВНЫХ НЕЙРОСЕТЕВЫХ КЛАССИФИКАТОРОВ**

В работе рассматривается применение методов системного анализа данных для синтеза коллективных нейросетевых классификаторов. Для построения областей компетенции частных классификаторов предлагается использовать методы локальной балансировки знаковых графов и алгоритмы выделения стереотипов системного поведения. Граф связей формируется на основе статистических зависимостей между переменными признакового пространства. Решения частных классификаторов интегрируются с использованием принципа голосования. Приводятся результаты моделирования для реальной базы данных с высокой степенью неоднородности признакового пространства.

### **1. Введение**

При синтезе коллективного классификатора основной задачей является построение областей компетенции частных классификаторов. Под областью компетенции понимается подмножество объектов признакового пространства, в пределах которого определена сфера действия частного классификатора с заданным подмножеством распознаваемых образов. В данной работе предлагается определять области компетенции частных нейросетевых классификаторов из условия статистической однородности взаимного поведения признаков. В статье [1] была дана математическая трактовка понятию однородного поведения и представлены методы структурной локализации однородных областей признакового пространства по графу статистических связей. Граф связей строится на основе меры парной корреляции и в алгоритме селекции областей используется его клипированный вариант – знаковый граф. Задача структурной локализации однородных областей сводится к задаче локальной балансировки знакового графа. В качестве рабочего инструмента селекции используются первичные системные единицы – разделяющие структуры SHARE, ко-

торые представляют собой минимальные артефакты, локально выражающие логические принципы симметрии и двухфакторного взаимодействия. Для структуры SHARE существует всего два варианта балансировки. Эти варианты называются *эталонными моделями* SHARE. Эталонная модель является структурным образом области данных с однородным поведением. Минимальное подмножество графа включающего все вершины разделяющей структуры называется *локальностью*. Верификация эталонной модели в исходной системе данных позволяет определить *стереотип поведения системы* в границах локальности. Стереотип включает в себя множество примеров из таблицы данных, отвечающих условиям однородности эталонной модели, поэтому его можно использовать как область компетенции для частного классификатора. Такой путь вполне допустим для структур типа SHARE, однако количество этих структур в системе данных обычно велико, их локальности обладают малой мощностью, а сами структуры сильно пересекаются между собой. Поэтому предварительно целесообразно, сделать следующий итерационный шаг, укрупнив структуры группируя их в классы по общности ядерных элементов. В данной работе рассматривается одно из положений концепции взаимодействия [2] первичных системных единиц SHARE, позволяющее корректно выполнить их интеграцию в более сложные структуры. Количество интегрированных структур значительно меньше, чем структур SHARE и их локальности обладают большей мощностью. Именно для *интегрированных структур* в работе строятся эталонные модели. Верификация эталонных моделей в исходной таблице данных завершает процедуру выделения областей компетенции частных классификаторов.

## 2. Разделяющие структуры

Конструкт разделяющей структуры основан на теореме «о разделении граней тетраэдра» [1]. Применение конструкта к графу связей позволяет найти все существующие структуры SHARE. На рис. 1 приведен пример SHARE-структуры в реальной системе данных (здесь и далее для примеров используется база данных, описанная в работе [3]). Первичная системная единица SHARE наделена морфологией: в ней имеется особая вершина, вершины базы, база, боковые ребра и вершины пары непересекающихся факторов. Каждый из факторов образует с одним из боковых ребер основания тетраэдра согласованные треугольники, а с другим боковым ребром – треугольники противоречий. Допустимое согласование достигается изменением знаков связей вершин одного из факторов с особой вершиной. Для различения факторов и соответствующих базовых вершин

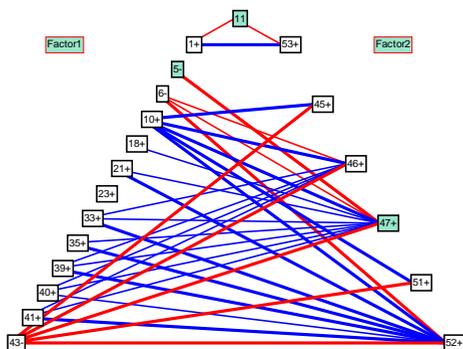


Рис. 1. Портрет разделяющей структуры SHARE в реальных данных. Положительные связи отмечены красным цветом (светлый тон), отрицательные – синим (темный тон). Утолщенными линиями показаны базы. Треугольник противоречий фрагментарно выделен. Особые вершины имеют темную окраску. Связи вершин факторов с особой вершиной не показаны, но их знаки отображаются после номера факторной вершины

удобно ввести ориентацию SHARE, задавая для нее направление обхода треугольника. Тогда фактором 1 (или Left-фактором) будем считать фактор, который расположен слева от особой вершины по направлению обхода треугольника, а фактором 2 (или Right – фактором) будем считать фактор, расположенный справа от особой вершины по направлению обхода.

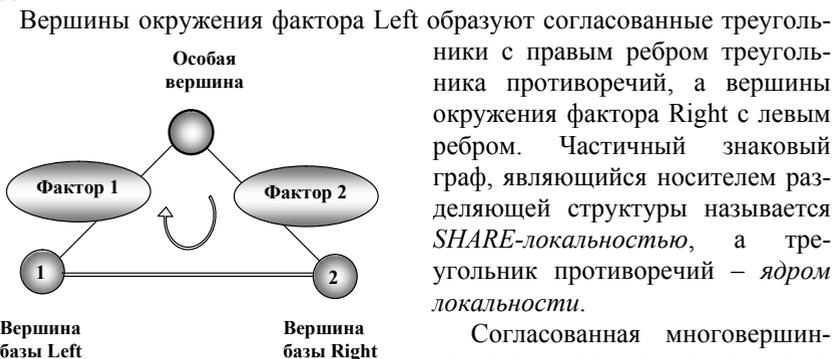


Рис. 2. Ориентированная разделяющая структура. Вершины баз условно выделены из факторов

Вершины окружения фактора Left образуют согласованные треугольники с правым ребром треугольника противоречий, а вершины окружения фактора Right с левым ребром. Частичный знаковый граф, являющийся носителем разделяющей структуры называется *SHARE-локальностью*, а треугольник противоречий – *ядром локальности*.

Согласованная многовершинная структура, полученная изменением связей Left-фактора с особой вершиной называется *Left-*

эталонной моделью, а изменением связей Right-фактора – Right-

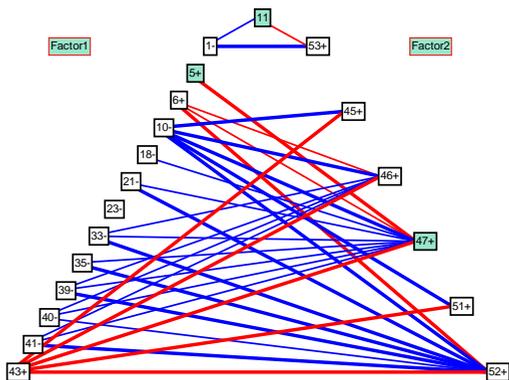


Рис. 3. Эталонная модель SHARE-Left

эталонной моделью. Каждая из эталонных моделей определяет один из двух возможных вариантов согласования разделяющей структуры SHARE. На рис. 3 показан пример эталонной модели Left. Граф эталонной модели полностью сбалансирован.

### 3. Интегрированная разделяющая структура

Локальности SHARE можно рассматривать как «точки кристаллиза-

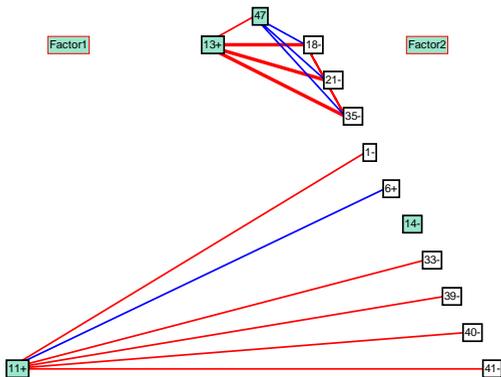


Рис. 4. Интегрированная структура ISHARE, образованная объединением трех структур SHARE с общей особой вершиной

ции», которые позволяют запустить механизм индукции в процедуре со-

гласования знакового графа. Одним из вариантов расширения локальности состоит в выделении на множестве SHARE однородных классов по особой вершине. В каждый класс включаются разделяющие структуры, которые имеют общую особую вершину (см. рис. 4). Интегрированная структура обозначается аббревиатурой ISHARE. Минимальный частичный граф, содержащий все ядра объединяемых SHARE, называется ядром структуры ISHARE. При построении ISHARE возникает проблема корректного объединения факторов SHARE в два фактора ISHARE. Задача ориентации имеет однозначное решение только в том случае, если граф ядра является связным и решается в результате анализа пересечений факторов SHARE и связей ядра ISHARE [4]. В рассматриваемом примере было локализовано 108 структур SHARE которые образовали 13 структур ISHARE.

#### 4. Верификация эталонных моделей

Конечным этапом в процедуре выделения областей компетенции является верификация эталонных моделей, которая заключается в выделении строк в исходной таблице данных удовлетворяющих взаимному поведению признаков эталонной модели. Выделенное подмножество строк, называется *кластером эталонной модели*. В пределах несущей локальности кластер проявляется как часть целого с характерной однородностью поведения системы.

Процедура верификации существенно зависит от метода выделения кластера. Различные способы детально рассмотрены в работе [4]. Ниже будет представлен метод статистической кластеризации, основанный на парной корреляции признаков. Функция парной корреляции является нормированной суммой составленной из произведений вида:

$$(x_i - m_x)(y_i - m_y),$$

где  $x_i, y_i$  - значения признаков для  $i$ -го примера таблицы, а  $m_x, m_y$  - соответствующие математические ожидания. Число слагаемых в сумме равно числу строк в таблице наблюдений. В эталонной модели знак некоторых связей графа изменяется на противоположный. При верификации необходимо выделить максимальное подмножество строк в таблице данных, для которого изменение знака является значимым. Идея состоит в том, чтобы добиться изменения знака связи за счет минимального изменения числа слагаемых корреляционной суммы. С этой целью слагаемые суммы ранжируются и удаляются те из них, которые дают наиболее существенный вклад в формирование знака связи. Оставшиеся слагаемые

образуют стереотипное множество примеров для изменяемой связи. Пересечение стереотипных множеств по всем изменяемым связям определяет кластер данных, в пределах которого статистически реализуется эталонная модель. После выделения кластера необходимо убедиться, что знаки неизменяемых связей сохранились, а дополнительно возникшие связи не привели к появлению противоречивых треугольников.

## 5. Коллективный нейросетевой классификатор

Практическое приложение метода выделения однородных областей рассмотрим на примере реализации нейросетевого классификатора образов для некомпактных классов. В рассматриваемой системе данных [3], образ задается именем класса, состоящим из пары слов Concept/Modifier, характеризующих семантику сегмента изображения (например, «горный склон», «голубое небо», «облачное небо», «морской прибор» и др.). Система данных сформирована по множеству прецедентов, и обладает высо-

Таблица. Характеристика системы данных

Показатель	Значение
Число объектов в системе данных	214
Число классов Concept/Modifier ( $M$ )	118
Размерность признакового пространства ( $N$ )	56
Максимальная представительность образа	24
Минимальная представительность образа	1

кой степенью неравномерности по наполнению классов и размещению их в пространстве признаков. В таблице представлены основные характеристики системы данных.

Задача классификации состоит в том, чтобы по количественным признакам неизвестного объекта определить его принадлежность к некоторому образу. Наполнение классов характеризуется полигоном накопленных частот  $F(j)$  (см. рис. 5) для объектов с заданным значением образа, где аргумент  $j = 1, 2, \dots, M$  - порядковый номер образа.

**Базовая модель классификатора.** Для построения классификаторов использованы нейронные сети прямого распространения. Для сетей данного типа необходимым условием обучения является требование, чтобы размерность признакового пространства  $N$  была больше или равна числу распознаваемых образов ( $N \geq M$ ). В противном случае задача классификации не доопределена. Для данной базы данных  $N = 56$  и  $M = 118$ , по-

этому необходимо разбить множество образов, по крайней мере, на три части.

Для построения базовой модели классификатора использовался коллектив из трех классифицирующих нейронных сетей  $NN_i$ , к которым

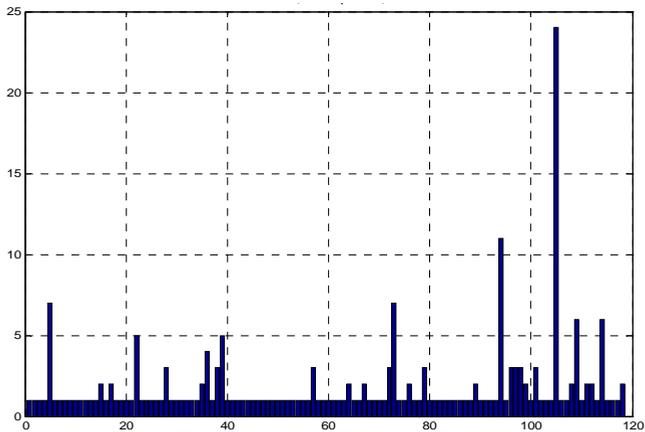


Рис. 5. Представительность образов в базе данных

были добавлены еще три селектирующие сети  $NNs_i$ , определяющие принадлежность паттерна к подмножеству образов (см. рис. 6).

Для кодирования образов использовался унитарный код, при котором

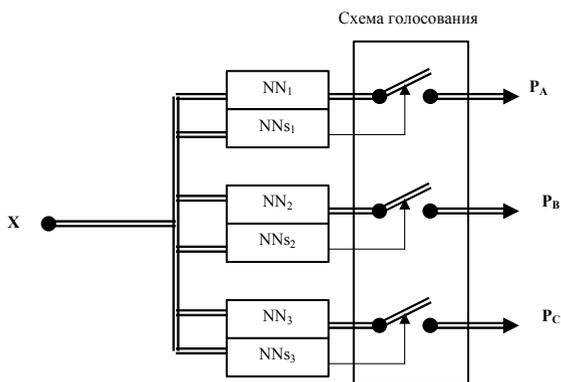


Рис. 6. Базовая модель коллективного классификатора

образу соответствовало кодовое слово с единичным значением на одном из выходов нейронной сети и нулевыми значениями на всех остальных. В процессе классификации код распознавался по позиции максимальной координаты в выходном векторе нейронной сети.

Для экспериментов использовались двухслойные нейронные сети прямого распространения с сигмоидными функциями активации в первом слое и линейными функциями во втором. Число нейронов в первом слое выбиралось равным удвоенной размерности входа нейронной сети. Обучение сетей прекращалось через 100 эпох в независимости от ошибки обучения. Селекционирующие сети обучались на полной базе данных, а классифицирующие на примерах с непересекающимися подмножествами образов. Результаты классификации оказались неудовлетворительными, число ошибок классификатора на обучающем множестве достигало 70%, и для 5% объектов фиксировался отказ от классификации. Причина плохой работы классификатора состояла в том, что нейронные сети плохо обучались на неоднородных данных. Данная модель классификатора использовалась как база для сравнения с другими вариантами.

**Коллективный классификатор с согласованной структурой.** Во второй модели классификатора использовался коллектив классифицирующих нейронных сетей, каждая из которых работала в собственной области компетенции. В качестве областей компетенции использовались кластеры эталонных моделей структур ISHARE.

Для интеграции решений частных классификаторов применялся принцип взвешенного голосования [5]. Формально задача интеграции частных решений ставится следующим образом: если  $S_j$  индивидуальные решения  $L$  классификаторов, то коллективное решение для паттерна  $X$  определяется как функция решений:

$$S = f(S_1, S_2, \dots, S_L, X).$$

Решение  $S$  в задаче классификации состоит в выборе номера одного из классов  $A_j$ ,  $j = 1, 2, \dots, J$ , или выборе пустого множества в случае отказа от классификации. Каждое частное решение  $S_j$  может принимать значение образа или быть пустым множеством, если паттерн не принадлежит области компетенции частного классификатора.

Для формализации схемы взвешенного голосования введем коэффициент надежности классификации  $\mu_j \leq 1$  образа  $j$  частным классификатором  $l$ . Определим этот коэффициент как долю объектов с заданным значением образа, попадающих в область компетенции  $l$ -го классификатора

$$\mu_{lj} = \frac{F_l(j)}{F(j)},$$

где  $F(j)$  - накопленная частота образа  $j$  в исходной базе данных,  $F_l(j)$  - накопленная частота образа  $j$  для частного классификатора  $l$  в его собственной области компетенции. Голосующая функция  $j$ -го класса определяется выражением:

$$q_j = \sum_l \mu_{lj}, \quad j = 1, 2, \dots, J.$$

Где суммирование производится по всем классификаторам. В данной сумме значение  $\mu_{lj}$  берется равным нулю, если паттерн  $X$  не принадлежит области компетенции частного классификатора  $l$ . Решение о принадлежности паттерна  $X$  к одному из классов  $A_j$  принимается по следующему правилу:

$$X \in A_{j^*} \text{ если } q_{j^*} = \max_j q_j \quad (1)$$

**Двухуровневая иерархическая классификация.** В этом случае индивидуальные решения  $S_l$  определяются промежуточной функцией решений нижнего уровня:

$$S_l = f_l(S_{l1}, S_{l2}, \dots, S_{lK}).$$

Коэффициенты надежности  $\mu_{klj} = F_{kl}(j)/F_l(j)$  и голосующая функция  $q_{lj}$  строятся для каждого индивидуального решения  $S_l$ . Задача принадлежности паттерна  $X$  к одному из классов  $A_j$  предварительно решается на нижнем уровне, следуя правилу:

$$X \in A_{j^*} \text{ если } q_{lj^*} = \max_j q_{lj}.$$

Полученному решению присваивается коэффициент надежности:

$$\mu_{lj} = \sum_k \mu_{klj}.$$

Далее вычисляется голосующая функция второго уровня и принимается окончательное решение по правилу (1).

**Реализация иерархического классификатора.** Область компетенции для частного классификатора с номером  $l$  характеризуется составом признаков -  $I_l$ , числом признаков -  $N_l = \text{card}(I_l)$ , подмножеством распознаваемых образов  $J_l$ , количеством распознаваемых образов

$M_l = \text{card}(J_l)$ , полигоном накопленных частот -  $F_l(j)$  для образов  $J_l$ . Как и в базовой модели, при построении частных классификаторов, подмножество образов  $J_l$  эталонной модели с номером  $l$  разбивалось на части  $J_{lk}$  так чтобы соблюдалось условие  $N_l \geq M_{lk}$ . На первом уровне иерархии частные классификаторы группируются по кластерам эталонных моделей. Для каждой  $k$ -ой компоненты  $J_{lk}$  подмножества образов в группе  $l$  строилась пара из классифицирующей и селектирующей сети на признаковом поле области компетенции. Классифицирующая нейронная сеть обучалась на объектах кластера эталонной модели с заданным подмножеством образов  $A_{lk}$ , селектирующая сеть обучалась на всем множестве объектов системы данных, с позитивными примерами на объектах подмножества  $A_{lk}$  и негативными примерами по всем остальным объектам. В целом схема для каждой области компетенции подобна модели базового классификатора (см. рис. 6), за исключением того, что она действует только в признаковом подпространстве области компетенции.

Частные решения  $S_l$  кодировались унитарным кодом. В режиме классификации кодовое слово распознавалось по позиции максимальной координаты в выходном векторе нейронной сети. Схема голосования была реализована в виде иерархической структуры, показанной на рис. 7. Для



Рис. 7. Модель иерархического классификатора с согласованной структурой реализации частных классификаторов использовались двухслойные нейронные сети прямого распространения с сигмоидными функциями активации в первом слое и линейными функциями во втором. Входной вектор

для каждого классификатора центрировался по математическому ожиданию  $X_{INP_i} = X_i - m_x$ .

Два возможных решения селектирующей сети («паттерн принадлежит области компетенции» и «паттерн не принадлежит области компетенции») также кодировались унитарным кодом с длиной кодового слова равным 2. Решение селектирующей сети принималась по позиции максимальной координаты ее выхода.

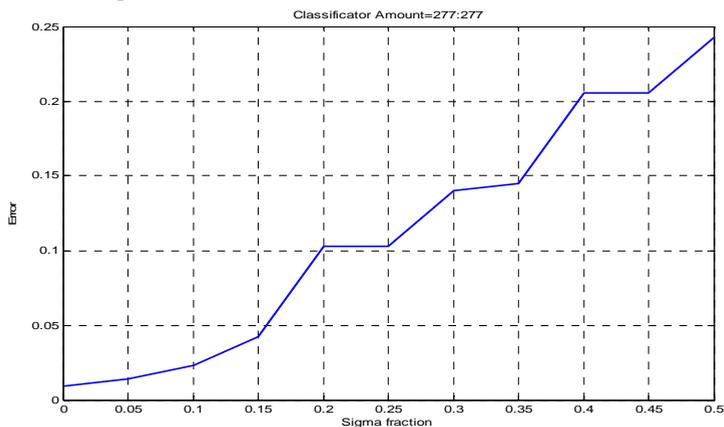


Рис. 8. Влияние шума на результаты классификации

На уровне кластера селектирующие сети обучались на всем множестве объектов системы данных, с позитивными примерами на объектах подмножества  $A_i$  (кластера эталонной модели с номером  $i$ ) и негативными примерами на всех остальных объектах.

Для построения частных классификаторов использовались все эталонные модели локальностей ISHARE без исключения. Области компетенции определялись через статистические кластеры эталонных моделей. Нейронные сети строились в автоматическом режиме, коллективный классификатор на первом уровне содержал 277 классифицирующих сетей и столько же селектирующих. Кроме того, 26 селектирующих сетей было образовано на уровне кластеров эталонных моделей. Обучение любой нейронной сети, прекращалось после 100 эпох тренировок в независимости от величины ошибки. На обучающем множестве ошибка классификации, не превышала 1% при отсутствии отказов в распознавании. Для оценки обобщающей способности классификатора был проведен эксперимент с зашумленными данными обучающего множества. Случайный

шум с равномерным распределением добавлялся к значениям каждого признака. Результаты эксперимента показаны на рис. 8. По оси абсцисс отложен уровень шума в долях от среднеквадратического отклонения, по оси ординат – доля ошибочных классификаций.

## 6. Заключение

В данной работе показано, что проблема построения областей компетенции частных классификаторов может быть решена методами системного анализа данных. Отправной точкой служит граф статистических зависимостей между переменными признакового пространства.

Рабочим инструментом системного анализа являются первичные артефакты SHARE. Структуры SHARE локализуют неоднородности системы данных и через критерий знакового баланса выражают локальные механизмы их порождения. Концепция взаимодействий первичных единиц, определяет пути расширения локальностей и выявляет возможные варианты их балансировки через построение эталонных моделей. По существу совокупность эталонных моделей выражает метафорические аттракторы системы данных, т.е. множества состояний которые являются наиболее типичными проявлениями поведения системы. Верификация эталонных моделей в системе данных позволяет оценить их адекватность и выделить однородные области в признаковом пространстве. В задаче классификации однородные области используются как признаковые поля области компетенции частных классификаторов. Отсутствие противоречий в однородной области обеспечивает обучаемость частного классификатора. Интеграция решений частных классификаторов может быть реализована по принципам взвешенного голосования.

### *Список литературы*

1. Дорогов А.Ю., Шестопалов М.Ю. Локализация однородных областей признакового пространства для задачи нейросетевой классификации образов. В настоящем сборнике.
2. Качанова Т.Л., Фомин Б.Ф. Симметрии, взаимодействия в локальностях, компоненты поведения сложных систем / Издательско-полиграфический центр СПбГЭТУ, СПб, 1998. - 126с. (Препринт № 2).
3. Дорогов А.Ю., Курбанов Р.Г., Разин В.В Быстродействующий алгоритм семантической классификации JPEG-изображений / Электронный журнал «Нейроинформатика» 2006, том 1, № 2 с.124-144. – <http://www.ni.iont.ru/Journal/N2/>.
4. Дорогов А.Ю. Математические основы методов оптимально частичной балансировки знаковых графов Деп. в ВИНТИ 23.07.2007, №760-B2007, 33с.

---

5. Растринин Л.А., Эренштейн Р.Х. Метод коллективного распознавания. - М.: Энергоиздат, 1981, 80с. (Б-ка по автоматике; Вып. 615)