

УДК 519.95

ИСПОЛЬЗОВАНИЕ ФУНКЦИИ КОНКУРЕНТНОГО СХОДСТВА ДЛЯ ПРОГНОЗИРОВАНИЯ КОЛИЧЕСТВЕННЫХ ПЕРЕМЕННЫХ

В. В. Дюбанов

*Учреждение Российской академии наук
Институт математики им. С. Л. Соболева Сибирского отделения РАН,
630090, г. Новосибирск, просп. Академика Коптюга, 4
E-mail: vladimir.dyubanov@gmail.com*

Предлагается метод использования функции конкурентного сходства (FRiS-функции) при решении задачи прогнозирования переменных, измеренных в сильных (количественных) шкалах. Описывается алгоритм прогнозирования FRiS-Pro и опыт его применения при решении задачи прогнозирования целевого признака, измеренного в абсолютной шкале (покупательского спроса) на международном конкурсе "Data Mining Cup 2009".

Ключевые слова: прогнозирование, ближайшие соседи, функция конкурентного сходства.

Введение. Функция конкурентного сходства (FRiS-функция (Function of Rival Similarity)) была введена для решения задач распознавания образов, в которых требуется предсказывать значение целевого признака, измеряемого в номинальной шкале [1, 2]. Кратко напомним суть FRiS-функции. В задачах распознавания обычно используются меры сходства, которые носят абсолютный характер и применяются для оценок сходства между контрольным объектом z и эталонами каждого образа в отдельности. Но легко убедиться, что восприятие человеком сходства носит относительный характер. Чтобы ответить на вопросы типа «близко — далеко?», «похож — не похож?», нужно знать ответ на вопрос «по сравнению с чем?». Для оценки сходства объекта z с эталоном первого образа необходимо определить не только расстояние r_1 до него, но и расстояние r_2 до того образа, который является его ближайшим конкурентом. Мера сходства является функцией от этих двух расстояний и может измеряться в шкале порядка, как это делается в методе ближайшего соседа (kNN). Но оказалось, что знанием величин r_1 и r_2 можно распорядиться более эффективно, если оценивать сходство не в шкале порядка, а в более сильной абсолютной шкале. Для этого можно использовать функцию F , которая называется FRiS-функцией:

$$F(z, 1 | 2) = (r_2 - r_1) / (r_2 + r_1).$$

Здесь величина $F(z, 1 | 2)$ характеризует сходство объекта z с эталоном первого образа в конкуренции с эталоном второго образа. Значения этой функции меняются в пределах от +1 до -1. При расстояниях $r_1 = r_2$ значения $F(z, 1 | 2) = F(z, 2 | 1) = 0$, что указывает на границу между образами.

Полезность применения FRiS-функции в задачах распознавания образов показана в ряде работ [1–3]. Целью данного исследования является демонстрация применения FRiS-функции при решении задачи прогнозирования целевого признака, измеренного в абсолютной шкале, т. е. хорошо известной задачи, решаемой методами регрессионного анализа. Разработанный для её решения алгоритм FRiS-Pro относится к классу методов заполнения пробелов в таблицах данных. В литературе этот класс известен под названиями "Inserting" и "Imputation" [4]. Методы заполнения пробелов, основанные на использовании закономерных связей между всеми элементами таблицы данных, называются «глобальными». Их описание можно найти в [4, 5]. Данная работа основана на «локальном» подходе,

при котором оценивается взаимосвязь между строками и столбцами таблицы в ограниченной окрестности заполняемого элемента [6].

В отличие от задач распознавания в задачах заполнения пробелов конкурирующие классы не задаются, здесь потребовалось создание виртуальных конкурирующих классов. Алгоритм FRiS-Pro был успешно применён при решении задачи прогнозирования на международном конкурсе "Data Mining Cup 2009".

Описание задачи прогнозирования. Задача состояла в предсказании значений переменных, измеренных в абсолютной шкале, и заключалась в следующем. Анализировались данные о том, сколько книг того или иного жанра было продано в разных магазинах в течение года. Эти данные представлены таблицей [7], в которой M строк (объектов) являются магазинами ($M = 4812$), а N столбцов (признаков) — жанрами книг ($N = 1864$). На пересечении строк и столбцов указывалось количество книг данного жанра, проданных за год в том или ином магазине. Количество таких продаж колебалось от 0 до 2300. Таблица сильно разрежена: 84 % клеток таблицы содержат нулевые значения. Последние восемь признаков целевые.

Таблица разделена по горизонтали на две части. В первой (обучающей) для $M_0 = 2394$ магазина указаны значения как описывающих, так и целевых признаков. Во второй (контрольной) для $M_k = 2418$ магазинов содержится информация только об $N - 8$ описывающих признаках. Требуется определить (угадать), сколько и каких книг из восьми жанров продано в каждом из контрольных магазинов, т. е. предсказать значения целевых признаков, измеренные в абсолютной шкале в 19344 ячейках матрицы размером 2418×8 .

Решение задачи. Для прогнозирования каждой пустой ячейки матрицы можно использовать локальный метод заполнения пробелов, аналогичный методу ZET [5]. Основная идея алгоритма ZET состоит в следующем. Пусть клетка (i, j) с пробелом находится на пересечении j -го столбца и i -й строки. Выбирается подмножество из k «компетентных» строк, являющихся ближайшими соседями i -й целевой строки, и n «компетентных» столбцов, наиболее сильно коррелированных с j -м целевым столбцом. Строки и столбцы этой «компетентной подматрицы» используются для прогнозирования значения пробела с опорой на известный постулат естественной классификации: «Объекты, похожие по $(n - 1)$ -му признаку, обычно похожи и по n -му признаку». Каждый столбец и каждая строка подматрицы вырабатывают свои варианты значения пробела (подсказки). В отличие от алгоритма ZET веса подсказок в алгоритме FRiS-Pro оцениваются по величине функции конкурентного сходства. Кроме того, существенные отличия имеются и в стратегии выбора параметров алгоритма.

При решении данной задачи обучение и распознавание делалось для каждого целевого признака в отдельности. Таким образом, задачу можно рассматривать как состоящую из восьми независимых задач. Для предсказания значений j -го целевого признака используется своё подмножество из n наиболее информативных описывающих признаков, которое выбирается с помощью алгоритма направленного перебора GRAD [5]. При определении величины b_{ij} , расположенной на пересечении i -й строки и j -го признака, используется своё подмножество из k строк обучающей выборки, наиболее похожих на i -ю строку по этим описывающим признакам (k ближайших соседей). Значения параметров n и k , как и других параметров алгоритма, определяются в процессе обучения. Каждому v -му сочетанию значений параметров P_v и оптимальному для него подмножеству признаков X_v соответствует своё решающее правило D_v , которое вырабатывает свой вариант b_{ij}^v предсказываемой величины b_{ij} . Окончательное решение получается в результате взвешенного усреднения значений b_{ij}^v , предсказанных коллективом наиболее компетентных решающих правил.

Каждое отдельное решающее правило представляет собой пару $\langle P, X \rangle$, где X — некоторое множество описывающих признаков, а P — фиксированный набор возможных значений следующих параметров:

- 1) N_1 — способ нормировки значений строки (отсутствие нормировки, нормировка по максимальному или по среднему значению);
- 2) N_2 — способ нормировки значений описывающего столбца (отсутствие нормировки, нормировка по максимальному значению);
- 3) L — вид метрики ($L1$ или $L2$);
- 4) k — число соседей ($k = 1, 2, \dots, 10$);
- 5) O — способ округления результата предсказания до целого числа (в большую или в меньшую сторону).

При заданном v -м варианте параметров P_v , $v = 1, 2, \dots, V$, и выбранном подмножестве признаков X_v прогнозирование варианта b_{ij}^v по решающему правилу $D_v = \langle P_v, X_v \rangle$ осуществляется таким образом:

$$b_{ij}^v = \left[\left(\sum_{t=1}^k F_t b_{tj} \right) / k \right],$$

где F_t — весовой коэффициент t -й строки, $t = 1, 2, \dots, k$; b_{tj} — j -й элемент t -й строки обучающей выборки.

В качестве весовых коэффициентов F_t для каждой из k строк, наиболее похожих на i -ю строку, используются значения FRiS-функции, рассчитываемые следующим образом:

1. Среди объектов обучающей выборки находятся $2k$ объектов (строк), которые являются ближайшими соседями анализируемой i -й строки в пространстве X_v описывающих признаков. Из них формируются два виртуальных класса — «свой» и «чужой». В свой класс включаются первые k ближайших соседей, а в чужой класс — следующие по порядку k ближайших соседей.

2. Расстояния от i -го объекта до каждого t -го из k своих ближайших соседей в отдельности играют роль расстояний r_{1t} , а за расстояние r_2 до класса-конкурента принимается среднее расстояние от i -го объекта до k объектов чужого класса. По этим расстояниям вычисляется значение FRiS-функции:

$$F_t = (r_2 - r_{1t}) / (r_2 + r_{1t}).$$

Полученное значение F_t принимается в качестве веса своего t -го ближайшего соседа.

С учётом изложенного алгоритм FRiS-Pro построения решающих правил и принятия решений можно представить следующими процедурами:

1. Фиксируется v -й вариант сочетания значений параметров P_v , $v = 1, 2, \dots, 360$.
2. Методом направленного перебора GRAD выбирается наилучший вариант подмножества признаков X_v .
3. Компетентность (предсказательная способность) правила $D_v = \langle P_v, X_v \rangle$ оценивается количеством правильных решений, полученных этим правилом на объектах обучающей выборки в режиме скользящего экзамена Cross Validation (CV) [8].
4. При том же варианте значений параметров P_v алгоритм GRAD запускается q раз, начиная с разных стартовых признаков. В результате находится q разных подпространств признаков и, следовательно, q разных решающих правил.
5. Процедуры 1–4 повторяются для всех 360 вариантов вектора параметров, в итоге генерируется $q \times 360$ решающих правил $\langle P, X \rangle$.
6. Из этих правил в ансамбль правил, по которым принимается коллективное решение, с помощью алгоритма GRAD выбирается наилучшее подмножество правил в количестве



Схема работы алгоритма прогнозирования FRiS-Pro для случая $q = 5$

от 10 до 20. Некоторые из них могут оказаться в составе подмножества более 1 раза. Качество каждого такого ансамбля (предлагаемого GRAD) оценивается в режиме скользящего экзамена типа One Leave Out (OLO). Общее решение принимается путём взвешенного усреднения результатов, полученных правилами, входящими в ансамбль. При этом веса правил равняются величине их компетентности, помноженной на число вхождений правила в коллектив. Это один из видов коллективного решающего правила, обсуждаемых сейчас в литературе [9].

Описанный алгоритм представлен в виде схемы на рисунке.

Решение конкурсной задачи. Конкурсы "Data Mining Cup" проводятся ежегодно накануне Международной конференции по анализу данных и машинному обучению (KDD/ML) [7]. В 2009 г. в конкурсе изъявили желание участвовать 618 команд из 164 организаций 42 стран: 231 команда решила эту задачу и прислала результаты; 49 команд преодолели порог приемлемых результатов, установленный организаторами. Качество решения оценивалось суммой модулей разностей между фактическими и предсказанными значениями в каждой из 19344 ячеек исходной таблицы данных. Результаты первых де-

Рейтинг	Команда	Очки	Рейтинг	Команда	Очки
1	Uni Karlsruhe TH-II	17260	16	TU Graz	23626
2	TU Dortmund	17912	18	Uni Weimar-I	23796
3	TU Dresden	18163	19	Zhejiang University	23952
4	Novosibirsk State University	18353	20	University Laval	24884
5	University Karlsruhe TH-I	18763	24	University of Southampton	25694
6	FH Brandenburg-I	19814	25	Telkom Institute of Techn.	25829
7	FH Brandenburg-II	20140	26	University of Central Florida	26254
8	Hochschule Anhalt	20767	32	Indian Institute of Technology	28517
9	University of Hamburg	21064	34	Anna University Coimbatore	28670
10	KTH Royal Institute of Technol.	21195	38	Technical University of Kosice	32841
11	RWTH Aachen-I	21780	39	University of Edinburgh	45096
14	Budapest University of Technol.	23277	48	Warsaw School of Economics	77551
15	Isfahan University of Technol.	23488	49	FH Hannover	1938612

сяти и некоторых других команд приведены в таблице. Как видно, среднее отличие прогнозных значений для каждой ячейки от истинного у разных команд колебалось от 0,89 до 100,22. У пяти команд эти ошибки были меньше единицы. Команда Новосибирского университета сделала 0,95 ошибки на ячейку и заняла четвертое место.

Заключение. Полученные результаты подтверждают возможность использования FRiS-функции не только в алгоритмах распознавания, связанных с предсказанием номинальных признаков, но и в алгоритмах прогнозирования количественных переменных. Высокие конкурентные качества предложенного алгоритма FRiS-Pro продемонстрированы результатами его сравнения с сотнями других алгоритмов, использованных участниками конкурса "Data Mining Cup 2009".

СПИСОК ЛИТЕРАТУРЫ

1. **Zagoruiko N. G., Borisova I. A., Dyubanov V. V., Kutnenko O. A.** Methods of recognition based on the function of rival similarity // Pattern Recogn. Image Analys. 2008. **18**, N 1. P. 1–6.
2. **Загоруйко Н. Г.** Интеллектуальный анализ данных, основанный на функции конкурентного сходства // Автометрия. 2008. **44**, № 3. С. 31–40.
3. **Борисова И. А., Дюбанов В. В., Загоруйко Н. Г., Кутненко О. А.** Сходство и компактность // Тр. 14-й Всерос. конф. «Математические методы распознавания образов» (ММРО-14). Суздаль, 2009. С. 89–92.
4. **Литтл Р. Дж. А., Рубин Д. Б.** Статистический анализ данных с пропусками. М.: Финансы и статистика, 1991. 336 с.
5. **Лапко А. В., Лапко В. А.** Анализ непараметрических алгоритмов распознавания образов в условиях пропуска данных // Автометрия. 2008. **44**, № 3. С. 65–74.
6. **Загоруйко Н. Г.** Прикладные методы анализа данных и знаний. Новосибирск: Изд-во ИМ СО РАН, 1999. 270 с.
7. **Обзор** результатов конкурса "Data Mining Cup 2009".
URL: <http://www.data-mining-cup.de/en/review/dmc-2009/> (дата обращения: 25.08.2010).
8. **Загоруйко Н. Г., Кутненко О. А.** Алгоритм GRAD для выбора информативного подпространства признаков // Вычислительные системы «Анализ структурных закономерностей». Новосибирск: Изд-во ИМ СО РАН, 2005. Вып. 174. С. 3–12.
9. **Kittler J., Hatef M., Duin R. P. W., Matas J.** On combining classifiers // IEEE PAMI. 1998. **20**, N 3. P. 226–239.

Поступила в редакцию 28 января 2010 г.
