

УДК 519.237

LRP - ЛОГИЧЕСКОЕ РАСПОЗНАЮЩЕЕ ПРАВИЛО  
(Описание программы. Решение модельных  
и прикладных задач)

Н.Г. Старцева

В работе даны краткое описание программы LRP , реализующей алгоритм LRP (см. [I]), иллюстрация работы программы на двух модельных примерах, а также сравнение LRP с четырьмя другими известными алгоритмами (на модельных и реальных примерах), которое позволяет убедиться в правильности принципов, заложенных в алгоритме LRP .

§ I. Программа LRP

Программа LRP (оформленная как подпрограмма) предназначена для построения решающего правила в виде логического дерева с заданным количеством вершин, соответствующих обучающей выборке (обучению), последняя (выборка) может быть разбита на  $K$  ( $K \geq 2$ ) образов. С помощью этого правила распознается контрольная выборка (контроль).

Программа LRP позволяет работать с разнотипными данными и таблицами, в которых есть пропуски. При построении решающего правила LRP одновременно выделяет подсистему информативных признаков. Общие понятия и теоретические исследования так же, как и алгоритм LRP , описаны в [I]. В приложении I даются описание параметров работы LRP и обращение к программе.

Качество работы алгоритма можно определить с помощью приема "скользящий экзамен", реализованного в программе, который состоит в следующем: из обучающей выборки выделяют один элемент и предлагают обучиться на оставшейся части последовательности и классифицировать выделенный элемент, затем выделяют другой элемент (первый возвращается на место) и снова проводят обучение и экзамен на

этом элементе, и так поочередно перебирают все элементы обучающей последовательности. Затем подсчитывается, сколько раз алгоритм ошибался при классификации выделенных элементов. Отношением числа ошибочных классификаций к объему выборки и оценивается качество решающего правила [2].

Рассмотрим режимы работы LRP и параметры, регулирующие качество решающего правила.

В программе реализованы четыре основных режима работы, задаваемые с помощью параметра IR2: IR2=0 - обучение; IR2 = 1 - обучение и контроль; IR2 = 2 - скользящий экзамен; IR2 = 3 - обучение и скользящий экзамен.

В качестве условия деления объектов на каждой вершине дерева рассматриваются простые высказывания или строится гиперплоскость. В зависимости от вида условия деления различаются три режима, устанавливаемые параметром NRE: NRE = 1 - режим без гиперплоскости; NRE = 2 - режим с гиперплоскостью; NRE = 3 - режим только с гиперплоскостью.

В каждой вершине дерева ищется оптимальное в смысле некоторого критерия условия деления объектов. С помощью параметра IR можно выбирать тот или другой критерий деления. При IR = 1 в программе LRP реализован только один критерий [2]. При IR = 2,3,4,5 можно вставить подпрограмму-функцию, аналогичную реализованной в LRP, результатом которой является другой критерий деления (исследования по выбору новых критериев будут проведены позже).

Алгоритм устроен таким образом, что деление каждый раз происходит из той вершины, у которой значение критерия наименьшее (ID = 0), но в LRP реализован также режим (ID = 1), при котором, если значения критериев для двух вершин отличаются меньше, чем на EPS (обычно EPS = 0), то деление будет происходить из вершины с наименьшей длиной внешнего пути.

Улучшать результаты обучения можно с помощью параметров KALP, KMET, KGAM, KWT, EPS. Параметры KALP =  $\alpha$ , KMET =  $\beta$ , KWT =  $\eta$ , EPS =  $\epsilon$  приведены в [1]. Через KGAM обозначено минимально возможное количество объектов каждого из двух классов, по которым строится гиперплоскость.

## § 2. Модельный пример и результаты решения

Количество образов в примере равно трем. Объем обучающей выборки - 20 реализаций (по 6 реализаций первого и второго образов

и 8 реализаций третьего образа), объем контрольной выборки – 4 реализации. В обучающей и контрольной выборках есть пропуски. Количество признаков – 6. Первый признак – наименование, четвертый – порядковый, остальные количественные.

Для второго и третьего признаков распределение строится следующим образом: первый образ представляет собой нормальное распределение  $N(\mu_1, \sigma^2)$ , второй –  $N(\mu_2, \sigma^2)$ , третий – смесь двух нормальных распределений  $N(\mu_3, \sigma^2)$  и  $N(\mu_4, \sigma^2)$  с априорными вероятностями  $\frac{1}{4}$  и  $\frac{3}{4}$  соответственно, где  $\mu_1 = \begin{pmatrix} -1 \\ 1 \end{pmatrix}$ ,  $\mu_2 = \begin{pmatrix} 1 \\ -1 \end{pmatrix}$ ,  $\mu_3 = \begin{pmatrix} 1 \\ 1 \end{pmatrix}$ ,  $\mu_4 = \begin{pmatrix} 0 \\ 0 \end{pmatrix}$ ,  $\sigma = 0,62$ .

Первый признак принимает имена "3" или "6" (с равной вероятностью), если при этом второй и третий признаки распределены по нормальному закону  $N(\mu_4, \sigma^2)$ , и имена "1" и "2" (с равной вероятностью) – для всех остальных реализаций. Четвертый признак – порядковый и равен "5" для реализаций, у которых второй и третий признаки распределены поциальному закону  $N(\mu_3, \sigma^2)$ , и равен "3" или "4" (с равной вероятностью) для всех других реализаций. Пятый и шестой признаки неинформативные (шумовые) и распределены одинаково и независимо для трех образов –  $N(0, 20)$ .

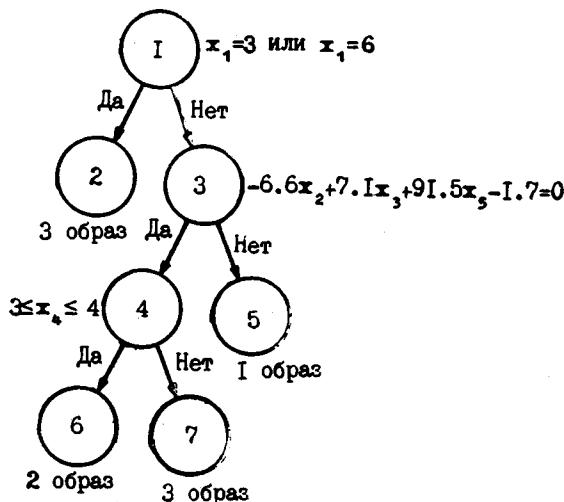


Рис. I

В приложении 2 приводится распечатка результатов работы программы.

На рис. I приведено дерево решений, построенное по результатам обучения.

Построенное решающее правило в виде дерева решений с нулевой ошибкой разбивает объекты обучающей выборки на три класса и является наглядной интерпретацией логических закономерностей данной моделируемой выборки.

### § 3. Результаты сравнения LRP с четырьмя алгоритмами распознавания образов на модельном примере

Количество классов в модельном примере равно двум. Объем обучающей выборки – 100 реализаций (по 50 реализаций каждого образа), объем контрольной выборки – 200 (по 100 реализаций каждого образа). Количество признаков – 20.

Первый признак распределен следующим образом: для первого класса признак попадает в интервалы  $(0,1)$ ,  $(2,3)$ ,  $(4,5)$  с вероятностью 0,95; в интервалы  $(1,2)$ ,  $(3,4)$ ,  $(5,6)$  с вероятностью 0,05 и распределен внутри каждого интервала равномерно. Для второго класса наоборот. Остальные 19 признаков неинформативные, они распределены одинаково и независимо для обоих классов  $\text{N}(0,20)$ .

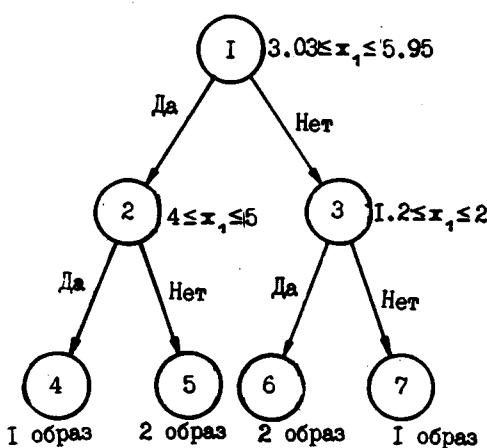


Рис.2

экспериментов<sup>\*)</sup>, где  $\alpha$  – номер алгоритма. Усреднение проводилось

<sup>\*)</sup> Под экспериментом понимается: генерирование обучающей выборки, построение решающего правила, генерирование контрольной выборки и вычисление оценки вероятности ошибки для данного решающего правила и заданного контроля.

Рассмотрим пять алгоритмов распознавания образов: первый алгоритм использует дискриминантную функцию Фишера [3], второй – использует квадратичную дискриминантную функцию [3], третий основан на непараметрической оценке [4], четвертый – на логических функциях [5], пятый – LRP.

Качество алгоритма определяется оценкой вероятности ошибочной классификации на контроле –  $P_e$ , усредненной по числу

по девяти экспериментам. Результаты работы первых четырех алгоритмов на данном модельном примере уже приводились в [6]:  $\bar{P}_1 = 0,45$ ,  $\bar{P}_2 = 0,47$ ,  $\bar{P}_3 = 0,47$ ,  $\bar{P}_4 = 0,18$ . Для алгоритма LEP оценка  $\bar{P}_5 = 0,08$ . Из приведенных выше результатов видно, что алгоритм LEP на данном модельном примере сработал наилучшим образом.

Необходимо отметить, что в решающем правиле распознавания (в узлах дерева) оказываются задействованы не все признаки.

Таким образом, одновременно с построением решающего правила решается задача выбора подсистемы информативных признаков.

На рис.2 приведено дерево решений, построенное по результата - там обучения одного из 9 экспериментов, для данного модельного примера.

#### § 4. Результаты сравнения LEP с четырьмя алгоритмами распознавания образов на прикладных задачах

Для эксперимента сравнения были выбраны те же четыре алгоритма, что и в § 3. Качество работы каждого алгоритма определялось оценкой вероятности ошибочной классификации на "скользящем экзамене" -  $\bar{P}_e^c$ . Сравнение пяти алгоритмов проводилось для трех реальных задач: распознавания больных с глубоким наркозом и больных с поверхностным наркозом при операции на сердце (Институт патологии кровообращения МЗ РСФСР) по анализу концентрации углекислого газа в артериальной крови (первая задача), в капиллярной крови (вторая задача), в венозной крови (третья задача). Данные для третьей задачи представлены в приложении 3. Число признаков в задачах - 6 (все признаки количественные), объем выборки - 14 для больных с глубоким наркозом и 12 - с поверхностным наркозом. В таблице представлены результаты сравнения.

Таблица

№ задачи	Вероятность ошибочной классификации				
	$\bar{P}_1^c$	$\bar{P}_2^c$	$\bar{P}_3^c$	$\bar{P}_4^c$	$\bar{P}_5^c$
I	0.39	0.35	0.29	0.61	0.13
2	0.36	0.54	0.29	0.46	0.12
3	0.5	0.54	0.36	0.36	0.11

Необходимо отметить, что при сравнении алгоритмов не учтывались положительные свойства LRP : возможность работать с пропусками в таблицах, с несколькими образами и с разнотипными данными, возможность в вершине дерева рассматривать в качестве условия деления гиперплоскость.

Несмотря на то, что положительные свойства алгоритма в эксперименте сравнения не были учтены, алгоритм LRP показал наилучшее качество решения по сравнению с четырьмя известными алгоритмами. Этот факт объясняется следующим: по сравнению с первым и вторым алгоритмами LRP использует более слабое предположение о виде законов распределения вероятностей; по сравнению с третьим алгоритмом LRP дал лучший результат, так как логические решающие правила являются статистически более устойчивыми [7]; по сравнению с четвертым алгоритмом, также основанным на логических решающих функциях, LRP использует более сложные предикаты (в частности, "двуэторонние интервалы") и имеет более сильный критерий [1].

### Л и т е р а т у р а

1. ЛБОВ Г.С., СТАРЦЕВА Н.Г. Алгоритм многоклассового распознавания, основанный на логических решающих функциях.- Настоящий сб., с. 3-10.
2. ВАЛНИК В.Н., ЧЕРВОНЕЦКИЙ А.Я. Теория распознавания образов. - М.: Наука, 1974. - 415 с.
3. ФУКУНАГА Е. Введение в статистическую теорию распознавания образов. - М.: Наука, 1979. - 367 с.
4. ЧЕГКАШИН Н.Т. Некоторые непараметрические алгоритмы распознавания образов балльной размерности. - В кн.: Математическая статистика и её приложение. Томск, 1979, с.156-162.
5. МАНОХИН А.Н. Методы распознавания образов, основанные на логических решающих функциях.- В кн.: Эмпирическое предсказание и распознавание образов (Вычислительные системы, вып.67). Новосибирск, 1976, с.42-53.
6. МАНОХИН А.Н., СТАРЦЕВА Н.Г. Экспериментальное сравнение 4-х алгоритмов распознавания образов.- В кн.: Обнаружение эмпирических закономерностей с помощью ЭВМ (Вычислительные системы, вып. 102). Новосибирск, 1985, с.127-132.
7. ЛБОВ Г.С. Методы обработки разнотипных экспериментальных данных. - Новосибирск: Наука, 1981. - 160 с.

Поступила в ред.-изд.отд.  
24 мая 1985 года

## ПРИЛОЖЕНИЕ I

### Обращение к программе LRP и описание параметров

Обращение к программе: CALL LRP(X,M,N,Y,M1,K,B,IR,KWT,NTP,  
NRE,LM,KBET,KGAM,KALF,EPS,MOB,LD,IPRINT,NPF,NWX,APF,OSS,NF,  
RA2,SI,E,KOB,C,IR2,NOB,ABE,OSR,MR1,RA3,M2,X1).

Входные параметры:

X - обучающая матрица размерности M x N,  
M - количество реализаций обучающей матрицы,  
N - количество признаков,  
Y - контрольная матрица размерности M1 x N,  
M1 - количество реализаций контрольной матрицы,  
K - количество образов,  
M2 - постоянная, если есть "скользящий экзамен" M2 = M - 1 ;  
если нет, то M2 = 1 ,

B - код пропуска (кодируется максимальным положительным значением, не встречающимся в таблице),

IR - параметр режима, определяет вариант критерия,  
KWT - максимально-возможное количество вершин (целое, нечетное),

NTP - массив размерности N x 2, первый столбец определяет тип признака: 0 - признак наименования, 1 - количественный, 2 - дисcretно-количественный, 3 - балльный; второй столбец рабочий,

NRE - параметр режима работы, определяющий вид выбора условия в вершине,

LM - максимальное количество имен в одном признаке,  
KBET, KGAM, KALF, EPS, LD - параметры, регулирующие качество решающего правила,

MOB - массив размерности M x 3, первый столбец - вектор принадлежности реализаций к образу, второй столбец - рабочий, третий - выходной - указывает номер вершины, в которую попадает объект обучающей выборки,

IPRINT - параметр, регулирующий печать: IPRINT = 0 - печати нет, IPRINT = 1 - есть вся печать, IPRINT = 2 - печать только результатов обучения,

IR2 - параметр режима.

**Выходные параметры:**

**О88** - количество ошибок на обучении,

**О99** - количество ошибок на "скользящем экзамене",

**И17** - массив размерности  $4 \times KWT$ , первый столбец - тип высказывания: 0 - набор имен, 1 - интервал, 2 - набор баллов или дискретов, 3 - гиперплоскость; второй столбец - номер признака, по которому строится высказывание; третий и четвертый - номера признаков для гиперплоскости,

**Н1X** - массив размерности  $Kx KWT$  - определяет количество объектов каждого образа в вершине,

**АРР** - массив размерности  $4 \times KWT$  пороговых значений, перечень имен для высказываний типа 0 (количество имен в наборе не более трех), если один из элементов массива равен В, то для соответствующей вершины это символ конца перечня имен или интервал для высказываний типа 1,2; третий и четвертый элементы строки равны 0 или коэффициенты гиперплоскости для 3,

**НР** - массив размерности  $KWT \times 4$ , первый столбец указывает номер вершины, в которую следует идти, если высказывание истинно, второй столбец определяет номер вершины, в которую следует идти, если высказывание ложно, третий столбец указывает номер текущей вершины, четвертый столбец - тип вершины (для конечной вершины значение равно 2),

**F** - вектор размерности  $KWT$  значений критерия.

**НОВ** - вектор размерности  $M$  - указывает номер предсказанного образа,

**АВЕ** - массив условных вероятностей размерности  $M \times K$ .

**Рабочие массивы:**

**RA2** - размерности  $M \times 2$

**SI** - размерности  $1M \times 2$

**В** - размерности  $2 \times N$

**КОВ** - размерности  $K \times 3$

**С** - размерности  $N \times 2$

**МВ1** - размерности  $M2 \times 3$

**RA3** - размерности  $M2 \times 2$

**X1** - размерности  $M2 \times N$

## ПРИЛОЖЕНИЕ 2

### Результаты работы программы

#### Исходные данные:

Количество объектов  $M = 20$

Количество признаков  $N = 6$

Параметр  $KWT = 1$

Параметр  $KGAM = 2$

Параметр  $KALF = 1$

Параметр  $KFS = 0,0$

Количество классов  $K = 3$

Количество ветвей  $KWT = 7$

Номер критерия  $IR = 1$

Длина внешнего пути есть  $ID = 1$

Пропуск  $B = 9,0$

#### Распределение объектов по образам в каждой вершине:

Вершина номер 1

6, 6, 8

Вершина номер 2

0, 0, 6

Вершина номер 3

6, 6, 2

Вершина номер 4

0, 6, 2

Вершина номер 5

6, 0, 0

Вершина номер 6

0, 6, 0

Вершина номер 7

0, 0, 2

#### Результат распознавания:

Количество объектов на контроле  $M_1 = 4$

Объект номер 1 принадлежит образу 3

Условные вероятности принадлежности к образам

0.0 0.0 1.000

Объект номер 2 принадлежит образу 3

Условные вероятности

0,0            0.0            1.000

Объект номер 3 принадлежит образу I

Условные вероятности

0.4286        0.4286        1.1429

Объект номер 4 принадлежит образу 3

Условные вероятности

0.0            0.0            1.000

Таблица I

## Результат обучения

k5	Решающее правило					
	NF(k5,3)	NJF(1,k5)	NJF(2,k5)	NJF(3,k5)	NJF(4,k5)	APF(1,k5)
I	I	0	I	0	0	3.0000
2	2	0	0	0	0	0.0
3	3	3	2	3	5	-6.6261
4	6	0	0	0	0	0.0000
5	7	0	0	0	0	0.0
6	4	2	4	0	0	3.00
7	5	0	0	0	0	0.0

k5	Решающее правило					
	APF(2,k5)	APF(3,k5)	APF(4,k5)	NF(k5,1)	NF(k5,2)	NF(k5,4)
I	6.0000	9.0	0.0	2	3	I
2	0.0	0.0	0.0	0	0	2
3	7.0922	-I.4888	-I.6850	4	5	I
4	0.0000	0.0	0.0	0	0	2
5	0.0	0.0	0.0	0	0	2
6	4.00	0.0	0.0	6	7	I
7	0.0	0.0	0.0	0	0	2

Здесь: k5 – номер, NF(k5,3) – номер исходящей вершины, NF(k5,1) – номер вершины, в которую надо идти, если высказывание истинно, NF(k5,2) – номер вершины, в которую надо идти, если высказывание можно, NF(k5,4) – указывает конечность вершины, NJF(1,k5) – индекс высказывания, NJF(j,k5), j = 2,4 – номера признаков, по которым строится высказывание, APF(j,k5), j = I,4, – пороги.

Количество ошибок при обучении OSS = 0.0.

Таблица 2

№ объекта	№ признака					
	1	2	3	4	5	6
I	5.0	6.0	5.6	6.0	5.8	0.0
2	0.3	0.3	5.7	6.0	6.1	3.7
3	0.5	5.6	5.0	1.8	14.0	6.8
4	0.0	II.1	17.5	0.0	17.0	13.0
5	3.9	0.0	4.7	0.0	17.2	9.1
6	7.4	5.4	7.5	0.0	22.2	18.0
7	6.8	10.0	0.0	0.0	0.0	8.5
8	8.0	II.2	10.1	14.8	13.3	4.4
9	4.8	6.3	0.0	7.8	18.8	1.6
10	0.0	0.0	3.8	3.9	7.6	3.1
II	II.0	0.0	0.0	0.0	22.1	II.7
I2	8.0	II.6	0.0	0.0	10.0	7.5
I3	7.5	0.0	3.5	5.0	0.0	5.0
I4	0.0	0.1	8.2	0.0	8.2	4.8
I5	0.0	5.8	5.6	6.0	19.9	12.2
I6	0.0	2.2	0.0	II.8	20.3	10.9
I7	2.2	0.5	3.0	0.0	15.0	10.0
I8	0.0	2.9	0.0	8.0	16.4	12.8
I9	0.5	0.0	0.0	5.6	14.9	7.5
20	0.0	6.0	10.0	0.0	14.8	13.2
2I	0.0	0.0	0.0	0.0	15.0	10.8
22	6.1	0.1	0.0	7.5	4.8	2.8
23	0.0	0.0	7.6	9.0	18.2	II.5
24	8.8	0.0	II.1	0.0	22.7	9.3
25	0.0	7.2	7.8	0.0	0.0	12.8
26	9.5	II.5	0.0	0.0	13.6	5.5
27	4.4	0.0	0.0	9.8	15.3	7.7
28	0.0	6.2	9.5	6.2	18.0	9.5