

规则描述中的统配符

黄玉霞 (中国科学院软件研究所 100080)

摘要:本文在规则描述中引入了统配符,并给出了相应的处理方案,可应用于信息管理与专家系统领域。

关键词:规则 统配符

一、统配符的引入

众所周知,DOS 文件系统中引入的统配符‘*’是可以与任何文件名匹配的符号,它给查找文件带来了极大的方便。例如要找一个批处理文件 ucdos.bat,而又不确切记得前面的 ucdos 时,可先用 `dir *.bat` 列出所有批处理文件如下:

a.bat
b.bat
ucoos.bat

在信息管理或专家系统中,经常需要描述这样一些规则,其形式为

表 1

		规则 1	规则 2	...
条 件	c_1	c_{11}	c_{12}	...
	c_2	c_{21}	c_{22}	...
	c_3	c_{31}	c_{32}	...
	$\vdots$	$\vdots$	$\vdots$	$\vdots$
	c_m	c_{m1}	c_{m2}	...
动作 集合 (或 序列)	a_1	a_{11}	a_{12}	...
	a_2	a_{21}	a_{22}	...
	a_3	a_{31}	a_{32}	...
	$\vdots$	$\vdots$	$\vdots$	$\vdots$
	a_n	a_{n1}	a_{n2}	...

规则 1 表示当条件 $c_1 = c_{11}$, $c_2 = c_{21}$, ..., $c_m = c_{m1}$ 时发生动作 a_{11} , a_{21} , a_{31} , ..., a_{n1} 或顺序发生动作 a_{11} , a_{21} , a_{31} , ..., a_{n1} 。

这里的条件是通过枚举的方式给出的,每个条件 c_i 的值域是有限的(设为 l_i),因而规则的最大个数是 $l_1 * l_2 * \dots * l_m$ 。随着条件数 m 的增大,这个排列数可能是相当大的。事实上,大量存在着这样的情况:某种条件的取值可以按其对应后面的动作影响作新的划分。例如,若条件 c_1 取值为 $c_{14}, c_{15}, \dots, c_{1l_1}$ 时后面的动作相同, c_1 可以进一步划分为 $c_{11}, c_{12}, c_{13}, c_1 *$ 。这个 $c_1 *$ 我们就用统配符 * 号来表示,它代表 c_{11}, c_{12}, c_{13} 以外 c_1 的所有可选值。当枚举集 $\{c_{11}, c_{12}, c_{13}\}$ 变为空集时,它表示可选值集合中的所有元素,与文件系统中的统配符意义相近。

二、规则中的列明优先原则

在引用规则时,条件的匹配采取列明优先的原则,即当条件的列明值和统配符值同时存在时,优先选用列明值相应的规则,施加其相应的动作。

三、统配符的范例

我们最近在开发国际集装箱运输运价系统时,发现集装箱运输的海运费费率是和集装箱的规格、箱型、货类、卸港、客户、运输条款等诸多条件相关的。

其中:集装箱规格 size 的值域为: $\{20^*, 40^*\}$

箱型 type 的值域为: $\{GP(\text{普通箱}), HC(\text{高箱}), FR(\text{冷藏箱}), OT(\text{开顶箱})\}$

货类 cargotype 的值域为: $\{GC(\text{干货}), HZ(\text{危险品}), *(\text{其他})\}$

卸港 pod(port of disload) 的值域为: $\{NY(\text{纽约}), HMB(\text{汉堡}), \dots, \}_{300}$

运输条款 term 的值域为: $\{YY(\text{场到场}), YD(\text{场到门}), DY(\text{门到场}), DD(\text{门到门})\}$

客户 customer 的值域为: $\{\text{客户 1}, \text{客户 2}, *(\text{其他客户})\}$

部分海运费率规则表 OFTRATE 可表述为:

表 2

size	type	cargotype	pod	term	customer	oftrate(usd)
20	GP	GC	NY	YY	客户 1	800
20	GP	GC	NY	YY	客户 2	810
20	GP	GC	NY	YY	*	850
20	GP	HZ	NY	YY	客户 1	1000
20	GP	HZ	NY	YY	客户 2	1100
20	GP	HZ	NY	YY	*	1200
20	GP	*	NY	YY	客户 1	900
20	GP	*	NY	YY	客户 2	920
20	GP	*	NY	YY	*	960

表 2 中,前面几列是条件,oftrate 是动作,表示费率 = 800 等值,表体列出的是到纽约的 20 # 普通箱用 YY 运输条款对不同客户和货类的费率值。在表达客户值时用 '*' 表示客户 1 和客户 2 以外的其他用户,而客户 1,客户 2 是货运公司的长期用户,享受各自的优惠费率。在表达货类时,用 '*' 表示 GC 和 HZ 以外的其他货类,其运价介于干货与危险品之间。

当没有枚举值出现时, '*' 也可以代表全部值的集合。例如:当运价与运输条款无关时,则用 '*' 表示运输条款的全部值。

表 3

size type cargotype pod term customer oftrate

20 GP GC HMB * 客户 1 700

表 3 表示的是为客户 1 运 20 # 普通箱到汉堡,干货类货不管用什么运输条款费率都是 700。

如果还存在另一条费率规则:

表 4

size type cargotype pod term customer oftrate

20 GP GC HMB * * 750

表 4 则表示在上例中除客户 1 以外的其他客户(包括客户 2),其海运费率均为 750。

列明优先的规则在这里体现为:对于客户 1,因为在

表 3 中有列明的客户值 customer = 客户 1,因而海运费率 = 700,而不是 750。对于客户 2 和其他客户,因为没有列明匹配的客户值,只能用表 4 的规则,即 customer = * 的费率 750。

四、规则引用中 '*' 的处理

——列明优先原则的实现


我们先从最简单的一个条件的规则来分析。设 c_1 的值域为 $\{c_{11}, c_{12}, \dots, c_{1n}, *\}$, 对于 $c_1 = c_{11}$, 一次找到的匹配规则可能有两类:

表 5

	规则 1	规则 2
c_1	c_{11}	*
动作集	a_{11}	a_{12}
	a_{21}	a_{22}
	$\vdots$	$\vdots$

对于 c_1 的任意指定值 $@c_1$ (假定为 c_{11}), 列明优先在程序中的实现方案有两个。

方案 1:



方案 1 对应的选择语句有两个。

方案 2:

用一个选择语句一次把匹配的规则都找到,然后通过排序找出列明优先者。大家知道,在 ASCII 字符集中, '*' 号位于字母、数字之前,更位于汉字之前(注:选 '*' 作为统配符出于两方面的考虑:(1)用户易于接受,(2)可选取值集合为字母、数字、汉字串)。对于给定的值 c_{11} ,我们只要用 ' $c_1 = c_{11}$, or $c_1 = *$ ' 一次查找,而将可能找到的两条规则用降序排列,取满足条件的第一个规则即可。用的 SQL 语言如下:


```
SELECT * INTO 临时表 FROM 原表
WHERE c1 = @c1 OR c1 = *
ORDER BY c1 DESC
```

对于两个以上的匹配条件, 设条件 c_2 的值域为 $\{c_{21}, c_{22}, \dots, c_{2l_2}, *\}$, $c_1 = @c_1$ (假定为 c_{11}), $c_2 = @c_2$ (假定为 c_{21}), 则匹配的规则至多有四条:

表 6

		规则 1	规则 2	规则 3	规则 4
条件	c_1	c_{11}	*	c_{11}	*
	c_2	c_{21}	c_{21}	*	*
动作集		a_{11}	a_{12}	a_{13}	a_{14}
		a_{21}	a_{22}	a_{23}	a_{24}
		$\vdots$	$\vdots$	$\vdots$	$\vdots$
		$\vdots$	$\vdots$	$\vdots$	$\vdots$

列明优先在程序中的实现也有两个方案。
方案 1:



方案 1 对应的选择语句有 6 个。

方案 2:

实现列明优先的一个选择语句如下:

```
SELECT * INTO 临时表 FROM 原表
WHERE c1 = @c1 OR c1 = *
AND c2 = @c2 OR c2 = *
ORDER BY c1 DESC,
        c2 DESC
```

然后取临时表中第一条记录的费率即可。两个方案比较不难看出, 方案 1 每一字段的匹配都需要一个 SE-

LECT 语句, 而方案 2 总共只需要一个 SELECT 语句。当允许统配符出现的字段从一个增加到两个时, 方案 1 的复杂度增加了许多, 它不止表现在 SELECT 语句数的增加, 而且还表现在程序的逻辑结构要复杂得多。相比之下, 方案 2 在逻辑上的复杂度几乎没有增加, 这一点当允许匹配的字段增加为多个时更为突出, 我们在查找特定条件下的海运费的费率值时用了以下的 SQL 语句:

```
SELECT * INTO OFTTMP FROM OFTRATE
WHERE size = @ size
AND type = @ type
AND cargotype = @ cargotype or cargotype = '*'
AND pod = @ pod
AND term = @ term
AND customer = @ customer or customer = '*'
ORDER BY customer DESC,
        cargotype DESC
```

方案 2 不仅程序结构清晰, 查询速度也相当理想, 若允许匹配的字段不止一个 (设为两个) 时,

- 规则 1 c_{11} c_{21} 有两个列明匹配
- 规则 2 * c_{21}
- 规则 3 c_{11} *
- 规则 4 * *

当规则 1 存在时, 毫无疑问, 应优先选它; 规则 1 不存在时, 规则 2 和规则 3 都只有一个列明匹配; 若它们同时存在, 应该如何选择呢? 这时, 应考虑在实际问题中条件 1 和条件 2 究竟哪个更重要, 将重要的条件紧随 ORDER BY 子句后首先列出。例如, 在客户和货类的条件中, 客户更为重要, 则可写成:

```
ORDER BY customer DESC,
        cargotype DESC
```

五、结束语

在描述规则时, 引入统配符 '*', 可以增强表现能力, 使规则数得到可观的减少, 这种减少会给规则引用时的匹配算法带来复杂性, 用 (三) 中介绍的第二种做法, 可使匹配算法结构清晰, 易于扩充, 并且有较快的运算速度。在信息管理和专家系统中, 规则被大量地描述、引用, 希望本文的介绍能对设计者有所补益。

(来稿时间: 1998 年 6 月)