

# 流行病学研究中数字型 ID 编码的校验

徐涛

在流行病学研究中存在大量个体样本,每个样本含有不同类型的研究内容,如样本的流行病学信息、实验室检测信息和用药信息等,这些信息存在于同一样本的不同调查表和不同的研究现场。为了确保个体样本信息的惟一性、关联性和易管理性,研究者大多采用十进制数字作为编码元素编制统一的 ID 编码,然后分配给每个研究对象作为其惟一的身份标识。但在实际工作中,处理这些十进制数字时常出现识别、书写和录入错误。这些错误主要表现为:①单个数字识别错误,如把 3 误认为 8;②相邻数字之间顺序颠倒错误,如 23 误认为 32,223 误认为 233;③数字跳跃错误,如 235 误认为 532,525 误认为 252;④遗漏一位或增加一位数字错误等。这些错误一般出现在调查表的填写和录入阶段。如果在流行病学研究中出现 ID 编码错误,会造成个体样本信息无法识别,信息无法利用。特别是在多中心流行病学研究中,同一个研究对象的数据来自不同的现场、实验室和医院等多个研究中心,当某个 ID 编码出现问题时,相同研究对象的数据无法连接,信息难以交换和利用。

为了尽量避免数据输入阶段出现 ID 编码错误,通常在程序设计时,对 ID 编码字段设置最小值和最大值的逻辑检查方式。这种方式只能够解决上述④中的错误,对符合逻辑检查范围合法值的其他类“错误”难以发现。例如原编码为 53230201 被误认为是 53320201 或 53230501 等类似错误。以下介绍一种十进制编码差错校验方法,以解决实际应用中存在的这类问题。

## 一、基本原理

1. Verhoeff's 两面体群  $D_5$  校验算法:数学家为了解决十进制数字编码的校验问题,先后提出了多种编码算法。其中,以 Verhoeff's 的十进制两面体群  $D_5$  码表校验算法应用较为广泛,该算法能够发现 100% 的单个数字错误和相邻数字之间顺序颠倒错误,95% 的双数字错误,94% 的数字跳跃错误和 100% 的数字缺失和增加数字错误。

Verhoeff's 以两面体群  $D_5$  码表(表 1)和 Verhoeff's 校验码表(表 2)为基础,提出了以校验等式为零的校验算法。校验等式为:

$$f_0(a_0) \# f_1(a_1) \# f_2(a_2) \# \dots \# f_{n-1}(a_{n-1}) = 0$$

式中的操作符“#”不是通常意义上的数字运算符,而是组群运算, $f_i$  表示固定顺序数列的第  $i$  次迭代。

作者单位:100050 北京,中国疾病预防控制中心公共卫生监测与信息中心

表1 Verhoeff's 两面体群  $D_5$  码表

*	0	1	2	3	4	5	6	7	8	9
0	0	1	2	3	4	5	6	7	8	9
1	1	2	3	4	0	6	7	8	9	5
2	2	3	4	0	1	7	8	9	5	6
3	3	4	0	1	2	8	9	5	6	7
4	4	0	1	2	3	9	5	6	7	8
5	5	9	8	7	6	0	4	3	2	1
6	6	5	9	8	7	1	0	4	3	2
7	7	6	5	9	8	2	1	0	4	3
8	8	7	6	5	9	3	2	1	0	4
9	9	8	7	6	5	4	3	2	1	0

表2 Verhoeff's 校验码表

	0	1	2	3	4	5	6	7	8	9
0	0	1	2	3	4	5	6	7	8	9
1	1	5	7	6	2	8	3	0	9	4
2	5	8	0	3	7	9	6	1	4	2
3	8	9	1	6	0	4	3	5	2	7
4	9	4	5	3	1	2	6	8	7	0
5	4	2	8	6	5	7	3	9	0	1
6	2	7	9	3	8	0	6	4	1	5
7	7	0	4	6	9	1	3	2	5	8

2. ID 编码规则:可校验的 ID 编码格式为“ID 编码 = 类标识位 + 顺序号 + 1 个十进制数字校验码”。该编码与普通编码的区别仅在于在编码最右侧增加 1 个十进制数字校验码。该格式编码各部分含义:①类标识位:类标识位表示样本个体的类别,研究者可以根据自己研究需要确定类标识位的长度和类别数,类标识中可以加入“-”以区别子类。例如某项艾滋病流行病学研究中要涉及两个现场和四类人群,其类标识符为:现场标识位 + 人群标识位。②顺序号:是 1, ...,  $n$ , 增量为 1 的正整数,如 0001, 0002, ...,  $n$ , 其中  $n$  为研究者最小子类中所需的最大样本数。③校验码:以“类标识位 + 顺序号”为基础,根据 Verhoeff's 校验算法由程序计算得到的校验码。

3. ID 编码生成及校验程序:根据 Verhoeff's 校验法, ID 编码的校验软件包含两部分内容:生成可校验的 ID 编码程序和编码校验程序。

(1)生成可校验的 ID 编码:本程序生成 ID 编码的最右侧的 1 位十进制数字校验码:

```
check_digit {
# 定义局部变量
local(@string) = split(//, $_[1]);
local($status, $i, $j, $k, $m, $rows, $cols);
local(@ip_rows, @ij_rows, %ip_cols, %ij_cols);
# 定义两个二维数组码表
```

```

%ip_cols=定义表 2 的 2 维数组
%ij_cols = 定义表 1 的 2 维数组
for ( $cols=1; $cols <= 8; $cols++ ) {
  @ip_rows=split(/,/,$ip_cols|$cols);
  for( $rows=1; $rows <= 10; $rows++ ) {
    $ip|$rows, $cols| = $ip_rows[ $rows];
  }
}
for( $cols=1; $cols <= 10; $cols++ ) {
  @ij_rows=split(/,/,$ij_cols|$cols);
  for( $rows=1; $rows <= 10; $rows++ ) {
    $ij|$rows, $cols| = $ij_rows[ $rows];
  }
}
$ k=0;
$ m=0;
if( $ k = 0 ) { $ status="1, "; }
else{ $ status="0, "; }
# 生成校验码
for( $ i=0; $ i <= 9; $ i++ ) {
  if( $ ij|$k+1, $ ip|$i+1, ($m%8)+1|+1) == 0 )
  | $ status .= $ i;
}
return( $ status);
}
}

```

#### 生成 ID 编码:

```

for( $ i= $ first; $ i <= $ last; $ i++ ); # first 是第 1 个样本的号; last 是最后样本的号
  $ id = sprintf( "%0$ {id_length}d", $ i );
  $ num = $ site. $ id; # site 是 ID 编码的类标识符, num = ID 编码的类标识编号 + 顺序号
  ( $ check, $ digit ) = split(/,/,$ &check_digit( $ num ));
  print ID "$ site - $ id - $ digit \ n";
}

```

(2) ID 编码校验程序: 编码校验程序由  $D_5$  码表二维数组、Verhoeff's 校验码表二维数组和编码校验三部分组成, 两个二维数组定义与 ID 编码生成程序相同, 此不再重复。以下是 ID 编码校验程序的主要部分:

```

while( $ j < length( $ cptid )); # cptid 是调查表中个案的实际填报的 ID 编码
  $ digit = substr( $ cptid, $ j, 1 );
  if( $ digit >= 0 & $ digit <= 9 ) {
    $ k = @ij[ $ k * 10 + @ip[ $ digit * 8 + ( $ m % 8 ) ] ];
    $ m ++ ;
  }
  $ j ++ ;
}

```

## 二、实例分析

以中国国际综合性艾滋病研究项目(CIPRA)的一个研究项目为例来说明可校验 ID 编码的使用过程。该研究是以 8 个地区的两类人群为研究对象, 估计总样本量为 5500, 研究目的是估计两类人群的 HIV-1 新发感染率和性病感染率。该研究由国家性病艾滋病中心等 5 个研究单位组成。各疾病预防控制中心(CDC)承担流行病学现场调查、相关疾病的实验室初筛检测、确认检测和实验室质量控制检测等。每个 CDC 将调查(检测)后得到的数据以调查表的方式通过传真或 Email 传到 CIPRA 项目的数据中心, 不同中心同一研究对象的数据是以 ID 编码进行关联。

1. 可校验 ID 编码的处理过程: ①生成 ID 编码: CIPRA 数据核心根据研究设计所需样本量, 利用 ID 编码生成程序

生成各类地区的可校验 ID 编码。例如第 4 类地区所需样本量为 1500, 编码生成程序将产生 1500 个 ID 编码。例如 4-0988-9 是一个实际使用的编码, 编码中 4 表示第四类地区, 0988 是第四类地区中第 988 个研究对象, 最后的数字 9 是该编码的校验码。②ID 编码使用: 数据核心将产生的可校验的 ID 编码提供给该研究项目负责人, 项目数据管理员将 ID 编码提供给现场调查人员, 现场调查员将编码分配给每个研究对象, 需要注意的是每个调查对象只能分配给一个 ID 编码, 即 ID 编码是惟一的。③ID 编码的自动校验: 当填有可校验 ID 编码的调查表发送到数据核心时, 数据核心的数据管理员对收到的调查表进行数据录入, 当录入到 ID 编码字段时, 编码校验程序自动捕获 ID 编码错误并通知数据管理员, 数据管理员根据正确的 ID 编码进行纠正, 不能纠正的错误将通知发生错误的研究中心(现场), 并将纠正后的调查表重新传送给数据中心。ID 编码校验程序调用非常简单, 当前流行的数据库管理软件都支持这种外部调用。

2. CIPRA 项目使用此类 ID 编码的效果: CIPRA 项目在中国开展了 5 个课题的研究, 在这些课题中的研究对象 ID 编码全部采用本文所述的编码方式, 在 CIPRA 的 5 年工作中, 共处理 ID 编码 241 836 次, 及时发现和纠正现场 ID 编码填写错误 200 多起, 数据管理人员错误录入 ID 编码现象更是无法计算。在如此大的错误发生率情况下, 未出现因未捕获 ID 编码错误而造成数据无法归档和关联情况, 使用效果令人满意。

## 三、讨论

当前对十进制数字编码的校验还没有一个无差错的编码解决方案, Verhoeff 提出的十进制两面体群  $D_5$  码表校验算法虽然应用广泛, 但也不能发现所有的十进制数字编码错误, 所以使用时应注意这一点。但从 CIPRA 项目对 24 万次的 ID 编码校验效果来看, 该编码算法还是一个值得信赖和实用的编码方法。

编码错误发现的及时性在流行病学资料处理时很重要, 若错误的编码不能及时被发现, 当资料处于分析阶段时再被发现, 将给纠正错误带来几何级数的工作量, 有时甚至无法纠正, 这样会给后续的资料分析带来不必要的麻烦。本编码方案能做到“即录即纠”的效果, 也就是说, 当数据管理员第一次将原始资料录入到数据库时, 就能及时捕捉到 ID 编码的错误, 在第一时间与现场联系纠正错误编码。

本文所述方法只能在数据录入阶段实现, 而不能在现场手工填写时使用, 这也是此方法的一个缺憾。另外本文所涉及程序是在 PERL 语言基础上开发的, 该程序只能在具有 PERL 语言编码解释器的计算机中运行。PERL 语言编码解释器可以从大部分的软件下载网站下载。基于 Windows 操作系统的 PERL 语言编码解释器是 Active PERL, 目前最新版本为 ActivePerl 5.8.8.822。

(收稿日期: 2008-01-14)

(本文编辑: 张林东)