用 tidyr 清理数据 : : 速查表

清理数据 **(Tidy data)** 这种方法主要用于整理列表数据，使其具有跨包兼容的一致性数据结构。一个整洁的数据集应具备如下特征：

每个变量
占一列 **(column)**

&

每组观测值，或每个案例，
占一行**(row)**

以向量**(vectors)**
的形式访问变量

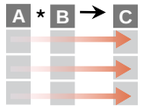

通过向量化运算
保存案例

Tibbles

一种扩展型数据框

Tibbles 作为一种列表格式，由 **tibble** 数据包提供。其继承了DataFrame 类型，但有如下改进：

- **取子集**] 仍返回 tibble, [[和 $ 返回向量
- 返回列时，**不进行部分匹配** (不存在就不返回)
- **显示** 在屏幕上显示数据的简洁视图

options(tibble.print_max = n, tibble.print_min = m, tibble.width = Inf**)** 控制默认的显示设置

View() or **glimpse()** 观察整个数据集

创建一个 **TIBBLE** 数据框

tibble(…**)** 根据列(columns)创建
tibble(x = 1:3, y = c("a", "b", "c"))

tribble(…**)** 根据行(rows)创建
tribble(~x, ~y,
1, "a",
2, "b",
3, "c")

两种创建方法结果一致

```
A tibble: 3 × 2
      x     y
  <int> <chr>
1     1     a
2     2     b
3     3     c
```

as_tibble(x, …**)** 将DataFrame类型转换为tibble

enframe(x, name = "name", value = "value"**)** 将向量转成 tibble，反之则为**deframe()**.

is_tibble(x**)** 检测 x 是否为 tibble 类型

重组数据 - 数据透视，调整格局

table4a

country	1999	2000
A	0.7K	2K
B	37K	80K
C	212K	213K

→

country	year	cases
A	1999	0.7K
B	1999	37K
C	1999	212K
A	2000	2K
B	2000	80K
C	2000	213K

pivot_longer(data, cols, names_to = "name", values_to = "value", values_drop_na = FALSE**)**

将多列折叠为两列，从而“拉长”数据。

原列名转移至新的 names_to 列，

原数值转移至新的 values_to 列。

pivot_longer(table4a, cols = 2:3, names_to ="year", values_to = "cases")

table2

country	year	type	count
A	1999	cases	0.7K
A	1999	pop	19M
A	2000	cases	2K
A	2000	pop	20M
B	1999	cases	37K
B	1999	pop	172M
B	2000	cases	80K
B	2000	pop	174M
C	1999	cases	212K
C	1999	pop	1T
C	2000	cases	213K
C	2000	pop	1T

→

country	year	cases	pop
A	1999	0.7K	19M
A	2000	2K	20M
B	1999	37K	172M
B	2000	80K	174M
C	1999	212K	1T
C	2000	213K	1T

pivot_wider(data, names_from = "name", values_from = "value"**)**

和 pivot_longer() 相反，将两列扩展为多列，从而“加宽”数据。

原来的两列数据，一列扩展为不同的新列名，另一列的数值也随之重新分布。

pivot_wider(table2, names_from = type, values_from = count)

拆分单元格 - 将单元格拆分或合并为独立数值

table5

country	century	year
A	19	99
A	20	00
B	19	99
B	20	00

→

country	year
A	1999
A	2000
B	1999
B	2000

unite(data, col, …, sep = "_", remove = TRUE, na.rm = FALSE**)** 多列合并为一列

unite(table5, century, year, col = "year", sep = "")

table3

country	year	rate
A	1999	0.7K/19M
A	2000	2K/20M
B	1999	37K/172M
B	2000	80K/174M

→

country	year	cases	pop
A	1999	0.7K	19M
A	2000	2K	20M
B	1999	37K	172M
B	2000	80K	174M

separate(data, col, into, sep = "[^[:alnum:]]+", remove = TRUE, convert = FALSE, extra = "warn", fill = "warn", …**)** 一列拆分为多列

也可用 **extract()**.

separate(table3, rate, sep = "/", into = c("cases", "pop"))

table3

country	year	rate
A	1999	0.7K/19M
A	2000	2K/20M
B	1999	37K/172M
B	2000	80K/174M

→

country	year	rate
A	1999	0.7K
A	1999	19M
A	2000	2K
A	2000	20M
B	1999	37K
B	1999	172M
B	2000	80K
B	2000	174M

separate_rows(data, …, sep = "[^[:alnum:].]+", convert = FALSE**)** 一列拆分为多行

separate_rows(table3, rate, sep = "/")

扩展表格

创建新的变量组合，或识别隐式缺失值(即没有呈现在数据集中的变量组合).

x

x1	x2	x3
A	1	3
B	1	4
B	2	3

→

x1	x2
A	1
A	2
B	1
B	2

expand(data, …**)**
创建一个新tibble，包含原数据 … 列中所有可能的变量取值组合，同时舍去其他未选中的变量。
expand(mtcars, cyl, gear, carb)

x

x1	x2	x3
A	1	3
B	1	4
B	2	3

→

x1	x2	x3
A	1	3
A	2	NA
B	1	4
B	2	3

complete(data, …, fill = list()**)** 补全 … 列中所有可能的变量取值组合，并在剩余的变量中相应填充为缺失值。
complete(mtcars, cyl, gear, carb)

处理缺失值

舍弃或替换明确的缺失值(NA).

x

x1	x2
A	1
B	NA
C	NA
D	3
E	NA

→

x1	x2
A	1
D	3

drop_na(data, …**)**
舍弃… 列中含有缺失值的所有行
drop_na(x, x2)

x

x1	x2
A	1
B	NA
C	NA
D	3
E	NA

→

x1	x2
A	1
B	1
C	1
D	3
E	3

fill(data, …, .direction = "down"**)** 将前个或后个数据填充…列中的缺失值 (默认自上而下填充)
fill(x, x2)

x

x1	x2
A	1
B	NA
C	NA
D	3
E	NA

→

x1	x2
A	1
B	2
C	2
D	3
E	2

replace_na(data, replace**)**
用特定值替换指定列中的所有缺失值NA
replace_na(x, list(x2 = 2))

嵌套数据

嵌套数据框 **(nested data frame)** 将不同的列表嵌套储存为一个更大数据框的 list-column 。List-columns 内也可以是一系列的向量或不同的数据类型。
嵌套数据框可用于:

- 保留观察值与数据各子集之间的关系。保留嵌套变量的类型 (比如因子型和日期时间型，不会被强制转为字符型)。
- 一次性处理多个子表格，通过 **purrr** 包中的map(), map2(), 和 pmap() 等函数，或 **dplyr** 包中的 rowwise() 分组。

创建嵌套数据

nest(data, …**)**

将成组的单元格移至一个数据框的list-column中。可单独使用，或与 dplyr::**group_by()** 函数配合使用。

1. 先用 **group_by()** 分组，然后用 **nest()** 将组移至list-column中。

```
n_storms <- storms %>%
  group_by(name) %>%
  nest()
```

2. 用 **nest(new_col = c(x, y))** 指定需要分组的列
   按照 dplyr::**select()** 语法

```
n_storms <- storms %>%
  nest(data = c(year:long))
```

name	yr	lat	long
Amy	1975	27.5	-79.0
Amy	1975	28.5	-79.0
Amy	1975	29.5	-79.0
Bob	1979	22.0	-96.0
Bob	1979	22.5	-95.3
Bob	1979	23.0	-94.6
Zeta	2005	23.9	-35.6
Zeta	2005	24.2	-36.1
Zeta	2005	24.7	-36.6

→

name	yr	lat	long
Amy	1975	27.5	-79.0
Amy	1975	28.5	-79.0
Amy	1975	29.5	-79.0
Bob	1979	22.0	-96.0
Bob	1979	22.5	-95.3
Bob	1979	23.0	-94.6
Zeta	2005	23.9	-35.6
Zeta	2005	24.2	-36.1
Zeta	2005	24.7	-36.6

→ 嵌套后的数据框

name	data
Amy	<tibble [50x3]>
Bob	<tibble [50x3]>
Zeta	<tibble [50x3]>

list-column中每个“单元格”的内容

yr	lat	long
1975	27.5	-79.0
1975	28.5	-79.0
1975	29.5	-79.0

yr	lat	long
1979	22.0	-96.0
1979	22.5	-95.3
1979	23.0	-94.6

yr	lat	long
2005	23.9	-35.6
2005	24.2	-36.1
2005	24.7	-36.6

用 [[]] 索引 list-column `n_storms$data[[1]]`

创建含有 list-columns 的 Tibbles

tibble::**tribble(…)** 按需要构造 list-columns

```
tribble( ~max, ~seq,
           3,   1:3,
           4,   1:4,
           5,   1:5)
```

max	seq
3	<int [3]>
4	<int [4]>
5	<int [5]>

tibble::**tibble(…)** 把输入列表保存为 list-columns

```
tibble(max = c(3, 4, 5), seq = list(1:3, 1:4, 1:5))
```

tibble::**enframe(**x, name="name", value="value"**)**
将多级列表转换为带有 list-columns 的tibble

```
enframe(list('3'=1:3, '4'=1:4, '5'=1:5), 'max', 'seq')
```

通过其他函数输出 list-columns

dplyr::**mutate()**, **transmute()**, and **summarise()**
当这些函数返回列表时，会输出 list-columns

```
mtcars %>%
  group_by(cyl) %>%
  summarise(q = list(quantile(mpg)))
```

重组嵌套数据

unnest(data, cols, ..., keep_empty = FALSE**)**

与 nest() 相反，将嵌套的列重新展开为常规列，

```
n_storms %>% unnest(data)
```

unnest_longer(data, col, values_to = NULL, indices_to = NULL**)**
将一个 list-column 按行展开

```
starwars %>%
  select(name, films) %>%
  unnest_longer(films)
```

name	films
Luke	<chr [5]>
C-3PO	<chr [6]>
R2-D2	<chr[7]>

→

name	films
Luke	The Empire Strik…
Luke	Revenge of the S…
Luke	Return of the Jed…
C-3PO	The Empire Strik…
C-3PO	Attack of the Cl…
C-3PO	The Phantom M…
R2-D2	The Empire Strik…
R2-D2	Attack of the Cl…
R2-D2	The Phantom M…

unnest_wider(data, col**)**
将一个 list-column 按列展开

```
starwars %>%
  select(name, films) %>%
  unnest_wider(films)
```

name	films
Luke	<chr [5]>
C-3PO	<chr [6]>
R2-D2	<chr[7]>

→

name	..1	..2	..3
Luke	The Empire...	Revenge of...	Return of...
C-3PO	The Empire...	Attack of...	The Phantom...
R2-D2	The Empire...	Attack of...	The Phantom...

hoist(.data, .col, ..., .remove = TRUE)
选择性地按列展开 list-column
用 purrr::pluck() 语法选择 list-column 中需要展开的列

```
starwars %>%
  select(name, films) %>%
  hoist(films, first_film = 1, second_film = 2)
```

name	films
Luke	<chr [5]>
C-3PO	<chr [6]>
R2-D2	<chr[7]>

→

name	first_film	second_film	films
Luke	The Empire…	Revenge of…	<chr [3]>
C-3PO	The Empire…	Attack of…	<chr [4]>
R2-D2	The Empire…	Attack of…	<chr [5]>

变换嵌套数据

一个向量化函数通常要取一个向量，平行变换每一个元素, 然后返回一个相同长度的向量。因此向量函数本身无法应用于列表，比如嵌套形成的 list-columns。

经 dplyr::**rowwise(**.data, …**)** 这一函数分组处理后，每行为一组，每组中的 list-columns 元素直接出现 (通过 [[访问), 而非长度为1的列表。**当你使用 rowwise() 函数时，dplyr 包中的函数就能以向量化处理的方式应用于 list-columns了。**

data
<tibble [50x4]>
<tibble [50x4]>
<tibble [50x4]>

→

data
<tibble [50x4]>
<tibble [50x4]>
<tibble [50x4]>

fun(<tibble [50x4]> , …) → result 1
fun(<tibble [50x4]> , …) → result 2
fun(<tibble [50x4]> , …) → result 3

将一个函数应用到一个list-column，
并创建一个新的 list-column。

```
n_storms %>%
  rowwise() %>%
  mutate(n = list(dim(data)))
```

dim() 每行返回两个值

加一层列表函数，令mutate函数创建一个list-column

将一个函数应用到一个list-column，
并创建一个新的常规列。

```
n_storms %>%
  rowwise() %>%
  mutate(n = nrow(data))
```

nrow() 每行返回一个整型

将**多个**list-columns 折叠为一个。

```
starwars %>%
  rowwise() %>%
  mutate(transport = list(append(vehicles, starships)))
```

append() 每行返回一个列表，所以列的类型必须为列表类型

将一个函数用于**多个**list-columns

```
starwars %>%
  rowwise() %>%
  mutate(n_transports = length(c(vehicles, starships)))
```

length() 每行返回一个整型

参见 **purrr** 包中的更多列表函数