

使用R进行logistic回归分析

Alex / 2025-05-13 / free_learner@163.com / AlexBrain.cn

本文介绍在R中使用logistic回归模型预测二分类变量的基本方法。

一、背景

Logistic回归模型和线性回归模型在形式上很接近，区别在于对于线性模型，响应变量（response variable）是连续变量，而对于logistic回归，响应变量是二分类变量：

$$\log\left(\frac{p}{1-p}\right) = \mathbf{X}\boldsymbol{\beta}$$

在上式中， p 表示事件发生（比如患病）的概率， $1 - p$ 表示事件未发生（比如不患病）的概率， $\frac{p}{1-p}$ 表示odds（一般翻译为“几率”）， $\log\left(\frac{p}{1-p}\right)$ 表示对odds取自然对数，一般称为log odds或logit； \mathbf{X} 和 $\boldsymbol{\beta}$ 分别表示预测变量（predictor variable）构成的矩阵和对应的回归系数。在线性回归中，回归系数（假设用 β_i 表示）表示某个预测变量（假设用 x_i 表示）增加一个单位，响应变量变化 β_i 个单位；在logistic回归中，回归系数表示 x_i 增加一个单位，log odds变化 β_i 个单位。 e^{β_i} 表示odds ratio (OR，几率比)，表示 x_i 增加一个单位，事件发生的几率变化为原来的 e^{β_i} 倍。比如， e^{β_i} 等于1.5，表示 x_i 增加一个单位，事件发生的几率变化为原来的1.5倍，即增加0.5倍。

Logistic回归模型既可以用于统计推断的目的，关注回归系数的方向和显著性，也可以用于预测，关注在新数据上的预测表现。

二、样例数据

我这里测试使用的样例数据为 `mlbench` 包里的 `PimaIndiansDiabetes2` 数据集，共包含9个变量。我们根据前8个变量来预测最后一个变量（是否患有糖尿病）。由于包含缺失值，因此先去除含有缺失值的样本，使用剩下的数据来构建模型。此外，将80%的数据作为训练集，20%的数据作为测试集。

```
## Load and clean data
data("PimaIndiansDiabetes2", package = "mlbench")
in_idx <- complete.cases(PimaIndiansDiabetes2)
all_dat <- PimaIndiansDiabetes2[in_idx,]
## Split the whole dataset into training and test sets
N <- nrow(all_dat)
set.seed(100)
train_idx <- sample(c(1:N), round(0.8*N))
train_dat <- all_dat[train_idx, ]
test_dat <- all_dat[-train_idx, ]
```

三、训练模型

```
## Train logistic regression model
logit_mod <- glm(diabetes ~ ., family = binomial(link = "logit"), data = train_dat)
summary(logit_mod)
## Calculate odds ratio
exp(coef(logit_mod))
```

在上面的代码中，使用R自带的 `glm` 函数进行模型拟合，对于响应变量的编码，可以将事件发生和未发生编码为数字1和0，也可以编码为一个因子变量，第一个水平表示事件未发生，第二个水平表示事件发生。模型拟合结果如下：

```
Call:
glm(formula = diabetes ~ ., family = binomial(link = "logit"),
     data = train_dat)
```

Coefficients:

	Estimate	Std. Error	z value	Pr(> z)	
(Intercept)	-9.4668206	1.3343757	-7.095	1.30e-12	***
pregnant	0.0847091	0.0599348	1.413	0.15755	
glucose	0.0377368	0.0062986	5.991	2.08e-09	***
pressure	-0.0105557	0.0132871	-0.794	0.42694	
triceps	0.0031191	0.0190381	0.164	0.86986	
insulin	-0.0008424	0.0013783	-0.611	0.54108	
mass	0.0894500	0.0297206	3.010	0.00262	**
pedigree	0.7272649	0.4615445	1.576	0.11509	
age	0.0342975	0.0201135	1.705	0.08816	.

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for binomial family taken to be 1)

Null deviance: 402.89 on 313 degrees of freedom
Residual deviance: 282.51 on 305 degrees of freedom
AIC: 300.51

Number of Fisher Scoring iterations: 5

从上面的结果可以看到，`glucose` 和 `mass` 对于预测 `diabetes` 具有显著贡献。每个回归系数对应的OR值如下：

(Intercept)	pregnant	glucose	pressure	triceps	insulin	mass
pedigree	age					
7.737703e-05	1.088400e+00	1.038458e+00	9.894998e-01	1.003124e+00	9.991579e-01	1.093573e+00
2.069413e+00	1.034892e+00					

从上面的结果可以看到，`glucose` 每增加一个单位，患糖尿病的几率增加3.8%倍。

四、测试模型

```
library(caret)
## Test model on unseen data
pred_prob <- predict(logit_mod, test_dat, type="response")
pred_class <- factor(ifelse(pred_prob > 0.5, 'pos', 'neg'), levels = c('neg', 'pos'))
caret::confusionMatrix(table(Predicted=pred_class, Real=test_dat$diabetes), positive = 'pos')
```

注意在使用 `predict` 函数时，需要加上 `type="response"`，返回的数值表示事件发生的概率，一般选择概率大于0.5为阈值，将预测值划分为两类。使用 `caret` 包里 `confusionMatrix` 函数计算一些反映预测表现的指标，结果如下：

Confusion Matrix and Statistics

	Real	
Predicted	neg	pos
neg	48	10
pos	7	13

Accuracy : 0.7821
95% CI : (0.6741, 0.8676)

No Information Rate : 0.7051
P-Value [Acc > NIR] : 0.08327

Kappa : 0.4552

Mcnemar's Test P-Value : 0.62763

Sensitivity : 0.5652
Specificity : 0.8727
Pos Pred Value : 0.6500
Neg Pred Value : 0.8276
Prevalence : 0.2949
Detection Rate : 0.1667
Detection Prevalence : 0.2564
Balanced Accuracy : 0.7190

'Positive' Class : pos