

Réplication “*Risk Analysis of the Space Shuttle: Pre-Challenger Prediction of Failure*”

Matthieu HAAS

05/02/2021

Dans ce travail, l’objectif est de répliquer certaines analyses de l’article *Risk Analysis of the Space Shuttle: Pre-Challenger Prediction of Failure*, disponible ici. A la quatrième page de l’article, ils présentent les meilleures estimations de la régression logistique utilisant uniquement la température comme étant : $\hat{\alpha} = 5.085$ et $\hat{\beta} = -0.1156$ et leur erreur standard asymptotique respective est de : $s_{\hat{\alpha}} = 3.052$ et $s_{\hat{\beta}} = 0.047$. La qualité d’ajustement de ce modèle est de : $G^2 = 18.086$ avec 21 degrés de liberté. Notre objectif est de reproduire les étapes derrière ce calcul et la figure 4 de l’article, en l’améliorant si possible.

Information technique sur l’ordinateur réalisant l’analyse

Nous utiliserons ici un langage R et la librairie ggplot2.

```
library(ggplot2)
sessionInfo()
```

```
## R version 4.0.3 (2020-10-10)
## Platform: x86_64-w64-mingw32/x64 (64-bit)
## Running under: Windows 10 x64 (build 19041)
##
## Matrix products: default
##
## locale:
## [1] LC_COLLATE=English_United Kingdom.1252
## [2] LC_CTYPE=English_United Kingdom.1252
## [3] LC_MONETARY=English_United Kingdom.1252
## [4] LC_NUMERIC=C
## [5] LC_TIME=English_United Kingdom.1252
##
## attached base packages:
## [1] stats      graphics  grDevices  utils      datasets  methods    base
##
## other attached packages:
## [1] ggplot2_3.3.3
##
## loaded via a namespace (and not attached):
## [1] knitr_1.31      magrittr_2.0.1  munsell_0.5.0   colorspace_2.0-0
## [5] R6_2.5.0        rlang_0.4.10    stringr_1.4.0   tools_4.0.3
## [9] grid_4.0.3      gtable_0.3.0    xfun_0.20       withr_2.4.1
## [13] htmltools_0.5.1 ellipsis_0.3.1  yaml_2.2.1      digest_0.6.27
```

```
## [17] tibble_3.0.6      lifecycle_0.2.0   crayon_1.4.0      vctrs_0.3.6
## [21] glue_1.4.2        evaluate_0.14     rmarkdown_2.6     stringi_1.5.3
## [25] compiler_4.0.3    pillar_1.4.7     scales_1.1.1      pkgconfig_2.0.3
```

Voici les librairies disponibles.

```
devtools::session_info()
```

```
## - Session info -----
## setting value
## version R version 4.0.3 (2020-10-10)
## os      Windows 10 x64
## system  x86_64, mingw32
## ui      RTerm
## language (EN)
## collate English_United Kingdom.1252
## ctype   English_United Kingdom.1252
## tz      Europe/Paris
## date    2021-02-09
##
## - Packages -----
## package * version date      lib source
## assertthat 0.2.1 2019-03-21 [1] CRAN (R 4.0.3)
## cachem      1.0.1 2021-01-21 [1] CRAN (R 4.0.3)
## callr       3.5.1 2020-10-13 [1] CRAN (R 4.0.3)
## cli         2.3.0 2021-01-31 [1] CRAN (R 4.0.3)
## colorspace  2.0-0 2020-11-11 [1] CRAN (R 4.0.3)
## crayon      1.4.0 2021-01-30 [1] CRAN (R 4.0.3)
## desc        1.2.0 2018-05-01 [1] CRAN (R 4.0.3)
## devtools    2.3.2 2020-09-18 [1] CRAN (R 4.0.3)
## digest      0.6.27 2020-10-24 [1] CRAN (R 4.0.3)
## ellipsis    0.3.1 2020-05-15 [1] CRAN (R 4.0.3)
## evaluate    0.14   2019-05-28 [1] CRAN (R 4.0.3)
## fastmap     1.1.0 2021-01-25 [1] CRAN (R 4.0.3)
## fs          1.5.0 2020-07-31 [1] CRAN (R 4.0.3)
## ggplot2     * 3.3.3 2020-12-30 [1] CRAN (R 4.0.3)
## glue        1.4.2 2020-08-27 [1] CRAN (R 4.0.3)
## gtable      0.3.0 2019-03-25 [1] CRAN (R 4.0.3)
## htmltools   0.5.1 2021-01-12 [1] CRAN (R 4.0.3)
## knitr       1.31   2021-01-27 [1] CRAN (R 4.0.3)
## lifecycle   0.2.0 2020-03-06 [1] CRAN (R 4.0.3)
## magrittr    2.0.1 2020-11-17 [1] CRAN (R 4.0.3)
## memoise     2.0.0 2021-01-26 [1] CRAN (R 4.0.3)
## munsell     0.5.0 2018-06-12 [1] CRAN (R 4.0.3)
## pillar      1.4.7 2020-11-20 [1] CRAN (R 4.0.3)
## pkgbuild    1.2.0 2020-12-15 [1] CRAN (R 4.0.3)
## pkgconfig   2.0.3 2019-09-22 [1] CRAN (R 4.0.3)
## pkgload     1.1.0 2020-05-29 [1] CRAN (R 4.0.3)
## prettyunits 1.1.1 2020-01-24 [1] CRAN (R 4.0.3)
## processx    3.4.5 2020-11-30 [1] CRAN (R 4.0.3)
## ps          1.5.0 2020-12-05 [1] CRAN (R 4.0.3)
## purrr       0.3.4 2020-04-17 [1] CRAN (R 4.0.3)
## R6          2.5.0 2020-10-28 [1] CRAN (R 4.0.3)
```

```
## remotes      2.2.0    2020-07-21 [1] CRAN (R 4.0.3)
## rlang        0.4.10   2020-12-30 [1] CRAN (R 4.0.3)
## rmarkdown    2.6      2020-12-14 [1] CRAN (R 4.0.3)
## rprojroot    2.0.2    2020-11-15 [1] CRAN (R 4.0.3)
## scales       1.1.1    2020-05-11 [1] CRAN (R 4.0.3)
## sessioninfo  1.1.1    2018-11-05 [1] CRAN (R 4.0.3)
## stringi      1.5.3    2020-09-09 [1] CRAN (R 4.0.3)
## stringr      1.4.0    2019-02-10 [1] CRAN (R 4.0.3)
## testthat     3.0.1    2020-12-17 [1] CRAN (R 4.0.3)
## tibble       3.0.6    2021-01-29 [1] CRAN (R 4.0.3)
## usethis      2.0.0    2020-12-10 [1] CRAN (R 4.0.3)
## vctrs        0.3.6    2020-12-17 [1] CRAN (R 4.0.3)
## withr        2.4.1    2021-01-26 [1] CRAN (R 4.0.3)
## xfun         0.20     2021-01-06 [1] CRAN (R 4.0.3)
## yaml         2.2.1    2020-02-01 [1] CRAN (R 4.0.3)
##
## [1] C:/Users/mhaas/Documents/R/win-library/4.0
## [2] C:/Program Files/R/R-4.0.3/library
```

Chargement et vérification des données


La première étape est de charger les données.

```
data = read.csv("https://app-learninglab.inria.fr/mocrr/gitlab/mocrr-session3/mocrr-reproducibility-
data
```

```
##      Date Count Temperature Pressure Malfunction
## 1  4/12/81     6          66        50           0
## 2 11/12/81     6          70        50           1
## 3  3/22/82     6          69        50           0
## 4 11/11/82     6          68        50           0
## 5  4/04/83     6          67        50           0
## 6  6/18/82     6          72        50           0
## 7  8/30/83     6          73       100           0
## 8 11/28/83     6          70       100           0
## 9  2/03/84     6          57       200           1
## 10 4/06/84     6          63       200           1
## 11 8/30/84     6          70       200           1
## 12 10/05/84    6          78       200           0
## 13 11/08/84    6          67       200           0
## 14 1/24/85     6          53       200           2
## 15 4/12/85     6          67       200           0
## 16 4/29/85     6          75       200           0
## 17 6/17/85     6          70       200           0
## 18 7/2903/85    6          81       200           0
## 19 8/27/85     6          76       200           0
## 20 10/03/85    6          79       200           0
## 21 10/30/85    6          75       200           2
## 22 11/26/85    6          76       200           0
## 23 1/12/86     6          58       200           1
```

On peut représenter l'impact de la température sur les échecs.

```
plot(data=data, Malfunction/Count ~ Temperature, ylim=c(0,1))
```



Régression logistique

Ainsi, une régression logistique doit nous permettre d'estimer l'influence de la température.

```
logistic_reg = glm(data=data, Malfunction/Count~Temperature, weights=Count, family=binomial(link='logit'))
summary(logistic_reg)
```

```
##
## Call:
## glm(formula = Malfunction/Count ~ Temperature, family = binomial(link = "logit"),
##      data = data, weights = Count)
##
## Deviance Residuals:
##      Min       1Q   Median       3Q      Max
## -0.95227  -0.78299  -0.54117  -0.04379   2.65152
##
## Coefficients:
##              Estimate Std. Error z value Pr(>|z|)
## (Intercept)  5.08498    3.05247   1.666  0.0957 .
## Temperature -0.11560    0.04702  -2.458  0.0140 *
## ---
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```


```
##
## (Dispersion parameter for binomial family taken to be 1)
##
##      Null deviance: 24.230  on 22  degrees of freedom
## Residual deviance: 18.086  on 21  degrees of freedom
## AIC: 35.647
##
## Number of Fisher Scoring iterations: 5
```

Les meilleures estimations de la régression logistique utilisant uniquement la température sont : $\hat{\alpha} = 5.08498$ et $\hat{\beta} = -0.11560$ et leur erreur standard asymptotique respective est de : $s_{\hat{\alpha}} = 3.05247$ et $s_{\hat{\beta}} = 0.04702$. La qualité d'ajustement de ce modèle est de : $G^2 = 18.086$ avec 21 degrés de liberté. De fait, je réplique les résultats de l'article de Dalal *et al.*

Prédiction du risque d'échec

Lors du lancement, la température lors du lancement était de 31°F. Estimons la probabilité d'un échec dans ces conditions en utilisant notre modèle:

```
# shuttle=shuttle[shuttle$r!=0,]
tempv =seq(from=30, to=90, by = .5)
rmv <-predict(logistic_reg,list(Temperature=tempv),type="response")
plot(tempv,rmv,type="l",ylim=c(0,1))
points(data=data, Malfunction/Count~Temperature)
```



Cette figure est proche de la figure 4 de l'article de Dalal *et al.* Ainsi, on considère qu'elle est bien répliquée.


Confiance de la prédiction

A l'aide de ggplot, représentons l'intervalle de confiance.

```
ggplot(data,aes(y=Malfuction/Count, x=Temperature))+ geom_point(alpha=.2, size = 2, color="blue")+geom_smooth()

## `geom_smooth()` using formula 'y ~ x'

## Warning in eval(family$initialize): non-integer #successes in a binomial glm!
```



On a un message d'avertissement de ggplot indiquant “non-integer #successes in a binomial glm!”. C’est étrange. De plus, cet intervalle de confiance est énorme.

```
data_flat=data.frame()
for(i in 1:nrow(data)){
  temperature = data[i,"Temperature"];
  malfuction = data[i,"Malfuction"];
  d =data.frame(Temperature=temperature,Malfuction=rep(0,times = data[i,"Count"]))
  if(malfuction>0) {d[1:malfuction, "Malfuction"]=1;}
  data_flat=rbind(data_flat,d)}
dim(data_flat)
```

```
## [1] 138  2
```

```
str(data_flat)
```


```
## 'data.frame': 138 obs. of 2 variables:
## $ Temperature: int 66 66 66 66 66 66 70 70 70 70 ...
## $ Malfunction: num 0 0 0 0 0 0 1 0 0 0 ...
```

```
logistic_reg_flat =glm(data=data_flat, Malfunction~Temperature, family=binomial(link='logit'))
summary(logistic_reg)
```

```
##
## Call:
## glm(formula = Malfunction/Count ~ Temperature, family = binomial(link = "logit"),
## data = data, weights = Count)
##
## Deviance Residuals:
##      Min       1Q   Median       3Q      Max
## -0.95227  -0.78299  -0.54117  -0.04379   2.65152
##
## Coefficients:
##              Estimate Std. Error z value Pr(>|z|)
## (Intercept)  5.08498    3.05247   1.666  0.0957 .
## Temperature -0.11560    0.04702  -2.458  0.0140 *
## ---
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## (Dispersion parameter for binomial family taken to be 1)
##
##      Null deviance: 24.230  on 22  degrees of freedom
## Residual deviance: 18.086  on 21  degrees of freedom
## AIC: 35.647
##
## Number of Fisher Scoring iterations: 5
```

```
ggplot(data=data_flat,aes(y=Malfunction, x=Temperature))+geom_smooth(method = "glm", method.args =list(
```

```
## `geom_smooth()` using formula 'y ~ x'
```



```
pred =predict(logistic_reg_flat,list(Temperature=30),type="response",se.fit = T)
pred
```

```
## $fit
##      1
## 0.834373
##
## $se.fit
##      1
## 0.2293304
##
## $residual.scale
## [1] 1
```

Pour une température de 30°F, le risque d'échec est de 0.834.

```
pred_link =predict(logistic_reg_flat,list(Temperature=30),type="link",se.fit = T)
pred_link
```

```
## $fit
##      1
## 1.616942
##
## $se.fit
```

```
## [1] 1.659473
##
## $residual.scale
## [1] 1
```

```
logistic_reg$family$linkinv(pred_link$fit)
```

```
##          1
## 0.834373
```

```
critval = 1.96
```

```
logistic_reg$family$linkinv(c(pred_link$fit-critval*pred_link$se.fit,pred_link$fit+critval*pred_link$se
```

```
##          1          1
## 0.1630612 0.9923814
```

L'intervalle de confiance à 95% pour notre estimation est [0.163,0.992]. C'est ce que ggplot a représenté.