

# ZIP Regression

Zero-Inflated Poisson Regression

Ricco Rakotomalala

Université Lumière Lyon 2



# Plan

1. Problématique – Modélisation – Estimation
2. Inférence statistique
3. Prédiction et résidus
4. Conclusion
5. Références



Principe et estimation des paramètres

# ZERO INFLATED POISSON REGRESSION



# Pourquoi la Régression ZIP

## Contexte

La loi de Poisson est privilégiée dans un modèle de comptage. Mais dans certains cas elle n'est pas adaptée, notamment parce qu'il y a une surreprésentation de la valeur 0.

## Pourquoi

Parce que la valeur 0 peut représenter l'absence du phénomène ou un nombre d'apparition nul sur la période étudiée c.-à-d. **il y a 2 sources de la valeur 0**. Ex. Nombre d'infidélité = 0 parce la personne est fidèle par nature, ou parce qu'elle n'a pas eu le temps ou l'opportunité de tromper son conjoint sur la période étudiée.

## Conséquence

On note une surdispersion dans la régression de Poisson. La variance de  $Y/X$  est supérieure à sa moyenne, violant la propriété sous-jacente à l'hypothèse Poisson.

## Solution

Combiner deux lois pour la modélisation : (1) loi binomiale pour la survenance ou non de  $Y = 0$  ; (2) loi de Poisson pour le comptage des événements, y compris **possiblement** la valeur 0.



# Principe de la Régression ZIP

La régression ZIP procède d'une modélisation avec la combinaison de 2 lois de distribution : Binomiale et Poisson

$X, Z$  : variables explicatives,  
à voir plus loin

Distribution de  $Y$

$$P(Y = y|X, Z) = \begin{cases} \pi + (1 - \pi)e^{-\mu} & \text{si } y = 0 \\ (1 - \pi) \frac{\mu^y e^{-\mu}}{y!} & \text{si } y > 0 \end{cases}$$

Éléments à  
modéliser

- $\pi$  est la probabilité que l'on ait structurellement 0, par conséquent il y a  $(1 - \pi)$  de chances d'être dans la situation modélisable par Poisson
- $\mu$  est le paramètre de la loi de Poisson

Propriétés

$$\left\{ \begin{array}{l} E[Y|X, Z] = (1 - \pi) \mu \\ V[Y|X, Z] = (1 - \pi) (\mu + \pi \mu^2) \end{array} \right.$$

Puisque  $(0 \leq \pi \leq 1)$  et  $(\mu > 0)$ , on note que la variance est au moins supérieure à la moyenne dans cette configuration.



# Double modélisation, combinée

**Modéliser  $\pi$**

Odds

$$\ln \frac{\pi}{1 - \pi} = \ln \lambda = a_0 + a_1 z_1 + \dots + a_m z_m$$

Log-Odds = LOGIT  
Fonction de lien LOGIT

$m$  explicatives,  $Z = (1 \mid z_1 \mid \dots \mid z_m)$

$$\lambda = \frac{\pi}{1 - \pi} \Rightarrow \pi = \frac{\lambda}{1 + \lambda}$$
$$\lambda = e^{a_0 + a_1 z_1 + \dots}$$

**Modéliser  $\mu$**

$$\ln \mu = b_0 + b_1 x_1 + \dots + b_k x_k$$

Fonction de lien LOG

$k$  explicatives,  $X = (1 \mid x_1 \mid \dots \mid x_k)$

$$\mu = e^{b_0 + b_1 x_1 + \dots}$$

$X, Z$  peuvent être identiques, avoir des variables en commun, ou être disjointes.



# Données et notations

Nombre d'infidélités d'une personne (sur 1 année)

Affairs	Constante	Gender	RatingMarriage	Occupation	YearsMarried
0	1	0	4	1	15
0	1	0	4	5	7
0	1	1	3	6	4
0	1	1	4	6	10
0	1	0	5	5	1.5
0	1	0	3	6	0.125
1	1	0	2	4	15
1	1	1	4	6	4
2	1	1	4	4	15
3	1	0	4	1	10
3	1	0	4	5	15
7	1	0	3	5	10
7	1	1	3	5	10
7	1	0	2	3	15
7	1	1	4	6	10
12	1	1	2	5	15
12	1	1	2	6	10
1	1	1	4	2	1.5
1	1	1	5	6	10
1	1	0	5	1	1.5

$n = 20$  observations,  
 $m = 2$  descripteurs,  $Z = (1, \text{Occupation}, \text{YearsMarried})$   
 $k = 2$  descripteurs,  $X = (1, \text{Gender}, \text{RatingMarriage})$   
 $X_i, Z_i$  description de l'individu n°i.  
 Ex.  $X_1 = (1, 0, 4), Z_1 = (1, 1, 15)$   
 $Y_i$  valeur de la cible pour l'individu n°i, Ex.  $Y_8 = 1$   
 Notation matricielle :  $a_0 + a_1 X_{i,1} + \dots = X_i a$

Gender : 1, homme ; 0, femme

Nombre d'années de mariage

Satisfaction dans l'union (1: faible ; 5 : très satisfait.e)

Type de profession (1 peu gratifiante, 7 très gratifiante)



On souhaite modéliser le nombre d'infidélités ( $Y = \text{Affairs}$ ) d'une personne sur l'année passée.



# Fonction de vraisemblance – Estimateur du Max. de Vraisemblance

L'EMV cumule deux bonnes propriétés asymptotiques : absence de biais, normalité

La **log-vraisemblance LL** se décompose en différentes parties selon que ( $y = 0$ ) ou pas. A maximiser en fonction de **b** et **a**.

$$LL = L1 + L2 - L3$$

Où

$$L1 = \sum_{\{i:y_i=0\}} \ln[\lambda_i + e^{-\mu_i}]$$

$$L2 = \sum_{\{i:y_i>0\}} [y_i \ln(\mu_i) - \mu_i - \ln(y_i!)]$$

$$L3 = \sum_{i=1}^n \ln(1 + \lambda_i)$$

Données « Affairs »

Cellules variables

Coefficients Logistique	-4.4574	1.1608	-0.3970
Coefficients Poisson	3.1027	0.6240	-0.6502

Optimisation avec le « solveur » Excel.

Affairs	Constante	Gender	RatingMarriage	Occupation	YearsMarried	Mu_i	Lambda_i	L1	L2	L3
0	1	0	4	1	15	1.6519	0.0001	-1.6514	0.0000	0.0001
0	1	0	4	5	7	1.6519	0.2387	-0.8432	0.0000	0.2140
0	1	1	3	6	4	5.9071	2.5072	0.9203	0.0000	1.2548
0	1	1	4	6	10	3.0832	0.2315	-1.2825	0.0000	0.2083
0	1	0	5	5	1.5	0.8622	2.1190	0.9327	0.0000	1.1375
0	1	0	3	6	0.125	3.1649	11.6774	2.4613	0.0000	2.5398
1	1	0	2	4	15	6.0637	0.0031	0.0000	-4.2614	0.0031
1	1	1	4	6	4	3.0832	2.5072	0.0000	-1.9572	1.2548
2	1	1	4	4	15	3.0832	0.0031	0.0000	-1.5244	0.0031
3	1	0	4	1	10	1.6519	0.0007	0.0000	-1.9379	0.0007
3	1	0	4	5	15	1.6519	0.0100	0.0000	-1.9379	0.0099
7	1	0	3	5	10	3.1649	0.0725	0.0000	-3.6252	0.0700
7	1	1	3	5	10	5.9071	0.0725	0.0000	-1.9992	0.0700
7	1	0	2	3	15	6.0637	0.0010	0.0000	-1.9726	0.0010
7	1	1	4	6	10	3.0832	0.2315	0.0000	-3.7266	0.2083
12	1	1	2	5	15	11.3175	0.0100	0.0000	-2.1885	0.0099
12	1	1	2	6	10	11.3175	0.2315	0.0000	-2.1885	0.2083
1	1	1	4	2	1.5	3.0832	0.0651	0.0000	-1.9572	0.0631
1	1	1	5	6	10	1.6093	0.2315	0.0000	-1.1335	0.2083
1	1	0	5	1	1.5	0.8622	0.0204	0.0000	-1.0105	0.0202

$$\hat{a} = \begin{pmatrix} -4.4574 \\ 1.1608 \\ -0.3970 \end{pmatrix}$$

$$\hat{b} = \begin{pmatrix} 3.1027 \\ 0.6240 \\ -0.6502 \end{pmatrix}$$

SUM	0.5371	-31.4205	7.4853
-----	--------	----------	--------

LL(a,b)	-38.3686
---------	----------

Cellule cible à maximiser





# Estimation des paramètres – Algorithme Newton-Raphson

Algorithme itératif, passage de l'étape (t) à (t+1) :

$$\begin{pmatrix} b \\ a \end{pmatrix}^{(t+1)} = \begin{pmatrix} b \\ a \end{pmatrix}^{(t)} - H^{-1} \times g$$

A l'optimum, toutes ses valeurs sont nulles.

A l'optimum, son inverse  $H^{-1}$  correspond à la matrice de variance covariance des coefficients  $\begin{pmatrix} \hat{b} \\ \hat{a} \end{pmatrix}$

Matrice hessienne, dérivées partielles secondes.

$$H = \begin{pmatrix} \frac{\partial^2 LL}{\partial b_r \partial b_s} & \frac{\partial^2 LL}{\partial b_r \partial a_s} \\ \frac{\partial^2 LL}{\partial b_r \partial a_s} & \frac{\partial^2 LL}{\partial a_r \partial a_s} \end{pmatrix}$$

Vecteur gradient, dérivées partielles premières.

$$g = \begin{pmatrix} \frac{\partial LL}{\partial b} \\ \frac{\partial LL}{\partial a} \end{pmatrix}$$


$$\frac{\partial LL}{\partial b_r} = \sum_{\{i:y_i=0\}} \left[ \frac{-x_{ir} \mu_i}{\lambda_i e^{\mu_i} + 1} \right] + \sum_{\{i:y_i>0\}} (y_i - \mu_i) x_{ir} \quad (r = 1, 2, \dots, k)$$

$$\frac{\partial LL}{\partial a_r} = \sum_{\{i:y_i=0\}} \left[ \frac{z_{ir} \lambda_i e^{\mu_i}}{\lambda_i e^{\mu_i} + 1} \right] - \sum_{i=1}^n \left( \frac{\lambda_i}{1 + \lambda_i} \right) z_{ir} \quad (r = 1, 2, \dots, m)$$

$$\frac{\partial^2 LL}{\partial b_r \partial b_s} = \sum_{\{i:y_i=0\}} \left[ \frac{x_{ir} x_{is} \mu_i [(\mu_i - 1) \lambda_i e^{\mu_i} - 1]}{(\lambda_i e^{\mu_i} + 1)^2} \right] - \sum_{\{i:y_i>0\}} \mu_i x_{ir} x_{is} \quad (r, s = 1, 2, \dots, k)$$

$$\frac{\partial^2 LL}{\partial a_r \partial a_s} = \sum_{\{i:y_i=0\}} \left[ \frac{z_{ir} z_{is} \lambda_i e^{\mu_i}}{(\lambda_i e^{\mu_i} + 1)^2} \right] - \sum_{i=1}^n \frac{z_{ir} z_{is} \lambda_i}{(\lambda_i + 1)^2} \quad (r, s = 1, 2, \dots, m)$$

$$\frac{\partial^2 LL}{\partial b_r \partial a_s} = \sum_{\{i:y_i=0\}} \left[ \frac{z_{ir} z_{is} \lambda_i \mu_i e^{\mu_i}}{(\lambda_i e^{\mu_i} + 1)^2} \right] \quad (r = 1, 2, \dots, k; s = 1, 2, \dots, m)$$



La convergence peut être actée de différentes manières : stabilité des coefficients, stabilité de la log-vraisemblance, etc.



# Un exemple sous R

```
#importation des données
library(xlsx)
D <- read.xlsx("affairs_for_R.xlsx",sheetIndex=1)
print(str(D))

## 'data.frame': 20 obs. of 9 variables:
## $ Affairs : num 0 0 0 0 0 1 1 2 3 ...
## $ Gender : num 0 0 1 1 0 0 0 1 1 0 ...
## $ Age : num 42 27 27 37 22 22 37 32 57 32 ...
## $ YearsMarried : num 15 7 4 10 1.5 0.125 15 4 15 10 ...
## $ Children : num 1 0 0 1 0 0 1 0 1 1 ...
## $ Religiousness : num 3 2 2 2 3 2 4 4 1 4 ...
## $ Education : num 12 17 18 18 16 16 14 20 17 14 ...
## $ Occupation : num 1 5 6 6 5 6 4 6 4 1 ...
## $ RatingMarriage: num 4 4 3 4 5 3 2 4 4 4 ...
```

Importation des données, 9 variables dont la cible « Affairs ». n=20.

```
#Library
library(pscl)

#modélisation
m1 <- zeroinfl(Affairs ~ Gender+RatingMarriage | Occupation+YearsMarried,data=D)
print(summary(m1))
```

Modélisation

```
##
## Count model coefficients (poisson with log link):
## Estimate Std. Error z value Pr(>|z|)
## (Intercept) 3.1027 0.4214 7.362 1.81e-13 ***
## Gender 0.6240 0.2681 2.328 0.0199 *
## RatingMarriage -0.6502 0.1325 -4.908 9.19e-07 ***
##
## Zero-inflation model coefficients (binomial with logit link):
## Estimate Std. Error z value Pr(>|z|)
## (Intercept) -4.4563 4.8644 -0.916 0.360
## Occupation 1.1605 0.8833 1.314 0.189
## YearsMarried -0.3970 0.2419 -1.641 0.101
## ---
## Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Number of iterations in BFGS optimization: 17
## Log-likelihood: -38.37 on 6 Df
```

$$\ln \mu = b_0 + b_1 \text{Gender} + b_2 \text{RatingMarriage}$$

$$\ln \frac{\pi}{1 - \pi} = \ln \lambda = a_0 + a_1 \text{Occupation} + a_2 \text{YearsMarried}$$

```
#matrice de variance covariance des coefficients
print(round(m1$vcov,5))
```

$$\sqrt{0.07187} = 0.2681$$

```
## count_(Intercept) count_Gender count_RatingMarriage
## count_(Intercept) 0.17761 -0.04395 -0.04770
## count_Gender -0.04395 0.07187 -0.00140
## count_RatingMarriage -0.04770 -0.00140 0.01755
## zero_(Intercept) -0.01908 -0.09538 0.03738
## zero_Occupation 0.00123 0.01184 -0.00422
## zero_YearsMarried -0.00294 0.00220 0.00091
## zero_(Intercept) zero_Occupation zero_YearsMarried
## count_(Intercept) -0.01908 0.00123 -0.00294
## count_Gender -0.09538 0.01184 0.00220
## count_RatingMarriage 0.03738 -0.00422 0.00091
## zero_(Intercept) 23.66270 -3.99549 -0.06026
## zero_Occupation -3.99549 0.78016 -0.05735
## zero_YearsMarried -0.06026 -0.05735 0.05853
```

$$\sqrt{0.05853} = 0.2419$$

Matrice de variance covariance des coefficients estimés. Nous avons les variances sur les diagonales.



Tests et intervalles de confiance

# INFÉRENCE STATISTIQUE



# Inférence basée sur la normalité asymptotique

Puisque :

$$\begin{cases} \hat{b}_r \cong \mathcal{N}(b_r, \hat{\sigma}_{\hat{b}_r}) \\ \hat{a}_r \cong \mathcal{N}(a_r, \hat{\sigma}_{\hat{a}_r}) \end{cases}$$

Nous pouvons effectuer différents tests, dont les tests de significativité.

Ex.  $\begin{cases} H_0: b_{Gender} = 0 \\ H_1: b_{Gender} \neq 0 \end{cases} \Rightarrow z_{Gender} = \frac{0.6240}{0.2681} = 2.328 \rightarrow P(> |z|) = p.value = 0.0199$

```
## Count model coefficients (poisson with log link):
##           Estimate Std. Error z value Pr(>|z|)
## (Intercept)   3.1027    0.4214   7.362 1.81e-13 ***
## Gender         0.6240    0.2681   2.328 0.0199 *
## RatingMarriage -0.6502    0.1325  -4.908 9.19e-07 ***
##
## Zero-inflation model coefficients (binomial with logit link):
##           Estimate Std. Error z value Pr(>|z|)
## (Intercept)  -4.4563    4.8644  -0.916 0.360
## Occupation    1.1605    0.8833   1.314 0.189
## YearsMarried -0.3970    0.2419  -1.641 0.101
## ---
```

Nous pouvons également calculer les intervalles de confiance.

Intervalle de confiance à 90% du coefficient de YearsMarried

$$\begin{cases} \hat{a}_{YearsMarried} \pm u_{0.95} \times \hat{\sigma}_{\hat{a}_{YearsMarried}} \\ -0.3970 \pm 1.6448 \times 0.2419 \\ [-0.79489, 0.00089] \end{cases}$$



# Test du rapport de vraisemblance

Permet de confronter des scénarios de modélisation  
ou tester la significativité d'un bloc de coefficients.

$$\ln \mu = b_0 + b_1 \text{Gender} + b_2 \text{RatingMarriage}$$
$$\ln \frac{\pi}{1 - \pi} = \ln \lambda = a_0 + a_1 \text{Occupation} + a_2 \text{YearsMarried}$$



$$\begin{cases} H_0 : a_1 = a_2 = 0 \\ H_1 : a_1 \neq 0 \text{ ou } a_2 \neq 0 \end{cases}$$

Log-vraisemblance  
du modèle sous H0.

Statistique de test :



$$LR = 2 \times [LL(M) - LL(M_0)]$$

Sous H0, suit une loi du  $\chi^2$  à (q = 2) degrés de liberté

```
#modèle sous H0 - Proba  $\pi_i$  estimée par une constante
m0 <- zeroinfl(Affairs ~ Gender+RatingMarriage | 1,data=D)
print(summary(m0))

##
## Count model coefficients (poisson with log link):
##           Estimate Std. Error z value Pr(>|z|)
## (Intercept)   3.0955     0.4188   7.392 1.44e-13 ***
## Gender         0.6106     0.2798   2.182  0.0291 *
## RatingMarriage -0.6427     0.1338  -4.802 1.57e-06 ***
##
## Zero-inflation model coefficients (binomial with logit link):
##           Estimate Std. Error z value Pr(>|z|)
## (Intercept)  -1.2879     0.6674  -1.93  0.0536 .
## ---
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Number of iterations in BFGS optimization: 9
## Log-likelihood: -41.73 on 4 Df

#stat. de test de rapport de vraisemblance
LR <- 2*(m1$loglik - m0$loglik)
print(LR)

## [1] 6.71756

#p-value
print(pchisq(LR,df=2,lower.tail=FALSE))

## [1] 0.03477765
```



$$LL(M) = -38.37 \text{ (page 6)}$$

$$LL(M_0) = -41.73$$

$$LR = 6.71756$$

$$p\text{-value} = 0.034$$

Au risque 5%, les données contredisent H0. L'estimation de la probabilité  $\pi_i$  avec une constante a dégradé significativement le modèle.

$$\hat{\lambda}_i = e^{(\hat{a}_0)} = e^{-1.2879} = 0.2758$$

$$\hat{\pi}_i = \frac{\hat{\lambda}_i}{1 + \hat{\lambda}_i} = 0.2162, \forall i$$



# Pertinence du scénario « zero-inflated »

Attention, la configuration ( $a_0 = a_1 = \dots = a_k = 0$ ) n'équivaut pas à une régression de Poisson « classique », parce que dans ce cas,  $\hat{\pi}_i = 0.5, \forall i$

➡ On passe par le **Test de Vuong** (1989) pour tester la légitimité de la régression ZIP par rapport à la régression de Poisson (modèles non-imbriqués).

Probabilité d'obtenir le bon compte  $y_i$  pour l'individu n°i avec le modèle MZ

➡ Stratégie : Créer les deux modèles : MZ pour ZIP Régression, MP pour régression de Poisson. Calculer les  $\hat{P}_{MZ}(Y = y_i) = \hat{p}_{MZ}(i)$  et  $\hat{P}_{MP}(Y = y_i) = \hat{p}_{MP}(i)$  fournies par les modèles en prédiction (en resubstitution). Les confronter avec  $v_i = \hat{p}_{MZ}(i) - \hat{p}_{MP}(i)$

```

#modèle ZIP à évaluer
MZ <- zeroinfl(Affairs ~ Gender+RatingMarriage | Occupation+YearsMarried,data = D)

#modèle de Poisson équivalent sans la partie zero-inflation
MP <- glm(Affairs ~ Gender+RatingMarriage, data = D, family = "poisson")

#confrontation
vuong(MZ,MP)

## Vuong Non-Nested Hypothesis Test-Statistic:
## (test-statistic is asymptotically distributed N(0,1) under the
## null that the models are indistinguishable)
## -----
##              Vuong z-statistic              H_A  p-value
## Raw              1.3800296 model1 > model2 0.083789

```

$$V = \sqrt{n} \frac{\bar{v}}{\sigma_v} \cong \mathcal{N}(0,1)$$

H0 : les deux modèles sont équivalents  
 $V > 0$ , MZ a tendance à être meilleur que MP  
 $V < 0$ , c'est l'inverse

➡ MZ est légèrement meilleur, mais ne se démarque pas significativement pour un test à 5%



# PRÉDICTION ET RÉSIDUS



# Prédiction pour un individu

Calcul de la prédiction pour l'individu n°2, et de la probabilité d'attribution du bon compte  $\mathbf{y}_2=0$

Coefficients Logistique		-4.457				1.161	-0.397
Coefficients Poisson		3.103	0.624	-0.650			
n°	Affairs	Constante	Gender	RatingMarriage	Occupation	YearsMarried	
1	0	1	0	4	1	15	
2	0	1	0	4	5	7	

$$\hat{\lambda}_2 = \exp(-4.457 + 1.161 \times 5 - 0.397 \times 7) = 0.239 \quad \Rightarrow \quad \hat{\pi}_2 = \frac{\hat{\lambda}_2}{1 + \hat{\lambda}_2} = 0.193 \quad (\text{page 6})$$

$$\hat{\mu}_2 = \exp(3.103 + 0.624 \times 0 - 0.650 \times 4) = 1.652 \quad (\text{page 6})$$

$$\hat{y}_2 = (1 - \hat{\pi}_2) \hat{\mu}_2 = (1 - 0.193) \times 1.652 = 1.334 \quad \Leftrightarrow \quad \begin{array}{l} \text{Prédiction de l'espérance de} \\ \text{Y pour l'individu n°2} \end{array} \quad (\text{page 5})$$

$$\hat{p}_{MZ}(2) = \hat{P}_{MZ}(Y = 0) = \hat{\pi}_2 + (1 - \hat{\pi}_2) e^{-\hat{\mu}_2} = 0.347 \quad \Leftrightarrow \quad \begin{array}{l} \text{Probabilité d'obtenir la} \\ \text{« bonne » valeur de Y (Y = 0)} \\ \text{pour l'individu n°2} \end{array} \quad (\text{page 5})$$

Remarque :  $\sum_{y=0,1,2,\dots,\max(y)} \hat{P}_{MZ}(Y = y) \times y = \hat{y}_2 = 1.334 \quad \Leftrightarrow \quad \begin{array}{l} \text{Moyenne pondérée de l'affectation aux} \\ \text{valeurs de Y = estimation de l'espérance} \\ \text{de Y pour l'individu n°2} \end{array}$





Les résidus permettent de diagnostiquer le modèle : identification des points atypiques, recherche des régularités. Bon modèle = résidus dispersés aléatoirement.

Résidu brut

$$r_i = y_i - \hat{y}_i$$

Résidu de Pearson  
(normalisé par l'écart-type de y)

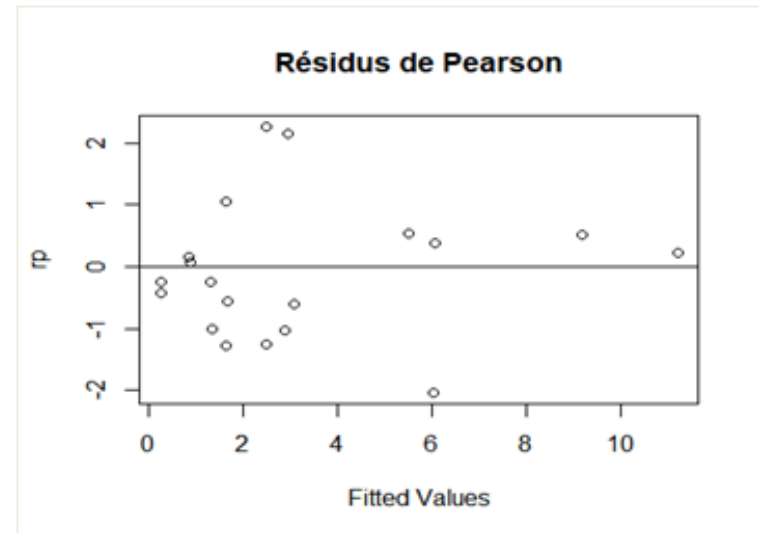
$$rp_i = \frac{y_i - \hat{y}_i}{\sqrt{\hat{\mu}_i(1 - \hat{\pi}_i)(1 + \hat{\mu}_i\hat{\pi}_i)}}$$

```
#résidus bruts
r <- MZ$residuals
print(r)

##          1          2          3          4          5          6
## -1.6517707 -1.3335920 -1.6844774 -2.5035108 -0.2764425 -0.2497220
##          7          8          9         10         11         12
## -5.0447962  0.1207892 -1.0736012  1.3492248  1.3643732  4.0491533
##          13         14         15         16         17         18
##  1.4924705  0.9422539  4.4964892  0.7943063  2.8104591 -1.8945478
##          19         20
## -0.3067043  0.1550322

#résidus de Pearson (résidus bruts normalisés)
rp <- residuals(MZ)

#graphique y^ vs. residus de Pearson
plot(MZ$fitted.values,rp,main="Résidus de Pearson",xlab="Fitted Values")
abline(h=0)
```



# CONCLUSION



- Adaptée dès lors que la variable cible  $Y$  représente un comptage avec une surreprésentation de la valeur ( $Y = 0$ ), conduisant à une surdispersion dans la régression de Poisson « classique ».
- Nous disposons d'un modèle à 2 étages : Binomial + Poisson
- L'arbitrage entre les variables à introduire dans le modèle Binomial et/ou celui de Poisson repose pour beaucoup sur la connaissance du domaine
- Procédure de sélection automatique de variables très compliquée à mettre en œuvre
- Le comptage peut s'effectuer sur une durée qui peut être différente d'un individu à l'autre (ex. nombre d'infidélité sur une durée variable selon les individus). On introduit alors le temps comme une variable `offset()` dans le modèle c.-à-d. une variable à laquelle on attribue d'emblée le coefficient 1. D'autres variables que la durée (temps) peuvent jouer le rôle d'offset (ex.  $Y$  = comptage nombre de sinistres pour un foyer, `offset` = nombre d'objets assurés).



# RÉFÉRENCES



- Documentation NCSS Statistical Software, « [Zero-Inflated Poisson Regression](#) », Chapter 329.
- D. Gilles, « [Notes on the Zero-Inflated Poisson Regression Model](#) », University of Victoria, March 2010.
- UCLA Institute for Digital Research & Education, « [Zero-Inflated Poisson Regressio – R Data Analysis Examples](#) ».
- S. Jackman et al., « Package “[pscl](#)” : Political Science Computational Laboratory », version 1.5.2 ; [Reference manual](#) ; Vignettes : « [Regression Models for Count Data in R](#) ».

