

Actuariat IARD - ACT2040

Partie 6 - modélisation des coûts individuels de sinistres ($Y \in \mathbb{R}_+$)

Arthur Charpentier

charpentier.arthur@uqam.ca

<http://freakonometrics.hypotheses.org/>





HIVER 2013

Modélisation de variables positives

Références : Frees (2010), chapitre 13, de Jong & Heller (2008), chapitre 8, et Denuit & Charpentier (2005), chapitre 11.

Préambule : avec le modèle linéaire, nous avions $\sum_{i=1}^n Y_i = \sum_{i=1}^n \hat{Y}_i$

```
> reg=lm(dist~speed,data=cars)
> sum(cars$dist)
[1] 2149
> sum(predict(reg))
[1] 2149
```



C'est lié au fait que $\sum_{i=1}^n \hat{\varepsilon}_i = 0$, i.e. “la droite de régression passe par le barycentre du nuage”.

Cette propriété était conservée avec la régression log-Poisson, nous avions que

$$\sum_{i=1}^n Y_i = \sum_{i=1}^n \hat{\mu}_i E_i, \text{ où } \hat{\mu}_i E_i \text{ est la prédition faite avec l'exposition, au sens où}$$

```
> sum(sinistres$nbre)
[1] 1924
> reg=glm(nbre~1+offset(log(exposition)),data=sinistres,
+ family=poisson(link="log"))
> sum(predict(reg,type="response"))
[1] 1924
> sum(predict(reg,newdata=data.frame(exposition=1),
+ type="response"))*sinistres$exposition
[1] 1924
```

et ce, quel que soit le modèle utilisé !

```
> reg=glm(nbre~offset(log(exposition))+ageconducteur+
+ zone+carburant,data=sinistres,family=poisson(link="log"))
> sum(predict(reg,type="response"))
[1] 1924
```

... mais c'est tout. En particulier, cette propriété n'est pas vérifiée si on change de fonction lien,

```
> reg=glm(nbre~1+log(exposition),data=sinistres,
> sum(predict(reg,type="response"))
[1] 1977.704
```

ou de loi (e.g. binomiale négative),

```
> reg=glm.nb(nbre~1+log(exposition),data=sinistres)
> sum(predict(reg,type="response"))
[1] 1925.053
```

Conclusion : de manière générale $\sum_{i=1}^n Y_i \neq \sum_{i=1}^n \widehat{Y}_i$

La base des coûts individuels

```

> sinistre=read.table("http://freakonometrics.free.fr/sinistreACT2040.txt",
+ header=TRUE,sep=";")
> sinistres=sinistre[sinistre$garantie=="1RC",]
> sinistres=sinistres[sinistres$cout>0,]
> contrat=read.table("http://freakonometrics.free.fr/contractACT2040.txt",
+ header=TRUE,sep=";")
> couts=merge(sinistres,contrat)
> tail(couts,4)

    nocontrat      no garantie     cout exposition zone puissance agevehicule
1921    6108364 13229       1RC 1320.0        0.74      B         9           1
1922    6109171 11567       1RC 1320.0        0.74      B        13           1
1923    6111208 14161       1RC  970.2        0.49      E        10           5
1924    6111650 14476       1RC 1940.4        0.48      E         4           0

    ageconducteur bonus marque carburant densite region
1921            32   100     12       E      83       0
1922            56    50     12       E      93      13
1923            30    90     12       E      53       2
1924            69    50     12       E      93      13

```

La loi Gamma

La densité de Y est ici

$$f(y) = \frac{1}{y\Gamma(\phi^{-1})} \left(\frac{y}{\mu\phi} \right)^{\phi^{-1}} \exp\left(-\frac{y}{\mu\phi}\right), \quad \forall y \in \mathbb{R}_+$$

qui est dans la famille exponentielle, puisque

$$f(y) = \left[\frac{y/\mu - (-\log \mu)}{-\phi} + \frac{1-\phi}{\phi} \log y - \frac{\log \phi}{\phi} - \log \Gamma(\phi^{-1}) \right], \quad \forall y \in \mathbb{R}_+$$

On en déduit en particulier le [lien canonique](#), $\theta = \mu^{-1}$ (fonction de lien inverse). De plus, $b(\theta) = -\log(\mu)$, de telle sorte que $b'(\theta) = \mu$ et $b''(\theta) = -\mu^2$. La [fonction variance](#) est alors ici $V(\mu) = \mu^2$.

Enfin, la déviance est ici

$$D = 2\phi[\log \mathcal{L}(y, y) - \log \mathcal{L}(\mu, y)] = 2\phi \sum_{i=1}^n \left(\frac{y_i - \mu_i}{\mu_i} - \log \left(\frac{y_i}{\mu_i} \right) \right).$$

La loi lognormale

La densité de Y est ici

$$f(y) = y \frac{1}{y\sqrt{2\pi\sigma^2}} e^{-\frac{(\ln y - \mu)^2}{2\sigma^2}}, \quad \forall y \in \mathbb{R}_+$$



Si Y suit une loi lognormale de paramètres μ et σ^2 , alors $Y = \exp[Y^*]$ où $Y^* \sim \mathcal{N}(\mu, \sigma^2)$. De plus,

$$\mathbb{E}(Y) = \mathbb{E}(\exp[Y^*]) \neq \exp[\mathbb{E}(Y^*)] = \exp(\mu).$$

Rappelons que $\mathbb{E}(Y) = e^{\mu + \sigma^2/2}$, et $\text{Var}(Y) = (e^{\sigma^2} - 1)e^{2\mu + \sigma^2}$.

```
> plot(cars)
> regln=lm(log(dist)~speed,data=cars)
> nouveau=data.frame(speed=1:30)
> preddist=exp(predict(regln,newdata=nouveau))
```

```
> lines(1:30,predist,col="red")
> (s=summary(regln)$sigma)
[1] 0.4463305
> lines(1:30,predist*exp(.5*s^2),col="blue")
```





Remarque on n'a pas, pour autant, $\sum_{i=1}^n Y_i = \sum_{i=1}^n \hat{Y}_i = \sum_{i=1}^n \exp\left(\hat{Y}_i^* + \frac{\sigma^2}{2}\right)$

```
> sum(cars$dist)
[1] 2149
> sum(exp(predict(regln)))
[1] 2078.34
> sum(exp(predict(regln))*exp(.5*s^2))
[1] 2296.015
```

même si on ne régresse sur aucune variable explicative...

```
> regln=lm(log(dist)~1,data=cars)
> (s=summary(regln)$sigma)
[1] 0.7764719
> sum(exp(predict(regln))*exp(.5*s^2))
[1] 2320.144
```



Loi Gamma ou loi lognormale ?



Mixture of two distributions



Loi Gamma ou loi lognormale ?

Loi Gamma ? Mélange de deux lois Gamma ?



Loi Gamma ou loi lognormale ?

Loi lognormale ? Mélange de deux lois lognormales ?



Autres lois possibles

Plusieurs autres lois sont possibles, comme la **loi inverse Gaussienne**,

$$f(y) = \left[\frac{\lambda}{2\pi y^3} \right]^{1/2} \exp\left(\frac{-\lambda(y-\mu)^2}{2\mu^2 y} \right), \quad \forall y \in \mathbb{R}_+$$

de moyenne μ (qui est dans la famille exponentielle) ou la loi **loi exponentielle**

$$f(y) = \lambda \exp(-\lambda y), \quad \forall y \in \mathbb{R}_+$$

de moyenne λ^{-1} .

Les régressions Gamma, lognormale et inverse Gaussienne

Pour la régression Gamma (et un lien \log i.e. $\mathbb{E}(Y|X) = \exp[X'\beta]$), on a

```
> regg=glm(cout~agevehicule+carburant+zone,data=couts,
+           family=Gamma(link="log"))
```

```
> summary(regg)
```

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	8.17615	0.22937	35.646	<2e-16 ***
agevehicule	-0.01715	0.01360	-1.261	0.2073
carburantE	-0.20756	0.14725	-1.410	0.1588
zoneB	-0.60169	0.30708	-1.959	0.0502 .
zoneC	-0.60072	0.24201	-2.482	0.0131 *
zoneD	-0.45611	0.24744	-1.843	0.0654 .
zoneE	-0.43725	0.24801	-1.763	0.0781 .
zoneF	0.24778	0.44852	0.552	0.5807

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

(Dispersion parameter for Gamma family taken to be 9.91334)

Les régressions Gamma, lognormale et inverse Gaussienne

Pour la régression inverse-Gaussienne, (et un lien \log i.e. $\mathbb{E}(Y|\mathbf{X}) = \exp[\mathbf{X}'\boldsymbol{\beta}]$),

```
> regig=glm(cout~agevehicule+carburant+zone,data=couts,
+           family=inverse.gaussian(link="log"),start=coefficients(regg))
> summary(regig)
```

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	8.07065	0.23606	34.188	<2e-16 ***
agevehicule	-0.01509	0.01118	-1.349	0.1774
carburantE	-0.18037	0.13065	-1.381	0.1676
zoneB	-0.50202	0.28836	-1.741	0.0819 .
zoneC	-0.50913	0.24098	-2.113	0.0348 *
zoneD	-0.38080	0.24806	-1.535	0.1249
zoneE	-0.36541	0.24975	-1.463	0.1436
zoneF	0.42854	0.56537	0.758	0.4486

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

(Dispersion parameter for inverse.gaussian family taken to be 0.004331898)

Les régressions Gamma, lognormale et inverse Gaussienne

Pour la régression log-normale i.e. $\mathbb{E}(\log Y | \mathbf{X}) = \mathbf{X}'\boldsymbol{\beta}$, on a

```
> regln=lm(log(cout)~agevehicule+carburant+zone,data=couts)
> summary(regln)

Coefficients:
            Estimate Std. Error t value Pr(>|t|)    
(Intercept) 6.876142   0.086483  79.508 <2e-16 ***
agevehicule -0.007032   0.005127  -1.372   0.170    
carburantE  -0.042338   0.055520  -0.763   0.446    
zoneB        0.080288   0.115784   0.693   0.488    
zoneC        0.015060   0.091250   0.165   0.869    
zoneD        0.099338   0.093295   1.065   0.287    
zoneE        0.004305   0.093512   0.046   0.963    
zoneF       -0.101866   0.169111  -0.602   0.547    
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```


Les régressions Gamma, lognormale et inverse Gaussienne

On peut comparer les prédictions (éventuellement en fixant quelques covariables),

```
> nouveau=data.frame(agevehicule=0:20,carburant="E",zone="C")
> s=summary(regln)$sigma
> predln=predict(regln,se.fit=TRUE,newdata=nouveau)
> predg=predict(regg,se.fit=TRUE,type="response",newdata=nouveau)
> predig=predict(regig,se.fit=TRUE,type="response",newdata=nouveau)
```


Pour le modèle log-Gamma, on a

```
> plot(0:20,predg$fit,type="b",col="red")
> lines(0:20,predg$fit+2*predg$se.fit,lty=2,col="red")
> lines(0:20,predg$fit-2*predg$se.fit,lty=2,col="red")
```



Pour le modèle log-inverse Gaussienne, on a


```
> plot(0:20,predig$fit,type="b",col="blue")
> lines(0:20,predig$fit+2*predg$se.fit,lty=2,col="blue")
> lines(0:20,predig$fit-2*predg$se.fit,lty=2,col="blue")
```



Pour le modèle lognormal, on a

```
> plot(0:20,exp(predln$fit+.5*s^2),type="b",col="green")
> lines(0:20,exp(predln$fit+.5*s^2+2*predln$se.fit),lty=2,col="green")
> lines(0:20,exp(predln$fit+.5*s^2-2*predln$se.fit),lty=2,col="green")
```

(les intervalles de confiance sur \hat{Y} n'ont pas trop de sens ici...)



Prise en compte des gros sinistres

On a ici quelques *gros* sinistres. L'idée est de noter que

$$\mathbb{E}(Y) = \sum_i \mathbb{E}(Y|\Theta = \theta_i) \cdot \mathbb{P}(\Theta = \theta_i)$$

Supposons que Θ prenne deux valeurs, correspondant au cas $\{Y \leq s\}$ et $\{Y > s\}$. Alors

$$\mathbb{E}(Y) = \mathbb{E}(Y|Y \leq s) \cdot \mathbb{P}(Y \leq s) + \mathbb{E}(Y|Y > s) \cdot \mathbb{P}(Y > s)$$

ou, en calculant l'espérance sous \mathbb{P}_X et plus \mathbb{P} ,

$$\mathbb{E}(Y|X) = \underbrace{\mathbb{E}(Y|X, Y \leq s)}_A \cdot \underbrace{\mathbb{P}(Y \leq s|X)}_B + \underbrace{\mathbb{E}(Y|Y > s, X)}_C \cdot \underbrace{\mathbb{P}(Y > s|X)}_B$$

Prise en compte des gros sinistres

Trois termes apparaissent dans

$$\mathbb{E}(Y|\mathbf{X}) = \underbrace{\mathbb{E}(Y|\mathbf{X}, Y \leq s)}_A \cdot \underbrace{\mathbb{P}(Y \leq s|\mathbf{X})}_B + \underbrace{\mathbb{E}(Y|Y > s, \mathbf{X})}_C \cdot \underbrace{\mathbb{P}(Y > s|\mathbf{X})}_B$$


- le coût moyen des sinistres normaux, A
- la probabilité d'avoir un gros, ou un sinistre normal, si un sinistre survient, B
- le coût moyen des sinistres importants, C

Prise en compte des gros sinistres

Pour le terme B , il s'agit d'une régression *standard* d'une variable de Bernoulli,

```
> s = 10000
> couts$normal=(couts$cout<=s)
> mean(couts$normal)
[1] 0.9818087
> library(splines)
> age=seq(0,20)
> regC=glm(normal~bs(agevehicule),data=couts,family=binomial)
> ypC=predict(regC,newdata=data.frame(agevehicule=age),type="response")
> plot(age,ypC,type="b",col="red")
> regC2=glm(normal~1,data=couts,family=binomial)
> ypC2=predict(regC2,newdata=data.frame(agevehicule=age),type="response")
> lines(age,ypC2,type="l",col="red",lty=2)
```

Prise en compte des gros sinistres




Prise en compte des gros sinistres

Pour le terme A , il s'agit d'une régression *standard* sur la base restreinte,

```
> indice = which(couts$cout<=s)
> mean(couts$cout[indice])
[1] 1335.878
> library(splines)
> regA=glm(cout~bs(agevehicule),data=couts,
+ subset=indice,family=Gamma(link="log"))
> ypA=predict(regA,newdata=data.frame(agevehicule=age),type="response")
> plot(age,ypA,type="b",col="red")
> ypA2=mean(couts$cout[indice])
> abline(h=ypA2,lty=2,col="red")
```

Prise en compte des gros sinistres




Prise en compte des gros sinistres

Pour le terme C , il s'agit d'une régression *standard* sur la base restreinte,

```
> indice = which(couts$cout>s)
> mean(couts$cout[indice])
[1] 34471.59
> regB=glm(cout~bs(agevehicule),data=couts,
+ subset=indice,family=Gamma(link="log"))
> ypB=predict(regB,newdata=data.frame(agevehicule=age),type="response")
> plot(age,ypB,type="b",col="blue")
> ypB2=mean(couts$cout[indice])
> plot(age,ypB,type="b",col="blue")
> abline(h=ypB2,lty=2,col="blue")
```

Prise en compte des gros sinistres




Prise en compte des gros sinistres

Reste à combiner les modèles, e.g.

$$\mathbb{E}(Y|\mathbf{X}) = \mathbb{E}(Y|\mathbf{X}, Y \leq s) \cdot \mathbb{P}(Y \leq s|\mathbf{X}) + \mathbb{E}(Y|Y > s, \mathbf{X}) \cdot \mathbb{P}(Y > s|\mathbf{X})$$


```
> indice = which(couts$cout>s)
> mean(couts$cout[indice])
[1] 34471.59
> prime = ypA*ypC + ypB*(1-ypC)
```



ou, e.g.

$$\mathbb{E}(Y|\mathbf{X}) = \mathbb{E}(Y|\mathbf{X}, Y \leq s) \cdot \mathbb{P}(Y \leq s|\mathbf{X}) + \mathbb{E}(Y|Y > s) \cdot \mathbb{P}(Y > s|\mathbf{X})$$


```
> indice = which(couts$cout>s)
> mean(couts$cout[indice])
[1] 34471.59
> prime = ypA*ypC + ypB2*(1-ypC)
```



voire e.g.

$$\mathbb{E}(Y|X) = \mathbb{E}(Y|X, Y \leq s) \cdot \mathbb{P}(Y \leq s) + \mathbb{E}(Y|Y > s) \cdot \mathbb{P}(Y > s)$$


```
> indice = which(couts$cout>s)
> mean(couts$cout[indice])
[1] 34471.59
> prime = ypA*ypC + ypB2*(1-ypC)
```



Mais on peut aussi changer le seuil s dans

$$\mathbb{E}(Y|X) = \mathbb{E}(Y|X, Y \leq s) \cdot \mathbb{P}(Y \leq s) + \mathbb{E}(Y|Y > s) \cdot \mathbb{P}(Y > s)$$


e.g. avec $s = 10,000\text{€}$,



Mais on peut aussi changer le seuil s dans

$$\mathbb{E}(Y|X) = \mathbb{E}(Y|X, Y \leq s) \cdot \mathbb{P}(Y \leq s) + \mathbb{E}(Y|Y > s) \cdot \mathbb{P}(Y > s)$$

e.g. avec $s = 25,000\text{€}$,



Et s'il y avait plus que *deux* types de sinistres ?

Il est classique de supposer que la loi de Y (coût individuel de sinistres) est un mélange de plusieurs lois,

$$f(y) = \sum_{k=1}^K p_k f_k(y), \forall y \in \mathbb{R}_+$$


où f_k est une loi sur \mathbb{R}_+ et $\mathbf{p} = (p_k)$ un vecteur de probabilités. Ou, en terme de fonctions de répartition,

$$F(y) = \mathbb{P}(Y \leq y) = \sum_{k=1}^K p_k F_k(y), \forall y \in \mathbb{R}_+$$

où F_k est la fonction de répartition d'une variable à valeurs dans \mathbb{R}_+ .

Et s'il y avait plus que *deux* types de sinistres ?

```
> n=nrow(couts)
> plot(sort(couts$cout),(1:n)/(n+1),xlim=c(0,10000),type="s",lwd=2,col="red")
```



Et s'il y avait plus que *deux* types de sinistres ?

On peut considérer un mélange de trois lois,


$$f(y) = p_1 f_1(x) + p_2 \delta_\kappa(x) + p_3 f_3(x), \forall y \in \mathbb{R}_+$$

avec

1. une loi exponentielle pour f_1
2. une masse de Dirac en κ (i.e. un coût fixe) pour f_2
3. une loi lognormale (décallée) pour f_3

```
> I1=which(couts$cout<1120)
> I2=which((couts$cout>=1120)&(couts$cout<1220))
> I3=which(couts$cout>=1220)
> (p1=length(I1)/nrow(couts))
[1] 0.3284823
> (p2=length(I2)/nrow(couts))
[1] 0.4152807
> (p3=length(I3)/nrow(couts))
```

```
[1] 0.256237
> X=couts$cout
> (kappa=mean(X[I2]))
[1] 1171.998
> X0=X[I3]-kappa
> u=seq(0,10000,by=20)
> F1=pexp(u,1/mean(X[I1]))
> F2= (u>kappa)
> F3=plnorm(u-kappa,mean(log(X0)),sd(log(X0))) * (u>kappa)
> F=F1*p1+F2*p2+F3*p3
> lines(u,F,col="blue")
```



Prise en compte des coûts fixes en tarification

Comme pour les gros sinistres, on peut utiliser ce découpage pour calculer $\mathbb{E}(Y)$, ou $\mathbb{E}(Y|\mathbf{X})$. Ici,

$$\begin{aligned}\mathbb{E}(Y|\mathbf{X}) &= \underbrace{\mathbb{E}(Y|\mathbf{X}, Y \leq s_1)}_A \cdot \underbrace{\mathbb{P}(Y \leq s_1|\mathbf{X})}_{D,\pi_1(\mathbf{X})} \\ &\quad + \underbrace{\mathbb{E}(Y|Y \in (s_1, s_2], \mathbf{X})}_B \cdot \underbrace{\mathbb{P}(Y \in (s_1, s_2]|\mathbf{X})}_{D,\pi_2(\mathbf{X})} \\ &\quad + \underbrace{\mathbb{E}(Y|Y > s_2, \mathbf{X})}_C \cdot \underbrace{\mathbb{P}(Y > s_2|\mathbf{X})}_{D,\pi_3(\mathbf{X})}\end{aligned}$$

Les paramètres du mélange, $(\pi_1(\mathbf{X}), \pi_2(\mathbf{X}), \pi_3(\mathbf{X}))$ peuvent être associés à une loi multinomiale de dimension 3.

Loi multinomiale (et GLM)

Rappelons que pour la régression logistique, si $(\pi, 1 - \pi) = (\pi_1, \pi_2)$

$$\log \frac{\pi}{1 - \pi} = \log \frac{\pi_1}{\pi_2} = \mathbf{X}'\boldsymbol{\beta},$$

ou encore

$$\pi_1 = \frac{\exp(\mathbf{X}'\boldsymbol{\beta})}{1 + \exp(\mathbf{X}'\boldsymbol{\beta})} \text{ et } \pi_2 = \frac{1}{1 + \exp(\mathbf{X}'\boldsymbol{\beta})}$$

On peut définir une **régression logistique multinomiale**, de paramètre $\boldsymbol{\pi} = (\pi_1, \pi_2, \pi_3)$ en posant

$$\log \frac{\pi_1}{\pi_3} = \mathbf{X}'\boldsymbol{\beta}_1 \text{ et } \log \frac{\pi_2}{\pi_3} = \mathbf{X}'\boldsymbol{\beta}_2$$

Loi multinomiale (et GLM)

ou encore

$$\pi_1 = \frac{\exp(\mathbf{X}'\boldsymbol{\beta}_1)}{1 + \exp(\mathbf{X}'\boldsymbol{\beta}_1) + \exp(\mathbf{X}'\boldsymbol{\beta}_2)}, \pi_2 = \frac{\exp(\mathbf{X}'\boldsymbol{\beta}_2)}{1 + \exp(\mathbf{X}'\boldsymbol{\beta}_1) + \exp(\mathbf{X}'\boldsymbol{\beta}_2)}$$

et $\pi_3 = \frac{1}{1 + \exp(\mathbf{X}'\boldsymbol{\beta}_1) + \exp(\mathbf{X}'\boldsymbol{\beta}_2)}.$

Remarque l'estimation se fait - là encore - en calculant numériquement le maximum de vraisemblance, en notant que

$$\mathcal{L}(\boldsymbol{\pi}, \mathbf{y}) \propto \prod_{i=1}^n \prod_{j=1}^3 \pi_{i,j}^{Y_{i,j}}$$

où Y_i est ici disjonctée en $(Y_{i,1}, Y_{i,2}, Y_{i,3})$ contenant les variables indicatrices de chacune des modalités. La log-vraisemblance est alors proportionnelle à

$$\log \mathcal{L}(\boldsymbol{\beta}, \mathbf{y}) \propto \sum_{i=1}^n \sum_{j=1}^2 (Y_{i,j} \mathbf{X}'_i \boldsymbol{\beta}_j) - n_i \log [1 + \exp(\mathbf{X}'\boldsymbol{\beta}_1) + \exp(\mathbf{X}'\boldsymbol{\beta}_2)]$$

Loi multinomiale (et GLM)

qui se résout avec un algorithme de type Newton-Raphson, en notant que

$$\frac{\partial \log \mathcal{L}(\boldsymbol{\beta}, \mathbf{y})}{\partial \beta_{k,j}} = \sum_{i=1}^n Y_{i,j} X_{i,k} - n_i \pi_{i,j} X_{i,k}$$

i.e.

$$\frac{\partial \log \mathcal{L}(\boldsymbol{\beta}, \mathbf{y})}{\partial \beta_{k,j}} = \sum_{i=1}^n Y_{i,j} X_{i,k} - n_i \frac{\exp(\mathbf{X}' \boldsymbol{\beta}_j)}{1 + \exp(\mathbf{X}' \boldsymbol{\beta}_1) + \exp(\mathbf{X}' \boldsymbol{\beta}_2)} X_{i,k}$$

Loi multinomiale (et GLM)

Sous R, la fonction `multinom` de `library(nnet)` permet de faire cette estimation.

On commence par définir les trois tranches de coûts,

```
> seuils=c(0,1120,1220,1e+12)
> couts$tranches=cut(couts$cout,breaks=seuils,
+ labels=c("small","fixed","large"))
> head(couts,5)

  nocontrat    no garantie      cout exposition zone puissance agevehicule
1     1870 17219       1RC 1692.29        0.11      C         5          0
2     1963 16336       1RC  422.05        0.10      E         9          0
3     4263 17089       1RC  549.21        0.65      C        10         7
4     5181 17801       1RC  191.15        0.57      D         5         2
5     6375 17485       1RC 2031.77        0.47      B         7         4

  ageconducteur bonus marque carburant densite region tranches
1             52    50     12           E      73     13   large
2             78    50     12           E      72     13 small
3             27    76     12           D      52      5 small
4             26   100     12           D      83      0 small
5             46    50      6           E      11     13   large
```

Loi multinomiale (et GLM)

On peut ensuite faire une régression multinomiale afin d'expliquer π_i en fonction de covariables X_i .

```
> reg=multinom(tranches~ageconducteur+agevehicule+zone+carburant,data=couts)
# weights:  30 (18 variable)
initial  value 2113.730043
iter  10 value 2063.326526
iter  20 value 2059.206691
final  value 2059.134802
converged
```

```
> summary(reg)
```

Call:

```
multinom(formula = tranches ~ ageconducteur + agevehicule + zone +
carburant, data = couts)
```

Coefficients:

	(Intercept)	ageconducteur	agevehicule	zoneB	zoneC
fixed	-0.2779176	0.012071029	0.01768260	0.05567183	-0.2126045
large	-0.7029836	0.008581459	-0.01426202	0.07608382	0.1007513
	zoneD	zoneE	zoneF	carburantE	
fixed	-0.1548064	-0.2000597	-0.8441011	-0.009224715	
large	0.3434686	0.1803350	-0.1969320	0.039414682	

Std. Errors:

	(Intercept)	ageconducteur	agevehicule	zoneB	zoneC	zoneD
fixed	0.2371936	0.003738456	0.01013892	0.2259144	0.1776762	0.1838344
large	0.2753840	0.004203217	0.01189342	0.2746457	0.2122819	0.2151504
	zoneE	zoneF	carburantE			
fixed	0.1830139	0.3377169	0.1106009			
large	0.2160268	0.3624900	0.1243560			

Loi multinomiale (et GLM)


On peut régresser suivant l'ancienneté du véhicule, avec ou sans lissage,

```
> library(splines)
> reg=multinom(tranches~agevehicule,data=couts)
# weights:  9 (4 variable)
initial  value 2113.730043
final   value 2072.462863
converged
> reg=multinom(tranches~bs(agevehicule),data=couts)
# weights:  15 (8 variable)
initial  value 2113.730043
iter    10 value 2070.496939
iter    20 value 2069.787720
iter    30 value 2069.659958
final   value 2069.479535
converged
```

Loi multinomiale (et GLM)

On peut alors prédire la probabilité, sachant qu'un accident survient, qu'il soit de type 1, 2 ou 3


```
> predict(reg,newdata=data.frame(agevehicule=5),type="probs")
   small    fixed    large
0.3388947 0.3869228 0.2741825
```



Loi multinomiale (et GLM)

ou en fonction de la densité de population

```
> reg=multinom(tranches~bs(densite),data=couts)
# weights: 15 (8 variable)
initial value 2113.730043
iter 10 value 2068.469825
final value 2068.466349
converged
> predict(reg,newdata=data.frame(densite=90),type="probs")
      small    fixed    large
0.3484422 0.3473315 0.3042263
```



Loi multinomiale (et GLM)

Il faut ensuite ajuster des lois pour les trois régions A, B ou C

```
> reg=multinom(tranches~bs(densite),data=couts)
# weights: 15 (8 variable)
initial value 2113.730043
iter 10 value 2068.469825
final value 2068.466349
converged
> predict(reg,newdata=data.frame(densite=90),type="probs")
      small    fixed    large
0.3484422 0.3473315 0.3042263
```

Pour A, on peut tenter une loi exponentielle (qui est une loi Gamma avec $\phi = 1$).

```
> regA=glm(cout~agevehicule+densite+carburant,data=sousbaseA,
+ family=Gamma(link="log"))
> summary(regA, dispersion=1)
```

Coefficients:

```

            Estimate Std. Error z value Pr(>|z|)
(Intercept) 6.0600491  0.1005279  60.282 <2e-16 ***
agevehicule 0.0003965  0.0070390   0.056   0.955
densite      0.0014085  0.0013541   1.040   0.298
carburantE -0.0751446  0.0806202  -0.932   0.351
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for Gamma family taken to be 1)

```

Pour **B**, on va garder l'idée d'une masse de Dirac en

```

> mean(sousbaseB$cout)
[1] 1171.998

```

(qui semble correspondre à un coût fixe.

Enfin, pour **C**, on peut tenter une loi Gamma ou lognormale décallée,

```

> k=mean(sousbaseB$cout)
> regC=glm((cout-k)~agevehicule+densite+carburant,data=sousbaseC,

```

```
+ family=Gamma(link="log"))
> summary(regC)
```

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	9.119879	0.378836	24.073	<2e-16 ***
agevehicule	-0.013393	0.028620	-0.468	0.6400
densite	-0.010814	0.004831	-2.239	0.0256 *
carburantE	-0.530964	0.287450	-1.847	0.0653 .

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

(Dispersion parameter for Gamma family taken to be 10.00845)

