

LE PROCESSUS DE POISSON ¹

PRÉPARATION À L'AGRÉGATION EXTERNE DE MATHÉMATIQUES DE L'UNIVERSITÉ RENNES 1
ANNÉE 2008/2009

1. LE PROCESSUS DE POISSON SIMPLE

[RÉF. : TOUTES]

A titre d'exemple, considérons les phénomènes suivants : émission de particules radioactives, appels dans un central téléphonique, ou bien arrivées de clients devant un guichet. En terme de modélisation, ce qui caractérise ces phénomènes -considérés comme aléatoires-, c'est une répartition dans le temps d'instant aléatoires où se produisent certains événements spécifiques. Un premier modèle est fourni par la famille des *processus de comptage* :

Définition 1.1 Soit $(X_t)_{t \geq 0}$ un processus stochastique à valeurs réelles. On dit que $(X_t)_{t \geq 0}$ est un processus de comptage si, pour \mathbb{P} -p.t. $\omega \in \Omega$, la trajectoire $t \mapsto X_t(\omega)$ est croissante par sauts d'amplitude 1, continue à droite et telle que $X_0(\omega) = 0$.

Par exemple, X_t représente le nombre de clients arrivés devant un guichet donné dans l'intervalle de temps $[0, t]$. Une telle famille de modèles est en fait beaucoup trop générale pour pouvoir prétendre être étudiée. Dans les 3 exemples présentés ci-dessus, on peut imposer des hypothèses supplémentaires, qui restent compatibles avec une modélisation raisonnable, et qui permettront au modélisateur de fournir des réponses quantitatives.

Définition 1.2 Un processus de comptage $(N_t)_{t \geq 0}$ est appelé processus de Poisson simple si :

- (i) pour tous $s, t \geq 0$, $N_{t+s} - N_s \perp \sigma(N_u, u \leq s)$; [ACCROISSEMENTS INDÉPENDANTS]
- (ii) pour tous $s, t \geq 0$, $N_{t+s} - N_s \sim N_t$. [STATIONNARITÉ]

MODÈLES.

- GUICHET. Ici, N_t représente le nombre de clients qui sont arrivés au guichet avant l'instant t . L'hypothèse sur les sauts d'amplitude 1 exprime le fait que les clients arrivent un par un au guichet. En revanche, les hypothèses (i) et (ii), qui posent des conditions sur $N_{t+s} - N_s$ (le nombre de clients arrivés au guichet dans l'intervalle de temps $]s, t+s]$), sont plus discutables. Malgré cela, une telle modélisation est une approximation raisonnable de la réalité, qui a en plus la vertu de pouvoir donner des solutions quantitatives simples.
- DÉSINTÉGRATION DE L'URANIUM. Le processus de Poisson modélise de manière très convenable les émissions radioactives de l'uranium 235 : l'observation de son processus de désintégration -très lent- montre qu'il est stationnaire et à accroissements indépendants.

EXISTENCE DU PROCESSUS DE POISSON. Soit $(D_n)_{n \geq 1}$ une suite de v.a.i.i.d. de loi $\mathcal{E}(\lambda)$. Le processus défini pour chaque $t \geq 0$ par

$$\sum_{n \geq 1} \mathbf{1}_{\{D_1 + \dots + D_n \leq t\}}, \quad t \geq 0. \quad (\star)$$

est un processus de Poisson simple. C'est d'ailleurs une autre définition du processus de Poisson simple.

2. LOI D'UN PROCESSUS DE POISSON ET DE SES INTER-ARRIVÉES

[RÉF. : TOUTES]

Expliquons rapidement de quelle manière on peut retrouver la loi marginale du processus de Poisson simple $(N_t)_{t \geq 0}$, lorsque N_t s'exprime par (\star) . Comme $S_n := D_1 + \dots + D_n \sim \gamma(n, \lambda)$ et $\{S_n \leq t\} = \{N_t \geq n\}$, on a :

$$\mathbb{P}(N_t = n) = \mathbb{P}(S_n \leq t) - \mathbb{P}(S_{n+1} \leq t) = \exp(-\lambda t) \frac{(\lambda t)^n}{n!},$$

i.e. $N_t \sim \mathcal{P}(\lambda t)$. Avec la définition 1.2, on peut établir (plus difficile) :

Théorème 2.1 Soit $(N_t)_{t \geq 0}$ est un processus de Poisson simple. Il existe $\lambda \geq 0$ tel que pour chaque $t \geq 0$, $N_t \sim \mathcal{P}(\lambda t)$. Le paramètre λ , appelé intensité du processus de Poisson, le caractérise entièrement.

¹Benoît Cadre - ENS Cachan Bretagne

Remarques 2.1

- (a) Le caractère "simple" de ce processus de Poisson tient essentiellement au fait qu'il est stationnaire, une propriété dont on a vu les limites en matière de modélisation. De manière plus générale, plutôt que l'hypothèse de stationnarité, on suppose que $N_{t+s} - N_s \sim \mathcal{P}(\int_s^{t+s} \lambda(u) du)$, où $\lambda(\cdot)$ est localement intégrable et strictement positive. La fonction $m(t) = \int_0^t \lambda(u) du$ est alors inversible, et le processus $(N_{m^{-1}(t)})_{t \geq 0}$ est un processus de comptage, qui est de surcroît à accroissements indépendants et stationnaires : c'est donc un processus de Poisson simple (d'intensité 1).
- (b) Le processus $(N_t)_{t \in \mathbb{N}}$ est une chaîne de Markov homogène d'espace d'états \mathbb{N} et matrice de transition $\mathcal{P} = (p_{ij})_{i,j \in \mathbb{N}}$, où $p_{ij} = 0$ si $j < i$ et, dans le cas $j \geq i$:

$$p_{ij} = \exp(-\lambda) \frac{\lambda^{j-i}}{(j-i)!}.$$

De plus, $(N_t)_{t \geq 0}$ est une sous-martingale, et $(N_t - \lambda t)_{t \geq 0}$ est une martingale. En effet, pour tous $0 \leq s \leq t$:

$$\mathbb{E}(N_t - \lambda t | N_u, u \leq s) = \mathbb{E}(N_t - N_s | N_u, u \leq s) + N_s - \lambda t = \mathbb{E}(N_{t-s}) + N_s - \lambda t = N_s - \lambda s.$$

Si $0 = T_0 < T_1 < T_2 < \dots$ sont les instants de sauts du processus de Poisson simple $(N_t)_{t \geq 0}$:

$$N_t = \sum_{n \geq 1} \mathbf{1}_{\{T_n \leq t\}}, \quad t \geq 0.$$

Théorème 2.2 Les instants d'inter-arrivées $(T_n - T_{n-1})_{n \geq 1}$ du processus de Poisson simple d'intensité λ sont des v.a.r. indépendantes et de même loi $\mathcal{E}(\lambda)$. De plus, (T_1, \dots, T_n) possède une densité f_n définie par

$$f_n(t_1, \dots, t_n) = \begin{cases} \lambda^n \exp(-\lambda t_n) & \text{si } 0 < t_1 < \dots < t_n; \\ 0 & \text{sinon.} \end{cases}$$

Preuve Cas $n = 2$. Soient $0 \leq s_1 < t_1 < s_2 < t_2$ et $A =]s_1, t_1] \times]s_2, t_2]$. En utilisant les propriétés de stationnarité et d'indépendance des accroissements d'un processus de Poisson, on obtient successivement :

$$\begin{aligned} \mathbb{P}((T_1, T_2) \in A) &= \mathbb{P}(N_{s_1} = 0, N_{t_1} - N_{s_1} = 1, N_{s_2} - N_{t_1} = 0, N_{t_2} - N_{s_2} \geq 1) \\ &= \mathbb{P}(N_{s_1} = 0) \mathbb{P}(N_{t_1 - s_1} = 1) \mathbb{P}(N_{s_2 - t_1} = 0) \mathbb{P}(N_{t_2 - s_2} \geq 1). \end{aligned}$$

Avec le théorème 2.1, cela donne finalement

$$\mathbb{P}((T_1, T_2) \in A) = \int_A \lambda^2 \exp(-\lambda x_2) dx_1 dx_2.$$

Notons \mathcal{A} la famille des pavés du type $A =]s_1, t_1] \times]s_2, t_2]$ avec $t_1 < s_2$ et $G = \{(x_1, x_2) : 0 < x_1 < x_2\}$. Alors, \mathcal{A} est un π -système et $\sigma(\mathcal{A}) = \mathcal{B}(G)$ donc, d'après le théorème de Dynkin, la formule ci-dessus est vraie pour tout $A \in \mathcal{B}(G)$. Les lois de T_1 et de $T_2 - T_1$ s'en déduisent aussitôt, de même que leur indépendance. •

FILE D'ATTENTE $M/M/1$ ET PROCESSUS DE POISSON. Dans la cadre d'une file d'attente $M/M/1$, la loi des inter-arrivées est $\mathcal{E}(\lambda)$, et celle des temps de service est $\mathcal{E}(\mu)$. Le processus d'arrivée des clients au serveur est donc un processus de Poisson simple de paramètre λ . De plus, en régime stationnaire, le processus de sortie du système est aussi un processus de Poisson simple d'intensité λ (la loi stationnaire du processus décrivant l'évolution de la taille du système à l'instant t , qui existe lorsque $\rho := \lambda/\mu < 1$, est $(1 - \rho)(1, \rho, \rho^2, \dots)$).

AMNÉSIE DE LA LOI EXPONENTIELLE. Dans le cadre d'une modélisation des arrivées de clients à un guichet, T_n représente l'instant d'arrivée du client n au guichet, et $(T_n - T_{n-1})$ représente le temps qui s'est écoulé entre les arrivées du $(n - 1)$ -ème et du n -ème client au guichet. La loi exponentielle des instants d'inter-arrivées des clients au guichet est héritée notamment de la propriété d'indépendance des accroissements du processus de Poisson. Rien d'étonnant à cela : l'indépendance des accroissements du processus de Poisson traduit un comportement "amnésique" des clients, et l'amnésie est précisément ce qui caractérise la loi exponentielle. Rappelons en effet qu'une v.a.r. Z possédant une densité suit une loi exponentielle si, et seulement si, pour tous $x, y \geq 0$:

$$\mathbb{P}(Z > x + y | Z > x) = \mathbb{P}(Z > y).$$

Autrement dit -une fonction de répartition caractérisant la loi-, la loi exponentielle se caractérise par son absence de mémoire :

$$\forall x \geq 0 : \mathcal{L}(Z - x | Z > x) = \mathcal{L}(Z).$$

Cette propriété traduit bien le comportement du temps d'arrivée du prochain client dans une file d'attente (mais aussi de la durée de vie des ampoules, ...). Si Z_1, \dots, Z_n sont des v.a.r. indépendantes de lois exponentielles de paramètres $\lambda_1, \dots, \lambda_n$, on montre que $\min(Z_1, \dots, Z_n) \sim \mathcal{E}(\lambda_1 + \dots + \lambda_n)$ et $\mathbb{P}(Z_i = \min(Z_1, \dots, Z_n)) = \lambda_i / (\lambda_1 + \dots + \lambda_n)$. Ainsi, dans le cadre d'une modélisation des arrivées des clients au guichet par un processus de Poisson simple d'intensité λ , la probabilité que le temps écoulé entre l'arrivée du $(i-1)$ -ème et du i -ème client soit la plus petite parmi les inter-arrivées des n premiers clients est indépendante de λ , et vaut $1/n$. De plus, parmi les n premiers clients, le temps minimum entre l'arrivée de 2 clients consécutifs suit une loi $\mathcal{E}(n\lambda)$.

3. ESTIMATION DE L'INTENSITE

[RÉF. : FOATA ET FUCHS]

Reprenons le modèle poissonnien des clients arrivant à une caisse. Soit $(N_t)_{t \geq 0}$ un processus de Poisson simple, dont l'intensité $\lambda > 0$ est donc le seul paramètre du modèle. En pratique, λ est inconnu et afin de connaître entièrement son modèle, le gérant du magasin doit donner une valeur pour λ . Dès lors, comment estimer λ ? Comment construire un intervalle de confiance pour λ ? Quel type de test statistique utiliser?

3.1 CAS OÙ LE PROCESSUS EST OBSERVÉ JUSQU'À UN INSTANT t

On peut écrire N_t comme une somme de v.a.r. indépendantes (et majoritairement de même loi) : $N_t = N_t - N_{[t]} + \sum_{i=0}^{[t]-1} (N_{i+1} - N_i)$. On peut alors montrer le résultat suivant :

Théorème 3.1 Lorsque $t \rightarrow \infty$:

$$\frac{N_t}{t} \xrightarrow{\text{p.s.}} \lambda \quad \text{et} \quad \sqrt{\frac{t}{\lambda}} \left(\frac{N_t}{t} - \lambda \right) \xrightarrow{\mathcal{L}} N(0, 1).$$

Si le processus de Poisson a été observé jusqu'à l'instant t (suffisamment grand), l'estimateur naturel de λ est donc N_t/t , et il l'estime sans biais. En pratique, il suffira au gérant du magasin de compter le nombre de clients qui arrivent à la caisse avant un instant t suffisamment grand pour en déduire une estimation de λ . La construction de l'intervalle de confiance asymptotique (ou le test statistique) pour λ est basé sur la partie (ii) du théorème précédent. Notons $u_{1-\alpha/2}$ le quantile d'ordre $1 - \alpha/2$ de la loi $N(0, 1)$. Un intervalle de confiance (asymptotique) pour λ au niveau $1 - \alpha$ est

$$\left[-u_{1-\alpha/2} \frac{\sqrt{N_t}}{t} + \frac{N_t}{t}, u_{1-\alpha/2} \frac{\sqrt{N_t}}{t} + \frac{N_t}{t} \right].$$

Remarque 3.1 Cet estimateur de l'intensité est aussi l'estimateur du maximum de vraisemblance : ayant observé le processus jusqu'à l'instant t , on dispose d'une part du nombre de sauts n et d'autre part des instants de sauts $0 < t_1 < \dots < t_n \leq t$ de la trajectoire de $(N_t)_{t \geq 0}$. La vraisemblance de ces observations est

$$L(n, t_1, \dots, t_n; \lambda) = f(t_1, \dots, t_n) \mathbb{P}(N_t = n),$$

où f désigne la densité de $\mathcal{L}(T_1, \dots, T_n | N_t = n)$. On vérifie que $f(u_1, \dots, u_n) = n! / t^n \mathbf{1}_{\{0 < u_1 < \dots < u_n \leq t\}}$: en effet, pour $n = 2$, on a d'après le théorème 2.2, pour tous $0 < s_1 < u_1 < s_2 < u_2 < t$,

$$\mathbb{P}(s_1 \leq T_1 \leq u_1, s_2 \leq T_2 \leq u_2, T_3 > t) = \frac{\mathbb{P}(s_1 \leq T_1 \leq u_1, s_2 \leq T_2 \leq u_2, T_3 > t)}{\mathbb{P}(N_t = 2)} = \frac{2!}{t^2} (u_1 - s_1)(u_2 - s_2).$$

On conclut, comme dans la preuve du théorème 2.2, en utilisant le théorème de Dynkin. La vraisemblance s'écrit donc :

$$L(n, t_1, \dots, t_n; \lambda) = \exp(-\lambda t) \frac{(\lambda t)^n n!}{n! t^n} = \lambda^n \exp(-\lambda t).$$

La valeur qui maximise cette expression est n/t , i.e. l'estimateur du maximum de vraisemblance de λ est N_t/t .

3.2 CAS OÙ LE PROCESSUS EST OBSERVÉ JUSQU'À SON n -IÈME SAUT

Notons $0 < t_1 < \dots < t_n$ les instants de saut observés. La vraisemblance de ces observations est

$$L(t_1, \dots, t_n; \lambda) = \lambda^n \exp(-\lambda t_n).$$

La valeur qui maximise cette expression est n/t_n , et l'estimateur du maximum de vraisemblance est donc n/T_n . En écrivant T_n sous la forme d'une somme de v.a.i.i.d. : $T_n = \sum_{i=1}^{n-1} (T_{i+1} - T_i)$, on démontre le résultat suivant, qui, tout comme le théorème précédent, permet de construire des intervalles de confiance et des tests statistiques pour la valeur de λ .

Théorème 3.2 Lorsque $n \rightarrow \infty$:

$$\frac{n}{T_n} \xrightarrow{\text{p.s.}} \lambda \quad \text{et} \quad \sqrt{n} \left(\lambda \frac{T_n}{n} - 1 \right) \xrightarrow{\mathcal{L}} N(0, 1).$$

4. UN PROCESSUS DE NAISSANCE ET DE MORT

[RÉF. : DACUNHA-CASTELLE ET DUFLO, FOATA ET FUCHS, GRIMMETT ET STIRZACKER]

On veut décrire l'évolution, en fonction du temps, de la taille d'une population.

MODÉLISATION.

- Chaque saut du processus de Poisson $(N_t)_{t \geq 0}$ d'intensité λ est interprété comme étant la naissance d'un individu ;
- Chaque individu a une durée de vie de fonction de répartition F , et les durées de vie des individus sont des v.a.i.i.d. et indépendantes du processus $(N_t)_{t \geq 0}$.

Soient T_k la date de naissance de l'individu k et X_k sa durée de vie. Le nombre d'individus en vie à l'instant $t \geq 0$, noté $Q(t)$, vaut alors (avec la convention habituelle " $\sum_{k=1}^0 = 0$ ") :

$$Q(t) = \sum_{k=1}^{N_t} \mathbf{1}_{\{T_k + X_k \geq t\}}.$$

LOI DE $Q(t)$. Pour tout $u \in \mathbb{R}$:

$$\varphi_{Q(t)}(u) := \mathbb{E} \left(\exp(iuQ(t)) \right) = \sum_{n \geq 0} \mathbb{P}(N_t = n) \mathbb{E} \left(\exp(iu \sum_{k=1}^n \mathbf{1}_{\{T_k + X_k \geq t\}}) \middle| N_t = n \right).$$

Or, la loi conditionnelle de (T_1, \dots, T_n) sachant $N_t = n$ a pour densité $n!/t^n \mathbf{1}_{\{0 < t_1 < \dots < t_n < t\}}$ (cf. Section 3.1). Ainsi, $\mathcal{L}(T_1, \dots, T_n | N_t = n) = \mathcal{L}(U_{(1)}, \dots, U_{(n)})$, où U_1, \dots, U_n sont des v.a.i. de même loi $\mathcal{U}([0, t])$. De l'égalité en loi

$$\sum_{k=1}^n \mathbf{1}_{\{U_{(k)} + X_k \geq t\}} \sim \sum_{k=1}^n \mathbf{1}_{\{U_k + X_k \geq t\}},$$

on déduit que :

$$\varphi_{Q(t)}(u) = \sum_{n \geq 0} \mathbb{P}(N_t = n) \left(\mathbb{E} \left(\exp(iu \mathbf{1}_{\{U_1 + X_1 \geq t\}}) \right) \right)^n.$$

De plus,

$$\mathbb{P}(U_1 + X_1 \geq t) = \frac{1}{t} \int_0^t \mathbb{P}(U_1 + X_1 \geq t | U_1 = s) ds = \frac{1}{t} \int_0^t (1 - F(u)) du.$$

On conclut à l'aide de ces observations que $Q(t) \sim \mathcal{P}(\lambda \int_0^t (1 - F(u)) du)$. Dans cette modélisation, on a ainsi, lorsque $t \rightarrow \infty$: $Q(t) \xrightarrow{\mathcal{L}} \mathcal{P}(\lambda \mathbb{E}(X))$. Cette conclusion est-elle conforme à la réalité ? Quelles simulations proposer ?

REFERENCES

- P. Billingsley, *Probability and Measure*. Wiley Series in Probability and Mathematical Statistics, 1995.
- D. Dacunha-Castelle et M. Duflo, *Probabilités et statistiques - Tome 2 : Problèmes à temps mobile (Cours et Exercices)*, Masson, 1993.
- D. Foata et A. Fuchs, *Processus stochastiques - Processus de Poisson, chaînes de Markov et martingales*, Dunod, 2002.
- G.R. Grimmett et D. Stirzaker *Probability and Random Processes*. Oxford Science Publications, 1992.
- J.-Y. Ouvrard, *Probabilités 2 : maîtrise agrégation*, Cassini, 2001.