

Change-point Detection in Astronomical Data by using a Hierarchical Model and a Bayesian Sampling Approach

Nicolas Dobigeon[†] Jean-Yves Tournet[†]
Jeffrey D. Scargle[◇]

[†] IRIT/ENSEEIH/TéSA
Toulouse, FRANCE

[◇] Space Science Division, NASA
Moffett Field, CA, USA

IEEE Workshop on Statistical Signal Processing, Bordeaux,
2005

Signal and Image Segmentation using Bayesian Inference

● Biomedical

- ✎ M. Lavielle, "Optimal segmentation of random processes," *IEEE Trans. on Signal Processing*, 1998.
- ✎ A. Gacek et al, "A genetic segmentation of ECG signals," *IEEE Trans. on Biomedical Engineering*, 2003

● Image Segmentation

- ✎ R. Fjortoft et al, "An Optimum multiedge Detector for SAR image segmentation," *IEEE Trans. on Geosci. Remote Sensing*, 1998.
- ✎ J-Y Tourneret et al, "Bayesian off-line detection of multiple change-points corrupted by multiplicative noise: application to SAR image edge detection," *Signal Processing*, 2003.


● Astronomy

- ✎ J. D. Scargle, "Studies in Astronomical Time Series Analysis: v. Bayesian blocks, a new method to analyze structure in Photon counting data," *The Astrophysical Journal*, 1998.
- ✎ B. Jackson et al, "An algorithm for optimal partitioning of data on an interval," *IEEE Sig. Proc. Letters*, 2005.

Astronomical Data


1D Data

- The number of photons counted in successive equally spaced intervals (bins) is distributed according to a Poisson distribution.
- The Poisson rate parameter varies as determined by the actual changes in brightness of the Gamma Ray Burst (GRB) source. The intensity of the GRB as a function of time consists of a series of pulses.

 *Determine rise and decay times of the pulses*

Multi-dimensional Data


- The energies are recorded in four energy channels: 25 – 60keV, 60 – 110keV, 110 – 325keV and $> 325\text{keV}$ by BATSE.

 *How GRB variability depends on the energy?*


Introduction

BATSE module

Burst And Transient Source Experiment



The Compton γ -Ray Observatory



Problem formulation

Modeling

Arrival time of photons are modeled by a discrete time Poisson counting process:

$$y_i \sim \mathcal{P}(\lambda_k)$$

where $k = 1, \dots, K$, $i \in \mathcal{I}_k = [l_{k-1} + 1, l_k]$, and :

- $\mathcal{P}(\lambda)$ denotes a Poisson distribution with parameter λ ,
- K is the number of segments in the observed signal,
- l_k is the sample point after which the k th change occurs in the signal (by convention $l_0 = 0$ and $l_K = n$ where n is the number of observed samples).

Problem

Estimation of (l_k, λ_k) from data $y = (y_i)_{i=1, \dots, n}$

Hierarchical Bayesian Model

A standard reparametrization

Indicators :

$$\begin{cases} r_i = 1 & \text{if there is a changepoint at lag } i, \\ r_i = 0 & \text{otherwise,} \end{cases}$$

The unknown parameter vector

$$\theta = (r, \lambda) \in \Theta = \{0, 1\}^n \times \mathbb{R}^K$$

- $r = (r_1, \dots, r_n)$ with $r_n = 1$,
- $\lambda = (\lambda_1, \dots, \lambda_K)$ with $K(r) = \sum_{i=1}^n r_i$,

Hierarchical Bayesian inference

Bayes' theorem :

$$f(\theta|y) \propto \int f(y|\theta)f(\theta|\phi)f(\phi)d\phi$$

Likelihood function

Likelihood function

$$\begin{aligned}
 f(y|\theta) &= \prod_{k=1}^K \prod_{i \in I_k} \frac{\lambda_k^{y_i} \exp(-\lambda_k)}{y_i!} \\
 &= \frac{1}{\prod_{i=1}^n y_i!} \prod_{k=1}^K \lambda_k^{s_k(r)} \exp(-\lambda_k n_k(r)) \\
 &\propto \prod_{k=1}^K \lambda_k^{s_k(r)} \exp(-\lambda_k n_k(r)),
 \end{aligned}$$

- $s_k(r) = \sum_{i \in I_k} y_i$
- $n_k(r) = l_k - l_{k-1}$ (number of samples in the k th interval l_k)

Parameter priors

Indicator vector

- $\mathbf{P}(r_i = 0) = 1 - P$ and $\mathbf{P}(r_i = 1) = P$ (do not depend on i),
- the variables r_i (for $i = 1, \dots, n$) are *a priori* independent,

The indicator prior distribution :

$$\begin{aligned} f(r|P) &= \prod_{i=1}^{n-1} P^{r_i} (1-P)^{1-r_i}, \\ &= P^{\sum_{i=1}^{n-1} r_i} (1-P)^{n-1-\sum_{i=1}^{n-1} r_i}, \end{aligned}$$

Poisson parameters

Gamma distribution:

$$f(\lambda_k | \nu, \gamma) \sim \mathcal{G}(\nu, \gamma),$$

where $\nu = 1$ and γ is an adjustable hyperparameter

Hyperparameter priors

Hyperparameter γ

Noninformative Jeffreys' prior:

$$f(\gamma) = \frac{1}{\gamma} \mathbb{I}_{\mathbb{R}^+}(\gamma).$$

Hyperparameter P

Uniform distribution on $[0, 1]$:

$$f(P) = \mathbb{I}_{[0,1]}(P).$$

Hyperparameter vector $\phi = (\gamma, P)$

Assuming the independence of different hyperparameters:

$$f(\Phi) = \frac{1}{\gamma} \mathbb{I}_{\mathbb{R}^+}(\gamma) \mathbb{I}_{[0,1]}(P).$$

Hierarchical Bayesian Model

Posterior changepoint distribution

After integration respect to the nuisance parameters P and λ_k :

$$f(r, \gamma | y) \propto C(r | y) \frac{1}{\gamma} \left(\frac{\gamma^\nu}{\Gamma(\nu)} \right)^K \prod_{k=1}^K \frac{\Gamma(n_k(r) + \nu)}{(s_k(r) + \gamma)^{n_k(r) + \nu}},$$

with

$$C(r | y) = \Gamma \left(\sum_{i=1}^{n-1} r_i + 1 \right) \Gamma \left(n - \sum_{i=1}^{n-1} r_i \right),$$

where $\Gamma(t)$ is the Gamma function.

A too complex posterior distribution...

☞ Simulation of samples distributed according to the $f(r, \gamma | y)$ by using MCMC methods.

Gibbs sampler for change-point detection

Generation of samples distributed according to $f(r|\gamma, y)$

- n-1 Bernoulli draws: $P(r_i = \epsilon | r_{-i}, \gamma, y) \propto f(r_i(\epsilon), \gamma | y)$.

Generation of samples distributed according to $f(\gamma|r, y)$

- Draw samples according to $f(\lambda|\gamma, r, y)$

$$\lambda_k | \gamma, r, y \sim \mathcal{G}(s_k(r) + \nu, n_k(r) + \gamma),$$

- Draw samples according to $f(\gamma|\lambda, r, y)$

$$\gamma | \lambda, r, y \sim \mathcal{G}\left(\nu K, \sum_{k=1}^K \lambda_k\right).$$

Updating P


$$f(P|r, y) \propto P^{\sum_{i=1}^{n-1} r_i} (1-P)^{n-1-\sum_{i=1}^{n-1} r_i}.$$

Synthetic data


Simulation Parameters

- Signal parameters: $n = 120$, $K = 4$, $l = (20, 50, 100, 120)$, $\lambda = (19, 9, 17, 7)$
- Algorithm: 64 Markov-Chains, 200 burn-in iterations, 800 iterations to compute the estimates

Posterior distribution of r




Posterior distribution of K




Synthetic data

Posterior distribution of λ



Posterior distribution of P



In good agreement with the theoretical results...



Real Astronomical Data

Parameters of the simulation

Raw data: 29000 photons, 256 time bins of 3.68ms,

Algorithm: 64 Markov-Chains, 50 burn-in iterations, 1500 computation iterations.

Posterior distribution of changepoint locations



Généralisation multi-capteurs

Modélisation

La statistique des données observées dans les diverses bandes énergétiques peut être décrite comme suit :

$$y_{j,i} \sim \mathcal{P}(\lambda_{j,k})$$

où $j = 1, \dots, J$, $k = 1, \dots, K_j$, $i \in \mathcal{I}_{j,k} = [l_{j,k-1} + 1, l_{j,k}]$, et :

- J est le nombre de signaux à segmenter,
- K_j est le nombre de segments du $j^{\text{ième}}$ signal observé,
- $l_{j,k}$ correspond à la $k^{\text{ième}}$ rupture dans le $j^{\text{ième}}$ signal,
- $\mathcal{P}(\lambda)$ désigne une loi de Poisson de paramètre λ .

Problème

Estimation conjointe des $l_{j,k}$ à partir des données :

$$y = (y_{j,i})_{j \in \{1, \dots, J\}, i \in \{1, \dots, n\}}$$

Modèle Bayésien Hiérarchique

Un reparamétrage classique

Introduction d'indicatrices :

$$\begin{cases} r_{j,i} = 1 \text{ s'il y a une rupture à l'instant } i \text{ du } j^{\text{ième}} \text{ signal,} \\ r_{j,i} = 0 \text{ sinon,} \end{cases}$$

Le vecteur des paramètres inconnus

$\theta = (r, \lambda) \in \Theta = \{0, 1\}^{nJ} \times \prod_{j=1}^J \mathbb{R}_+^{K_j}$, $K(r) = \sum_{i=1}^n r_i$ avec :

- $r = (r_1, \dots, r_n)$ et $r_i = (r_{1,i}, \dots, r_{J,i})^T$,
- $\lambda = (\lambda_1, \dots, \lambda_J)$ et $\lambda_j = (\lambda_{j,1}, \dots, \lambda_{j,K_j})^T$,

Inférence Bayésienne Hiérarchique

Théorème de Bayes :

$$f(\theta|y) \propto \int f(y|\theta)f(\theta|\phi)f(\phi)d\phi$$

Vraisemblance

Hypothèses

Les séquences $y_l = (y_{l,1}, \dots, y_{l,n})$ et $y_m = (y_{m,1}, \dots, y_{m,n})$ sont indépendantes pour $l \neq m$

Fonction de vraisemblance

Elle s'exprime comme :

$$f(y|\theta) \propto \prod_{j=1}^J \prod_{k=1}^{K_j} \lambda_{j,k}^{s_{j,k}(r)} \exp(-\lambda_{j,k} n_{j,k}(r)),$$

- $s_{j,k}(r) = \sum_{i \in \mathcal{I}_{j,k}} y_{j,i}$ (somme des points du $k^{\text{ième}}$ intervalle $\mathcal{I}_{j,k}$ du $j^{\text{ième}}$ signal)
- $n_{j,k}(r) = l_{j,k} - l_{j,k-1}$ (longueur du segment $\mathcal{I}_{j,k}$)

Lois a priori : Vecteur des indicatrices

Hypothèses

- Les probabilités $P(r_i = \epsilon)$ ne dépendent pas de i avec :

$$r_i = (r_{1,i}, \dots, r_{J,i})^T, \quad \epsilon = (\epsilon_1, \dots, \epsilon_J)^T \in \{0, 1\}^J,$$

- Les variables r_i (pour $i = 1, \dots, n$) sont *a priori* indépendantes,

Loi a priori des indicatrices

Sous ces hypothèses :

$$f(r|P) = \prod_{\epsilon \in \{0,1\}^J} p_{\epsilon}^{S_{\epsilon}(r)},$$

- $P_{\epsilon} \in \{P_{0\dots 0}, \dots, P_{1\dots 1}\}$,
- $S_{\epsilon}(r)$ est le nombre d'instants tels que $r_i = \epsilon$

Introduction d'une corrélation entre les séquences

- Grande valeur de $P_{0\dots 0} \Rightarrow$ absence de ruptures simultanées
- Grande valeur de $P_{1\dots 1} \Rightarrow$ présence de ruptures simultanées

Lois a priori : Paramètres de Poisson

Hypothèses (lois conjuguées)

- $f(\lambda_{j,k}|\nu, \gamma) \sim \mathcal{G}(\nu, \gamma)$, où :
 - $\nu = 1$,
 - γ est un hyperparamètre,
- les paramètres $\lambda_{j,k}$ sont *a priori* indépendants,

Loi a priori des paramètres de Poisson

$$\begin{aligned}
 f(\lambda|\nu, \gamma) &= \prod_{j=1}^J \prod_{k=1}^{K_j} f(\lambda_{j,k}|\nu, \gamma), \\
 &= \prod_{j=1}^J \left[\frac{\gamma^{\nu K_j} e^{-\gamma \sum_{k=1}^{K_j} \lambda_{j,k}}}{\Gamma(\nu)^{K_j}} \prod_{k=1}^{K_j} \left(\lambda_{j,k}^{\nu-1} \mathbb{I}_{\mathbb{R}^+}(\lambda_{j,k}) \right) \right],
 \end{aligned}$$

où $\mathbb{I}_{\mathbb{R}^+}$ est la fonction indicatrice sur \mathbb{R}^+ .

Lois a priori des hyperparamètres

Hyperparamètre γ

Loi non-informative de Jeffrey : $f(\gamma) = \frac{1}{\gamma} \mathbb{I}_{\mathbb{R}^+}(\gamma)$.

Hyperparamètre $P = (P_\epsilon)_{\epsilon \in \{0,1\}^J}$

Loi de Dirichlet de vecteur-paramètre $(\alpha_{0\dots 0}, \dots, \alpha_{1\dots 1})^T$ définie sur le simplexe $\mathfrak{P} = \left\{ P; \sum_{\epsilon \in \{0,1\}^J} P_\epsilon = 1, P_\epsilon > 0 \right\}$:

$$f(P|\alpha) \sim \mathcal{D}_{2^J}(\alpha).$$

Vecteur d'hyperparamètres $\phi = (\gamma, P)$

En supposant l'indépendance des différents hyperparamètres, :

$$f(\Phi|\alpha) = \left(\prod_{\epsilon \in \{0,1\}^J} P_\epsilon^{\alpha_\epsilon - 1} \right) \frac{1}{\gamma} \mathbb{I}_{\mathbb{R}^+}(\gamma) \mathbb{I}_{\mathfrak{P}}(P).$$

Modèle Bayésien Hiérarchique

Loi a posteriori des instants de ruptures

Après intégration par rapport aux paramètres de nuisance P et λ_k :

$$f(r, \gamma | y) \propto \frac{C(r|y)}{\gamma} \left(\frac{\gamma^\nu}{\Gamma(\nu)} \right)^K \prod_{k=1}^K \frac{\Gamma(n_k(r) + \nu)}{(s_k(r) + \gamma)^{n_k(r) + \nu}},$$

avec

$$C(r|y) = \Gamma\left(\sum_{i=1}^{n-1} r_i + 1\right) \Gamma\left(n - \sum_{i=1}^{n-1} r_i\right),$$

où $\Gamma(t)$ est la fonction Gamma.

Une loi a posteriori trop complexe...

... pour obtenir une expression simple des estimateurs bayésiens.

☞ Simulation d'échantillons asymptotiquement distribués suivant $f(r, \gamma | y)$ à l'aide d'une **méthode MCMC**.

Echantillonneur de Gibbs pour la détection de rupture

Génération suivant $f(r|\gamma, y)$

$$P(r_i = \epsilon | r_{-i}, \gamma, y) \propto f(r_i(\epsilon), \gamma | y),$$

Génération suivant $f(\gamma|r, y)$

- Tirage d'échantillons suivant $f(\lambda|\gamma, r, y)$

$$\lambda_{j,k} | \gamma, r, y \sim \mathcal{G}(s_{j,k}(r) + \nu, n_{j,k}(r) + \gamma),$$

- Tirage d'échantillons suivant $f(\gamma|\lambda, r, y)$

$$\gamma | \lambda, r, y \sim \mathcal{G}\left(\nu \sum_{j=1}^J K_j, \sum_{j=1}^J \sum_{k=1}^{K_j} \lambda_{j,k}\right).$$

Mise à jour de P


$$f(P|r, y, \alpha) \sim \mathcal{D}_{2^J}(\alpha_\epsilon + S_\epsilon(r)).$$

Simulations : données synthétiques


Paramètres

- Paramètres du signal : $J = 2$, $n = 120$, $K = 4$, $h_1 = (20, 50, 100, 120)$, $h_2 = (50, 120)$, $\lambda_1 = (19, 9, 16, 6)$, $\lambda_2 = (8, 11)$,
- Algorithme : 200 itérations de chauffage, 800 itérations utilisées pour les estimations.

Segmentation non conjointe





Segmentation conjointe





Simulations : données synthétiques

Nombre de changements



Loi a posteriori de P



En accord avec les résultats théoriques...


Simulations : données réelles

Paramètres de simulation


4 bandes d'énergie : 25 – 60keV, 60 – 110keV, 110 – 325keV et > 325keV.

Algorithme : 200 itérations de chauffage, 3300 itérations d'intérêts.

Loi a posteriori des instants de ruptures



Reconstruction du signal



Conclusions

Travail réalisé

Une méthode de segmentation conjointe de données astrophysiques issues de multiples capteurs basée sur :

- le caractère poissonnien des données,
- l'introduction d'une corrélation *a priori* des instants de ruptures (approche **conjointe**),
- un modèle Bayésien Hiérarchique,
- l'utilisation d'un échantillonneur de Gibbs.

Perspectives

- Traitement de données astronomiques avec une autre mise en forme,
- Généralisation à d'autres types de signaux (vent, arc-tracking, bio-médical, ...).