

# Modélisation de signaux électromyographiques par des processus de renouvellement - Filtre bayésien pour l'estimation séquentielle de paramètres à destination de la commande d'une prothèse d'avant-bras

Jonathan Monsifrot

LUNAM - Équipe ADTSI et Robotique, IRCCyN UMR 6597

11/12/2013

## Rapporteurs

David Brie, Professeur, Université de Lorraine  
Emmanuel Duflos, Professeur, École Centrale de Lille

## Examineurs

Dario Farina, Professeur, Universitätsmedizin Göttingen  
David Guiraud, Directeur de Recherche INRIA, Université de Montpellier  
Yannick Aoustin, Maître de conférences (HDR), Université de Nantes  
Eric Le Carpentier, Maître de conférences, École Centrale de Nantes

## Membre invité

Antoine Nordez, Maître de conférences (HDR), Université de Nantes

**Objectif à long terme** Commande de prothèses par signaux électro-myographiques intra-musculaires (iEMG),  
*Collaboration avec le laboratoire de neuro-réhabilitation Bernstein Center for Computational Neurosciences;*

**Objectif de la thèse** Décomposition en ligne de signaux iEMG,  
*Suite de la thèse de Di GE consacrée à la décomposition hors-ligne;*

**Modèle des iEMG** Somme de trains d'impulsions indépendants (les unités motrices, MU),  
filtrés linéairement (chaque réponse impulsionnelle est un potentiel d'MU);

**Modélisation des trains** Processus de renouvellement;

**Estimation des paramètres du modèle** Filtrage bayésien approché;

**Validation** Simulation et signaux réels.

**Objectif à long terme** Commande de prothèses par signaux électro-myographiques intra-musculaires (iEMG),  
*Collaboration avec le laboratoire de neuro-réhabilitation Bernstein Center for Computational Neurosciences;*

**Objectif de la thèse** Décomposition en ligne de signaux iEMG,  
*Suite de la thèse de Di GE consacrée à la décomposition hors-ligne;*

**Modèle des iEMG** Somme de trains d'impulsions indépendants (les unités motrices, MU), filtrés linéairement (chaque réponse impulsionnelle est un potentiel d'MU);

**Modélisation des trains** Processus de renouvellement ;

**Estimation des paramètres du modèle** Filtrage bayésien approché ;

**Validation** Simulation et signaux réels.


- 1 Problématique
- 2 Modèle d'un train d'impulsions
- 3 Nombre d'unités motrices connu : modélisation et estimation
- 4 Nombre d'unités motrices inconnu : modélisation et estimation
- 5 Conclusion et perspectives

- 1 Problématique
- 2 Modèle d'un train d'impulsions
- 3 Nombre d'unités motrices connu : modélisation et estimation
- 4 Nombre d'unités motrices inconnu : modélisation et estimation
- 5 Conclusion et perspectives

- Objectif** Retrouver l'utilisation proportionnée et locale d'un muscle ;
- Divers protocoles**
- sEMG** ÉlectroMyoGramme de surface (sEMG) ou intramusculaire (iEMG) ;  
récupération du signal électrique des muscles de surface,  
signal interférentiel : action de chacun des muscles difficilement discernable ;
- iEMG** récupération du signal localement dans un muscle ;
- Postulat** les signaux iEMG seront plus à même de répondre à la problématique.
- Utilisations** comprendre le fonctionnement musculaire, aide à la réhabilitation, compression de données, pilotage de prothèse, etc.

- Objectif** Retrouver l'utilisation proportionnée et locale d'un muscle ;
- Divers protocoles**
- sEMG** ÉlectroMyoGramme de surface (sEMG) ou intramusculaire (iEMG) ;  
récupération du signal électrique des muscles de surface,  
signal interférentiel : action de chacun des muscles difficilement discernable ;
- iEMG** récupération du signal localement dans un muscle ;
- Postulat** les signaux iEMG seront plus à même de répondre à la problématique.
- Utilisations** comprendre le fonctionnement musculaire, aide à la réhabilitation, compression de données, **pilotage de prothèse**, etc.

# Signaux iEMG




## Caractéristiques

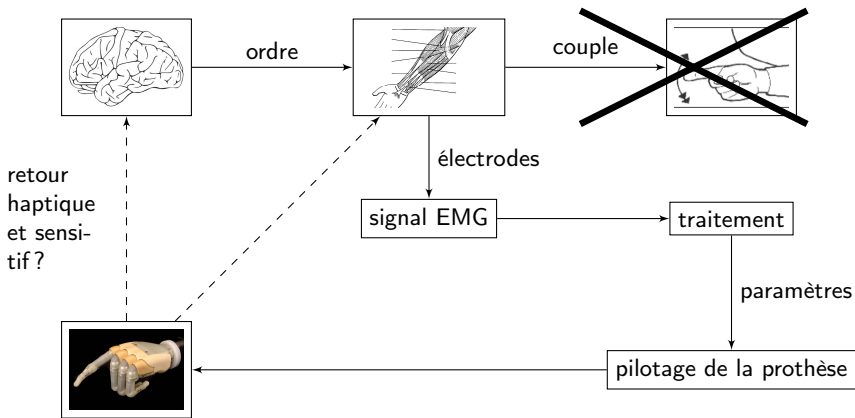
- diverses formes, chacune se répétant pour créer un train d'impulsions ;
- interférences entre les trains ;
- pas d'auto-interférence (contrainte physiologique : au moins une période réfractaire).



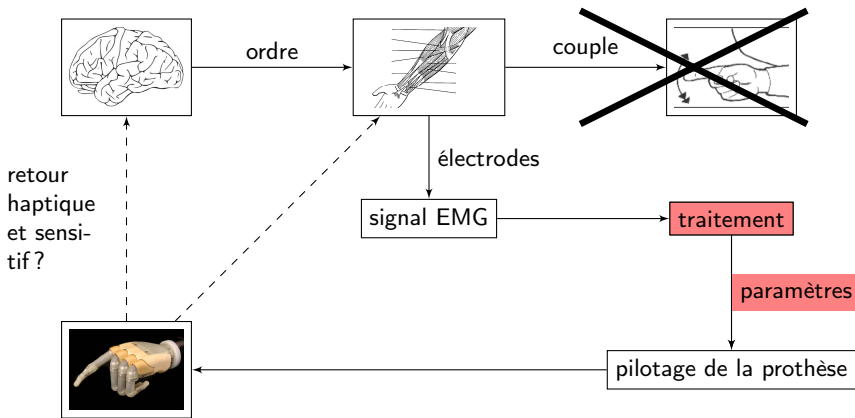
# Réalisation d'un mouvement



## Réalisation d'un mouvement




## Réalisation d'un mouvement



# Traitement classique

## Retrouver l'intention de l'utilisateur




**Cependant** Mouvement sur un seul degré de liberté et non proportionné ;

**Proposition** Nous cherchons le taux de contraction de chaque muscle

# Traitement classique

## Retrouver l'intention de l'utilisateur




**Cependant** Mouvement sur un seul degré de liberté et non proportionné ;

**Proposition** Nous cherchons le taux de contraction de chaque muscle


# Traitement classique

## Retrouver l'intention de l'utilisateur




## Cependant Proposition

Mouvement sur un seul degré de liberté et non proportionné ;  
 Nous cherchons le taux de contraction de chaque muscle



## Modélisation adoptée



### Modèle


Somme de  $n_{\text{mu}}$  trains d'impulsions  $(U_i)_{i \in \{1 \dots n_{\text{mu}}\}}$  convolués avec leur ondelette respective  $h_i$ ; l'observation est entachée d'un bruit additif [Farina 01] :

$$Y[n] = \sum_{i=1}^{n_{\text{mu}}} (h_i * U_i)[n] + W[n]$$

### Hypothèses

- $U_i$  sont des trains de 0-1 non-observables;
- $W$  est le bruit de mesure (gaussien, centré de variance  $\nu$ );  $W$  et  $U_i$  mutuellement indépendants;
- $h_i$  (filtre de longueur  $\ell_{ri}$ ) inconnus : potentiel de l'unité motrice liée à la source  $i$ ;
- $n_{\text{mu}}$  connu, puis inconnu.

## Modélisation adoptée



### Modèle

Somme de  $n_{\text{mu}}$  trains d'impulsions  $(U_i)_{i \in \{1 \dots n_{\text{mu}}\}}$  convolués avec leur ondelette respective  $h_i$ ; l'observation est entachée d'un bruit additif [Farina 01] :

$$Y[n] = \sum_{i=1}^{n_{\text{mu}}} (h_i * U_i)[n] + W[n]$$

### Hypothèses

- $U_i$  sont des trains de 0-1 non-observables;
- $W$  est le bruit de mesure (gaussien, centré de variance  $\nu$ );  $W$  et  $U_i$  mutuellement indépendants;
- $h_i$  (filtre de longueur  $\ell_{ri}$ ) inconnus : potentiel de l'unité motrice liée à la source  $i$ ;
- $n_{\text{mu}}$  connu, puis inconnu.



- 1 Problématique
- 2 Modèle d'un train d'impulsions**
- 3 Nombre d'unités motrices connu : modélisation et estimation
- 4 Nombre d'unités motrices inconnu : modélisation et estimation
- 5 Conclusion et perspectives


## Processus associés

## Variables

$U[n]$ , la valeur du train à l'instant  $n$  ;  
 $\Delta[N]$  le  $N$ -ième temps inter-impulsion ( $N \in \mathbb{Z}$ ) ;  
 $T[n]$  le temps de séjour à l'instant  $n$  ;

## Relation

$$T[n] = \begin{cases} T[n-1] + 1 & \text{si } U[n] = 0 \\ 0 & \text{si } U[n] = 1 \end{cases}$$



**Temps inter-impulsion** séquence indépendante et identiquement distribuée et de masse de probabilité  $\Pr(\Delta[N] = t), t \geq 1$ .


## Processus associés

## Variables

$U[n]$ , la valeur du train à l'instant  $n$  ;  
 $\Delta[N]$  le  $N$ -ième temps inter-impulsion ( $N \in \mathbb{Z}$ ) ;  
 $T[n]$  le temps de séjour à l'instant  $n$  ;

## Relation

$$T[n] = \begin{cases} T[n-1] + 1 & \text{si } U[n] = 0 \\ 0 & \text{si } U[n] = 1 \end{cases}$$



**Temps inter-impulsion** séquence indépendante et identiquement distribuée et de masse de probabilité  $\Pr(\Delta[N] = t), t \geq 1$ .

## Représentation de la masse de probabilité

**Fonction de fiabilité**  $s(t)$ , probabilité qu'un nouvel événement ne se soit pas produit jusqu'à l'instant discret  $t - 1$  :

$$s(t) = \sum_{\tau=t}^{+\infty} \Pr(\Delta[N]=\tau)$$

**Taux de hasard**  $r(t)$ , probabilité qu'un événement survienne à l'instant  $t$  sachant qu'il n'y en a pas eu jusqu'à  $t - 1$  :

$$r(t) = \Pr(\Delta[N]=t \mid \Delta[N] \geq t) = \frac{\Pr(\Delta[N]=t)}{s(t)}$$

# Propriétés du processus des temps de séjours $T$

**Notation**  $T^n$  signifie  $[T[1], \dots, T[n]]$

**$T$  markovien**<sup>1</sup>  $\Pr(T[n+1]=t | T^n) = \Pr(T[n+1]=t | T[n])$

**Loi de transition**

$$\Pr(T[n+1]=t | T[n]) = \begin{cases} r(T[n]+1) & \text{si } t=0 \\ 1 - r(T[n]+1) & \text{si } t=T[n]+1 \\ 0 & \text{sinon} \end{cases} \quad (1)$$

**Distribution invariante**  $\Pr(T[n]=t) = s(t+1)/E\{\Delta[N]\}$

**Nombre moyen d'impulsions par échantillon**  $1/E\{\Delta[N]\}$

---

1. J. Monsifrot, E. Le Carpentier, Y. Aoustin & D. Farina. *Sequential Decoding of Intramuscular EMG Signals via Estimation of a Markov Model*. IEEE Trans. on Neural Systems Rehabilitation Engineering, vol. Submitted, 2013.

# Propriétés du processus des temps de séjours $T$

**Notation**  $T^n$  signifie  $[T[1], \dots, T[n]]$

**T markovien**<sup>1</sup>  $\Pr(T[n+1]=t | T^n) = \Pr(T[n+1]=t | T[n])$

**Loi de transition**

$$\Pr(T[n+1]=t | T[n]) = \begin{cases} r(T[n]+1) & \text{si } t=0 \\ 1 - r(T[n]+1) & \text{si } t=T[n]+1 \\ 0 & \text{sinon} \end{cases} \quad (1)$$

**Distribution invariante**  $\Pr(T[n]=t) = s(t+1)/E\{\Delta[N]\}$

**Nombre moyen d'impulsions par échantillon**  $1/E\{\Delta[N]\}$

---

1. J. Monsifrot, E. Le Carpentier, Y. Aoustin & D. Farina. *Sequential Decoding of Intramuscular EMG Signals via Estimation of a Markov Model*. IEEE Trans. on Neural Systems Rehabilitation Engineering, vol. Submitted, 2013.

# Propriétés du processus des temps de séjours $T$

**Notation**  $T^n$  signifie  $[T[1], \dots, T[n]]$

**T markovien**<sup>1</sup>  $\Pr(T[n+1]=t | T^n) = \Pr(T[n+1]=t | T[n])$

**Loi de transition**

$$\Pr(T[n+1]=t | T[n]) = \begin{cases} r(T[n]+1) & \text{si } t=0 \\ 1 - r(T[n]+1) & \text{si } t=T[n]+1 \\ 0 & \text{sinon} \end{cases} \quad (1)$$

**Distribution invariante**  $\Pr(T[n]=t) = s(t+1)/E\{\Delta[N]\}$

Nombre moyen d'impulsions par échantillon  $1/E\{\Delta[N]\}$

---

1. J. Monsifrot, E. Le Carpentier, Y. Aoustin & D. Farina. *Sequential Decoding of Intramuscular EMG Signals via Estimation of a Markov Model*. IEEE Trans. on Neural Systems Rehabilitation Engineering, vol. Submitted, 2013.

# Propriétés du processus des temps de séjours $T$

**Notation**  $T^n$  signifie  $[T[1], \dots, T[n]]$

**T markovien**<sup>1</sup>  $\Pr(T[n+1]=t | T^n) = \Pr(T[n+1]=t | T[n])$

**Loi de transition**

$$\Pr(T[n+1]=t | T[n]) = \begin{cases} r(T[n]+1) & \text{si } t=0 \\ 1 - r(T[n]+1) & \text{si } t=T[n]+1 \\ 0 & \text{sinon} \end{cases} \quad (1)$$

**Distribution invariante**  $\Pr(T[n]=t) = s(t+1)/E\{\Delta[N]\}$


**Nombre moyen d'impulsions par échantillon**  $1/E\{\Delta[N]\}$

---

1. J. Monsifrot, E. Le Carpentier, Y. Aoustin & D. Farina. *Sequential Decoding of Intramuscular EMG Signals via Estimation of a Markov Model*. IEEE Trans. on Neural Systems Rehabilitation Engineering, vol. Submitted, 2013.



# Modélisation des temps inter-impulsion $\Delta$



## Etude

Histogramme des temps inter-impulsion d'un signal iEMG traité par un expert ;

### Proposition 1

Temps inter-impulsion suivent une loi exponentielle [Monsifrot 11] ;<sup>2</sup>


### Proposition 2

Temps inter-impulsion suivent une loi de Weibull discrète de type I [Nakagawa 75] [Monsifrot 13c]<sup>3</sup>.

2. J. Monsifrot, E. Le Carpentier, D. Farina & Y. Aoustin. *Sequential estimation of intramuscular EMG model parameters for prosthesis control*. In IEEE/RSJ Int. Conf. on Intelligent Robots and Systems, Workshop on Robotics for Neurology and Rehabilitation, San Francisco, Ca, 2011.

3. Jonathan Monsifrot, Éric Le Carpentier, Yannick Aoustin & Dario Farina. *Online estimation of EMG signals model based on a renewal process*. In ICASSP, IEEE Int. Conf. on Acoustics, Speech and Signal Processing, Vancouver, Canada, 2013.

# Modélisation des temps inter-impulsion $\Delta$



## Etude

Histogramme des temps inter-impulsion d'un signal iEMG traité par un expert ;

## Proposition 1

Temps inter-impulsion suivent une loi exponentielle [Monsifrot 11] ;<sup>2</sup>


## Proposition 2

Temps inter-impulsion suivent une loi de Weibull discrète de type I [Nakagawa 75] [Monsifrot 13c]<sup>3</sup>.

2. J. Monsifrot, E. Le Carpentier, D. Farina & Y. Aoustin. *Sequential estimation of intramuscular EMG model parameters for prosthesis control*. In IEEE/RSJ Int. Conf. on Intelligent Robots and Systems, Workshop on Robotics for Neurology and Rehabilitation, San Francisco, Ca, 2011.

3. Jonathan Monsifrot, Éric Le Carpentier, Yannick Aoustin & Dario Farina. *Online estimation of EMG signals model based on a renewal process*. In ICASSP, IEEE Int. Conf. on Acoustics, Speech and Signal Processing, Vancouver, Canada, 2013.

# Modélisation des temps inter-impulsion $\Delta$



**Etude** Histogramme des temps inter-impulsion d'un signal iEMG traité par un expert ;


**Proposition 1** Temps inter-impulsion suivent une loi exponentielle [Monsifrot 11] ;<sup>2</sup>

**Proposition 2** Temps inter-impulsion suivent une loi de Weibull discrète de type I [Nakagawa 75] [Monsifrot 13c]<sup>3</sup>.

2. J. Monsifrot, E. Le Carpentier, D. Farina & Y. Aoustin. *Sequential estimation of intramuscular EMG model parameters for prosthesis control*. In IEEE/RSJ Int. Conf. on Intelligent Robots and Systems, Workshop on Robotics for Neurology and Rehabilitation, San Francisco, Ca, 2011.

3. Jonathan Monsifrot, Éric Le Carpentier, Yannick Aoustin & Dario Farina. *Online estimation of EMG signals model based on a renewal process*. In ICASSP, IEEE Int. Conf. on Acoustics, Speech and Signal Processing, Vancouver, Canada, 2013.

# Loi de Weibull discrète de type I à trois paramètres ( $t_0, \beta, t_r$ )



**Masse**

$$\Pr(\Delta[M] = t | \Theta) = \exp \left[ - \left( \frac{t-1-t_r}{t_0-t_r} \right)^\beta \right] - \exp \left[ - \left( \frac{t-t_r}{t_0-t_r} \right)^\beta \right]$$

**Taux de hasard**


$$r(t, \Theta) = 1 - \exp \left[ \left( \frac{t-1-t_r}{t_0-t_r} \right)^\beta - \left( \frac{t-t_r}{t_0-t_r} \right)^\beta \right]$$

**Espérance**

Seulement un encadrement (démonstré dans le manuscrit)

$$(t_0 - t_r) \Gamma \left( 1 + \frac{1}{\beta} \right) + t_r \leq E\{\Delta[M] | \Theta\} \leq (t_0 - t_r) \Gamma \left( 1 + \frac{1}{\beta} \right) + t_r + 1$$

# Loi de Weibull discrète de type I à trois paramètres ( $t_0, \beta, t_r$ )



**Masse**

$$\Pr(\Delta[M]=t|\Theta) = \exp \left[ - \left( \frac{t-1-t_r}{t_0-t_r} \right)^\beta \right] - \exp \left[ - \left( \frac{t-t_r}{t_0-t_r} \right)^\beta \right]$$

**Taux de hasard**


$$r(t, \Theta) = 1 - \exp \left[ \left( \frac{t-1-t_r}{t_0-t_r} \right)^\beta - \left( \frac{t-t_r}{t_0-t_r} \right)^\beta \right]$$

**Espérance**

Seulement un encadrement (démonstré dans le manuscrit)

$$(t_0 - t_r) \Gamma \left( 1 + \frac{1}{\beta} \right) + t_r \leq E\{\Delta[M]|\Theta\} \leq (t_0 - t_r) \Gamma \left( 1 + \frac{1}{\beta} \right) + t_r + 1$$

# Loi de Weibull discrète de type I à trois paramètres ( $t_0, \beta, t_r$ )



**Masse**

$$\Pr(\Delta[M]=t|\Theta) = \exp\left[-\left(\frac{t-1-t_r}{t_0-t_r}\right)^\beta\right] - \exp\left[-\left(\frac{t-t_r}{t_0-t_r}\right)^\beta\right]$$

**Taux de hasard**


$$r(t, \Theta) = 1 - \exp\left[\left(\frac{t-1-t_r}{t_0-t_r}\right)^\beta - \left(\frac{t-t_r}{t_0-t_r}\right)^\beta\right]$$

**Espérance**

Seulement un encadrement (démonstré dans le manuscrit)

$$(t_0 - t_r)\Gamma\left(1 + \frac{1}{\beta}\right) + t_r \leq E\{\Delta[M]|\Theta\} \leq (t_0 - t_r)\Gamma\left(1 + \frac{1}{\beta}\right) + t_r + 1$$

# Loi de Weibull discrète de type I à trois paramètres ( $t_0, \beta, t_r$ )



**Masse**

$$\Pr(\Delta[M] = t | \Theta) = \exp \left[ - \left( \frac{t-1-t_r}{t_0-t_r} \right)^\beta \right] - \exp \left[ - \left( \frac{t-t_r}{t_0-t_r} \right)^\beta \right]$$

**Taux de hasard**


$$r(t, \Theta) = 1 - \exp \left[ \left( \frac{t-1-t_r}{t_0-t_r} \right)^\beta - \left( \frac{t-t_r}{t_0-t_r} \right)^\beta \right]$$

**Espérance**

Seulement un encadrement (démonstré dans le manuscrit)

$$(t_0 - t_r) \Gamma \left( 1 + \frac{1}{\beta} \right) + t_r \leq E\{\Delta[M] | \Theta\} \leq (t_0 - t_r) \Gamma \left( 1 + \frac{1}{\beta} \right) + t_r + 1$$

# Loi de Weibull discrète de type I à trois paramètres ( $t_0, \beta, t_r$ )



**Masse**

$$\Pr(\Delta[M] = t | \Theta) = \exp \left[ - \left( \frac{t-1-t_r}{t_0-t_r} \right)^\beta \right] - \exp \left[ - \left( \frac{t-t_r}{t_0-t_r} \right)^\beta \right]$$

**Taux de hasard**

$$r(t, \Theta) = 1 - \exp \left[ \left( \frac{t-1-t_r}{t_0-t_r} \right)^\beta - \left( \frac{t-t_r}{t_0-t_r} \right)^\beta \right]$$


**Espérance**

Seulement un encadrement (démonstré dans le manuscrit)

$$(t_0 - t_r) \Gamma \left( 1 + \frac{1}{\beta} \right) + t_r \leq E\{\Delta[M] | \Theta\} \leq (t_0 - t_r) \Gamma \left( 1 + \frac{1}{\beta} \right) + t_r + 1$$



# Loi de Weibull discrète de type I à trois paramètres ( $t_0, \beta, t_r$ )



**Masse**

$$\Pr(\Delta[M]=t|\Theta) = \exp\left[-\left(\frac{t-1-t_r}{t_0-t_r}\right)^\beta\right] - \exp\left[-\left(\frac{t-t_r}{t_0-t_r}\right)^\beta\right]$$

**Taux de hasard**


$$r(t, \Theta) = 1 - \exp\left[\left(\frac{t-1-t_r}{t_0-t_r}\right)^\beta - \left(\frac{t-t_r}{t_0-t_r}\right)^\beta\right]$$

**Espérance**

Seulement un encadrement (démonstré dans le manuscrit)

$$(t_0 - t_r)\Gamma\left(1 + \frac{1}{\beta}\right) + t_r \leq E\{\Delta[M]|\Theta\} \leq (t_0 - t_r)\Gamma\left(1 + \frac{1}{\beta}\right) + t_r + 1$$

# Loi de Weibull discrète de type I à trois paramètres ( $t_0, \beta, t_r$ )



**Masse**

$$\Pr(\Delta[M] = t | \Theta) = \exp \left[ - \left( \frac{t-1-t_r}{t_0-t_r} \right)^\beta \right] - \exp \left[ - \left( \frac{t-t_r}{t_0-t_r} \right)^\beta \right]$$

**Taux de hasard**

$$r(t, \Theta) = 1 - \exp \left[ \left( \frac{t-1-t_r}{t_0-t_r} \right)^\beta - \left( \frac{t-t_r}{t_0-t_r} \right)^\beta \right]$$

**Espérance**

Seulement un encadrement (démonstré dans le manuscrit)

$$(t_0 - t_r) \Gamma \left( 1 + \frac{1}{\beta} \right) + t_r \leq E\{\Delta[M] | \Theta\} \leq (t_0 - t_r) \Gamma \left( 1 + \frac{1}{\beta} \right) + t_r + 1$$

## Estimation hors-ligne des paramètres : critère

**Estimation par maximum de vraisemblance** Pour une trajectoire  $t^n$  connue,  $\theta$  étant les paramètres de la loi [Monsifrot 13b]<sup>4</sup>

$$\hat{\theta}_{t^n} = \arg \min_{\theta} \underbrace{-\frac{1}{n} \ln \Pr(T^n = t^n | \Theta = \theta)}_{J_{t^n}(\theta)}$$

**Notation**

$$J_{t^1}(\theta) = - \ln \underbrace{\Pr(T[1] = t[1] | \Theta = \theta)}_{\text{loi initiale}}$$

$$Q_{t^n}(\theta) = - \ln \underbrace{\Pr(T[n] = t[n] | \Theta = \theta, T[n-1] = t[n-1])}_{\text{loi de transition}}$$

**Critère**

$$\begin{aligned} J_{t^n}(\theta) &= \frac{1}{n} J_{t^1}(\theta) + \frac{1}{n} \sum_{k=2}^n Q_{t^k}(\theta) \\ &= \frac{1}{n} Q_{t^n}(\theta) + \left(1 - \frac{1}{n}\right) J_{t^{n-1}}(\theta) \end{aligned}$$

4. J. Monsifrot, É. Le Carpentier & Y. Aoustin. Modélisation de trains d'impulsions à l'aide d'une loi de Weibull discrète. Estimation hors-ligne et séquentielle des paramètres. In 24e colloque GRETSI sur le traitement du signal et des images, Brest, France, September 2013.

## Estimation hors-ligne des paramètres : optimisation

**Méthode de Quasi-Newton** Itérative (récurrence sur  $i$ )

$$\hat{\theta}_{t^n}^i = \hat{\theta}_{t^n}^{i-1} - \gamma_i \left[ \tilde{J}_{t^n}'' \left( \hat{\theta}_{t^n}^{i-1} \right) \right]^{-1} J_{t^n}' \left( \hat{\theta}_{t^n}^{i-1} \right)$$

**Gradient exact et approximation de la matrice hessienne** Pour tout  $i$ , récurrence sur  $n$


$$J_{t^n}'(\theta) = \frac{1}{n} Q_{t^n}'(\theta) + \left(1 - \frac{1}{n}\right) J_{t^{n-1}}'(\theta)$$

$$\tilde{J}_{t^n}''(\theta) = \frac{1}{n} [Q_{t^n}'(\theta)] [Q_{t^n}'(\theta)]^\top + \left(1 - \frac{1}{n}\right) \tilde{J}_{t^{n-1}}''(\theta)$$

**Justification** Comparaison avec la matrice d'information de Fisher

## Estimation hors-ligne des paramètres : exemple

Loi de Weibull discrète :  $\theta = [t_0, \beta]$ , la période réfractaire  $t_r$  étant supposée connue. Le gradient se calcule simplement.



Ici  $t_0 = 450$ ,  $\beta = 5$  et  $t_r = 100$

## Estimation en ligne des paramètres : algorithme

### Principe

Adaptation de la méthode hors-ligne.

Les récurrences sur  $i$  et  $n$  sont confondues [Ljung 85][Monsifrot 13a]

$$\hat{\theta}_{t^n} = \hat{\theta}_{t^{n-1}} - \frac{1}{n} \mathbf{G}_{t^n}^{-1} Q'_{t^n}(\hat{\theta}_{t^{n-1}})$$

où

$$\mathbf{G}_{t^n} \approx \tilde{J}_{t^n}''(\hat{\theta}_{t^{n-1}})$$

suit la récurrence

$$\mathbf{G}_{t^n} = \frac{1}{n} \left[ Q'_{t^n}(\hat{\theta}_{t^{n-1}}) \right] \left[ Q'_{t^n}(\hat{\theta}_{t^{n-1}}) \right]^T + \left( 1 - \frac{1}{n} \right) \mathbf{G}_{t^{n-1}}$$

**Cas particulier : loi de Weibull avec  $\beta = 1$**  (loi exponentielle décalée)


$\hat{t}_0$  a une formule explicite.


**Application à l'initialisation dans le cas de la loi de Weibull**

$\hat{\beta}$  figé à 1 jusqu'à la deuxième impulsion ;

Mais la récurrence sur  $\mathbf{G}_{t^n}$  est conservée.

Estimation en ligne des paramètres : exemple  $\hat{\theta}_{t^n} = [\hat{t}_{0,t^n}, \hat{\beta}_{t^n}]$



Estimation en ligne des paramètres : exemple  $E\{U[n]|\Theta = \hat{\theta}_{t,n}\}$ 




- 1 Problématique
- 2 Modèle d'un train d'impulsions
- 3 Nombre d'unités motrices connu : modélisation et estimation**
  - Système, état et modèle de Markov caché
  - Filtrage bayésien
  - Simulation et expérimentation
- 4 Nombre d'unités motrices inconnu : modélisation et estimation
- 5 Conclusion et perspectives

- 1 Problématique
- 2 Modèle d'un train d'impulsions
- 3 **Nombre d'unités motrices connu : modélisation et estimation**
  - **Système, état et modèle de Markov caché**
  - Filtrage bayésien
  - Simulation et expérimentation
- 4 Nombre d'unités motrices inconnu : modélisation et estimation
- 5 Conclusion et perspectives

Système, état et modèle de Markov caché

## Rappel du modèle



## Modèle

$$Y[n] = \sum_{i=1}^{n_{mu}} (h_i * U_i)[n] + W[n]$$

## État et hypothèse

## État

$\mathbf{T}$  les temps de séjours concaténés ( $\mathbf{T}[n] = [T_i[n]]_{i \in \{1 \dots n_{\text{mu}}\}}$ );

$\Theta$  les paramètres des lois de Weibull discrètes concaténés  
 ( $\Theta_i = \{t_{0,i}, \beta_i\}$ );

$\mathbf{H}$  les coefficients des ondelettes concaténés ( $\mathbf{H} = [\mathbf{H}_1^\top \dots \mathbf{H}_{n_{\text{mu}}}^\top]^\top$ ).

## Hypothèses

$n_{\text{mu}}$  connu et fini;

pour chaque source :

- $\Delta_i^n$  suit une loi de Weibull discrète (**instants d'impulsions inconnus**),
- convolution de  $U_i^n$  par une ondelette  $h_i$  de longueur  $\ell_{i1}$ ;

$Y$  noyé dans un bruit blanc  $W$  gaussien (de variance  $v$  inconnue);

$T_1, \dots, T_{n_{\text{mu}}}$  et  $W$  supposés mutuellement indépendants;

$\mathbf{T}$  suit le modèle présenté auparavant.

**État**  $\mathbf{T}[n], \Theta, H;$

**Modèle markovien**

- loi de transition de l'état :

$$\begin{cases} \Theta, H \text{ constants} \\ \forall i, \Pr(T_i[n+1] | T_i[n], \Theta_i) \text{ donné section précédente} \end{cases}$$

- loi d'observation :  $Y[n] = \underbrace{[\varphi(T_1[n]) \dots \varphi(T_{n_{\text{mu}}}[n])]}_{\psi(\mathbf{T}[n])} H + W[n]$

**Exemple**

$$\psi \left( \begin{bmatrix} 0 \\ 3 \end{bmatrix} \right) = [ \varphi(0) \quad \varphi(3) ] = [ \underbrace{1 \quad 0 \quad 0 \quad 0 \quad 0 \quad 0 \quad 0 \quad 0 \quad 0 \quad 1 \quad 0}_{\varphi(0)} \quad \underbrace{\phantom{1 \quad 0 \quad 0 \quad 0 \quad 0 \quad 0 \quad 0 \quad 0 \quad 1 \quad 0}}_{\varphi(3)} ]$$

**État**  $\mathbf{T}[n], \Theta, H;$

**Modèle markovien**

- loi de transition de l'état :

$$\begin{cases} \Theta, H \text{ constants} \\ \forall i, \Pr(T_i[n+1] | T_i[n], \Theta_i) \text{ donné section précédente} \end{cases}$$

- loi d'observation :  $Y[n] = \underbrace{[\varphi(T_1[n]) \dots \varphi(T_{n_{\text{mu}}}[n])]}_{\psi(\mathbf{T}[n])} H + W[n]$

**Exemple**

$$\psi \left( \begin{bmatrix} 0 \\ 3 \end{bmatrix} \right) = [ \varphi(0) \quad \varphi(3) ] = \underbrace{[ 1 \quad 0 \quad 0 \quad 0 \quad 0 ]}_{\varphi(0)} \underbrace{[ 0 \quad 0 \quad 0 \quad 1 \quad 0 ]}_{\varphi(3)}$$

- 1 Problématique
- 2 Modèle d'un train d'impulsions
- 3 Nombre d'unités motrices connu : modélisation et estimation**
  - Système, état et modèle de Markov caché
  - Filtrage bayésien**
  - Simulation et expérimentation
- 4 Nombre d'unités motrices inconnu : modélisation et estimation
- 5 Conclusion et perspectives

**Principe** Calculer la loi de  $\mathbf{T}^n, \Theta, H$  connaissant  $Y^n$  (loi *a posteriori*) à partir d'un prior sur l'état  $\mathbf{T}^0, \Theta, H$  et du modèle.

**Decomposition de la loi de probabilité *a posteriori***

- densité  $p_{\Theta|\mathbf{T}^n, H, Y^n}$
- densité  $p_{H|\mathbf{T}^n, Y^n}$ ;
- masse  $\Pr(\mathbf{T}^n = \mathbf{t}^n | Y^n)$ .



**Principe** Calculer la loi de  $\mathbf{T}^n, \Theta, H$  connaissant  $Y^n$  (loi *a posteriori*) à partir d'un prior sur l'état  $\mathbf{T}^0, \Theta, H$  et du modèle.

**Decomposition de la loi de probabilité *a posteriori***

- densité  $p_{\Theta|\mathbf{T}^n, H, Y^n}$
- densité  $p_{H|\mathbf{T}^n, Y^n}$  ;
- masse  $\Pr(\mathbf{T}^n = \mathbf{t}^n | Y^n)$ .

**Principe** Calculer la loi de  $\mathbf{T}^n, \Theta, H$  connaissant  $Y^n$  (loi *a posteriori*) à partir d'un prior sur l'état  $\mathbf{T}^0, \Theta, H$  et du modèle.

**Decomposition de la loi de probabilité *a posteriori***

- densité  $p_{\Theta|\mathbf{T}^n, H, Y^n} = \prod_{i=1}^{n_{mu}} p_{\Theta_i|\mathbf{T}_i^n}$ ;
- densité  $p_{H|\mathbf{T}^n, Y^n}$ ;
- masse  $\Pr(\mathbf{T}^n = \mathbf{t}^n | Y^n)$ .

## Filtrage bayésien

**Principe** Calculer la loi de  $\mathbf{T}^n, \Theta, H$  connaissant  $Y^n$  (loi *a posteriori*) à partir d'un prior sur l'état  $\mathbf{T}^0, \Theta, H$  et du modèle.

**Decomposition de la loi de probabilité *a posteriori***

- densité  $p_{\Theta|\mathbf{T}^n, H, Y^n} = \prod_{i=1}^{n_{mu}} p_{\Theta_i|\mathbf{T}_i^n}$ ;
- densité  $p_{H|\mathbf{T}^n, Y^n}$ ;
- masse  $\Pr(\mathbf{T}^n = \mathbf{t}^n | Y^n)$ .

Problème

Explosion combinatoire du nombre de trajectoires  $\mathbf{T}^n$  à investiguer ;

Stratégie

Seules les  $n_c$  plus probables *a posteriori* sont retenues ( $n_c$  paramètre de la méthode) [Monsifrot 13a].

## Filtrage bayésien

**Principe** Calculer la loi de  $\mathbf{T}^n, \Theta, H$  connaissant  $Y^n$  (loi *a posteriori*) à partir d'un prior sur l'état  $\mathbf{T}^0, \Theta, H$  et du modèle.

**Decomposition de la loi de probabilité *a posteriori***

- densité  $p_{\Theta|\mathbf{T}^n, H, Y^n} = \prod_{i=1}^{n_{mu}} p_{\Theta_i|\mathbf{T}_i^n}$ ;
- densité  $p_{H|\mathbf{T}^n, Y^n}$  ;
- masse  $\Pr(\mathbf{T}^n = \mathbf{t}^n | Y^n)$ .

**Problème** Explosion combinatoire du nombre de trajectoires  $\mathbf{T}^n$  à investiguer ;

**Stratégie** Seules les  $n_s$  plus probables *a posteriori* sont retenues ( $n_s$  paramètre de la méthode) [Monsifrot 13a].

**Notation**  $|\cdot|^n$  signifiera « connaissant  $Y^n$  ».

## Filtrage bayésien

**Principe** Calculer la loi de  $\mathbf{T}^n, \Theta, H$  connaissant  $Y^n$  (loi *a posteriori*) à partir d'un prior sur l'état  $\mathbf{T}^0, \Theta, H$  et du modèle.

**Decomposition de la loi de probabilité *a posteriori***

- densité  $p_{\Theta|\mathbf{T}^n, H, Y^n} = \prod_{i=1}^{n_{mu}} p_{\Theta_i|\mathbf{T}_i^n}$ ;
- densité  $p_{H|\mathbf{T}^n, Y^n}$  ;
- masse  $\Pr(\mathbf{T}^n = \mathbf{t}^n | Y^n)$ .

**Problème** Explosion combinatoire du nombre de trajectoires  $\mathbf{T}^n$  à investiguer ;

**Stratégie** Seules les  $n_s$  plus probables *a posteriori* sont retenues ( $n_s$  paramètre de la méthode) [Monsifrot 13a].

**Notation**  $|\cdot|^n$  signifiera « connaissant  $Y^n$  ».

## Filtrage bayésien

**Principe** Calculer la loi de  $\mathbf{T}^n, \Theta, H$  connaissant  $Y^n$  (loi *a posteriori*) à partir d'un prior sur l'état  $\mathbf{T}^0, \Theta, H$  et du modèle.

**Decomposition de la loi de probabilité *a posteriori***

- densité  $p_{\Theta|\mathbf{T}^n, H, Y^n} = \prod_{i=1}^{n_{mu}} p_{\Theta_i|\mathbf{T}_i^n}$ ;
- densité  $p_{H|\mathbf{T}^n, Y^n}$  ;
- masse  $\Pr(\mathbf{T}^n = \mathbf{t}^n | Y^n)$ .

**Problème** Explosion combinatoire du nombre de trajectoires  $\mathbf{T}^n$  à investiguer ;

**Stratégie** Seules les  $n_s$  plus probables *a posteriori* sont retenues ( $n_s$  paramètre de la méthode) [Monsifrot 13a].

**Notation**  $|\cdot|^n$  signifiera « connaissant  $Y^n$  ».

Loi de  $H|T^n, Y^n$ 

**Principe**  $T^n$  étant fixé à  $t^n$ , le modèle est linéaire gaussien ;

**Conséquence** la loi de  $H|T^n = t^n, Y^n$  est gaussienne de moyenne et variance fournies par le filtre de Kalman ;

**En outre** le filtre de Kalman fournit :

- la prédiction de  $Y[n]$  connaissant le passé :  $\hat{Y}_t^n|^{n-1}$ ,
- sa variance  $\nu_t^n$  (variance de l'innovation).

**Problème** Pas de formulation explicite.

**Solution approchée**

Nous utiliserons plus loin l'estimateur du maximum de vraisemblance récursif obtenu à la section précédente ;

La loi de  $\Theta_i | T_i^n = t_i^n$  est considérée comme concentrée autour de  $\hat{\theta}_{T_i^n}$ .

**Approximation** Pour toute fonction  $\phi : E\{\phi(\Theta_i) | T_i^n = t_i^n\} \approx \phi(\hat{\theta}_{T_i^n})$ .



Probabilité de  $\mathbf{T}^n | Y^n$ 

## Mise à jour

$\Pr^n(\mathbf{T}^n = \mathbf{t}^n) \propto \Pr^{n-1}(\mathbf{T}^n = \mathbf{t}^n) g(Y[n] - \hat{Y}_{\mathbf{t}^n}^{n-1}, \nu_{\mathbf{t}^n})$   
 où  $g(\cdot, \nu)$  densité gaussienne centrée de variance  $\nu$ ;

## Prédiction

Fait intervenir le taux de hasard  $r(t, \theta)$

$$\Pr^n(\mathbf{T}^{n+1} = \mathbf{t}^{n+1}) = \Pr^n(\mathbf{T}^n = \mathbf{t}^n) \times \prod_{i=1}^{n_{\text{mu}}} \begin{cases} \mathbb{E}\{r(t_i[n] + 1, \Theta_i) | T_i^n = t_i^n\} & \text{si } t_i[n + 1] = 0 \\ 1 - \mathbb{E}\{r(t_i[n] + 1, \Theta_i) | T_i^n = t_i^n\} & \text{si } t_i[n + 1] = t_i[n] + 1 \\ 0 & \text{sinon} \end{cases}$$

## Prédiction approchée

$$\Pr^n(\mathbf{T}^{n+1} = \mathbf{t}^{n+1}) \approx \Pr^n(\mathbf{T}^n = \mathbf{t}^n) \times \prod_{i=1}^{n_{\text{mu}}} \begin{cases} r(t_i[n] + 1, \hat{\theta}_{t_i^n}^n) & \text{si } t_i[n + 1] = 0 \\ 1 - r(t_i[n] + 1, \hat{\theta}_{t_i^n}^n) & \text{si } t_i[n + 1] = t_i[n] + 1 \\ 0 & \text{sinon} \end{cases}$$

# Probabilité de $\mathbf{T}^n | \mathbf{Y}^n$

## Mise à jour

$\Pr^n(\mathbf{T}^n = \mathbf{t}^n) \propto \Pr^{n-1}(\mathbf{T}^n = \mathbf{t}^n) g(Y[n] - \widehat{Y}_{\mathbf{t}^n}^{n-1}, \nu_{\mathbf{t}^n})$   
 où  $g(\cdot, \nu)$  densité gaussienne centrée de variance  $\nu$ ;

## Prédiction

Fait intervenir le taux de hasard  $r(t, \theta)$

$$\Pr^n(\mathbf{T}^{n+1} = \mathbf{t}^{n+1}) = \Pr^n(\mathbf{T}^n = \mathbf{t}^n) \times \prod_{i=1}^{n_{\text{mu}}} \begin{cases} \mathbb{E}\{r(t_i[n] + 1, \Theta_i) | T_i^n = t_i^n\} & \text{si } t_i[n + 1] = 0 \\ 1 - \mathbb{E}\{r(t_i[n] + 1, \Theta_i) | T_i^n = t_i^n\} & \text{si } t_i[n + 1] = t_i[n] + 1 \\ 0 & \text{sinon} \end{cases}$$

## Prédiction approchée

$$\Pr^n(\mathbf{T}^{n+1} = \mathbf{t}^{n+1}) \approx \Pr^n(\mathbf{T}^n = \mathbf{t}^n) \times \prod_{i=1}^{n_{\text{mu}}} \begin{cases} r(t_i[n] + 1, \widehat{\theta}_{t_i^n}^n) & \text{si } t_i[n + 1] = 0 \\ 1 - r(t_i[n] + 1, \widehat{\theta}_{t_i^n}^n) & \text{si } t_i[n + 1] = t_i[n] + 1 \\ 0 & \text{sinon} \end{cases}$$

## Estimateurs bayésiens

**Espérance *a posteriori* pour  $H$**  moyenne pondérée par les probabilités :

$$\hat{H}^{|n} = \sum_{\mathbf{t}^n} \underbrace{E^{|n}\{H|\mathbf{T}^n=\mathbf{t}^n\}}_{\hat{H}_{\mathbf{t}^n}^{|n}} \Pr^{|n}(\mathbf{T}^n=\mathbf{t}^n)$$

**Espérance *a posteriori* pour  $\Theta_i$**  pour chaque source  $i$  :

$$\begin{aligned} \hat{\Theta}_i^{|n} &= \sum_{t_i^n} E\{\Theta_i|T_i^n=t_i^n\} \Pr^{|n}(T_i^n=t_i^n) \\ &\approx \sum_{t_i^n} \hat{\theta}_{t_i^n} \Pr^{|n}(T_i^n=t_i^n) \end{aligned}$$

**Principe**

Dans le cas des paramètres lentement variables, mise en place d'un oubli exponentiel en faisant intervenir la longueur équivalente de fenêtre :

$$\begin{cases} \ell[1] & = 1 \\ \ell[n+1] & = \left(1 - \frac{1}{\ell_\infty}\right) \ell[n] + 1 \end{cases}$$

**Pour  $\Theta$ ;**

pour tout  $n \geq 0$ ,

$$\begin{cases} \hat{\theta}_{t^n} & = \hat{\theta}_{t^{n-1}} - \frac{1}{\mathbf{G}_{t^n}} \frac{\partial Q_{t^n}(\hat{\theta}_{t^{n-1}})}{\partial \theta} \\ \mathbf{G}_{t^n} & = \frac{1}{\left[\frac{\partial Q_{t^n}(\hat{\theta}_{t^{n-1}})}{\partial \theta}\right] \left[\frac{\partial Q_{t^n}(\hat{\theta}_{t^{n-1}})}{\partial \theta}\right]^T} + \left(1 - \frac{1}{\ell_\infty}\right) \mathbf{G}_{t^{n-1}} \end{cases}$$

**Pour H**

variance d'erreur d'estimation de l'état regonflée artificiellement en la divisant par  $1 - \frac{1}{\ell_\infty}$

**Principe**

Dans le cas des paramètres lentement variables, mise en place d'un oubli exponentiel en faisant intervenir la longueur équivalente de fenêtre :

$$\begin{cases} \ell[1] & = 1 \\ \ell[n+1] & = \left(1 - \frac{1}{\ell_\infty}\right) \ell[n] + 1 \end{cases}$$

**Pour  $\Theta$ ;**

pour tout  $n \geq 0$ ,

$$\begin{cases} \hat{\theta}_t^n & = \hat{\theta}_{t^{n-1}} - \frac{1}{n} \mathbf{G}_{t^n}^{-1} \frac{\partial Q_{t^n}(\hat{\theta}_{t^{n-1}})}{\partial \theta} \\ \mathbf{G}_{t^n} & = \frac{1}{n} \left[ \frac{\partial Q_{t^n}(\hat{\theta}_{t^{n-1}})}{\partial \theta} \right] \left[ \frac{\partial Q_{t^n}(\hat{\theta}_{t^{n-1}})}{\partial \theta} \right]^T + \left(1 - \frac{1}{n}\right) \mathbf{G}_{t^{n-1}} \end{cases}$$

**Pour H**

variance d'erreur d'estimation de l'état regonflée artificiellement en la divisant par  $1 - \frac{1}{\ell_\infty}$

**Principe**

Dans le cas des paramètres lentement variables, mise en place d'un oubli exponentiel en faisant intervenir la longueur équivalente de fenêtre :

$$\begin{cases} \ell[1] & = 1 \\ \ell[n+1] & = \left(1 - \frac{1}{\ell_\infty}\right) \ell[n] + 1 \end{cases}$$

**Pour  $\Theta$ ;**

pour tout  $n \geq 0$ ,

$$\begin{cases} \hat{\theta}_t^n & = \hat{\theta}_t^{n-1} - \frac{1}{\ell[n]} \mathbf{G}_t^{n-1} \frac{\partial Q_t^n(\hat{\theta}_t^{n-1})}{\partial \theta} \\ \mathbf{G}_t^n & = \frac{1}{\ell[n]} \left[ \frac{\partial Q_t^n(\hat{\theta}_t^{n-1})}{\partial \theta} \right] \left[ \frac{\partial Q_t^n(\hat{\theta}_t^{n-1})}{\partial \theta} \right]^\top + \left(1 - \frac{1}{\ell[n]}\right) \mathbf{G}_t^{n-1} \end{cases}$$

**Pour H**

variance d'erreur d'estimation de l'état regonflée artificiellement en la divisant par  $1 - \frac{1}{\ell_\infty}$

**Principe**

Dans le cas des paramètres lentement variables, mise en place d'un oubli exponentiel en faisant intervenir la longueur équivalente de fenêtre :

$$\begin{cases} \ell[1] & = 1 \\ \ell[n+1] & = \left(1 - \frac{1}{\ell_\infty}\right) \ell[n] + 1 \end{cases}$$

**Pour  $\Theta$ ;**

pour tout  $n \geq 0$ ,

$$\begin{cases} \hat{\theta}_{t^n} & = \hat{\theta}_{t^{n-1}} - \frac{1}{\ell[n]} \mathbf{G}_{t^n}^{-1} \frac{\partial Q_{t^n}(\hat{\theta}_{t^{n-1}})}{\partial \theta} \\ \mathbf{G}_{t^n} & = \frac{1}{\ell[n]} \left[ \frac{\partial Q_{t^n}(\hat{\theta}_{t^{n-1}})}{\partial \theta} \right] \left[ \frac{\partial Q_{t^n}(\hat{\theta}_{t^{n-1}})}{\partial \theta} \right]^\top + \left(1 - \frac{1}{\ell[n]}\right) \mathbf{G}_{t^{n-1}} \end{cases}$$

**Pour H**

variance d'erreur d'estimation de l'état regonflée artificiellement en la divisant par  $1 - \frac{1}{\ell_\infty}$

### Temps réfractaire

fixé par la physiologie ;

plus  $t_r$  est grand, plus le nombre de trajectoires possibles est faible ;



$n_s$

paramètre de la méthode à choisir en fonction des ressources en calcul ;




- 1 Problématique
- 2 Modèle d'un train d'impulsions
- 3 Nombre d'unités motrices connu : modélisation et estimation**
  - Système, état et modèle de Markov caché
  - Filtrage bayésien
  - Simulation et expérimentation**
- 4 Nombre d'unités motrices inconnu : modélisation et estimation
- 5 Conclusion et perspectives

## Acquisition des signaux réels




- création d'un **dictionnaire de formes** à partir de signaux réels
- un expert réalise la déconvolution

## Signaux simulés et réels



Réel,  $\text{SNR} \approx 11$ ,  $n_{\text{mu}} = 4$




Simulé,  $\text{SNR} = 10$ ,  $n_{\text{mu}} = 4$


Test sur des simulations pour valider notre méthode

→ réglage du nombre  $n_s$  de trajectoires retenues et vérification de l'estimation du paramètre ☹

## Signaux simulés et réels



Réel,  $\text{SNR} \approx 11$ ,  $n_{\text{mu}} = 4$







Simulé,  $\text{SNR} = 10$ ,  $n_{\text{mu}} = 4$

Test sur des simulations pour valider notre méthode





→ réglage du nombre  $n_s$  de trajectoires retenues et vérification de l'estimation du paramètre  $\Theta$

## Simulation et expérimentation

Résultats sur simulation : variation de  $n_s$ 

→ nous retenons un nombre de trajectoires  $n_s = 64$





# Résultats sur simulation : variation de $n_s$







→ nous retenons un nombre de trajectoires  $n_s = 64$

# Résultats sur simulation : taux de mise à feu estimés $E\{U_i[n]|\Theta_i = \hat{\theta}_{t_i}^n\}$

Simulation à paramètres  $\theta$  constant,  
Fenêtre d'oubli  $\ell_\infty = +\infty$  et  $n_s = 64$



## Résultats sur signaux iEMG : déconvolution





 $n_s = 64$  et  $\ell_\infty T_s = 0.9s$ 



## Simulation et expérimentation


Résultats sur signaux iEMG : taux de mise à feu estimés  $E\{U_i[n]|\Theta_i=\hat{\theta}_{t_i^n}\}$ 

$n_s = 64$  et  $\ell_\infty T_s = 0.9s$



- 1 Problématique
- 2 Modèle d'un train d'impulsions
- 3 Nombre d'unités motrices connu : modélisation et estimation
- 4 Nombre d'unités motrices inconnu : modélisation et estimation**
- 5 Conclusion et perspectives

## Rappel du modèle



## Modèle

$$Y[n] = \sum_{i=1}^{n_{mu}[n]} (h_i * U_i)[n] + W[n]$$

## Modélisation

### Source $i$

Une source peut être :

- active et rester active (émission d'impulsion possible) ;
- active et s'inactiver (émission impossible) ;
- inactive et s'activer (émission d'impulsion à nouveau possible).

### État

$T[n]$  (temps de séjours) ;

$\Theta[n]$  (paramètres des lois de Weibull discrètes) ;

$H[n]$  (coefficients des ondelettes) ;

$A[n]$  l'ensemble des sources actives, de cardinal  $n_{\text{act}}[n]$ .

La déconvolution de  $X[n]$  est l'évaluation de  $T[n]$  et  $\Theta[n]$  à partir de  $X[n]$  et  $A[n]$  (et éventuellement  $H[n]$ ).

## Modélisation

### Source $i$

Une source peut être :

- active et rester active (émission d'impulsion possible) ;
- active et s'inactiver (émission impossible) ;
- inactive et s'activer (émission d'impulsion à nouveau possible).

### État

$\mathbf{T}[n]$  (temps de séjours) ;

$\Theta[n]$  (paramètres des lois de Weibull discrètes) ;

$\mathbf{H}[n]$  (coefficients des ondelettes) ;

$\mathbf{A}[n]$  l'ensemble des sources actives, de cardinal  $n_{\text{mu}}[n]$ .

### Remarque

la dimension de  $\Theta[n]$  et  $\mathbf{H}[n]$  varie au cours du temps (état continu de dimension variable).

## Modélisation

### Source $i$

Une source peut être :

- active et rester active (émission d'impulsion possible) ;
- active et s'inactiver (émission impossible) ;
- inactive et s'activer (émission d'impulsion à nouveau possible).

### État

$\mathbf{T}[n]$  (temps de séjours) ;

$\Theta[n]$  (paramètres des lois de Weibull discrètes) ;

$\mathbf{H}[n]$  (coefficients des ondelettes) ;

$\mathbf{A}[n]$  l'ensemble des sources actives, de cardinal  $n_{\text{mu}}[n]$ .

### Remarque

la dimension de  $\Theta[n]$  et  $\mathbf{H}[n]$  varie au cours du temps (état continu de dimension variable).

### Hypothèses

les sources actives ne sont pas connues ;

Mais leurs ondelettes appartiennent à un dictionnaire de formes approximatives connues.

## Modélisation

### Source $i$

Une source peut être :

- active et rester active (émission d'impulsion possible) ;
- active et s'inactiver (émission impossible) ;
- inactive et s'activer (émission d'impulsion à nouveau possible).

### État

$\mathbf{T}[n]$  (temps de séjours) ;

$\Theta[n]$  (paramètres des lois de Weibull discrètes) ;

$\mathbf{H}[n]$  (coefficients des ondelettes) ;

$\mathbf{A}[n]$  l'ensemble des sources actives, de cardinal  $n_{\text{mu}}[n]$ .

### Remarque

la dimension de  $\Theta[n]$  et  $\mathbf{H}[n]$  varie au cours du temps (état continu de dimension variable).

### Hypothèses

les sources actives ne sont pas connues ;

Mais leurs ondelettes appartiennent à un dictionnaire de formes approximatives connues.

## Modélisation

### Source $i$

Une source peut être :

- active et rester active (émission d'impulsion possible) ;
- active et s'inactiver (émission impossible) ;
- inactive et s'activer (émission d'impulsion à nouveau possible).

### État

$\mathbf{T}[n]$  (temps de séjours) ;

$\Theta[n]$  (paramètres des lois de Weibull discrètes) ;

$\mathbf{H}[n]$  (coefficients des ondelettes) ;

$\mathbf{A}[n]$  l'ensemble des sources actives, de cardinal  $n_{\text{mu}}[n]$ .

### Remarque

la dimension de  $\Theta[n]$  et  $\mathbf{H}[n]$  varie au cours du temps (état continu de dimension variable).

### Hypothèses

les sources actives ne sont pas connues ;

Mais leurs ondelettes appartiennent à un dictionnaire de formes approximatives connues.



## Stratégie de naissance et de mort des sources

### Nouveaux paramètres

- une source n'ayant pas émis depuis un temps  $t_i$  est considérée comme inactive ;
- $\lambda$ , probabilité d'activation d'une source.

### Mort


S'il existe des sources  $i$  telles que  $T_i = t_i$ , alors elles sont désactivées et rangées dans le dictionnaire ;

### Naissance

Sinon, une source est activée avec la probabilité  $\lambda$  et équiprobabilité parmi les sources inactives.


## Simulation

Dictionnaire de 4 formes,  $t_I = 1500$ ,  $\lambda = 3.165 \cdot 10^{-4}$







## Simulation

Dictionnaire de 4 formes,  $t_I = 1500$ ,  $\lambda = 3.165 \cdot 10^{-4}$




## Simulation

Dictionnaire de 4 formes,  $t_I = 1500$ ,  $\lambda = 3.165 \cdot 10^{-4}$




## Signaux expérimentaux

Dictionnaire de 4 formes,  $t_I = 0,15\text{s}$ ,  $\lambda = 3.165 \cdot 10^{-4}$




# Signaux expérimentaux

Dictionnaire de 4 formes,  $t_l = 0,15\text{s}$ ,  $\lambda = 3.165 \cdot 10^{-4}$







# Signaux expérimentaux

Dictionnaire de 4 formes,  $t_l = 0,15\text{s}$ ,  $\lambda = 3.165 \cdot 10^{-4}$



## Signaux expérimentaux

Dictionnaire de 4 formes,  $t_l = 0, 15s$ ,  $\lambda = 3.165 \cdot 10^{-4}$





- 1 Problématique
- 2 Modèle d'un train d'impulsions
- 3 Nombre d'unités motrices connu : modélisation et estimation
- 4 Nombre d'unités motrices inconnu : modélisation et estimation
- 5 Conclusion et perspectives

## Apport de la thèse

### Modélisation d'un train d'impulsions

- Propriétés du processus des temps de séjour  $T$  ;
- Choix d'une loi de Weibull discrète de type I pour la modélisation des temps inter-impulsion ;
- Estimation en ligne de paramètres par une méthode dérivée d'une méthode de Quasi-Newton (hors-ligne) ;

### Modélisation du système à nombre de sources connues

- Modèle de Markov caché ;
- Filtrage bayésien pour l'obtention d'estimateurs des taux de décharge des sources ;

### Modélisation du système à nombre de sources inconnues

- Proposition de lois de transitions pour le processus de naissance/mort de sources ;

### Expérimentations

- Création d'un dictionnaire de formes ;
- Validation de notre modèle sur des simulations ;
- Déconvolution de signaux iEMG.

## Apport de la thèse

### Modélisation d'un train d'impulsions

- Propriétés du processus des temps de séjour  $T$  ;
- Choix d'une loi de Weibull discrète de type I pour la modélisation des temps inter-impulsion ;
- Estimation en ligne de paramètres par une méthode dérivée d'une méthode de Quasi-Newton (hors-ligne) ;

### Modélisation du système à nombre de sources connues

- Modèle de Markov caché ;
- Filtrage bayésien pour l'obtention d'estimateurs des taux de décharge des sources ;

### Modélisation du système à nombre de sources inconnues

- Proposition de lois de transitions pour le processus de naissance/mort de sources ;

### Expérimentations

- Création d'un dictionnaire de formes ;
- Validation de notre modèle sur des simulations ;
- Déconvolution de signaux iEMG.

## Apport de la thèse

### Modélisation d'un train d'impulsions

- Propriétés du processus des temps de séjour  $T$  ;
- Choix d'une loi de Weibull discrète de type I pour la modélisation des temps inter-impulsion ;
- Estimation en ligne de paramètres par une méthode dérivée d'une méthode de Quasi-Newton (hors-ligne) ;

### Modélisation du système à nombre de sources connues

- Modèle de Markov caché ;
- Filtrage bayésien pour l'obtention d'estimateurs des taux de décharge des sources ;

### Modélisation du système à nombre de sources inconnues

- Proposition de lois de transitions pour le processus de naissance/mort de sources ;

### Expérimentations

- Création d'un dictionnaire de formes ;
- Validation de notre modèle sur des simulations ;
- Déconvolution de signaux iEMG.

## Apport de la thèse

### Modélisation d'un train d'impulsions

- Propriétés du processus des temps de séjour  $T$  ;
- Choix d'une loi de Weibull discrète de type I pour la modélisation des temps inter-impulsion ;
- Estimation en ligne de paramètres par une méthode dérivée d'une méthode de Quasi-Newton (hors-ligne) ;

### Modélisation du système à nombre de sources connues

- Modèle de Markov caché ;
- Filtrage bayésien pour l'obtention d'estimateurs des taux de décharge des sources ;

### Modélisation du système à nombre de sources inconnues

- Proposition de lois de transitions pour le processus de naissance/mort de sources ;

### Expérimentations

- Création d'un dictionnaire de formes ;
- Validation de notre modèle sur des simulations ;
- Déconvolution de signaux iEMG.

## Travaux futurs et perspectives

### Validation

- Faire des tests sur plus de signaux réels et plus complexes ;
- Obtenir des plages de valeurs pour le temps réfractaire, le taux d'activation et le temps d'inactivation ;
- Affiner la modélisation (double décharge, schéma de recrutement, stratégie de naissance/mort de sources *etc.*) ;

### Pilotage de prothèse

- Faire le lien entre les informations extraites (taux de décharge des sources) avec la commande de la prothèse ;
- Mettre en place un processus d'apprentissage ;
- Exécuter l'algorithme en temps réel ;

### Autre utilisations

- Médical : étude physiologique, réhabilitation, suivi de l'évolution de pathologie, *etc.* ;
- Signal : démultiplexage, compression de données ;
- Industrie : prévision de panne, détection d'événements, *etc.*

## Travaux futurs et perspectives

### Validation

- Faire des tests sur plus de signaux réels et plus complexes ;
- Obtenir des plages de valeurs pour le temps réfractaire, le taux d'activation et le temps d'inactivation ;
- Affiner la modélisation (double décharge, schéma de recrutement, stratégie de naissance/mort de sources *etc.*) ;

### Pilotage de prothèse

- Faire le lien entre les informations extraites (taux de décharge des sources) avec la commande de la prothèse ;
- Mettre en place un processus d'apprentissage ;
- Exécuter l'algorithme en temps réel ;

### Autre utilisations

- Médical : étude physiologique, réhabilitation, suivi de l'évolution de pathologie, *etc.* ;
- Signal : démultiplexage, compression de données ;
- Industrie : prévision de panne, détection d'événements, *etc.*

## Travaux futurs et perspectives

### Validation

- Faire des tests sur plus de signaux réels et plus complexes ;
- Obtenir des plages de valeurs pour le temps réfractaire, le taux d'activation et le temps d'inactivation ;
- Affiner la modélisation (double décharge, schéma de recrutement, stratégie de naissance/mort de sources *etc.*) ;

### Pilotage de prothèse

- Faire le lien entre les informations extraites (taux de décharge des sources) avec la commande de la prothèse ;
- Mettre en place un processus d'apprentissage ;
- Exécuter l'algorithme en temps réel ;

### Autre utilisations

- Médical : étude physiologique, réhabilitation, suivi de l'évolution de pathologie, *etc.* ;
- Signal : démutiplexage, compression de données ;
- Industrie : prévision de panne, détection d'événements, *etc.*





J. Monsifrot, E. Le Carpentier, D. Farina & Y. Aoustin.

*Sequential estimation of intramuscular EMG model parameters for prosthesis control.*

In IEEE/RSJ Int. Conf. on Intelligent Robots and Systems, Workshop on Robotics for Neurology and Rehabilitation, San Francisco, Ca, 2011.



J. Monsifrot, E. Le Carpentier, Y. Aoustin & D. Farina.

*Sequential Decoding of Intramuscular EMG Signals via Estimation of a Markov Model.*

IEEE Trans. on Neural Systems Rehabilitation Engineering, vol. To be published, 2013.



Jonathan Monsifrot, Éric Le Carpentier & Yannick Aoustin.

*Modélisation de trains d'impulsions à l'aide d'une loi de Weibull discrète. Estimation hors-ligne et séquentielle des paramètres.*

In 24e colloque GRETSI sur le traitement du signal et des images, Brest, France, September 2013.



Jonathan Monsifrot, Éric Le Carpentier, Yannick Aoustin & Dario Farina.

*Online estimation of EMG signals model based on a renewal process.*

In ICASSP, IEEE Int. Conf. on Acoustics, Speech and Signal Processing, Vancouver, Canada, 2013.

Merci pour votre attention !