

MCMC pour la décomposition automatique de signal EMG

Di GE, Eric LE CARPENTIER

Institut de Recherche en Communications et Cybernétique de Nantes (UMR CNRS 6597)
Ecole Centrale de Nantes, 1 rue de la Noë, BP 92101, F44321 Nantes Cedex 3, France

(Di.Ge|Eric.Le-Carpentier)@irccyn.ec-nantes.fr

Résumé – On traite ici le problème de la décomposition des signaux électromyographiques (EMG) mono-capteur, résultants de la superposition d’ondes élémentaires. Le problème est sous-déterminé: les inconnues, y compris les formes d’ondes et leurs instants d’apparition sont plus nombreuses que les données observées. L’approche par simulation stochastique *MCMC* est adoptée partant d’une modélisation bayésienne. Les contraintes physiologiques sont incorporées sous forme de loi a priori conjuguée. L’échantillonnage des trains d’impulsions, initialement un problème combinatoire, est contourné par une étape réversible de type « Metropolis-Hastings ». En explorant un sous-ensemble d’espace par itération, cette étape garantit l’irréductibilité de la chaîne. La méthode est validée sur les signaux EMG simulés par Farina *et coll.* [3], pour lesquels on connaît les trains d’impulsions de chaque unité motrice. Par rapport à la décomposition effectuée par un opérateur expert sur les signaux expérimentaux à 5% et 10% de la force maximale de la contraction, la méthode a abouti à une précision de $89,0 \pm 1,6\%$.

Abstract – We treat here the problem of electromyographic (EMG) signal decomposition based on the observation from a single sensor. The EMG signal is constituted of the superposition of action potentials. The problem is underdetermined: the unknowns, including potential shapes and their firing instants are more numerous than the observed data. The stochastic simulation approach, (MCMC) is adopted from a Bayesian modeling. Physiological constraints are incorporated into prior laws. The sampling of impulse trains, originally a combinatorial problem is circumvented by a reversible “Metropolis-Hastings” sampling step. By exploring a subset of the solution space per iteration, this step ensures the irreducibility of the chain. The method is validated on simulated EMG signals by Farina *et coll.* [3], for which the pulse train of each motor unit is known. Compared with the decomposition performed by an expert operator on experimental signals to 5% and 10% of the maximum value of contraction (MVC), the method has led to an accuracy of $89.0 \pm 1.6\%$.

1 Introduction

Un signal électromyographique (EMG) est une superposition d’ondes élémentaires (potentiels d’action), dont la forme et le taux d’apparition sont caractéristiques d’unités indépendantes des fibres musculaires, les unités motrices. La décomposition consiste à restituer pour chaque unité motrice le train d’impulsions correspondant et permet l’analyse ultérieure des propriétés des unités motrices musculaires [2] en fournissant une interprétation des rôles de neurones dans les muscles.

Un prétraitement est nécessaire pour déterminer le nombre d’unités motrices actives dans le signal et la forme caractéristique pour chacune des unités motrices détectées. Pour cela, la méthode proposée s’inspire des œuvres existants dans la littérature [9, 8, 6]. La difficulté majeure de la décomposition reste la séparation des potentiels de différentes unités motrices. On propose une décomposition totalement automatique par simulation stochastique (MCMC) contrairement aux méthodes dans la littérature faisant appel à l’intervention des opérateurs humains [6, 10]. Or, un algorithme MCMC par balayage scalaire des trains d’impulsions (vecteur binaire) unité par unité s’avère inefficace : la chaîne reste coincée dans les modes de la distribution cible. Un algorithme de Gibbs hybride est proposé, dans lequel une étape « Metropolis-Hastings » sur les train d’impulsions, permet d’éviter un calcul de complexité exponentielle, tout en garantissant l’irréductibilité de la chaîne de Markov. D’un point de vue pratique, cette méthode exige peu de paramètres à régler par rapport à la version déterministe basée sur la même modélisation bayésienne [5, 4].

2 Modélisation

Un signal EMG z qui comprend les contributions de I unités motrices peut être modélisé par la somme bruitée de I composantes, chacune étant la réponse d’un système linéaire (dont la réponse impulsionnelle h_i correspond à l’onde élémentaire de chaque unité) excité par un train d’impulsion s_i :

$$z = \sum_{i=1}^I h_i * s_i + \epsilon \quad (1)$$

où ϵ est un bruit i.i.d. gaussien de variance σ_ϵ^2 inconnue. Chaque train s’exprime par une fonction indicatrice, soit $s_i = 1_{x_i}$, où x_i contient les instants des impulsions. Le raccourci $(\bullet)_i$ remplace dans la suite l’ensemble $\{\bullet, i = 1, \dots, I\}$, e.g., $(s_i)_i = \{s_i, i = 1, \dots, I\}$.

Le processus de génération d’un signal EMG de longueur N , connaissant $(x_i, h_i)_i, \sigma_\epsilon^2$, s’écrit alors :

$$P(z | (x_i, h_i)_i, \sigma_\epsilon^2) = \left(\frac{1}{\sqrt{2\pi\sigma_\epsilon^2}} \right)^N \exp \left(-\frac{\|z - \sum_i 1_{x_i} * h_i\|^2}{2\sigma_\epsilon^2} \right) \quad (2)$$

Des justifications physiologiques (chaque impulsion est suivie d’une période réfractaire, l’intervalle de temps entre les impulsions est relativement régulier [11]) conduisent aux hypothèses suivantes :

1. l’intervalle de temps entre impulsions $x_{i,j+1} - x_{i,j}$ est supérieur à la période réfractaire T_R (de l’ordre de 10ms) ;

2. $T_{ij} = \mathbf{x}_{i,j+1} - \mathbf{x}_{i,j} - T_R$ suit une distribution discrète d'allure gaussienne de moyenne m_i et d'écart type σ_i ;

La génération des trains d'impulsions est donc décrite par :

$$P(\mathbf{x}_i | m_i, \sigma_i^2) \propto (2\pi\sigma_i^2)^{-(n_i-1)/2} \exp \left\{ -\frac{1}{2\sigma_i^2} \sum_{j=1}^{n_i-1} (T_{ij} - m_i)^2 \right\} \quad (3)$$

où $n_i = \dim(\mathbf{x}_i)$ indique le nombre d'impulsions de la i -ième unité motrice, un paramètre inconnu a priori. Par ailleurs, on suppose l'indépendance des sources par souci de simplicité, la discussion sur la validité d'une telle hypothèse est portée dans [4]. On obtient donc :

$$P((\mathbf{x}_i)_i | (m_i, \sigma_i^2)_i) = \prod_{i=1}^I P(\mathbf{x}_i | m_i, \sigma_i^2) \quad (4)$$

3 Décomposition

Le processus de décomposition est réalisé en deux étapes : un prétraitement pour segmenter le signal EMG et fournir une approximation des formes d'ondes élémentaires, suivi d'une « décomposition bayésienne » par MCMC. Aucune manipulation humaine n'intervient dans ce processus, les deux étapes sont complètement automatiques.

3.1 Prétraitement

Le prétraitement est constitué de 3 sous étapes [9, 8, 4] :

1. le filtrage passe-bande [8] permet d'accentuer les potentiels d'action par rapport aux autres activités de fond ;
2. la segmentation par seuillage du signal filtré [9, 8] permet de réduire la charge de calcul dans la phase de « décomposition bayésienne » qui suivra ;
3. la classification des potentiels d'action isolés détermine le nombre d'unités motrices actives et les formes approximatives $\mathbf{h}_i^{(0)}$.

La Fig. 1 donne un exemple de 2 segments délimités par les crochets. $\mathbf{x}_i^k = \mathbf{x}_i \cap \text{Seg}_k$, $i = 1, \dots, I$ désignent désormais les coordonnées de \mathbf{x}_i à l'intérieur du segment Seg_k et l'exposant $(-k)$ indique les variables dans les segments appartenant à $\cup_{j \neq k} \text{Seg}_j$.

3.2 Décomposition bayésienne

Les priors conjugués sont choisis avec les hyper-paramètres fixés $(\alpha_i, \beta_i)_i, \alpha_s, \beta_s, \mu_0, \sigma_0^2, \sigma_h^2$ telles que :

$$m_i \sim \mathcal{N}(\mu_0, \sigma_0^2), \quad \sigma_i^2 \sim \mathcal{IG}(\alpha_i, \beta_i), \quad (5)$$

$$\mathbf{h}_i \sim \mathcal{N}(\mathbf{h}_i^{(0)}, \sigma_h^2 \mathbf{I}_P), \quad \sigma_\epsilon^2 \sim \mathcal{IG}(\alpha_s, \beta_s), \quad (6)$$

où \mathcal{IG} est la distribution d'inverse gamma et \mathbf{I}_P la matrice d'identité de dimension P ($P = \dim(\mathbf{h}_i)$). Une forme approximative des potentiels d'action $\mathbf{h}_i^{(0)}$ et leur nombre I sont obtenus dans le prétraitement, et utilisés comme connaissance *a priori*. Une autre condition physiologique sur régularité des trains d'impulsions telle que $\sigma_i/m_i < 0.3$ n'est pas introduite

dans la loi *a priori* par simplicité. On vérifiera *a posteriori* qu'elle est satisfaite pour toutes les sources.

La distribution a posteriori s'écrit alors :

$$P((\mathbf{x}_i, m_i, \sigma_i^2, \mathbf{h}_i)_i, \sigma_\epsilon^2 | \mathbf{z}) \propto P(\mathbf{z} | (\mathbf{x}_i, \mathbf{h}_i)_i, \sigma_\epsilon^2) \prod_{i=1}^I (P(\mathbf{x}_i | m_i, \sigma_i^2) P(m_i) P(\sigma_i^2) P(\mathbf{h}_i)) P(\sigma_\epsilon^2) \quad (7)$$

Les variables $\Theta = \{(\mathbf{x}_i, m_i, \sigma_i^2, \mathbf{h}_i)_i, \sigma_\epsilon^2\}$ sont échantillonnées itérativement suivant leurs lois conditionnelles. L'estimation des variables continues est obtenue par moyennage, tandis que la détection d'impulsions ($(\mathbf{x}_i)_i$ variable discrète) correspond au vote majoritaire (maximum a posteriori marginal).

Le schéma de la « décomposition bayésienne » par l'approche MCMC est donné comme suit :

- 1: Initialiser $(\mathbf{h}_i)_i$ et σ_ϵ par le prétraitement ;
- 2: Initialiser $(m_i, \sigma_i^2)_i$ par leurs lois a priori ;
- 3: $\mathbf{x}_i = \emptyset$ (ou $\mathbf{1}_{\mathbf{x}_i} = \mathbf{0}$) pour tout i .
- 4: **Répéter**
- 5: Pour tout k , échantillonner $(\mathbf{x}_i^k)_i \sim P((\mathbf{x}_i^k)_i | \Theta \setminus (\mathbf{x}_i^k)_i, \mathbf{z})$ % Etape M-H ;
- 6: Pour tout i , échantillonner $m_i \sim P(m_i | \Theta \setminus m_i, \mathbf{z})$;
- 7: Pour tout i , échantillonner $\sigma_i^2 \sim P(\sigma_i^2 | \Theta \setminus \sigma_i^2, \mathbf{z})$;
- 8: échantillonner $(\mathbf{h}_i)_i \sim P((\mathbf{h}_i)_i | \Theta \setminus (\mathbf{h}_i)_i, \mathbf{z})$;
- 9: échantillonner $\sigma_\epsilon^2 \sim P(\sigma_\epsilon^2 | \Theta \setminus \sigma_\epsilon^2, \mathbf{z})$;
- 10: **Jusqu'à Convergence**

On donne directement les lois conditionnelles a posteriori pour les étapes 6-9 de l'algorithme (voir les détails dans [4]).

Loi conditionnelle de m_i

Pour tout $i = 1, \dots, I$, $P(m_i | \Theta \setminus m_i, \mathbf{z})$ est une gaussienne $\mathcal{N}(\bar{m}_i, \bar{\sigma}_i^2)$ avec :

$$\bar{\sigma}_i^{-2} = \sigma_0^{-2} + (n_i - 1)\sigma_i^{-2}, \quad (8)$$

$$\bar{m}_i = \bar{\sigma}_i^2 \left(\frac{\mu_0}{\sigma_0^2} + \frac{\sum_{j=1}^{n_i-1} T_{ij}}{\sigma_i^2} \right). \quad (9)$$

Loi conditionnelle de σ_i^2

Pour tout $i = 1, \dots, I$, $P(\sigma_i^2 | \Theta \setminus \sigma_i^2, \mathbf{z})$ est une inverse gamma paramétrée par $(\bar{\alpha}_i, \bar{\beta}_i)$:

$$\bar{\alpha}_i = \alpha_i + \frac{n_i - 1}{2} \quad (10)$$

$$\bar{\beta}_i = \beta_i + \frac{1}{2} \sum_{j=1}^{n_i-1} (T_{ij} - m_i)^2 \quad (11)$$

Loi conditionnelle de $\mathbf{h} = [\mathbf{h}_1; \dots; \mathbf{h}_I]$

$P(\mathbf{h} | \Theta \setminus \mathbf{h}, \mathbf{z})$ suit une loi Gaussienne $\mathcal{N}(m_{\mathbf{h}}, \Sigma_{\mathbf{h}})$:

$$\Sigma_{\mathbf{h}}^{-1} = \sigma_h^{-2} \mathbf{I}_{PI} + \sigma_\epsilon^{-2} \mathbf{M}^t \mathbf{M} \quad (12)$$

$$m_{\mathbf{h}} = \Sigma_{\mathbf{h}} \left(\sigma_h^{-2} \mathbf{h}^{(0)} + \sigma_\epsilon^{-2} \mathbf{M}^t \mathbf{z} \right) \quad (13)$$

où $\mathbf{M} = [\mathbf{M}_1, \dots, \mathbf{M}_I]$, et chaque $\mathbf{M}_i, i = 1, \dots, I$ est une matrice Toeplitz de convolution telle que $\mathbf{M}_i \mathbf{h}_i = \mathbf{1}_{\mathbf{x}_i} * \mathbf{h}_i$. $\mathbf{h}^{(0)} = [\mathbf{h}_1^{(0)}; \dots; \mathbf{h}_I^{(0)}]$, est un vecteur de taille $PI \times 1$ construit par concatenation.

Loi conditionnelle de σ_ϵ^2

$P(\sigma_\epsilon^2 | \Theta \setminus \sigma_\epsilon^2, \mathbf{z})$ suit la loi inverse gamma paramétrée par $(\bar{\alpha}_s, \bar{\beta}_s)$:

$$\bar{\alpha}_s = \alpha_s + \frac{N}{2}$$

$$\bar{\beta}_s = \beta_s + \frac{\|\mathbf{z} - \mathbf{M}\mathbf{h}\|^2}{2}$$

Échantillonnage de $(\mathbf{x}_i^k)_i$

Contrairement aux échantillonnages des variables continues, celui des trains d'impulsions pour chaque segment, notés $\mathbf{u} = [1_{x_1}^k; \dots; 1_{x_I}^k] \in \{0, 1\}^{\dim(\text{Seg}_k)I}$ sans spécifier l'exposant k par simplicité, ne peut pas être tiré directement selon la loi conditionnelle :

$$P((\mathbf{x}_i^k)_i | \Theta \setminus (\mathbf{x}_i^k)_i, \mathbf{z})$$

$$\propto P(\mathbf{z} | (\mathbf{x}_i^k)_i, (\mathbf{x}_i^{-k})_i, (\mathbf{h}_i)_i, \sigma_\epsilon^2) P((\mathbf{x}_i^k)_i | (\mathbf{x}_i^{-k})_i, (m_i, \sigma_i^2)_i)$$

car cela consisterait à évaluer un nombre explosif de probabilités. On propose donc une étape « Metropolis-Hastings » afin d'éviter de calculer $P(\mathbf{u})$ pour tout $\mathbf{u} \in \{0, 1\}^{\dim(\text{Seg}_k)I}$. Par conséquent l'algorithme MCMC vu de l'ensemble devient un algorithme hybride, soit du Metropolis-Hastings dans Gibbs.

La structure de l'étape M-H est donné dans la suite où $\omega(\mathbf{u})$ est un sous-ensemble contenant toutes les configurations admissibles à partir de la configuration courante de \mathbf{u} :

1: Faire une proposition $\mathbf{u} \mapsto \mathbf{u}^+$ selon la loi

$$q(\mathbf{u} \mapsto \mathbf{u}^+) = \begin{cases} 0 & \text{si } \mathbf{u}^+ \notin \omega(\mathbf{u}) \\ P(\mathbf{u}^+)/F(\mathbf{u}) & \text{sinon} \end{cases}$$

$$\text{où } F(\mathbf{u}) = \sum_{\mathbf{y} \in \omega(\mathbf{u})} P(\mathbf{y}).$$

2: Accepter \mathbf{u}^+ avec la probabilité

$$\rho(\mathbf{u} \mapsto \mathbf{u}^+) = \min\{1, F(\mathbf{u})/F(\mathbf{u}^+)\}.$$

Dans cette application, on définit $\omega(\mathbf{u}) = \{\mathbf{v} | \|\mathbf{u} - \mathbf{v}\|_1 \leq 1\}$ avec $\|\bullet\|_1$ la norme-L1. On vérifie que :

1. $\omega(\mathbf{u})$ contient toutes les configurations à une impulsion près de \mathbf{u} (soit par rajout ou suppression d'une impulsion) ;
2. $\mathbf{u} \in \omega(\mathbf{v}) \Rightarrow \mathbf{v} \in \omega(\mathbf{u})$, et $\mathbf{u} \in \omega(\mathbf{u})$, cette propriété assure la réversibilité de la chaîne : soit pour tout couple $(\mathbf{u}, \mathbf{u}^+) \in \{0, 1\}^{\dim(\text{Seg}_k)}$,

$$P(\mathbf{u})q(\mathbf{u} \mapsto \mathbf{u}^+)\rho(\mathbf{u} \mapsto \mathbf{u}^+)$$

$$= P(\mathbf{u}^+)q(\mathbf{u}^+ \mapsto \mathbf{u})\rho(\mathbf{u}^+ \mapsto \mathbf{u})$$

3. la chaîne de Markov est irréductible : capable de parcourir l'ensemble de l'espace combinatoire (cf appendice).
4. la complexité par itération reste linéaire par rapport à N et I ($\dim(\omega(\mathbf{u})) \leq NI$).

4 Simulation et test réel

En utilisant le simulateur de signaux EMG décrit dans [3], on fixe les paramètres suivants afin de tester la méthode :

- a) 4-5 unités motrices activées dans le signal EMG avec l'écart d'énergie des potentiels d'action à 70% ;
- b) le niveau de superposition maximal à 100% ;

TAB. 1 – Résultat de la simulation. I_{Val} est le nombre d'unités validées, A la performance.

	EMG#1	EMG#2	EMG#3	EMG#4	EMG#5
I	5	5	4	4	4
I_{Val}	3	3	3	4	2
A	90.3%	88.0%	90.1%	88.7%	94.6%

c) le taux de potentiels superposés à 70% ;

On récapitule dans le tableau 1 les résultats pour les 5 signaux EMG ainsi simulés avec SNR = 10dB. Le résultat de la décomposition de chaque train d'impulsions est validé si la régularité est satisfaite, soit $\sigma_i/m_i < 0.3$. Pour évaluer la performance de la méthode proposée, nous avons suivi le critère présenté dans [1] : pour la i -ième unité motrice,

$$A(i) = \frac{N_{\text{Dis}}(i) - N_{\text{FN}}(i) - N_{\text{FP}}(i)}{N_{\text{Dis}}(i)} \times 100\%$$

où $N_{\text{Dis}}(i)$ est le nombre d'impulsions. $N_{\text{FN}}(i)$ et $N_{\text{FP}}(i)$ sont le nombre de faux négatifs et de faux positifs par rapport à la référence. La performance totale de la décomposition [1] est mesurée par :

$$A = \frac{1}{I} \sum_{i=1}^I A(i)$$

Les signaux EMG expérimentaux sont issus du muscle « abductor digiti minimi », en fixant l'auriculaire sur un support et appliquant la force d'une contraction isométrique. Les signaux EMG sont d'abord décomposés par un expert utilisant un algorithme semi-automatique (Emglab) [7, 10] comme référence. Ensuite, chaque impulsion estimée par notre méthode est approuvée si elle est comprise dans la fenêtre de 1ms centrée à l'instant de référence. La figure 1 illustre les résultats de la référence et ceux de la méthode proposée en (a), ainsi que la reconstruction d'une superposition des potentiels en (b). Dans cet exemple, tous les potentiels sont correctement décomposés.

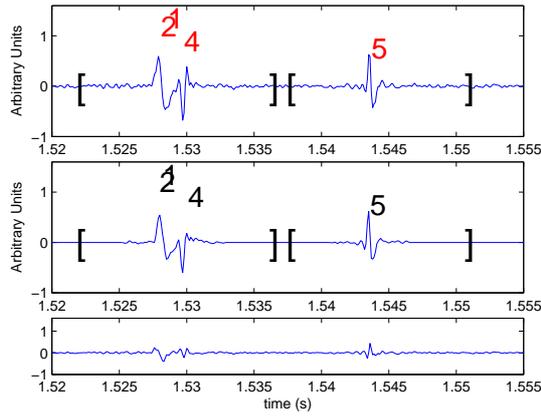
Le tableau 2 présente les résultats sur tous les signaux expérimentaux. La performance moyenne était de $88.5 \pm 1.3\%$ et $89.4 \pm 1.9\%$ pour les contractions à 5% et 10% de la force maximale de contraction (MVC), respectivement.

TAB. 2 – Décomposition des signaux EMG expérimentaux.

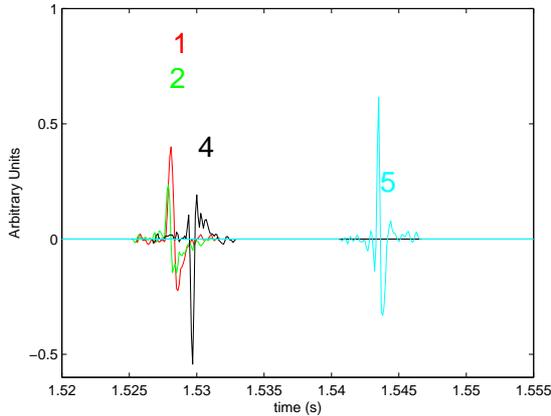
	MVC = 5%				
	EMG#1	EMG#2	EMG#3	EMG#4	EMG#5
I	4	7	5	5	5
I_{Val}	2	5	3	5	4
A	90,2%	89,3%	87,3%	88,7%	87,1%
	MVC = 10%				
	EMG#1	EMG#2	EMG#3	EMG#4	EMG#5
I	5	5	8	8	4
I_{Val}	4	4	4	4	2
A	87,1%	90,4%	92,3%	89,2%	90,7%

5 Conclusion

Une nouvelle méthode de décomposition des signaux EMG intramusculaire a été proposée. Elle est entièrement automatique et atteint une performance totale d'environ 90% sur les



(a)



(b)

FIG. 1 – Décomposition des EMG réels. (a) En haut : EMG bruité et décomposé par expert. Les numéros indiquent les labels d’unités motrices présentes. Au milieu : Décomposition par la méthode proposée, dont la version séparée des potentiels est donnée en (b). En bas : erreur de reconstruction. (b) Illustration de la superposition des potentiels d’action par reconstruction.

signaux EMG du muscle « abductor digiti minimi », par rapport à la décomposition effectuée par un opérateur expert. Cette méthode a pour principal objectif d’éviter de régler les paramètres de l’approche déterministe [4] issue de la même modélisation statistique, et fournit donc une solution encore plus *automatisée* vis-à-vis de l’utilisateur.

La méthode ne fait pas d’hypothèses sur la forme des potentiels d’action ni sur leurs propriétés spectrales et peut donc être appliquée à d’autres problèmes de décomposition, tels que sur les signaux intracorticaux.

Appendice

Pour démontrer l’irréductibilité, il suffit de montrer que pour tout $\mathbf{u} \in \{0, 1\}^{I \dim(\text{Seg}_k)}$, tel que $P(\mathbf{u}) > 0$, la probabilité de suivre un chemin composé de $\{\mathbf{u}^{(0)} = \mathbf{0} \dots \mapsto \mathbf{u}^{(i)} \mapsto \dots \mathbf{u}^{(L)} = \mathbf{u}\}$, où $L = |\mathbf{u}|_1$ et $|\mathbf{u}^{(i)} - \mathbf{u}^{(i-1)}|_1 = 1$, n’est pas nulle. Le chemin est construit en ajoutant une impulsion par itération. Il suffit alors de montrer que pour tout i ,

$$q(\mathbf{u}^{(i-1)} \mapsto \mathbf{u}^{(i)})\rho(\mathbf{u}^{(i-1)} \mapsto \mathbf{u}^{(i)}) > 0. \quad (\text{A-1})$$

On vérifie que $\mathbf{u}^{(i)} \in \omega(\mathbf{u}^{(i-1)})$, qui permet d’écrire :

$$\begin{aligned} & q(\mathbf{u}^{(i-1)} \mapsto \mathbf{u}^{(i)})\rho(\mathbf{u}^{(i-1)} \mapsto \mathbf{u}^{(i)}) \\ &= \frac{P(\mathbf{u}^{(i)})}{F(\mathbf{u}^{(i-1)})} \min\left\{1, \frac{F(\mathbf{u}^{(i-1)})}{F(\mathbf{u}^{(i)})}\right\} \\ &= \min\left\{\frac{P(\mathbf{u}^{(i)})}{F(\mathbf{u}^{(i-1)})}, \frac{P(\mathbf{u}^{(i)})}{F(\mathbf{u}^{(i)})}\right\} \end{aligned}$$

Une condition suffisante de l’inégalité (A-1) est $P(\mathbf{u}^{(i)}) > 0$ pour tout i . Or, la condition $P(\mathbf{u}) > 0$ implique que $P(\mathbf{u}^{(i)}) > 0$ est vrai pour tout i .

Références

- [1] C. J. DE LUCA, A. ADAM, R. WOTIZ, L. D. GILMORE et S. H. NAWAB : Decomposition of Surface EMG Signals. *J. Neurophysiol.*, 96:1646–1657, mai 2006.
- [2] C. J. DE LUCA, R. S. LEFEVER, M. P. MCCUE et A. P. XENAKIS : Control scheme governing concurrently active human motor units during voluntary contractions. *J. Physiol.*, 329:129–142, août 1982.
- [3] D. FARINA, A. CROSETTI et R. MERLETTI : A model for the generation of synthetic intramuscular EMG signals to test decomposition algorithms. *IEEE Trans. Biomed Eng.*, 48(1):66–77, janvier 2001.
- [4] D. GE, E. LE CARPENTIER et D. FARINA : Unsupervised Bayesian Decomposition of Multi-Unit EMG Recordings using Tabu Search. *IEEE Trans. Biomed Eng.*, 2009. à paraître.
- [5] D. GE, E. LE CARPENTIER, D. FARINA et J. IDIER : Unsupervised Bayesian EMG decomposition algorithm using tabu search. *In Applied Sciences on Biomedical and Communication Technologies*, Aalborg, Denmark, octobre 2008.
- [6] M. S. LEWICKI : A review of methods for spike sorting : the detection and classification of neural action potentials. *Network : Computation in Neural Systems*, 9(4):R53–R78, 1998.
- [7] K. C. MCGILL : Optimal resolution of superimposed action potentials. *IEEE Trans. Biomed Eng.*, 49(7):640–650, juillet 2002.
- [8] K. C. MCGILL, K. L. CUMMINS et L. J. DORFMAN : Automatic decomposition of the clinical electromyogram. *IEEE Trans. Biomed Eng.*, BME-32(7):470–477, juillet 1985.
- [9] K. C. MCGILL et L. J. DORFMAN : High-resolution alignment of sampled waveforms. *IEEE Trans. Biomed Eng.*, BME-31(6):462–468, juin 1984.
- [10] K. C. MCGILL, Z. C. LATEVA et H. R. MARATEB : EMGLAB : An interactive EMG decomposition program. *J. Neurosci. Methods*, 149(2):121–133, décembre 2005.
- [11] C. T. MORITZ, B. K. BARRY, M. A. PASCOE et R. M. ENOKA : Discharge rate variability influences the variation in force fluctuations across the working range of a hand muscle. *J. Neurophysiol.*, 93(5):2449–2459, mai 2005.