

# Transformée en ondelettes et modèles de Markov cachés pour la segmentation automatique du signal ECG

R.V. ANDREÃO<sup>1</sup>, B. DORIZZI<sup>1</sup>, J. BOUDY<sup>1</sup> et J.C.M. MOTA<sup>2</sup>

<sup>1</sup>INT, dépt EPH, 9 rue Charles Fourier, 91011 Evry Cedex

{rodrigo.andreao,bernadette.dorizzi, jerome.boudy}@int-evry.fr

<sup>2</sup>UFC, Deti, CP 6005 Campus do Pici, 60455-760 Fortaleza Brésil

mota@deti.ufc.br

**Résumé** – Cette article présente une approche de segmentation automatique du signal ECG qui utilise la transformée en ondelettes et les modèles de Markov cachés (MMC). Le modèle MMC est la concaténation des modèles markoviens élémentaires de chaque onde P, QRS et T d'un battement cardiaque, permettant la détection de toutes ces ondes dans un signal ECG. Malgré la faible taille du corpus d'apprentissage, le MMC proposé montre une très bonne précision dans la segmentation des différents battements, comparée à 1 méthode classique. Le MMC a le grand avantage de s'adapter aux variations du signal ECG et surtout de faire de manière conjointe la détection du battement cardiaque et sa segmentation en ondes P, QRS et T.

**Abstract** – This article presents an automatic approach for ECG segmentation and waveform boundaries detection based on hidden Markov models (HMM) and wavelet transform. Our proposed HMM is the concatenation of elementary markov models of each wave P, QRS and T, allowing the detection of all ECG waves in the whole signal. Despite the small size of the training set, the HMM approach shows a very good precision compared to a standard approach on waveform boundaries detection. The HMM has the major advantage to adapt to the ECG signal variations, and to perform the beat detection and segmentation at the same time.

## 1. Introduction

Le signal d'électrocardiogramme (ECG) est une source d'information très riche pour le suivi de patients qui souffrent de troubles du rythme cardiaque. Il permet d'observer l'activité électrique du cœur, plus précisément ses ondes de dépolarisation et repolarisation qui jouent un rôle fondamental dans le diagnostic des arythmies cardiaques (voir figure 1).

Le but de ce travail est de proposer une méthode nouvelle permettant de segmenter de manière précise et efficace le signal ECG en ondes élémentaires, afin d'avoir un meilleur diagnostic des arythmies. Cette tâche est difficile car elle est liée à la localisation de sous parties du signal qui puissent être associées aux ondes d'un battement cardiaque. De plus, les ondes peuvent prendre des formes spatio-temporelles variées selon les personnes, les pathologies etc... et aussi être affectées par différentes sources de bruit [6].

Plusieurs approches ont été proposées dans la littérature pour la segmentation automatique du signal ECG et surtout pour la détection du complexe QRS [19,7]. Les plus utilisées combinent des techniques de filtrage et des mesures de seuils et permettant déjà d'obtenir de performances satisfaisantes [8,16,13]. D'autres approches plus complexes sont possibles en particulier, celles qui font la modélisation statistique du signal par des modèles de Markov cachés (MMC) [3,2]. Nous sommes convaincus que cette approche est bien adaptée à ce problème car elle permet de modéliser la dynamique du

signal et elle rend possible l'adaptation du système de segmentation à la variabilité intrinsèque du signal.

Les approches qui utilisent des modèles de Markov cachés se différencient sur deux points: le codage du signal, qui correspond aux observations, et la structure du modèle markovien. En ce qui concerne cette dernière, nous avons constaté que dans toutes les approches classiques, le battement cardiaque est modélisé globalement par un seul MMC.

Dans la suite de cet article, on va d'abord expliquer ce que l'on entend précisément par segmentation du signal ECG, puis nous donnons des précisions sur le codage du signal que nous avons utilisé ainsi que sur la structure de ces modèles MMC dans le paragraphe 3. Enfin, nous décrivons la Base de données que nous avons utilisée et les expériences associées dans les paragraphes 4 et 5.

## 2. Segmentation du Signal ECG

Le signal ECG est composé d'une suite de battements cardiaques. En isolant un battement cardiaque normal (voir figure 1), on observe l'existence de trois ondes élémentaires : onde P, complexe QRS et l'onde T. L'onde P correspond à la dépolarisation des oreillettes et est suivie de la dépolarisation des ventricules, qu'on appelle le complexe QRS. La repolarisation des ventricules est connue comme étant l'onde T.

Segmenter le signal ECG consiste donc à détecter les ondes P, QRS et T et à indiquer précisément des points de début et fin de chacune de ces ondes. Parmi celles-ci, celle qui est à l'origine de la majorité des erreurs de détection est

l'onde P. Sa faible amplitude la rend vulnérable aux bruits et pour cette raison elle risque de ne pas être détectée.

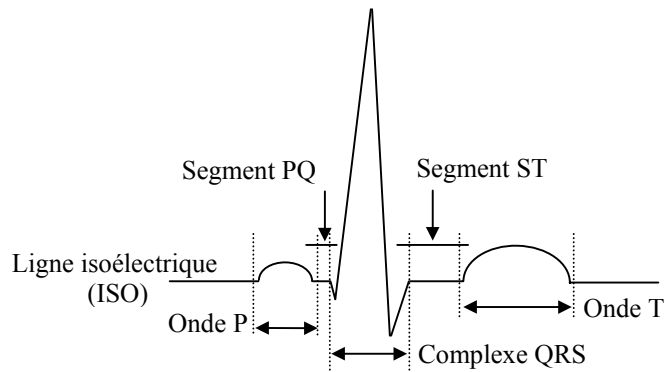


FIG. 1 : Illustration d'un battement cardiaque

### 3. Mise en Œuvre des Modèles de Markov Cachés

Les modèles de Markov cachés ont été mis en évidence dans les applications de reconnaissance de la parole [15]. Ensuite, leur utilisation a été étendue à différents domaines et, en particulier, pour le traitement de signaux biomédicaux [4].

Coast a été pionnier dans l'utilisation de MMC pour les signaux ECG [3]. Il a proposé un MMC pour la classification du battement cardiaque et la détection de l'onde P. D'autres approches MMC ont été proposées pour la segmentation du battement cardiaque, mais cette fois, le battement a été préalablement détecté par une approche de détection du QRS [2,12] Une autre approche proposée par Koski utilise un MMC pour créer un signal ECG synthétique, mais aussi pour classifier les battements [9].

Dans ce travail le MMC fait la segmentation complète du battement cardiaque, c'est-à-dire la segmentation du signal ECG en battements et la segmentation de chaque battement en ondes P, QRS et T par des modèles d'ondes élémentaires.

#### 3.1 Codage du Signal ECG

Le signal ECG peut être codé de différentes façons. On trouve dans [3] le calcul approché de la dérivée du signal combinée à un filtre passe-bas. Plus tard, Clavier [2] observe que la pente (dérivée du signal) représente mieux le signal ECG, en étant moins sensible aux variations d'amplitude. Koski propose une approximation du signal par segments de droites [9]. Plus récemment, Le Page utilise la transformée en ondelettes du signal ECG à plusieurs échelles. L'ondelette Haar a été choisie comme une approximation de la pente du signal [12].

Dans notre travail, l'ondelette Chapeau Mexicain a été utilisée étant donnée sa bonne résolution temporelle, nécessaire pour une détection précise des ruptures [17]. La transformée en ondelettes a été calculée uniquement sur trois échelles. Ces échelles ont été choisies afin d'assurer une bonne représentation des différentes ondes du battement cardiaque et donc pour améliorer la performance de la segmentation. D'ailleurs, nous avons montré en [1] que

l'ondelette Chapeau Mexicain est très performante dans la détection du complexe QRS et la classification des morphologies du signal ECG.

#### 3.2 Topologie et Apprentissage des MMCs

Le modèle de battement correspond à la concaténation des modèles isolés de chaque onde (P, QRS et T), segment (PQ et ST) et ligne isoélectrique (ISO). La topologie des modèles isolés est montrée dans figure 2.




FIG. 2 : HMM de 3 états et de topologie gauche-droite

Les transitions possibles entre ces modèles isolés doivent respecter la topologie de la figure 3. Il faut remarquer que le modèle de battement peut être modifié dans les cas où les exemples des modèles isolés viennent à manquer dans l'ensemble d'apprentissage, ce qui fait que certains modèles ne peuvent pas être appris.




FIG. 3 : Topologie du modèle de battement

L'apprentissage est fait uniquement sur les modèles isolés pour chaque fichier de la base. Pour cela, on a regroupé les battements d'apprentissage en fonction de ses étiquettes P, PQ, QRS, ST et T. Deux étapes d'apprentissage ont été mises en œuvre pour chaque modèle isolé : d'abord, la séquence d'observation est segmentée uniformément entre les états du modèle. Cette procédure est nécessaire pour une meilleure estimation de la probabilité d'émission du MMC. Ensuite, l'algorithme de Baum-Welch est employé et l'apprentissage se termine lorsque la différence de la vraisemblance entre deux itérations consécutives est inférieure à  $10^{-3}$ . Comme on considère le MMC dépendant du patient, cette procédure est répétée pour chaque fichier de la base.

Plusieurs essais ont été réalisés afin de déterminer le nombre d'états de chaque modèle isolé. Pour ne pas augmenter excessivement la complexité des MMCs, on a considéré les valeurs suivantes : 3 états pour les modèles ISO, P et QRS ; 2 états pour les modèles PQ et ST ; 6 états pour le modèle T.

Les expérimentations ont montré que les meilleurs résultats sont obtenus lorsque les probabilités de transition entre états ne sont pas considérées, ce qui est souvent le cas dans certaines applications.

Il existe d'autres stratégies d'apprentissage possibles qui ont été expérimentées, mais qui ne se sont pas montrées plus performantes. Une des ces stratégies consiste à réestimer les modèles isolés à partir des exemples segmentés par le modèle

MMC du battement, dans une procédure de réestimation itérative.

#### 4. La Base de Données

La base de données que nous utilisons dans ce travail a été créée par Laguna. Cette base, appelée *QT Database* [11], rassemble plusieurs enregistrements d'autres bases qui forment l'ensemble *Physionet Bank* disponible gratuitement sur la *Web* [14]. Cette base est très riche car on trouve une grande variété de morphologies du complexe QRS, du segment ST et de l'onde T. D'ailleurs, il y a des enregistrements qui sont dégradés par différentes sources de bruit, ce qui est très utile pour évaluer la robustesse de la méthode de segmentation.

Dans un total de 105 fichiers (un fichier par patient), *QT Database* a pour chaque enregistrement au moins 30 battements étiquetés par un cardiologue. Ces battements seront utilisés pour comparer entre elles les différentes méthodes de segmentation. Chaque fichier contient 2 canaux enregistrés (dérivations) à une fréquence d'échantillonnage de 250 Hz. De plus, le résultat de la segmentation fait par l'approche de Laguna est fourni avec la base [11,10].

Pour chaque patient, un corpus d'apprentissage a été créé pour apprendre le modèle statistique correspondant. Cependant, une caractéristique de cette base est que les battements étiquetés par le cardiologue ne sont pas toujours consécutifs. Pour cette raison, on a décidé de créer le corpus d'apprentissage à partir du tirage au sort de 10 battements étiquetés par le cardiologue. Un total de 10 battements par fichier compose la base d'apprentissage. Comme les étiquettes concernent les 2 canaux enregistrés, on a 10 battements d'apprentissage pour chaque canal.

#### 5. Expérimentation

Deux paramètres ont été calculés pour évaluer la performance de la segmentation :

- 1) Précision : les points de référence des ondes détectées sont comparés avec les étiquettes du cardiologue pour obtenir la moyenne  $\mu$  et l'écart-type  $\sigma$  de la différence entre les deux.
- 2) Détection : le nombre d'ondes P, QRS et T correctement détectées et en accord avec les ondes étiquetées par le cardiologue.

L'approche MMC a été comparée avec l'approche de Laguna et les résultats sont présentés dans les tableaux 1 et 2. Il faut remarquer que dans les fichiers où la qualité du signal est faible sur le canal 1, alors le résultat du deuxième canal a été considéré.

Les résultats sur le tableau 1 montrent clairement que l'approche MMC est supérieure. Cela montre l'intérêt de l'approche statistique qui s'adapte au signal de chaque patient, grâce à une bonne estimation des modèles P, QRS, T et ISO. On peut remarquer que un tel résultat a pu être obtenu avec une apprentissage de seulement quelques battements.

Le tableau 2 présente l'efficacité, en terme de détection des différentes ondes, de 2 méthodes de segmentation considérées. L'approche MMC est plus performante notamment pour la détection de l'onde P. Il faut remarquer que celle-ci joue un rôle important dans l'analyse du rythme cardiaque ainsi que dans le diagnostic de plusieurs arythmies.

TAB. 1 : Précision en ms des approches de segmentation par rapport les étiquettes faites par le cardiologue

Points de référence		MMC	Laguna	
Onde P	Début	$\mu$	1,48	12,10
		$\sigma$	19,71	24,04
	Fin	$\mu$	-5,53	-4,30
		$\sigma$	14,60	21,19
QRS	Début	$\mu$	4,92	-6,99
		$\sigma$	11,63	16,9
	Fin	$\mu$	-4,37	-3,58
		$\sigma$	13,11	19,36
Onde T	Début	$\mu$	-8,44	8,31
		$\sigma$	25,38	66,19
	Fin	$\mu$	13,13	22,07
		$\sigma$	49,25	70,58

TAB. 2 : Nombre d'ondes P, QRS et T correctement détectées

Approche	Onde P	QRS	Onde T
MMC	3151	3620	3540
Laguna	2825	3609	3465
Etiquettes faites par le cardiologue	3194	3623	3543

On peut envisager une stratégie pour améliorer encore les mauvaises étiquetages en rejetant les ondes mal détectées qui dépassent une durée admissible. Cependant, cela entraîne la réduction du nombre des ondes reconnues, ainsi que l'a constaté par Vullings [18].

Le résultat de l'approche de Laguna présenté ici a été obtenu à partir des étiquettes disponibles avec la base *QT Database* [11]. On ne trouve pas exactement les mêmes résultats pour la méthode de Laguna que ceux présentés dans les articles [8,13], bien qu'ils aient été obtenus sur la même base, car les conditions expérimentales ne sont pas tout à fait les mêmes. De même, il n'est pas possible de comparer directement notre méthode à celles proposées par les autres auteurs déjà cités [8,13,18].

#### 6. Conclusion

L'intérêt de l'approche de segmentation par les modèles de Markov cachés a été déjà remarqué par d'autres auteurs [3,2,9], mais ses performances n'avaient pas été encore évaluées sur une base standard des signaux ECG et comparée à d'autres méthodes.

Dans l'approche proposée, les ondes P, QRS et T sont modélisées par des modèles MMC isolés. Cette approche, qui utilise comme codage d'entrée la transformée en ondelettes par la fonction Chapeau Mexicain, a démontré sa précision et

son efficacité pour la détection des ondes du battement cardiaque. D'ailleurs, le MMC détecte beaucoup mieux d'onde P que les autres approches, ce qui est indispensable pour une exacte classification des arythmies.

Les approches de segmentation citées dans ce travail ont été mises en œuvre avec de perspectives différentes : les méthodes de Laguna [10,8] et Martinez [13] n'ont pas besoin d'apprendre pour segmenter; Vullings [18] a créé un corpus d'apprentissage avec les morphologies dominantes de la base pour son modèle et en plus il a utilisé une approche de détection du QRS pour isoler les battements ; l'approche par les MMCs demande un corpus d'apprentissage, et dans ce travail ce corpus est dépendent du patient. Dans la suite de notre travail, une procédure sera mise en œuvre pour apprendre des morphologies qui ne sont pas contenues dans la base d'apprentissage initiale.

La possibilité de choisir le canal le moins bruité rend les approches de segmentation plus fiables, toutefois cela n'est pas toujours possible. Par ailleurs, dans les situations où les deux canaux sont bruités, il est envisageable de faire la segmentation du signal en dépit du bruit. Une solution est de combiner les résultats des deux canaux et de cette façon on pourra utiliser la redondance entre les signaux peut améliorer la fiabilité de la segmentation. Ceci est l'objet de nos travaux futurs.

## Références

- [1] R.V. Andreão, B. Dorizzi; P.C. Cortez et J.C.M. Mota. *Efficient ECG multi-level wavelet classification through neural network dimensionality reduction*. **In:** Proc. IEEE Workshop on Neural Network for Signal Processing, Martigny, Suisse, pp. 395-404, 2002.
- [2] L. Clavier. *Analyse du signal électrocardiographique en vue du dépistage de la fibrillation auriculaire*. Thèse de doctorat, Université de Rennes I, 1997.
- [3] D.A. Coast et al. *An approach to cardiac arrhythmia analysis using hidden markov models*. IEEE Trans. on Biomedical Engineering, Vol. 37, No. 9, 1990.
- [4] A. Cohen. *Hidden Markov Models in Biomedical Signal Processing*. **In:** Proc. 20<sup>th</sup> Annual Conf. IEEE EMBS, Hong Kong, China, Vol. 3, pp. 1145-1150, 1998.
- [5] Cuiwei Li et al. *Detection of ECG characteristic points using wavelet transforms*. IEEE Trans. on Biomedical Engineering Vol. 42, No. 1, 1995.
- [6] G.M. Friesen et al. *A Comparison of the Noise Sensitivity of Nine QRS Detection Algorithms*. IEEE Transactions on Biomedical Engineering, Vol.37, No. 1, pp. 85-98, 1990.
- [7] B.-U. Köhler et al. *The Principles of Software QRS Detection*. IEEE Engineering in Medicine and Biology, Vol. 21, No. 1, pp. 42-57, 2002.
- [8] R. Jané et al. *Evaluation of an Automatic Threshold Based Detector of Waveform Limits in Holter ECG with the QT Database*. **In:** Computers in Cardiology, Lund, Suède, pp. 295-298, 1997.
- [9] A. Koski. *Modelling ECG signals with hidden Markov models*. Artificial Intelligence in Medicine, Vol. 8, No. 5, pp. 453-471, 1996.
- [10] P. Laguna et al. *Automatic detection of wave boundaries in multilead ECG signals. Validation with the CSE database*. Comput. Biomed. Resear., Vol. 27, No. 1, pp. 45-60, 1994.
- [11] P. Laguna et al. *A Database for evaluation of algorithms for measurement of QT and other waveform intervals in the ECG*. **In:** Computers in Cardiology, Lund, Suède, pp. 673-676, 1997.
- [12] R. Le Page et J.M. Boucher. *Détection et analyse de l'onde P d'un électrocardiogramme*. **In:** Proc. 18<sup>ème</sup> colloque GRETSI, Toulouse, France, 2001.
- [13] J.P. Martínez et al. *Evaluation of a Wavelet-Based ECG Waveform Detector on the QT Database*. **In:** Computers in Cardiology, Cambridge, MA, USA, pp. 81-84, 2000.
- [14] G.B. Moody et al. *Physionet: A Web-Based Resource for the Study of Physiologic Signals*. IEEE Engineering in Medicine and Biology, Vol. 20, No. 3, pp. 70-75, 2001.
- [15] L. R. Rabiner. *A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition*. Proc. IEEE, Vol. 77, No. 2, pp. 257-286, 1989.
- [16] J.S. Sahambi et al. *Using Wavelet Transforms for ECG Characterization*. IEEE Engineering in Medicine and Biology, Vol. 16, No. 1, pp. 77-83, 1997.
- [17] C. Torrence et G.P. Compo. *A Pratical Guide to Wavelet Analysis*. Bulletin of the American Meteorological Society, Vol. 79, No. 1, pp. 61-78, 1998.
- [18] H.J.L.M Vullings et al. *Automated ECG segmentation with Dynamic Time Warping*. Proc. 20<sup>th</sup> Annual Conf. IEEE EMBS, Hong Kong, China, Vol. 1, pp. 163-166, 1998.
- [19] J.L. Willems et al. *Assessment of the performance of electrocardiographic computer programs with the use of a reference data base*. Circulation, Vol. 71, No. 3, pp. 523-34, 1985.