

DESCOMPOSICIÓN DE KARHUNEN-LOÈVE DE REGISTROS ELECTROCARDIOGRÁFICOS ABDOMINAL MATERNO

Miguel Altuve¹, Philip Warrick²

¹Facultad de Ingeniería Electrónica, Universidad Pontificia Bolivariana, Bucaramanga, Colombia

²PeriGen Inc., Montreal, Canada

miguel.altuve@upb.edu.co, philip.warrick@perigen.com

RESUMEN

El ECG abdominal materno adquirido durante el embarazo muestra las actividades cardíacas materna y fetal combinadas, por lo que es necesario separar estas componentes con el fin de obtener un ECG fetal útil. En el presente estudio, se analizan las actividades materna y fetal a través de la descomposición en funciones ortogonales del ECG abdominal materno, mediante la transformada de Karhunen-Loève (KL). Se desarrollaron varios clasificadores basados en máquinas de soporte vectorial con el fin de detectar la presencia/ausencia de complejos QRS materno y fetal, en segmentos de ECG de 250 ms de duración. Estos clasificadores utilizan características extraídas de la descomposición de KL y de las señales ECG. Los resultados muestran que un complejo QRS fetal puede ser detectado correctamente cuando éste no se encuentra solapado con un complejo QRS materno (sensibilidad de 88,8 % y especificidad de 97,1 %) mientras que el desempeño disminuye cuando ambos complejos QRS se encuentran solapados (sensibilidad de 90,7 % y especificidad de 75,9 %).

Palabras Clave: Descomposición de Karhunen-Loève, Electrocardiograma Fetal Abdominal, Máquinas de Soporte Vectorial, Procesamiento Digital de Señales Biomédicas.

INTRODUCCIÓN

Durante el embarazo es posible conocer varias características del feto así como la evolución de su estado de salud, usando diversos dispositivos electrónicos, como la fonocardiografía, la cardiotocografía, la magnetocardiografía, la oximetría de pulso y el ultrasonido Doppler. Las técnicas no invasivas son preferibles para evaluar la condición del feto, ya que son menos riesgosas y confortables que las invasivas, sin embargo los métodos invasivos suelen ser muchos más precisos y confiables. El electrocardiograma (ECG) de superficie es una técnica no invasiva rutinaria en la evaluación del estado de salud de una persona joven o adulta, pero no es comúnmente utilizada durante el embarazo para conocer la condición del feto.

El análisis del electrocardiograma fetal (fECG, por sus siglas en inglés *fetal ECG*) no es una práctica rutinaria debido principalmente a la falta de algoritmos y tecnologías para obtener un registro ECG útil y fiable, de una manera no invasiva. El fECG puede ser obtenido de manera invasiva únicamente durante el parto y es empleado cuando se sospecha de un parto complicado, por lo que es necesario asegurarse del buen funcionamiento del corazón del feto durante el parto y evitar una hipoxemia fetal. Esta técnica riesgosa y complicada consiste en colocar un electrodo directamente en el cuero cabelludo del feto a través del cuello uterino de la madre. Por otro lado, el fECG puede ser obtenido de manera no invasiva a partir

la 20^{ava} semana de gestación usando electrodos de superficie colocados en el abdomen de la madre [1]. La señal ECG obtenida por esta técnica contiene, de manera combinada, las actividades cardíacas fetal y materna así como también ruidos indeseables. Extraer el fECG de la señal de ECG abdominal materna es por lo tanto una tarea complicada debido principalmente a la superposición de las señales materna y fetal en el dominio del tiempo y en el dominio de la frecuencia, y a la baja relación señal a ruido del fECG.

El desarrollo de algoritmos para la extracción del fECG de manera no invasiva, a partir de registros ECG abdominal materno, es un tema de investigación vigente, sobre todo motivado por el desafío de PhysioNet/Computing in Cardiology del año 2013 [2, 3]. Siguiendo estos esfuerzos de investigación, el objetivo principal de este estudio es analizar las actividades cardíacas materna y fetal a través de la descomposición de los registros ECG abdominal materno en funciones ortogonales utilizando la transformada de Karhunen-Loève (KL). La descomposición de una señal en componentes ortogonales es un enfoque común para generar representaciones compactas; la transformada de KL da la representación compacta óptima de la señal. Los componentes de la descomposición de KL son utilizados para obtener una señal de ECG reconstruida y los porcentajes de contribución de energía de dichos componentes. La dispersión de la señal de ECG, la dispersión de los coeficientes de KL y los porcentajes de contribución de energía son

utilizados luego por máquinas de soporte vectorial (SVMs, por sus siglas en inglés *support vector machines*) para clasificar segmentos de ECG que contienen QRS materno, QRS fetal, QRS materno y fetal, o ningún QRS.

METODOLOGÍA

ECG abdominal materno

Las señales ECG abdominal materno fueron obtenidas del conjunto A del desafío de PhysioNet/Computing in Cardiology del año 2013 [2]. Se utilizó un conjunto compuesto por 25 registros de un minuto de duración de cuatro canales de ECG abdominal materno, adquiridos simultáneamente a una frecuencia de muestreo de 1 kHz y con una resolución de 16 bits. Estas señales cuentan con las anotaciones de la posición de los complejos QRS fetal (fQRS), realizadas por expertos.

Preprocesamiento y creación de clases

En primer lugar, se utilizó un filtro adaptativo para eliminar la fluctuación de la línea de base del ECG [4]. Luego se eliminó la interferencia de la línea eléctrica con un filtro digital IIR rechaza banda de segundo orden, centrado en 50 Hz y con factor de calidad 15, usando las funciones de MATLAB *iirnotch()* y *filter()*. Posteriormente, se aplicó un detector de complejos QRS [5] a cada canal de ECG limpio u_n , $n = 1, \dots, 4$, para estimar candidatos a complejos QRS materno (mQRS). Finalmente, se seleccionó un mQRS cuando se observó la detección de éste en al menos tres canales diferentes, en una ventana de observación de 70 ms.

Ya conocidas las localizaciones exactas de los fQRS (a partir de las anotaciones suministradas) y las posiciones estimadas de los mQRS, se extrajeron de las señales u_n segmentos de ECG v_m de 250 ms de duración y con un solapamiento de un tercio (33.33%). Estos segmentos v_m fueron asignados a una de las siguientes clases: *i*) Feto (F): un fQRS presente en el segmento, *ii*) Madre (M): un mQRS presente en el segmento, *iii*) Madre y Feto (MF): un mQRS y un fQRS presentes en el segmento, y *iv*) Ninguno (N): ni mQRS ni fQRS presentes en el segmento (i.e., ruido).

Para evitar que complejos fQRS y complejos mQRS se encuentren en los bordes de los segmentos en las clases F, M y MF, solo se almacenaron los segmentos en los que los fQRS y los mQRS se encontraban alejados de los bordes en al menos 25 ms (para los fQRS) y 50 ms (para los mQRS); en caso contrario, el segmento se descartaba. Además, para evitar la inclusión de segmentos en la clase N con ondas T pronunciadas, complejos mQRS no detectados y artefactos, las muestras del segmento debían estar dentro del 70% del valor mínimo y el 70% del valor máximo de la señal ECG u_n . La longitud del segmento (250 ms) fue elegida para evitar que dos fQRS consecutivos se encuentren dentro de un mismo segmento, y el solapamiento de un tercio fue elegido para tener múltiples realizaciones de las señales, aumentar la observabilidad y reducir los efectos de borde. También se excluyó el primer y

el último segundo de la señal u_n para evitar los efectos de borde del procedimiento de filtrado adaptativo, asociado a la convergencia del filtro.

Un total de $M = 12355$ segmentos de cuatro canales fueron extraídos de los 25 registros de ECG. 4415 de estos segmentos fueron asignados a la clase F, 1550 fueron asignados a la clase M, 1842 a la clase MF y 4548 a la clase N.

Descomposición de Karhunen-Loève

La descomposición de KL es comúnmente utilizada para reducir la dimensionalidad de los datos y capturar las variaciones más importantes en los primeros componentes de la descomposición. En general, dado un conjunto de funciones de base ortonormales ϕ_n que abarca un espacio vectorial lineal de dimensión N , una función $f(k)$ en ese espacio puede ser representada como [6]:

$$f(k) = \sum_{n=0}^{N-1} \theta_n \phi_n(k), \quad 0 \leq k \leq N-1 \quad (1)$$

donde los coeficientes espectrales θ_j están dados por el producto interno:

$$\theta_j = \sum_{k=0}^{N-1} f(k) \phi_j^*(k), \quad 0 \leq j \leq N-1 \quad (2)$$

La transformada de KL encuentra, a través de una descomposición en valores singulares, el conjunto de funciones de base que mejor representan a la señal en un sentido de error cuadrático medio. La descomposición de la señal con estas funciones de base es tal que también se minimiza el error cuadrático medio de la expansión truncada. Esta minimización implica que:

$$(\mathbf{R} - \lambda_i \mathbf{I}_N) \phi_i = 0, \quad 0 \leq i \leq N-1 \quad (3)$$

donde $\mathbf{R} = E[\mathbf{ff}^T]$ es el valor esperado de la matriz de covarianza de f , λ_i son los valores propios y ϕ_i son los vectores propios. El error de truncamiento de la reconstrucción es minimizado cuando los valores propios están ordenados de forma descendente. La transformada de KL descorrelaciona completamente la señal y maximiza la compactación de energía (información) contenida en la señal, es decir, la transformada de KL contiene la mayor varianza (energía) en un menor número de coeficientes de transformación. Esto último es debido a que la transformada de KL redistribuye la energía de la señal de tal manera que la mayor parte de la energía está contenida en un pequeño número de coeficientes.

Se determinaron las funciones de base de KL a partir del análisis propio de cada uno de los 25 registros ECG u_n , considerando a cada uno de los canales como independientes. El análisis propio se llevó a cabo por lo tanto sobre $25 \times 4 = 100$ registros ECG. Se escogió una ventana de 80 ms para el análisis propio (*eigenanalysis*) dado que este intervalo abarcaba la duración de la mayoría de los complejos mQRS encontrados.

Luego, se proyectó la señal u_n s en los primeros $L = 8$ vectores propios (*eigenvectors*) para obtener los coeficientes de KL. Se escogió $L = 8$ a partir de la inspección de los valores propios y para asegurar una apropiada reconstrucción de la señal a partir de su descomposición (generalmente mayor al 99 %). Se analizaron las distribuciones de probabilidad de la señal de ECG u_n y las desviaciones estándar de los coeficientes de KL σ_{KL_i} , $i = 1, \dots, L$, de los segmentos de 250 ms de cada clase (F, M, MF y N).

Dado que se encontró una enorme variación en la ganancia de la señal u_n tanto en la señal misma como en los diferentes canales, se especuló que una mejor separación de las clases podría lograrse si estas ganancias eran extraídas de la información de KL. Para lograr esto, se determinaron las señales ECG reconstruidas u_n^i , usando $i = 1, \dots, L$ coeficientes de KL. Por ejemplo, u_2^2 corresponde a la señal ECG reconstruida del segundo canal (u_2) usando los dos primeros coeficientes ($i = 1, 2$).

Luego, se obtuvieron los segmentos reconstruidos v_m^i a partir de u_n^i . Posteriormente, se calculó el porcentaje de varianza explicada (%*VAF*_{*i*}, por sus siglas en inglés *percent variance accounted for*) de cada uno de los segmentos v_m^i , de acuerdo con la ecuación 4, donde σ_e^2 es la varianza del error de reconstrucción del segmento ($v_m^i - v_m$), y σ_v^2 es la varianza del segmento v_m .

$$\%VAF = 100 \times \left(1 - \frac{\sigma_e^2}{\sigma_u^2}\right). \quad (4)$$

Finalmente, se determinó el porcentaje de contribución de energía de los coeficientes de KL de acuerdo con la ecuación 5, con $\%E_{KL1} = \%VAF_1$.

$$\%E_{KL_i} = \%VAF_i - \%VAF_{i-1}, \quad i = 2, \dots, L \quad (5)$$

Clasificación usando máquinas de soporte vectorial

Las máquinas de soporte vectorial son consideradas el estado del arte de los clasificadores y han sido aplicadas con éxito en muchos dominios. En primer lugar, se construyeron tres clasificadores de segmentos, usando SVMs con un núcleo Gaussiano: *i*) madre M-MF: donde las clases M o MF son etiquetadas como verdadero y N o F como falso, *ii*), solo feto F: donde F es etiquetada como verdadero y N, M o MF como falso, y *iii*) feto F-MF: donde F o MF son etiquetadas como verdadero y N o M como falso. En esta etapa no se hace distinción entre los canales, es decir, la clasificación del segmento es considerado como una tarea de aprendizaje independiente por cada canal, sin embargo, todos los canales tienen la misma etiqueta de entrenamiento (verdadero o falso).

Se consideraron tres conjuntos de características en el proceso clasificación por SVMs: *i*) σ_u : desviación estándar del canal de entrada, *ii*) σ_{KL_i} : desviación estándar de cada coeficiente de KL, y *iii*) σ_u y $\%E_{KL_i}$: porcentaje de contribución de energía de cada coeficiente de KL, con σ_u como factor de escala.

Se realizó una validación cruzada de 10 iteraciones (*10-fold cross-validation*), dejando el 10 % de los datos de entrenamiento de cada iteración para validación, a fin de elegir los hiperparámetros de las SVMs. Se eligieron los hiperparámetros que maximizan la suma de la sensibilidad (Se) y la especificidad (Sp).

Posteriormente, se construyó un conjunto de clasificadores de segmentos que combinan las decisiones de cada canal de los clasificadores de segmentos anteriormente descritos. Para cada uno de los tres clasificadores (M-MF, F-MF, y F), se combinaron las decisiones (verdadero o falso) de los canales por mayoría de votos, para obtener una clasificación única del segmento: si al menos tres canales arrojan una etiqueta verdadera, el segmento se clasificaba como verdadero. Además, un clasificador conjunto F||MF se desarrolló combinando los clasificadores de segmento F y F-MF usando la lógica OR.

RESULTADOS

La figura 1 muestra la media \pm desviación estándar de los %*VAF* de cada clase, para los 8 coeficientes de KL utilizados. Como se observa, las clases M y MF tienen mayor %*VAF* que las clases F y N, especialmente en los primeros coeficientes que contienen la mayor cantidad de energía.

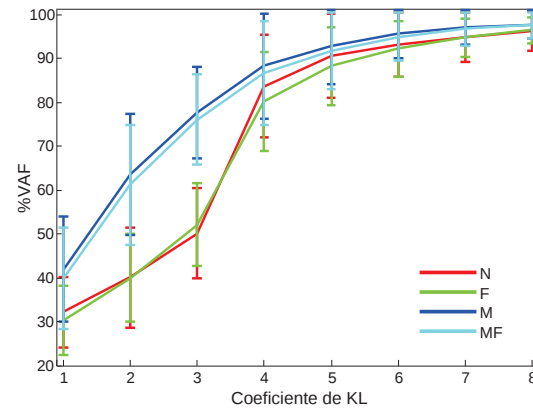


Figura 1. %*VAF* de cada coeficiente de KL para las clases M, F, MF y N.

Las distribuciones de probabilidad de los porcentajes de contribución de energía $\%E_{KL_i}$ separaron las clases de diferentes maneras. Por ejemplo, en la figura 2 se observa que los valores bajos $\%E_{KL_2}$ separan la clase F de los valores altos de $\%E_{KL_2}$ de las clases M y MF. Sin embargo, en todas las distribuciones de probabilidad de $\%E_{KL_i}$ se continuó observando la superposición significativa de las clases M y MF, y F y N.

La tabla I muestra el desempeño de clasificación de los segmentos usando SVMs, para las distintas características y etiquetas. Estos resultados fueron obtenidos tomando los canales de ECG de forma independiente. Se observa un bajo desempeño del clasificador madre M-MF usando la característica σ_u (Se= 63,7 %, Sp= 98,2 %) pero el desempeño

mejora usando las características σ_u y $\%E_{KL_i}$ (Se= 95, 8 %, Sp= 99, 7 %). Por esta razón no se usó σ_u en estudios posteriores. El clasificador que utiliza las características σ_{KL_i} cae en esos extremos (Se= 81, 5 %, Sp= 99, 4 %). El clasificador solo feto F también se comporta mejor con σ_u y $\%E_{KL_i}$ (Se= 90, 1 %, Sp= 86, 3 %) pero no tiene un buen desempeño usando σ_{KL_i} (Se= 0 %, Sp= 100 %). Por esta razón sólo se utilizó σ_u y $\%E_{KL_i}$ para el clasificador F-MF cuyo desempeño fue ligeramente inferior al clasificador solo F.




Figura 2. Distribución de probabilidad de $\%E_{KL2}$.

Tabla I. Desempeño de clasificación de segmentos usando SVMs, tratando los canales de ECG de forma independiente.

Características	M-MF (%)	F (%)	F-MF (%)
σ_u	Se= 63, 7 Sp= 98, 2	–	–
σ_{KL_i}	Se= 81, 5 Sp= 99, 4	Se= 0 Sp= 100	–
$\sigma_u, \%E_{KL_i}$	Se= 95, 8 Sp= 99, 7	Se= 90, 1 Sp= 86, 3	Se= 81, 2 Sp= 76, 3

La tabla II muestra los resultados de la clasificación de los segmentos usando la regla de mayoría de votos de los clasificadores de segmentos aplicados a los canales de manera independiente. El desempeño mejora para todos los clasificadores de segmento, incluso para el clasificador M-MF (no mostrado). El clasificador de segmento F-MF mejora tanto en sensibilidad como en especificidad con respecto al caso por canal, y el clasificador de segmento conjunto F||MF mejora ligeramente con respecto al clasificador de segmento F-MF.

Tabla II. Desempeño de clasificación de segmentos usando SVMs, combinando las decisiones de los canales por mayoría de votos.

Característica	F (%)	F-MF (%)	F MF (%)
$\sigma_u, \%E_{KL_i}$	Se= 88, 8 Sp= 97, 1	Se= 85, 4 Sp= 78, 9	Se= 90, 7 Sp= 75, 9

DISCUSIÓN

La similitud en los $\%VAF$ de las clases M y MF es el resultado de la dominación de la actividad cardíaca materna sobre la actividad cardíaca fetal, y ésta es también la razón

por la cual los porcentajes de contribución de energía de los coeficientes de KL no son capaces de separar limpiamente estas clases.

A pesar del uso de la validación cruzada durante el entrenamiento de las SVMs, estas clasificaciones son probablemente optimista ya que utilizan un conjunto fijo de funciones base de KL, calculadas en las señales del conjunto de entrenamiento. El próximo estudio se enfocará en utilizar los registros ECG abdominal materno del conjunto de prueba (set B) de Physionet.

Por último, el conjunto de características σ_u y $\%E_{KL_i}$ proporcionó los mejores desempeño de clasificación de los segmentos, lo que indica la importancia de la normalización del canal, realizada después del análisis propio. El incremento del desempeño luego de combinar la clasificación de los canales por mayoría de votos sugiere que la detección de la actividad fetal es más robusta cuando se emplea un mayor número de canales, es decir, se cubre una mayor superficie abdominal de la madre, ya que de esta manera se está incrementando la observabilidad del sistema.

CONCLUSIONES

La detección de la actividad cardíaca materna usando la descomposición de Karhunen-Loève de las señales ECG es una tarea relativamente sencilla, sin embargo, la detección de la actividad cardíaca fetal se logró de manera efectiva sólo cuando el complejo QRS fetal no está acompañado (solapado) de un complejo QRS materno. No obstante, las tasas de clasificación logradas en este trabajo preliminar son bastante alentadoras.

En trabajos futuros se emplearán vectores propios de clases específicas y se enfocará en la detección del instante de tiempo en el que ocurren los fQRS y en el cálculo del intervalo RR fetal.

REFERENCIAS

- [1] Peters, M. et al (2001): Monitoring the fetal heart non-invasively: a review of methods. *Journal of perinatal medicine*, 29(5):408–416.
- [2] Silva, I. et al (2013): Noninvasive fetal ECG: the physionet/computing in cardiology challenge 2013. *Computing in Cardiology Conference (CinC), 2013*, pp 149–152.
- [3] Clifford, G.D. et al (2014): Non-invasive fetal ECG analysis. *Physiological measurement*, 35(8):1521.
- [4] Thakor, N.V. y Zhu, Y.S. (1991): Applications of adaptive filtering to ECG analysis: noise cancellation and arrhythmia detection. *Biomedical Engineering, IEEE Transactions on*, 38(8):785–794.
- [5] Pan, J. y Tompkins, W.J. (1985): A real-time QRS detection algorithm. *Biomedical Engineering, IEEE Transactions on*, (3):230–236.
- [6] Akansu, A.N. y Haddad, P.R. (2000): *Multiresolution Signal Decomposition: Transforms, Subbands, and Wavelets*. Editorial Academic Press.