

REDES NEURONALES PARA RECONSTRUIR SEÑALES ADQUIRIDAS EN UNA UNIDAD DE CUIDADOS INTENSIVOS

Alexander Hoyo¹, Carlos Lollett¹, Miguel Vera², Sara Wong¹, Miguel Altuve¹

¹ Grupo de Bioingeniería y Biofísica Aplicada, Universidad Simón Bolívar, Caracas, Venezuela

² Departamento de Ciencias, Universidad de Los Andes, Núcleo Táchira, Venezuela

ahoyo@usb.ve, clollett@usb.ve, veramig@gmail.com, swong@usb.ve, maltuve@usb.ve

Resumen

El monitoreo de señales fisiológicas en una unidad de cuidados intensivos permite evaluar el estado de salud de un paciente y proveer un diagnóstico y un tratamiento efectivo según el tipo de patología. Sin embargo, debido a fallas de los sensores o por ruido (movimientos del paciente, desconexión de electrodos, etc), las señales pueden corromperse o perderse, dificultándose el diagnóstico de las patologías. En este trabajo se propone reconstruir señales fisiológicas utilizando la información contenida en otras señales, a partir de una metodología basada en Redes Neuronales de una capa, entrenada con un algoritmo de mínimos cuadrados. Los resultados obtenidos muestran que es posible hacer una reconstrucción de las señales con un elevado coeficiente de correlación (0.93 para reconstruir la presión arterial a partir del electrocardiograma). Los trabajos futuros están orientados a la extensión multicapa de esta metodología con el fin de incrementar el desempeño de la reconstrucción.

Palabras Clave: redes neuronales, reconstrucción multivariable, coeficiente de correlación, señales fisiológicas.

Introducción

En una unidad de cuidados intensivos (UCI), el monitoreo de señales fisiológicas es realizado con el fin de diagnosticar patologías y proporcionar un tratamiento oportuno. Este proceso se puede descomponer en cuatro etapas [1], descritas en la figura 1: *i*) adquisición, donde se obtienen los datos del paciente, tales como señales fisiológicas, imágenes, exámenes de laboratorio, etc., *ii*) detección, que caracteriza los datos para proporcionar una descripción útil para el diagnóstico, *iii*) diagnóstico, realizado por el médico, basado en la información aportada por la etapa previa, sus experiencias y conocimientos, y *iv*) terapia, que consiste en la indicación y aplicación de un conjunto de medios de diversas clases (higiénicos, farmacológicos, quirúrgicos y/o físicos) con el fin de abordar la patología del paciente.



Figura 1: Proceso de monitoreo en una UCI

En la etapa de adquisición son comunes las pérdidas o perturbaciones de las señales adquiridas, debido a factores diversos: falla de algún sensor, ruidos provocados por el movimiento del paciente, desconexión de electrodos, etc. Esto puede ser perjudicial al paciente, especialmente cuando se requiere de observaciones continuas para detectar eventos fisiopatológicos o simplemente como base para el pronóstico de la enfermedad.

En una aplicación en tiempo real, la reconstrucción de señales fisiológicas puede ser utilizada para la esti-

mación de parámetros, como la frecuencia cardíaca, presión arterial o respiración, cuando las señales primarias utilizadas para tal fin no están disponibles o son poco confiables. Además, la reconstrucción puede facilitar la detección de cambios en la salud del paciente cuando la dinámica de las señales evoluciona [2].

Varios trabajos han sido propuestos para la reconstrucción de señales fisiológicas defectuosas. En este sentido, usando una red neuronal (RN) multicapas entrenada con el algoritmo de Hinton, se logró reconstruir 30 s del electrocardiograma, la respiración, la presión arterial, etc., con un coeficiente de correlación promedio de 0,905 [3]. De igual manera, con una RN con retardo distribuidas se logró obtener un coeficiente de correlación promedio de 0,897 para reconstruir las mismas señales [4], y un coeficiente de correlación promedio de 0,841 usando filtros adaptativos GALL (*Gradient Adaptive Lattice Laguerre*) [5].

En este trabajo se propone una metodología basada en una RN de una capa, entrenada con el algoritmo de Widrow y Hoff, para la reconstrucción de señales fisiológicas a partir de la información contenida en otras señales disponibles.

El resto del trabajo está organizado de la siguiente manera. La siguiente sección presenta la metodología, comenzando por la descripción de la base de datos utilizada, el proceso de reconstrucción y la técnica de evaluación. Luego se muestran y analizan los resultados y finalmente se exponen las conclusiones y los trabajos futuros.

Metodología

Base de datos

Las señales de electrocardiograma (ECG), respiración (RESP), presión arterial (ABP), presión venosa central (CVP), pletismografía (PLETH) y presión arterial pulmonar (PAP) fueron obtenidas de 100 pacientes (100 registros), recluidos en una UCI, a una frecuencia de muestreo de 125 Hz [7]. Un ejemplo de estas señales se puede observar en la figura 2. Cada registro $\mathcal{S}_i, \forall i \in \{1, \dots, 100\}$, contiene un conjunto de \mathcal{V}_j señales diferentes ($6 \leq j \leq 8$), de 10 min de duración cada una. Los últimos 30 s de una de las señales, elegida de forma aleatoria, han sido suprimidos para simular la pérdida de la señal.




Figura 2: Ejemplo de señales adquiridas en una UCI

Reconstrucción de señales usando RN

Una RN de una capa es utilizada para reconstruir la señal suprimida (señal objetivo) \mathcal{V}_α , a partir de la información contenida en las \mathcal{V}_{j-1} señales restantes disponibles. La arquitectura de la RN propuesta se muestra en la figura 3, donde $\mathbf{x} = \{x_1, \dots, x_K\}$ es el vector de entrada compuesto de la concatenación de las muestras contenidas en una ventana deslizante de tamaño n de cada señal $\mathcal{V}_j \neq \mathcal{V}_\alpha, K = n(j-1)$, y es la salida de la RN, $\mathbf{w} = \{w_1, \dots, w_K\}$ es el vector de pesos, b es el umbral y f es la función de transferencia de tipo lineal. Además, se ha agregado una entrada adicional $x_{K+1} = 1$ con peso $w_{K+1} = b$, para integrar el valor del umbral en el vector de pesos (ecuación 1), donde $\langle \cdot \rangle$ es el producto punto.

$$y = f \left(\sum_{k=1}^{K+1} w_k \cdot x_k \right) = f(\langle \mathbf{w} \cdot \mathbf{x} \rangle) = \langle \mathbf{w} \cdot \mathbf{x} \rangle \quad (1)$$




Figura 3: Arquitectura de la RN propuesta

En la etapa de entrenamiento, se determinan los parámetros \mathbf{w} y b usando el algoritmo de Widrow y Hoff [8], introduciendo a la RN patrones entrada-salida $\{\mathbf{x}, y^o\}$, donde y^o es la salida original deseada.

Un subconjunto de entrenamiento fue construido para llevar a cabo esta tarea. Para cada registro \mathcal{S}_i , se deslizó la ventana n con un paso de una muestra, sobre los primeros 9 min 30 s de los datos, para obtener diferentes patrones $\{\mathbf{x}, y^o\}$. Finalmente, el subconjunto de entrenamiento está formado por el 5% de los patrones $\{\mathbf{x}, y^o\}$ de cada registro, tomados aleatoriamente.

El algoritmo de entrenamiento converge iterativamente a la solución de mínimos cuadrados, en el que el valor de los peso \mathbf{w} se modifican usando la ecuación:

$$\mathbf{w}(t+1) = \mathbf{w}(t) + \lambda (y^o - y) \mathbf{x}_k \quad (2)$$

donde λ es la constante de entrenamiento elegida heurísticamente y $(y^o - y)$ es la diferencia entre el valor de la señal original y^o y la reconstruida y , obtenida al aplicar la ecuación 1.

El entrenamiento culmina cuando se alcanza un mínimo coeficiente de correlación (0,99) entre las señales original y reconstruida o cuando se alcanza un máximo número de iteraciones (10000 iteraciones).

Una vez concluida la etapa de entrenamiento, la etapa de prueba consiste en evaluar la RN (ecuación 1), para reconstruir la porción de 30 s que ha sido suprimida de la señal objetivo.

Método de evaluación

La calidad de la reconstrucción es evaluada usando dos indicadores: i) Q_1 definido en la ecuación 3, donde mse representa el error cuadrático medio entre las señales original y^o y reconstruida y y var es la varianza, y ii) Q_2 definido en la ecuación 4, es el coeficiente de correlación entre las señales original y reconstruida, donde Cov es la covarianza.

$$Q_1 = \max \left(1 - \frac{mse(y^o, y)}{var(y^o)}, 0 \right) \quad (3)$$

$$Q_2 = \max \left(\frac{Cov(y^o, y)}{\sigma(y^o)\sigma(y)}, 0 \right) \quad (4)$$

Resultados

La reconstrucción se llevó a cabo usando $j = 2$ o $j = 3$ señales fisiológicas:

- ECG aVR se reconstruyó utilizando ABP (cuando estaba disponible), ECG II y ECG V.

- ECG II se reconstruyó utilizando ECG V y ECG aVR. Cuando ECG aVR no estaba disponible se utilizó ECG I o ABP.
- ABP se reconstruyó utilizando PLETH y ECG aVR si estaban disponibles, en caso contrario se utilizó ECG II y ECG V.
- PLETH se reconstruyó utilizando RESP, ECG II y ECG V. Cuando alguna de estas señales de ECG no estaban disponible, se sustituye por ABP.
- CVP se reconstruyó utilizando ABP, RESP y PLETH si estaban disponibles, en otros casos se utilizó ABP y ECG II.
- RESP se reconstruyó utilizando PLETH y ABP. Cuando estas señales no estaban disponibles, se utilizó CVP y señales de ECG

Se encontró que el tamaño óptimo de la ventana n fue de 1 s para las señales ECG, ABP y PLETH, mientras que fue de 3,6 s para la RESP y CVP. Para el caso del ECG, esta ventana corresponde aproximadamente a la duración promedio del ciclo cardíaco de una persona adulta. Para el caso de la respiración, el tamaño de la ventana encontrado está en concordancia con el período de la respiración (3 s aproximadamente).

El cuadro 1 detalla los valores promedio \pm desviación estándar de los indicadores Q_1 y Q_2 , para la reconstrucción de diferentes señales fisiológicas.

En las figuras 4, 5 y 6 se muestran diferentes ejemplos de reconstrucción de señales fisiológicas. En estas figuras se puede observar claramente las similitudes entre las señales original y reconstruida.

Cuadro 1: Valores promedios \pm desviación estándar de los indicadores Q_1 y Q_2

Señal objetivo	Q_1	Q_2
ECG aVR	0,96 \pm 0,03	0,95 \pm 0,04
ECG II	0,91 \pm 0,06	0,90 \pm 0,07
ABP	0,89 \pm 0,14	0,93 \pm 0,09
PLETH	0,86 \pm 0,11	0,92 \pm 0,07
CVP	0,86 \pm 0,18	0,78 \pm 0,07
RESP	0,72 \pm 0,33	0,73 \pm 0,29




Figura 4: ECG II reconstruido a partir de ECG aVR y ECG V. $Q_1 = 0,92$ y $Q_2 = 0,94$




Figura 5: PLETH reconstruida a partir de RESP, ECG II y ECG V. $Q_1 = 0,97$ y $Q_2 = 0,98$




Figura 6: RESP reconstruida a partir de ABP y PLETH. $Q_1 = 0,98$ y $Q_2 = 0,92$

Estos resultados muestran que utilizando una RN como la planteada en este trabajo es posible obtener altos coeficientes de correlación, mayores de 0,9, cuando se reconstruyen señales de electrocardiogramas, de presión arterial y de pletismografía. Sin embargo, en la reconstrucción de señales como la presión venosa central y la respiración, los coeficientes de correlación son inferiores a 0,8, probablemente debido a una baja correlación entre las señales usadas para reconstruirla.

Conclusiones y trabajos futuros

En este trabajo se utilizó una RN de una capa entrenada con un algoritmo de mínimos cuadrados y una

función kernel lineal para reconstruir señales fisiológicas, adquiridas en una unidad de cuidados intensivos. El desempeño de la reconstrucción se estimó usando el coeficiente de correlación entre la señal reconstruida y la señal original.

Los resultados muestran que la metodología propuesta es eficiente para reconstruir señales de electrocardiogramas, presión arterial y pletismografía. Sin embargo, las reconstrucciones de señales como la respiración y la presión venosa central no son tan eficientes por lo que se requiere un estudio más detallado.

En un futuro se espera adaptar esta metodología a una red neuronal multicapas y ensayar con diferentes funciones kernel para reconstruir este tipo de señales fisiológicas y aumentar el desempeño de la reconstrucción. Además, otra técnicas pudieran ser utilizadas para la reconstrucción de señales fisiológicas, en especial las máquinas de soporte vectorial o la fusión de datos [6].

Referencias

- [1] Cruz J. *et al* (2007): *Sistema multiagentes para el monitoreo inteligente*, CLAIB 2007, IFMBE Proceedings 18: pp. 501–505.
- [2] Farrell P. *et al* (2002): *SIDS, ALTE, Apnea, and the use of home monitors*, Pediatrics in Review, 23(1), 3–9.
- [3] Rodrigues R. (2010): *Fill in the Gap: A general method using Neural Networks*, Computing in Cardiology 2010; 37: 453–456.
- [4] McBride J. *et al* (2011): *Reconstruction of physiological signals using iterative retraining and accumulated averaging of neural network models*, Physiological Measurement, 32, 661–675.
- [5] Silva I. (2010): *PhysioNet 2010 Challenge: A Robust Multi-Channel Adaptive Filtering Approach to the Estimation of Physiological Recordings*, Computing in Cardiology 2010, 37: 313–316.
- [6] Hernández A. *et al* (1999): *Multisensor fusion for atrial and ventricular activity detection in coronary care monitoring*, IEEE Transactions on biomedical engineering, 46: 1186–1190.
- [7] Physionet. (2010): *Physiologic signal archives for biomedical research*, Disponible en: <http://www.physionet.org>, último acceso Junio de 2012.
- [8] Cristianini N. *et a* (2000): *An Introduction to Support Vector Machines and Other Kernel-based Learning Methods*, Cambridge University Press.