

Análisis e interpretación de señales cardiorrespiratorias para determinar el momento óptimo de desconexión de un paciente asistido mediante ventilación mecánica.

Pinto F Jorge y Arizmendi P Carlos
{jpinto11, carizmendi}@unab.edu.co

Resumen. El momento óptimo de extubación de un paciente es un gran desafío para la práctica clínica. En este trabajo se estudian las diferencias en la variabilidad del patrón respiratorio de 154 pacientes, clasificados en 3 grupos: Grupo Éxito (94 pacientes con éxito en la extubación), Grupo Fracaso (39 pacientes que fallaron en el proceso de extubación) y Grupo Reintubados (21 pacientes que superaron en el proceso de extubación pero pasadas 48 horas fueron entubados). Cada paciente ha sido caracterizado por un lado con 32 variables correspondientes a 8 series temporales y 5 índices de un análisis espectral de potencia; y por otro lado con 40 variables correspondientes a 8 series temporales y 5 estadísticos. En este estudio se realizó un análisis espectral de potencia (PSD), se aplicó un análisis en el dominio de tiempo-frecuencia con la transformada wavelet discreta (TWD), se hizo uso de estadísticos de dispersión para analizar la variabilidad de los datos, se realizó una etapa de clasificación con redes neuronales artificiales (RNA), análisis discriminante lineal (LDA); estas dos últimas técnicas combinadas con forward y Bidireccional search, técnicas de reducción de dimensionalidad. Las mejores diferencias estadísticas se obtuvieron entre los grupos fracaso y reintubados con un 91.6% de clasificación correcta, seguido de la comparación Éxito y reintubados con un 86.9% de clasificación correcta, y como tercera mejor la diferenciación entre los grupos éxito y fracaso con un 84.6% de clasificación correcta.

Palabras claves—redes neuronales, análisis discriminante lineal, destete, ventilación mecánica, cardiorrespiratoria, análisis densidad espectral.

1. Introducción

Uno de los objetivos en la sustitución de la ventilación mecánica es la recuperación de la respiración espontánea lo más pronto posible. Retirar la ventilación mecánica es a veces más difícil que mantenerla. Según las estadísticas, alrededor del 40% de los pacientes que llegan a cuidados intensivos necesitan algún soporte de ventilación mecánica. El prolongado uso de la ventilación mecánica aumenta la morbimortalidad de pacientes en unidades de cuidados intensivos [1], [2], [3], [4]. Una prueba fallida en el proceso de desconexión de la ventilación mecánica es molesta para el paciente, y puede ocasionar distrés cardiopulmonar. Hasta un 25% de pacientes sometidos a la extubación sufren distress lo bastante severo como para que tengan que ser reintubados [5].

La variabilidad del patrón respiratorio es no randomica y puede ser explicada por mecanismos neurocentrales o por inestabilidad de los lazos de realimentación. El estudio de la variabilidad del patrón respiratorio ha sido analizado en [6], [7], [8], [9], entre otros.

El comportamiento de la variabilidad del ritmo cardiaco (HRV) está relacionada entre otros, con la acción que ejerce la respiración sobre el sistema cardiovascular, lo que genera un ritmo de sincronización en el rango de alta frecuencia (HF) y un ritmo secundario en el rango de baja frecuencia (LF) [10]. La banda de alta frecuencia está relacionada con la actividad del sistema parasimpático y se debe principalmente a la arritmia sinusal respiratoria. Esta componente se reduce ante un ejercicio moderado o intenso, o frente a un aumento en la frecuencia respiratoria. La banda de baja frecuencia está relacionada con la modulación del sistema simpático, aunque su interpretación es controvertida [11]. Durante el proceso de extubación se produce una estimulación adrenal la cual puede verse reflejada en una caída de la actividad del sistema nervioso parasimpático, con la consiguiente afectación a las componentes de alta frecuencia del HRV. La respuesta final de la ventilación mecánica depende de las condiciones cardiovasculares basales del paciente [12].

En este trabajo se presenta el análisis e interpretación de señales cardiorrespiratorias para determinar el momento óptimo de desconexión de un paciente asistido mediante ventilación. Como objetivo principal se analizan los datos en base a su variabilidad, por medio de técnicas de transformación, reducción de dimensionalidad, clasificación, caracterizando los patrones cardiorrespiratorios y extrayendo índices que expresen la variabilidad entre las clases de forma significativa y permita una mejor diferenciación de los diferentes grupos de pacientes.

2. Datos analizados

Se han analizado señales electrocardiográficas (ECG) y señales de flujo respiratorio (FLU) de 154 pacientes sometidos a ventilación mecánica y en proceso de extubación (base de datos WEAN DB). Las señales provienen de pacientes registrados en los Departamentos de Cuidados Intensivos del Hospital de la Santa Creu i Sant Pau y del Hospital de Getafe, de acuerdo con los protocolos aprobados por los comités éticos.

Los pacientes registrados en esta base de datos fueron sometidos a la prueba de tubo en T, como protocolo para la desconexión del ventilador mecánico y se clasificaron en tres grupos de acuerdo con los criterios clínicos basados en la prueba ya mencionada: grupo S, 94 pacientes con éxito en la extubación y que han podido mantener la respiración espontánea pasadas 48 horas, grupo F, 39 pacientes que no pueden mantener la respiración espontánea y son reconectados al ventilador pasados los 30 minutos, y grupo R, 21 pacientes con éxito en la prueba durante los 30 minutos, que fueron desconectados del ventilador, pero que tuvieron que ser reintubados y conectados de nuevo a un ventilador mecánico antes de 48 horas.

Las Señales ECG se obtuvieron utilizando un monitor SpaceLabs Medical, derivación I, II o III. Las señales FLU se obtuvieron a partir de un neumotacógrafo, utilizando un monitor Datex-Ohmeda con transductor de reluctancia variable Validyne Model MP45-1-871, conectado a un tubo endotraqueal. Las señales han sido registradas a partir del momento en que la clínica consideraba viable la extubación (“weaning”), con los pacientes respirando de forma espontánea, a través del tubo T, durante 30 minutos.

A partir de las señales ECG y FLU se obtuvieron las correspondientes series temporales: relación frecuencia-volumen tidal (f/V_T), duración del ciclo cardíaco (RR), tiempo de espiración (T_E), tiempo de inspiración (T_I), fracción inspiratoria (T_I/T_{Tot}), duración del ciclo respiratorio (T_{Tot}), flujo inspirado medio (V_T/T_I), volumen tidal (V_T).

3. Metodología

3.1. Análisis frecuencial

Se realiza un Análisis de Densidad Espectral de Potencia (PSD). En base a este análisis se selecciona la frecuencia de 2 Hz, con la cual se genera la interacción cardiorrespiratoria por medio de osciladores.

Además, se genera una Base de Datos con 32 características obtenidas del PSD (BD2) tal y como se presenta en la figura 1.

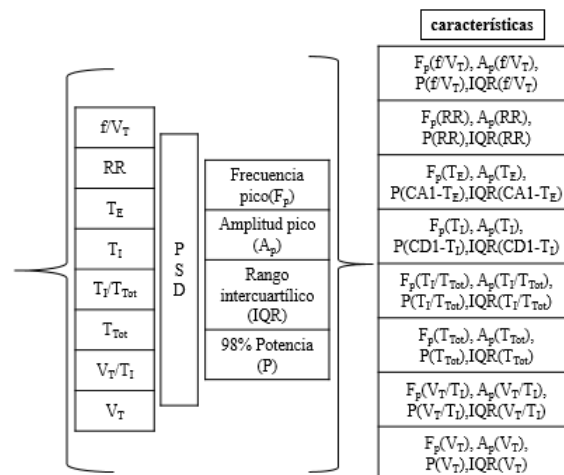


Figura 1. Representación de las 32 características por cada paciente obtenidas mediante el PSD con 8 series temporales.

3.2. Análisis tiempo-frecuencia

Se desarrolla un análisis tiempo-frecuencia, haciendo uso de la Transformada Wavelet Discreta (TWD). Se seleccionan las familias que mejor se adaptan a las diferentes series temporales con base en el Error Medio Cuadrático (MSE). En la tabla 1 se presenta la elección de las familias wavelet para las diferentes series temporales.

Tabla 1. Familias Wavelet utilizadas.

	f/Vt	RR	Te	Ti	Ti/Ttot	Ttot	Vt/Ti	Vt
Familia	Bior	Bior	Bior	Bior	Bior	Bior	Bior	Bior
Wavelet	2.4	2.6	2.6	2.6	2.4	2.4	2.6	2.6
MSE^a	6	1	5	1	1	5	2	4

^avalores *E-21

Seleccionada la familia para cada tipo de variable, se seleccionan los coeficientes de aproximación (CA) y detalle (CD), el nivel de descomposición, y las medidas de dispersión estadística que mejor se adaptan al problema con el fin de obtener la mayor información de los datos en base a su variabilidad. Para eso, se descomponen las señales con las familias seleccionadas en los niveles de descomposición y detalle hasta el nivel máximo permitido por la familia (nivel 8 para la familia Biortogonal); seguido, se calculan la media, la desviación estándar, la curtosis, la oblicuidad y el rango intercuartílico de los CA y CD de cada nivel. A este punto, se tendrían 5 estadísticos, de 8 CA y 8 CD, de las 8 variables existentes; lo que da un total de 640 características.

Al hacer la transformación de las señales, se logra tener la información de estas codificadas. Ahora, se busca hallar los coeficientes que aporten mayor información para una posterior clasificación. Para ello, como se realizó anteriormente, se realiza una prueba de U de Mann-Whitney con la cual se busca descartar los estadísticos de los coeficientes que menos ayuden a diferir entre las clases a contrastar y si entorpezcan una futura clasificación. Además, se establece un cuantificador que permita evaluar y comparar los coeficientes y niveles para validar la elección final. El cuantificador es representado por Q, y se define como:

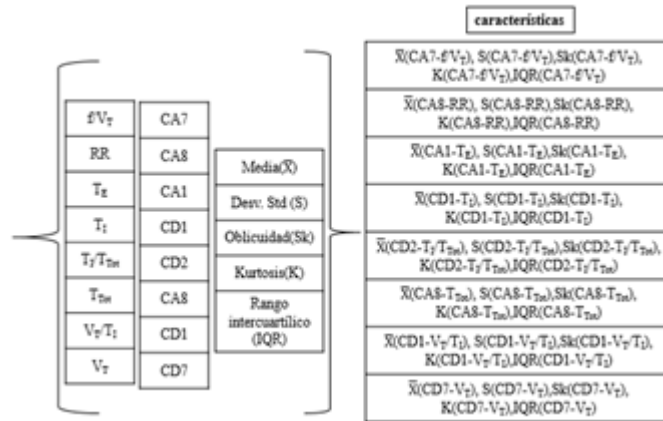
$$Q_i = \frac{1 + \text{moda } i}{\text{promedio } i} \quad (1)$$

En donde la Moda es el número de variables que pasan la prueba de U de Mann-Whitney por cada coeficiente y cada nivel, y el Promedio está definido como:

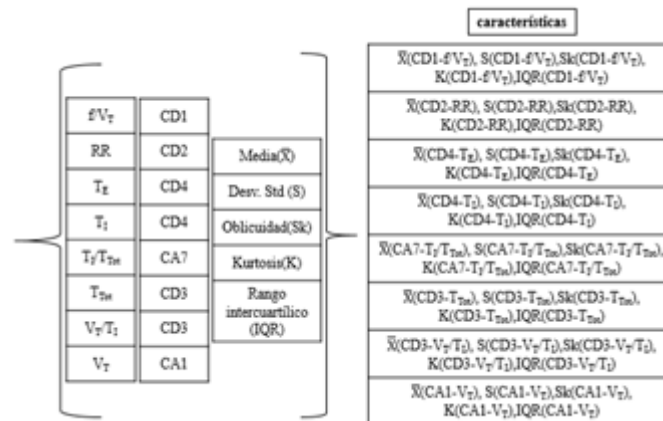
$$\text{promedio} = \frac{1}{n} \sum_{i=1}^n X_i \quad (2)$$

Donde n es el número de estadísticos por nivel (5), y cada es el p-value de cada estadístico del respectivo coeficiente y nivel de descomposición. En la figura 2 se exponen los coeficientes y niveles seleccionados por cada caso, señalados como mejores en base al cuantificador Q expuesto anteriormente.

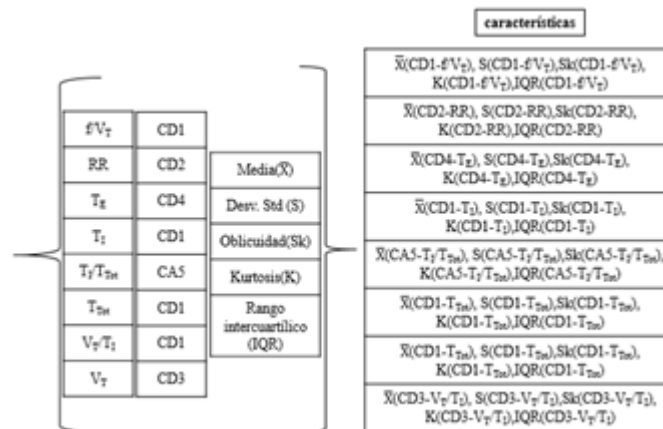
En la figura 2(a) se representan las 40 características de cada paciente que mejor difieren entre las clases “Éxito” y “Fracaso”; en la figura 2(b) se representan las 40 características de cada paciente que mejor difieren entre las clases “Fracaso” y “Reintubados”; y en la figura 2(c) se representan las 40 características de cada paciente que mejor difieren entre las clases “Éxito” y “Reintubados”.



(a)



(b)



(c)

Figura 2. Representación de las 40 características por cada paciente obtenidas mediante la TWD con 8 series temporales y 5 estadísticos.

3.3. Reducción de Datos y Clasificación

En la etapa de reducción de dimensionalidad se aborda el problema con dos propuestas. La primera se hace uso de Forward Selection, y la segunda se aplica Bidirectional search. En cuanto a las técnicas de clasificación se trabajan las Redes Neuronales Artificiales (RNA) y el Análisis Discriminante Lineal (LDA).

En la figura 3 se presenta el esquema de la red neural sintonizada para la clasificación de este problema.




Figura 3. Esquema de la Red Neuronal sintonizada.

En la clasificación con RNA, se sintoniza una red neuronal con la estructura presentada en la figura 3. Se fraccionan los datos de manera aleatoria de la siguiente forma: Del 100% de los datos, se toma un 70% para realizar el ajuste de la red, en donde se subdividen del siguiente modo: 70% para el entrenamiento, 15% para la validación, y 15% para el test. Con el 20% final se realiza el test final de la red y se presentan los mejores resultados en la tabla 2. Este proceso se realiza tanto para la Base de Datos obtenida del PSD (BD2), como para la Base de Datos obtenida del análisis por medio de TWD (BD1).

Debido a que la división de los datos se realiza de manera aleatoria, se realiza el proceso de entrenamiento, validación y test 150 veces y se promedian los resultados.

En las tabla 2, tabla 3 y tabla 4vse presentan los resultados de clasificación con RNA para los diferentes casos.

Tabla 2. Resultados del test de clasificación con RNA, para el mejor conjunto de variables para el caso “Éxito Vs Fracaso” obtenidas después de la reducción de dimensionalidad.

Base de datos	Características	Resultado de la prueba
BD1	IQR(CD1-TI), K(CA8-RR)	84,61±3%
BD1	IQR(CD1-TI), K(CA8-RR), IQR(CD1-VT/TI), K(CD1-TI), X(CA7-f/VT)	80,76±6%
BD2	Fp(f/VT), P(VT/TI), IQR(TI/TTot), Ap(f/VT)	65,3±0,9%
BD2	Fp(f/VT), P(VT/TI), IQR(TI/TTot)	54,4±0,9%

Tabla 3. Resultados del test de clasificación con RNA, para el mejor conjunto de variables para el caso “Éxito Vs Reintubado” obtenidas después de la reducción de dimensionalidad.

Base de datos	Características	Resultado de la prueba
BD1	X(CD1-f/V _T)	82,6±3%
BD1	X(CD1-f/V _T), IQR(CD3-V _T /T _I)	86,9±1%
BD2	P(RR)	78,2±0.7%
BD2	P(RR), F _p (f/V _T)	86,8±0.7%

Tabla 4. Resultados del test de clasificación con RNA, para el mejor conjunto de variables para el caso “Fracaso Vs Reintubados” obtenidas después de la reducción de dimensionalidad.

Base de datos	Características	Resultado de la prueba
BD1	S(CD1-TTot), X(CD1-f/VT), IQR(CD1-f/VT), K(CD2-RR), Sk(CD1-f/VT), K(CD1-f/VT)	83,3%
BD1	S(CD1-TTot), X(CD1-f/VT), IQR(CD1-f/VT), K(CD2-RR), Sk(CD1-f/VT), K(CD1-f/VT), S(CD1-f/VT), X(CA5-TI/TTot), S(CD1-TI), K(CD1-TTot), Sk(CD1-TTot), IQR(CD2-RR), K(CD4-TE)	91,6%
BD2	Fp(f/VT), Ap(TI/TTot), Ap(TI), Ap(RR), Ap(f/VT), IQR(TTot), IQR(CD1-TI), IQR(RR), IQR(f/VT)	50±1,6%
BD2	Fp(f/VT), Ap(TI/TTot), Ap(TI), Ap(RR), Ap(f/VT), P(TTot)	58,3±1,3%

Por otro lado, en la clasificación con análisis discriminante, se utiliza una discriminación lineal. Se dividen los datos tanto de la BD1 como de la BD2 en la forma mencionada anteriormente. Los mejores resultados de la clasificación con LDA se presentan en la tabla 5, tabla 6 y tabla 7.

Tabla 5. Resultados del test de clasificación con LDA, para el mejor conjunto de variables para el caso “Éxito Vs Fracaso” obtenidas después de la reducción de dimensionalidad.

Base de datos	Características	Resultado de la prueba
BD1	IQR(CD2-TI/TTot)	71,64±8
BD1	IQR(CD2-TI/TTot) X(CA7-f/VT), IQR(CD1-VT/TI)	72,13±8
BD2	Ap(f/VT)	70±7,8
BD2	Ap(f/VT), P(f/VT)	70,6±7,7

Tabla 6. Resultados del test de clasificación con RNA, para el mejor conjunto de variables para el caso “Éxito Vs Reintubado” obtenidas después de la reducción de dimensionalidad.

Base de datos	Características	Resultado de la prueba
BD1	X(CD1-f/VT),	83,33±7,4%
BD1	X(CD1-f/VT), IQR(CD3-TTot)	82,55±7,5%
BD2	Fp(f/VT)	80,9±6,4%
BD2	Fp(f/VT), IQR(VT/TI)	81,3±6,8%

Tabla 7. Resultados del test de clasificación con RNA, para el mejor conjunto de variables para el caso “Fracaso Vs Reintubados” obtenidas después de la reducción de dimensionalidad.

Base de datos	Características	Resultado de la prueba
BD1	χ (CD2-RR)	75,3±11,3%
BD1	χ (CD2-RR), S(CD2-RR)	80,1±10.6%
DB2	Fp(f/VT), Ap(f/VT), Ap(TE), Ap(TI/TTot), P(f/VT)	76±10,8%
BD2	Fp(f/VT), Ap(f/VT), Ap(TE), Ap(TI/TTot)	75±11%

4. Resultados

La red entrenada con el conjunto completo de 40 características obtenidas a partir del análisis tiempo-frecuencia obtuvo un porcentaje de clasificados correctamente del 80,7% para el grupo Éxito-Fracaso, 82,64% para el grupo Éxito-Reintubado y 74,9% para Fracaso-Reintubado. Después de aplicada la selección de características, se obtuvo un porcentaje del 84.6% para el grupo Éxito-Fracaso, 86,9% para el grupo Éxito-Reintubado y 91,6% para Fracaso-Reintubado, utilizando únicamente dos, dos y trece de las 40 características.

La red entrenada con el conjunto completo de 32 características provenientes del análisis en frecuencia presenta porcentajes de clasificación entre 50% y 75% para los tres casos.

En la comparación entre grupos se aprecia que las características derivadas de la señal f/VT, y los valores Fp de las señales son las que más información aportan los clasificadores.

La mayor parte de información de las series temporales que mejor difieren los grupos está concentrada en las altas frecuencias, o lo que es lo mismo, tienden a quedar almacenada en los CD luego de una descomposición en tiempo-frecuencia.

5. Discusión Y Conclusiones

Las redes neuronales son una técnica muy sofisticada capaz de modelar funciones complejas de diversa índole. Conjuntamente con la técnica forward selection permite obtener un buen subconjunto de características de entrada a la misma.

Para un problema de clasificación como el presentado en este trabajo, se obtienen mejores resultados si los índices son extraídos de un análisis tiempo-frecuencia, permitiendo diferir mejor los patrones de las diferentes clases.

Los resultados de la clasificación aplicando análisis discriminante lineal en comparación con los presentados por parte de las redes neuronales reflejan lo robustas que pueden llegar a ser estas últimas en cuanto a clasificación se trata. A pesar de aplicar ambas técnicas un aprendizaje supervisado, la arquitectura de las redes neuronales les permite adaptarse a casi cualquier tipo de datos y manejar en buena medida el problema de generalización de datos.

Como futuras extensiones se pretenden realizar más aportaciones en la detección de nuevos índices y características que ayuden a mejorar la detección del momento óptimo de desconexión de pacientes sometidos a ventilación mecánica, haciendo uso de técnicas pertenecientes a la inteligencia artificial y estadística que día a día van tomando más fuerza para la aportación de información en el campo biomédico y solución de problemas en el mismo como lo son las máquinas de soporte vectorial entre otras.

Es necesario realizar un modelo con las más importantes características y estudiar la generalización del sistema. Por otra parte se podría incrementar el número de patrones en el conjunto de entrenamiento con el objetivo de minimizar el error de generalización.

6. Referencias

- [1] Christophe Girault, Isabelle Daudenthun, Virginie Chevron. Noninvasive Ventilation as a Systematic Extubation and Weaning Techniques in Acute-on-Chronic Respiratory Failures, *Am J. Respir Crit Care Med*, 1999, Vol. 160, pp 86-92.
- [2] Jiin-Chyr Hsu, Yung-Fu Chen, Hsuan-Hung Lin, ChiHsiang Li and Xiaoyi Jiang, .Construction of prediction module for successful ventilator weaning., *New Trends in Applied Artificial Intelligence*, 2007, pp. 766-775 .
- [3] Adrienne G. Randolph, David Wypij. Effect of Mechanical Ventilator Weaning Protocols on Respiratory Outcomes in Infants and Childres, *JAMA*, 2002;288(20):2561-2568 (doi:10.1001/jama.288.20.2561), 2002, Vol. 288, No. 20 2561
- [4] P. Casaseca de la Higuera, M Martín Fernández, C Alberola López. Weaning from mechanical ventilation: A retrospective analysis leading to a multimodal perspective, *IEEE Trans Biomed Eng*, Vol.53, 2006, 1330-45.
- [5] M.J. Tobin. Advances in mechanical ventilation, *N. Engl. J. Med*, 2001, Vol. 344, N. 26, pp 766-775.
- [6] G. Benchetrit, Breathing pattern in humans: diversity and individuality, *Respiration Physiology*, 122, pp. 123-129, 2000.
- [7] P. Caminal, L. Domingo, B.F. Giraldo, M. Vallverdú, S. Benito, G.Vázquez, D. Kaplan. Variability analysis of the respiratory volume based on nonlinear prediction methods, *Medical & Biological Engineering & Computing*, 42, pp. 86-91, 2004.
- [8] E.N. Bruce, Measures of respiratory pattern variability, in *Bioengineering approaches to pulmonary physiology and medicine*, Plenum Press, pp. 149–160, 1996.
- [9] M.C.Khoo, Determinants of ventilatory instability and variability, *Respiratory physiology*, 122, pp. 167–182, 2000.
- [10] Sergio Cerutti, Anna Bianchi, Harald Reiter. Analysis of sleep and stress profiles from biomedical signal processing in wearable devices. *Proceedings of the 28th IEEE MBS Annual International Conference*, New York City, USA, 2006.
- [11] Hsiu-Nien Shen, Lian-Yu Lin. Changes of Heart Rate Variability During Ventilator Weaning. *Chest* 2003;123;1222-1228 (doi 10.1378/chest.123.4.1222).
- [12] Michael R. Pinsky. Cardiovascular issues in respiratory care, *Chest*, 2005, 128, pp. 592-597.