

Análisis HRV en la Detección de Somnolencias en Conductores

J. Vicente^{1,2}, P. Laguna^{1,2}, A. Bartra³, R. Bailón^{1,2}

¹ Grupo de Tecnologías de las Comunicaciones, Instituto de Investigación en Ingeniería de Aragón, Universidad de Zaragoza, Zaragoza, España, pepo.vicente@unizar.es

² CIBER de Bioingeniería, Biomateriales y Nanomedicina (CIBER-BBN), España

³ Ficomirrors, Ficosa International, Barcelona, España

Resumen

Se estima que entorno al 10-30% de los accidentes con víctimas mortales en carretera están relacionados con conductores somnolientos o fatigados. La detección de somnolencias en conductores, basada tanto en señales biológicas como del vehículo, está siendo investigada en la seguridad preventiva en automóviles. La actividad del Sistema Nervioso Autónomo (SNA), que puede ser medida de forma no invasiva a partir de la Variabilidad del Ritmo Cardíaco (HRV) obtenida del ECG de superficie, presenta alteraciones durante episodios de estrés, fatiga extrema y somnolencia. Nuestra hipótesis es que estas alteraciones del SNA se manifiestan en la HRV. En este trabajo hemos desarrollado un detector en línea de somnolencias de conductores basado en el análisis de la HRV. Se han analizado dos bases de datos proporcionadas por la empresa Ficomirrors: una de simulación de conducción, en la que los sujetos presentan diferentes niveles de privación de sueño, y otra de conducción en carretera sin privación de sueño. Cada minuto de los registros fue anotado como despierto o somnoliento por un observador externo y constituye nuestra referencia. El detector propuesto clasifica los minutos de somnolencias con una sensibilidad de 0.85 y un valor predictivo positivo de 0.93 utilizando 25 características.

1. Introducción

Durante 2009 en España se produjeron 1690 accidentes mortales en carretera [1], y un total de 96.445 en los 33 países miembros de International Road Traffic and Accident Database (IRTAD) [2]. Investigaciones previas estiman que entorno al 10-30% de estos accidentes están relacionados con conductores somnolientos o fatigados [2, 3]. Es por esto que la detección de las somnolencias del conductor es un reto tan importante en la seguridad preventiva en vehículos.

El electroencefalograma (EEG) es la señal usada mayoritariamente para analizar el nivel de relajación de un sujeto. Sin embargo, la necesidad de emplear incómodos electrodos de contacto en la cabeza del sujeto hace que esta técnica no sea apropiada como parte de un sistema de seguridad en escenarios reales de conducción, por lo que otras señales biológicas y del propio vehículo están siendo estudiadas.

La actividad del Sistema Nervioso Autónomo (SNA) presenta alteraciones durante episodios de estrés, fatiga extrema y somnolencia [4]. Los estados de vigilia se caracterizan por un incremento en la actividad simpática

del SNA y/o un decremento de la actividad parasimpática, mientras que los estados de relajación extrema se caracterizan por un incremento de la actividad parasimpática y/o un decremento de la actividad simpática [4, 5]. La actividad del SNA puede medirse de forma no invasiva a partir de la señal de Variabilidad del Ritmo Cardíaco (HRV) obtenida del ECG de superficie. La potencia en la banda de baja frecuencia (LF) (0.04-0.15Hz) es considerada principalmente como una medida de la actividad simpática, mientras que la potencia en la banda de alta frecuencia (HF) (0.15-0.4Hz) es considerada de origen parasimpático en el análisis de HRV clásico [6]. El balance entre los sistemas simpático y parasimpático es medido por el cociente LF/HF.

El dominio del sistema simpático que caracteriza los estados de vigilia decrece durante el sueño no-REM, y crece de nuevo casi hasta los niveles de vigilia durante el sueño REM [7]. La HRV ha sido también estudiada en las transiciones de estados de vigilia a estados de relajación extrema. Se ha observado un decremento en el ritmo cardíaco (HR) y en la HRV al comienzo del sueño. El periodo de transición se caracteriza por un decremento en la oscilación de la muy baja frecuencia (VLF) del HR que anticipa un cambio en el cociente LF/HF hacia un predominio parasimpático [8].

El objetivo de este trabajo es desarrollar un detector en línea de somnolencias del conductor basado en el análisis de HRV.

2. Materiales

Para el desarrollo y validación del detector se han utilizado dos bases de datos facilitadas por FICO MIRRORS S.A.:

- Conducción en Simulador (SDDDB): Consiste en 11 registros de 120 minutos de duración en un entorno de conducción simulada. El simulador fue construido en colaboración con un proveedor especializado en ensayos, siguiendo protocolos bien definidos que asegurasen el control y la repetitividad. Los sujetos participantes en estos ensayos siguieron un protocolo de privación de sueño de entre 7 y 26 horas previas a la prueba. Tras una calibración inicial, los sujetos realizaron una prueba de conducción de unas 2 horas. Durante los últimos 15 minutos el simulador se apagó y la adquisición de señales se mantuvo, permitiendo descansar a la mayoría de los

sujetos con las luces apagadas. Un ECG de 2 derivaciones fue registrado con una frecuencia de muestreo de 256 Hz junto con otras señales no utilizadas en este estudio. El estado de los conductores puede calcularse a partir del porcentaje de cierre del ojo (PERCLOS), de las grabaciones en vídeo, de los errores de conducción reportados por el simulador, de las anotaciones de un experto basadas en la grabación del EEG, y de las anotaciones de un observador externo. Las anotaciones del observador externo, que clasificó cada minuto como somnoliento (S), fatigado o de sperto (D), han sido utilizadas como referencia en este estudio para validar el detector.

• **Conducción Real (RDDDB):** Consiste en 10 registros de unas 6 horas de duración obtenidos de conductores profesionales en una situación de conducción cotidiana: sujetos conduciendo un vehículo en autovía o carretera durante una jornada laboral. Los sujetos no presentan privación de sueño, y tuvieron que realizar paradas al menos cada 2 horas. Un ECG de 2 derivaciones fue registrado a una frecuencia de muestreo de 256 Hz junto con otras señales no utilizadas en este estudio. En este caso sólo están disponibles la información de PERCLOS y las anotaciones del observador externo que, al igual que en SDDB, constituye nuestra referencia.

3. Métodos

3.1. Descripción del sistema

Nuestro sistema trabaja analizando una ventana deslizante de 5 minutos de ECG y genera una salida cada minuto. La ventana se alimenta y desliza minuto a minuto. El sistema está compuesto por los siguientes subsistemas/pasos como muestra la Figura 1:

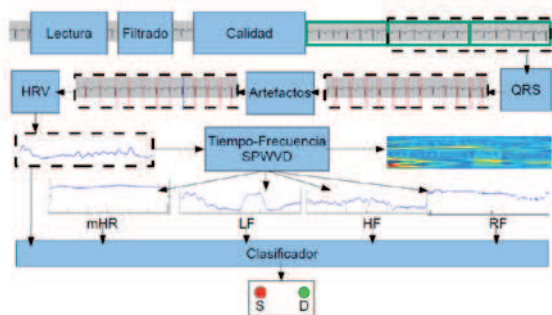


Figura 1. Componentes del sistema

- Lectura de datos
- Filtrado de las interferencias de línea base y red eléctrica.
- Cuantificación de la calidad de cada segmento (minuto), descartando del análisis posterior aquellos con calidad muy baja (que pueden corresponder con pérdida de señal o saturación). Detalles en la sección 3.2
- Detección de complejos QRS utilizando el delineador descrito en [9]. Previamente las señales ECG fueron remuestreadas a 500 Hz para cumplir con los requisitos del delineador.

- Artefactos: identifica latidos ectópicos y falsas detecciones siguiendo el algoritmo descrito en [10].
- Estimación de la señal HRV usando el algoritmo basado en el modelo IPFM descrito en [11].
- Análisis tiempo-frecuencia de la señal HRV utilizando la Distribución PseudoWigner-Ville Suavizada (SPWVD), que permite filtrados independientes en tiempo y frecuencia, tal como se describe en [12].
- Extracción de características, descrito en la sección 3.3, calcula parámetros de HRV a partir de la SPWVD.
- El bloque de clasificación utiliza un análisis lineal discriminante (LDA) para clasificar cada minuto como despierto (D) o somnoliento (S), detallado en la sección 3.4

3.2. Bloque de calificación de la calidad de la señal

La calificación de la calidad de la señal se hace en dos pasos. En el primero se caracteriza el i -ésimo minuto del ECG que entra al sistema calculando el valor definido por la función f_i

$$f_i(x_i(n)) = \begin{cases} \sqrt{\frac{1}{L} \sum_{n=0}^{L-1} |x_i(n) - \bar{x}_i|^2} & \text{if } \frac{\max(|x_i(n)|)}{|\bar{x}_i|} \leq T_h \\ 0 & \text{if } \frac{\max(|x_i(n)|)}{|\bar{x}_i|} > T_h \end{cases} \quad (1)$$

donde T_h es un umbral definido experimentalmente, $x_i(n)$ es el segmento de ECG correspondiente al i -ésimo minuto y \bar{x}_i es la media de $x_i(n)$. En este trabajo $T_h = 30 \mu\text{V}$.

El segundo paso califica la calidad del nuevo minuto con uno de los siguientes valores: Excelente, Buena, Pobre o Mala. Hemos definido dos umbrales $C_1=40 \mu\text{V}$ y $C_2=5000 \mu\text{V}$ tales que si $f_i < C_1$ ó $f_i \geq C_2$ entonces la calidad del nuevo minuto es calificada como Mala, en otro caso la calificación se asigna mediante la función de calificación definida en (2),

$$g_i(g_i) = \begin{cases} \text{Excelente} & \text{if } g_i < E_1 \\ \text{Buena} & \text{if } E_1 \leq g_i < E_2 \\ \text{Pobre} & \text{if } E_2 \leq g_i < E_3 \\ \text{Mala} & \text{if } g_i \geq E_3 \end{cases} \quad (2)$$

donde

$$g_i = f_i - \sum_{k=1}^{i-1} \frac{f_k}{i-1}$$

y E_i son umbrales ajustados experimentalmente con valores $E_1=60 \mu\text{V}$, $E_2=125 \mu\text{V}$, $E_3=300 \mu\text{V}$.

3.3. Extracción de características

El ritmo cardíaco (HR) instantáneo es filtrado paso-bajo con una frecuencia de corte de 0.03 Hz y constituye el HR medio tiempo-variante. Las potencias instantáneas en las bandas de LF y HF se calcularon integrando, para cada instante de tiempo, la SPWVD de la señal HRV en las bandas correspondientes. El cociente LF/HF también se calculó. La potencia de LF y HF fue entonces normalizada dividiéndola por la suma de las potencias en LF y HF. Por último, la frecuencia respiratoria (RF) se

estimó como la frecuencia en la que se encuentra el pico máximo de la SPWVD en la banda de HF para cada instante de tiempo [13].

Dado que las anotaciones del estado del conductor están sólo disponibles para un minuto completo, se calcularon para cada minuto la media, desviación típica (SD), mediana, desviación mediana absoluta (MAD), valores mínimo y máximo de los parámetros instantáneos definidos previamente. El valor medio de los tres primeros minutos de cada característica se consideró como línea base y fue sustraído de los valores de los minutos siguientes. Además de esta normalización respecto de los tres primeros minutos, también se calculó la diferencia del valor de cada característica respecto del valor en el minuto anterior. Estos valores por minuto constituyen el conjunto de características.

3.4. Clasificación

El clasificador está basado en LDA utilizando la estrategia leave-one-out para obtener los coeficientes de las funciones discriminantes y evaluar su rendimiento. Para la selección de características se ha utilizado el criterio de minimización de la lambda de Wilks.

Para el entrenamiento se han utilizado tres escenarios diferentes: entrenamiento con SDDB, entrenamiento con RDDB y entrenamiento con las dos bases de datos juntas. El rendimiento se evaluó sobre las tres bases de datos (SDDB, RDDB y SDDB∪RDDB) para cada escenario. Las medidas de rendimiento valor predictivo positivo (P+) y sensibilidad (Se) se calcularon tras balancear la matriz de confusión. Nuestro objetivo era identificar estados del conductor no aptos para la conducción, por lo que los estados somnoliento y fatigado se consideraron iguales en la referencia renombrando ambos casos como somnoliento. La Tabla 1 muestra el total de episodios anotados en cada base de datos.

Base de datos	D	S
SDDB	60	1153
RDDB	2102	510
Total	2162	1663

Tabla 1. Número de episodios anotados

4. Resultados

- Entrenamiento con SDDB: los sujetos de la base de datos SDDB presentaban privación de sueño, por lo que la referencia presenta más minutos anotados como fatigado o somnoliento que anotados como despierto. Siete características fueron seleccionadas. Las cinco más significativas son: mínimo de RF referenciada a los 3 primeros minutos (RF3Min), máximo del HR medio referenciado a los 3 primeros minutos (mHR3max), mediana de LF normalizada referenciada a los 3 primeros minutos (LF3nuMed), mediana de LF normalizada (LFnuMed) y máximo del HR medio (mHRMax). La Tabla 2 muestra el rendimiento.

Base de datos	nº de características	P+	Se
SDDB	7	0.663	0.4987
RDDB	7	0.3867	0.4196
SDDB∪RDDB	7	0.4205	0.4746

Tabla 2. Rendimientos clasificador entrenado con SDDB

- Entrenamiento con RDDB: los sujetos de la base de datos RDDB no siguieron ningún protocolo de privación de sueño, y la referencia presenta anotaciones de estado despierto en la mayoría de los minutos. Esto es cierto para todos los sujetos excepto el 052, que paró a dormir después de la primera hora de conducción. Se seleccionaron 12 características, siendo las cinco más significativas: media de RF referenciada a los 3 primeros minutos (RF3Mean), RF3Min, media de RF (RFMean), mínimo de RF (RFMin) y mediana de LF normalizada (LFnuMed). El rendimiento se muestra en la Tabla 3.

Base de datos	nº de características	P+	Se
SDDB	12	0.4707	0.7112
RDDB	12	0.8826	0.6941
SDDB∪RDDB	12	0.8631	0.7058

Tabla 3. Rendimientos clasificador entrenado con RDDB

- Entrenamiento con SDDB∪RDDB: La base de datos resultante de unir ambas bases de datos presenta un equilibrio entre las anotaciones de estados despierto y somnoliento en la referencia. 25 características fueron seleccionadas. Las cinco más significativas: RF3Mean, RFMean, RF3Min, RFMin y LFnuMed. La Tabla 4 muestra el rendimiento obtenido.

Base de datos	nº de características	P+	Se
SDDB	25	0.4943	0.9775
RDDB	25	0.9406	0.4723
SDDB∪RDDB	25	0.9313	0.8534

Tabla 4. Rendimientos clasificador entrenado con SDDB∪RDDB

Las figuras 2a y 2b muestran detalles de la clasificación de dos sujetos, uno de SDDB y otro de RDDB. Los segmentos de ECG de calidad Mala, en color rojo, son descartados y no muestran referencia ni predicción en sus posiciones. La Tabla 5 muestra la media (μ) y desviación estándar (σ) de las características más significativas.

5. Discusión y conclusiones

Antes de implementar el clasificador se analizaron las características de todos los sujetos junto con la referencia buscando patrones como los descritos en trabajos previos [4, 5]. Nos centramos en la caracterización de minutos completos en lugar de eventos instantáneos. No encontramos patrones relevantes antes de los cambios de estado.

El mejor rendimiento se consiguió utilizando ambas bases de datos para el entrenamiento, por lo que incluir sujetos

sin privación de sueño es importante para obtener clasificadores fiables.

Las características más significativas en la Tabla 5 muestran una RF más baja y estable en estados S, lo que puede reflejar una predominancia de la actividad parasimpática. Los estados D presentan una LF mayor y más estable, que puede asociarse con la vigilia.

Característica	Estado	$\mu \pm \sigma$
RF3Min	D	-0.0778 ± 0.1281 Hz
	S	-0.0749 ± 0.696 Hz
RF3Mean	D	0.0586 ± 0.0895 Hz
	S	-0.0232 ± 0.0664 Hz
RFMean	D	0.3223 ± 0.1017 Hz
	S	0.2982 ± 0.0713 Hz
RFMin	D	0.2951 ± 0.0895 Hz
	S	0.2792 ± 0.0734 Hz
LFnuMed	D	65.1050 ± 15.6273 %
	S	64.2910 ± 18.8805 %

Tabla 5. Características más significativas




Figura 2. Detalle de calidad de señal y clasificación de: a) sujeto 18 de SDDB y b) Sujeto 56 de RDDB. Anotaciones de la referencia (O) y predicción (X). Calidad: Mala (rojo), Baja (azul), Buena (Verde) o Excelente (Verde).

La Fig. 2a muestra que el clasificador sobreestima los estados de somnolencia en sujetos con privación de sueño. La Fig. 2b muestra la subestimación de somnolencias en sujetos sin privación de sueño. Estos resultados sugieren que el clasificador identifica el estado global del sujeto como apto para conducir o no. Aunque el principio y el final de episodios aislados de somnolencia no son identificados con precisión en sujetos sin privación de sueño, en general el detector es capaz de identificar algunos minutos aislados de episodios tanto de somnolencia como de vigilia.

Agradecimientos

Este trabajo ha sido financiado por el Ministerio de Ciencia e Innovación bajo los proyectos TEC2010-21703-C03-02 y TRA2009-0127, por la Diputación general de Aragón a través del Grupo Consolidado GTC Ref.: T30, y por el Instituto de la Salud Carlos III mediante CIBER CB06/01/0062.

Referencias

- [1] Ministerio del Interior. Accidentes mortales en carretera 2009. En Dirección General de Tráfico. España, 2010; .
- [2] Wegman F. Annual report. In IRTAD Road safety 2010. International Traffic Safety Data and Analysis Group, 2010; 278.
- [3] Ministerio del Interior. La fatiga causa el 30% de los accidentes de tráfico en España. En Nota de Prensa. Dirección General de Tráfico, España, 2008; 1–2.
- [4] Michail E, Kokonozi A, Chouvarda I, Maglaveras N. EEG and HRV markers of sleepiness and loss of control during car driving. In Engineering in Medicine and Biology Society, 2008. EMBS 2008. 30th Annual International Conference of the IEEE. 2008; 2566–2569.
- [5] Furman G, Baharav A, Cahan C, Akselrod S. Early detection of falling asleep at the wheel: A heart rate variability approach. En Computers in Cardiology, 2008; 1109–1112.
- [6] TASK FORCE OF ESC AND NASPE. Heart rate variability: Standards of measurement, physiological interpretation, and clinical use. Circulation 1996; vol 93(5):1043–1065.
- [7] Baharav A, Kotagal S, Gibbons V, Rubin BK, Pratt G, Karin J, Akselrod S. Fluctuations in autonomic nervous activity during sleep displayed by power spectrum analysis of heart rate variability. Neurology 1995;45(6):1183–1187.
- [8] Shinar Z, Akselrod S, Dagan Y, Baharav A. Autonomic changes during wake-sleep transition: a heart rate variability based approach. Auton Neurosci 2006; 130:17–27.
- [9] Martínez J, Almeida R, Olmos S, Rocha A, Laguna P. A wavelet-based ecg delineator: evaluation on standard databases. Biomedical Engineering IEEE Transactions on april 2004;51(4):570–581.
- [10] Mateo J, Laguna P. Analysis of heart rate variability in the presence of ectopic beats using the heart timing signal. Biomedical Engineering IEEE Transactions on march 2003;50(3):334–343.
- [11] Mateo J, Laguna P. Improved heart rate variability signal analysis from the beat occurrence times according to the ipfm model. Biomedical Engineering IEEE Transactions on aug. 2000;47(8):985–996.
- [12] Bailón R, Laouini G, Grao C, Orini M, Laguna P, Meste O. The integral pulse frequency modulation model with time-varying threshold: Application to heart rate variability analysis during exercise stress testing. IEEE transaction On Biomedical Engineering 2011;58(3):642–652.
- [13] Bailón R, Mainardi L, Orini M, Sörnmo L, Laguna P. Analysis of heart rate variability during exercise stress testing using respiratory information. Biomedical Signal Processing and Control 2010;5(4):299–310.