

Teoría y Aplicaciones en Probabilidad y Estadística

Editores:

Fernando Velasco Luna

Víctor Hugo Vázquez Guevara

Francisco Solano Tajonar Sanabria

Hortensia Josefina Reyes Cervantes

Bulmaro Juárez Hernández

Hugo Adán Cruz Suárez



Teoría y Aplicaciones en Probabilidad y Estadística

Teoría y Aplicaciones en Probabilidad y Estadística

Editores:

Fernando Velasco Luna

Víctor Hugo Vázquez Guevara

Francisco Solano Tajonar Sanabria

Hortensia Josefina Reyes Cervantes

Bulmaro Juárez Hernández

Hugo Adán Cruz Suárez

Benemérita Universidad Autónoma de Puebla
2022

PRÓLOGO

El Cuerpo Académico de Probabilidad y Estadística, perteneciente a la Facultad de Ciencias Físico Matemáticas de la Benemérita Universidad Autónoma de Puebla pone a disposición de todos los interesados la edición del libro “***Teoría y Aplicaciones en Probabilidad y Estadística***”. Esta obra recopila las investigaciones realizadas por investigadores y académicos de diferentes instituciones de Educación Superior, tanto nacionales como internacionales, se abarcan distintas áreas del conocimiento relacionadas con temáticas diversas de Probabilidad y Estadística. Este libro consta de 16 capítulos en los cuales se tratan temas de aplicaciones y trabajos teóricos, hay seis de ellos en el área de Probabilidad y diez en el área de Estadística.

El contenido del libro está elaborado por trabajos inéditos aportados por los autores, después de haber sido sometidos a una rigurosa revisión arbitrada, tanto en forma parcial de cada capítulo para ser parte de la edición como capítulos de libro, así como arbitraje general de la obra. Se les agradece a los árbitros el gran esfuerzo que hicieron con sus sugerencias en el trabajo final de esta obra.

Atentamente.
Los editores.

Benemérita Universidad Autónoma de Puebla
Rectora: Ma. Lilia Cedillo Ramírez
Secretaria General: José Manuel Alonso Orozco
Vicerrector de Extensión y Difusión de la Cultura: José Carlos Bernal Suárez
Dirección General de Publicaciones: Luis Antonio Lucio Venegas

Primera edición: 2022
ISBN: 978-607-525-933-8

DR © Benemérita Universidad Autónoma de Puebla
4 sur 104, Col. Centro Histórico, Puebla, Pue. CP 72000
Teléfono: 222 229 55 00
www.buap.mx

DR© Dirección General de Publicaciones
2 norte 1404, Centro Histórico, Puebla, Pue., cp 72000
Tels.: 01 (222) 246 85 59 y 01 (222) 229 55 00, exts. 5768
www.dgp.buap.mx | dgp@correo.buap.mx
publicaciones.buap.mx

Diseño de portada: Fernando Velasco Luna

Impreso y hecho en México
Printed and made in Mexico

ÍNDICE GENERAL

Capítulo 1	1
Detección de fibrilación auricular en electrocardiogramas de corta duración	
Marco Scavino, Virginia Estragó, Matías Muñoz Wolf, Andrés Castrillejo, Ramón Álvarez-Vaz	
Capítulo 2	14
Características sociodemográficas de las jóvenes que tuvieron más de un embarazo durante su adolescencia	
Catherine Menkes B., Itzel A. Sosa S.	
Capítulo 3	24
El Problema de la Ruina del Jugador	
Francisco Solano Tajonar Sanabria, María Cristina Medel López, Fernando Velasco Luna, Hortensia J. Reyes Cervantes	
Capítulo 4	45
Años Potenciales de Vida Perdidos por Siniestros de Tránsito	
Gonzalo De Armas, Ramón Álvarez-Vaz, Mauro Loprete	
Capítulo 5	61
Factores de riesgo asociados a las muertes por COVID-19 en México: un análisis de supervivencia	
Eduardo Pérez-Castro, María Guzmán-Martínez, Flaviano Godínez-Jaimes, Ramón Reyes-Carreto, Cruz Vargas-De-León	
Capítulo 6	76
CPO-grama: una herramienta de visualización a través del análisis de datos Composicionales para la estructura multivariante de los componentes del CPO	
Ramón Álvarez-Vaz, Fernando Massa, Matías Muñoz Wolf	

Capítulo 7	91
¿El embarazo de las adolescentes mexicanas cuenta con la aprobación de su pareja y de su familia?	
Catherine Menkes, David De Jesús-Reyes, Olga Serrano, Leopoldo Núñez	
Capítulo 8	101
Medidas de desigualdad en salud bucal: una experiencia para los escolares de 12 años de la ciudad de Montevideo, Uruguay	
Ramón Álvarez-Vaz, Mikaela Lezcano	
Capítulo 9	117
Optimalidad de Políticas (s; S) para un Modelo de Inventario vía la Teoría de los Procesos de Decisión de Markov.	
Karla Carrero-Vera, Hugo Cruz-Suárez, Raúl Montes-de-Oca	
Capítulo 10.....	136
Modelos GAMLSS: una alternativa para la modelización de la Espirometría en Niños Uruguayos	
Pablo Palamarchuk, Ramón Álvarez-Vaz	
Capítulo 11	152
Aplicación del modelo de regresión logística múltiple en el análisis de variables asociadas al consumo de drogas, legales e ilegales.	
Olga V. Serrano Sánchez, Carolina Espinosa Luna	
Capítulo 12.....	166
Clasificación de pacientes hospitalizados con COVID-19 según tengan respiración asistida	
Ana Cecilia Caiseros Lagunes, Francisco Sergio Salem Silva, Juana Elisa Escalante Vega	
Capítulo 13	185
Uso de la Teoría Ergódica para la revisión y remodelación de algunos modelos de decisiones económicas	
Martín Pérez-Vidal, Hortensia Reyes-Cervantes, Sergio Adán Juárez, Francisco Tajonar-Sanabria	

Capítulo 14.....	198
Analisis, usando el factor de Bayes, para múltiples puntos de cambio temporales de un conjunto de datos simulados con un proceso Poisson	
Bulmaro Juárez-Hernández, Luis Felipe Munguía acá, Víctor Hugo Vázquez-Guevara	
Capítulo 15	209
Un ejemplo de una línea de espera controlada: Aspectos teóricos y numéricos	
Gustavo Portillo-Ramírez, Hugo Cruz-Suárez, Fernando Velasco-Luna	
Capítulo 16.....	220
El problema de Consumo e Inversión a través de un Proceso de Decisión de Markov con Factor de Descuento Variable y Horizonte Aleatorio	
Octavio Paredes-Pérez, Víctor Hugo Vázquez-Guevara, Hugo Cruz-Suárez, Bulmaro Juárez Hernández	

Capítulo 1

Detección de fibrilación auricular en electrocardiogramas de corta duración

**Marco Scavino¹, Virginia Estragó², Matías Muñoz Wolf³, Andrés Castrillejo⁴,
Ramón Álvarez-Vaz⁵**

^{1,4,5}*Instituto de Estadística (IESTA), Facultad de Ciencias Económicas y de
Administración, Universidad de la República, Uruguay*

^{2,3}*Comisión Honoraria para la Salud Cardiovascular (CHSCV), Presidencia de la
República, Uruguay*

marco.scavino@fcea.edu.uy, vikyestrango@gmail.com ,
matias.mw@gmail.com , castrillejoandres@gmail.com, ramon.alvarez@fcea.edu.uy

Resumen. En este capítulo se presentan los lineamientos generales para la aplicación de dos algoritmos de aprendizaje automático para la identificación de una patología cardíaca, la fibrilación auricular (FA), a partir de la señal electrocardiográfica (ECG) de una derivación y de corta duración registrada con un dispositivo móvil de tecnología electrónica (DMTE). Visto la importancia del diagnóstico temprano de patologías cardiovasculares tales como la FA, nuestro objetivo es mejorar la capacidad de clasificación del DMTE el cual, en la práctica, deja sin clasificar un conjunto relevante de registros de ECG. Se analiza el desempeño de técnicas de clasificación supervisada tales como árboles generados por partición recursiva y los bosques aleatorios, empleadas en combinación con métodos de extracción de características de la señal ECG, aplicadas a un banco de entrenamiento internacional y a un conjunto de prueba nacional de registros de ECG, generado en 2019, de una población adulta mayor del Uruguay, en virtud de una colaboración entre la CHSCV y el Plan Ibirapitá. Los resultados obtenidos se interpretan a través de los diagnósticos disponibles de los ECG realizados por expertos cardiólogos clínicos.

Abstract. In this chapter, we present the general guidelines in the application of two machine learning algorithms to detect a common cardiac arrhythmia, atrial fibrillation (AF), when employing short-duration recordings taken through a portable single-lead electrocardiographic (ECG) electronic device. Due to the importance of the early diagnosis of cardiovascular pathologies such as AF, our goal is to improve the classification performance of the mobile device that, in practice, leaves a relevant set of ECG recordings unclassified. We analyze the performance of supervised classification techniques such as recursive partitioning and random forests in combination with ECG signal feature extraction methods. Our methodology applies to an international ECG training set and a national test set of ECG recordings generated in 2019 for the elder adult population of Uruguay, under a collaboration between the CHSCV and the Ibirapitá Plan. The available diagnoses of the ECG signals performed by expert clinical cardiologists allow the interpretation of the obtained results.

Palabras clave: Fibrilación Auricular, Electrocardiograma, Dispositivo Móvil de Tecnología Electrónica, Clasificación supervisada.

1.1. Introducción

La fibrilación auricular (FA) es un trastorno del ritmo cardíaco frecuente en el adulto y cuya prevalencia aumenta con la edad [1]. Entre sus implicancias clínicas, la FA se asocia al accidente cardiovascular, entre 20 % y 30 % de los pacientes con ictus isquémico tienen un diagnóstico de FA antes, durante o después del evento inicial de accidente cerebrovascular [2]. La FA puede cursar de forma asintomática pero exponer a quien la padece a un riesgo significativo de morbimortalidad y por esa razón es relevante diagnosticar esta arritmia, y contar con un método de detección que sea rápido, accesible, inocuo, de bajo costo y que pueda superar barreras geográficas.

La contracción cardíaca requiere de un sistema de estimulación y conducción eléctrica que está compuesto por fibras especializadas a nivel del corazón. El electrocardiograma (ECG) es el registro gráfico de los potenciales eléctricos que genera el corazón y representa el funcionamiento del corazón. Cualquier comportamiento anormal en la señal de ECG es una medida indicativa de un mal funcionamiento del corazón, denominado condición de arritmia. El ECG de 12 derivaciones se considera el patrón oro para el diagnóstico de muchas enfermedades cardiovasculares, entre ellas la FA. Sin embargo, cabe observar que es posible llegar al diagnóstico de FA con el registro de ECG de una sola derivación.

El trazado de un ECG representa el voltaje de la actividad eléctrica del corazón en función del tiempo. El registro de un ciclo cardíaco normal (ver Figura 1.1 más abajo) se compone de una onda P, que corresponde a la activación auricular, un complejo QRS, asociado a la fase de despolarización ventricular, y una onda T, que corresponde a la fase de repolarización ventricular. La medida del intervalo RR, que es el tiempo que transcurre desde el inicio de una onda R hasta el inicio de la onda siguiente, es clínicamente relevante. También son clínicamente relevantes la medida del intervalo PR que se mide desde el inicio de la onda P hasta el inicio del complejo QRS, el intervalo QRS que incluye al conjunto de ondas que conforman el complejo QRS, y el intervalo QT que se mide desde el inicio del complejo QRS hasta el final de la onda T ([3], [4]).

En un ritmo normal se observa la regularidad de los intervalos RR, cuya duración depende de la frecuencia cardíaca. Mientras que, en términos generales, la FA puede ser detectada debido a la presencia de intervalos RR irregulares, y a la ausencia de onda P (entre otros aspectos [5]).

Hoy en día es posible detectar la FA utilizando dispositivos móviles de tecnología electrónica (DMTE) que permiten grabar, almacenar y transmitir los registros de ECG en forma remota. Nuestro trabajo tiene el objetivo de validar la utilización de un DMTE para la detección de fibrilación auricular en un grupo de adultos mayores de Uruguay.

La colaboración entre la Comisión Honoraria para la Salud Cardiovascular (CHSCV) y el Plan Ibirapitá, que promueve la inclusión digital al servicio de las personas mayores con el fin de mejorar la inclusión social, la participación y la equidad,

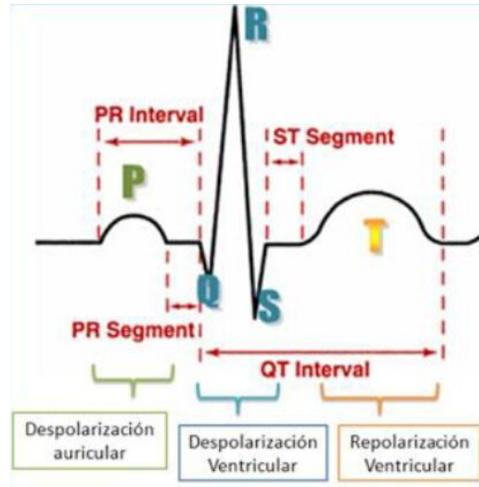


Figura 1.1: Esquemática de un latido en un ritmo cardíaco normal.

ha posibilitado la realización de talleres en los cuales centenares de personas han participado del estudio de tamizaje de FA apoyando el pulpejo de los dedos sobre las almohadillas del dispositivo y recibiendo su diagnóstico validado por expertos cardiólogos.



Figura 1.2: Dispositivo móvil de tecnología electrónica.

1.1.1. Banco de datos del plan piloto

En el ámbito de un plan piloto previo a la realización de los talleres CHSCV-Plan Ibirapitá, se obtuvieron los registros de ECG de 114 participantes tanto con el DM-

TE de una derivación y de corta duración (un sensor KardiaMobile de AliveCor[®] vinculado con una aplicación Kardia (Alivecor inc.) que se instala en smartphones) como con el ECG de doce derivaciones [6]. El dispositivo realiza registros de 30 segundos de duración y genera tres posibles diagnósticos automáticos, que son: normal, posible FA o sin clasificar.

Se ha constatado que el DMTE dejó sin clasificar el 18 % de los registros, los cuales sí fueron clasificados por el equipo de cardiólogos de la CHSCV, quienes emplearon el patrón de oro dado por el ECG de doce derivaciones.

Cuadro 1.1: Resultados del plan piloto.

	Posible FA	Normal	Sin Clasificar	Total
Con FA	4	0	1	5
Sin FA	3	86	20	109
Total	7	86	21	114

De aquí la importancia de desarrollar algoritmos de clasificación que, utilizando la salida del DMTE, permitan mejorar la capacidad de clasificación del dispositivo. A los efectos del posterior análisis estadístico, cada registro de salida del DMTE, de duración 30 segundos y frecuencia de muestreo 300 Hz, está sometido a un procedimiento de conversión, del original PDF a TSV (valores separados por tabuladores).



Figura 1.3: Salida original PDF del DMTE: parte del registro (110305).

De esta forma se obtuvieron 9000 pares de puntos por cada registro de ECG. En las Figuras 1.4 y 1.5 de la siguiente página se muestran algunos ejemplos de registros de ECG, clasificados y no clasificados por el DMTE, junto con el correspondiente diagnóstico de los cardiólogos.

Visto la relevancia clínica de los intervalos RR hemos empleado el algoritmo de Pan y Tompkins, que consta de una etapa de preprocesamiento y de otra basada en reglas de decisiones para la individuación del pico de la onda R en cada latido. Posteriormente, hemos utilizado dos técnicas de clasificación supervisada entrenadas con 3326 registros procedentes de la competencia Physionet 2017, y aplicadas

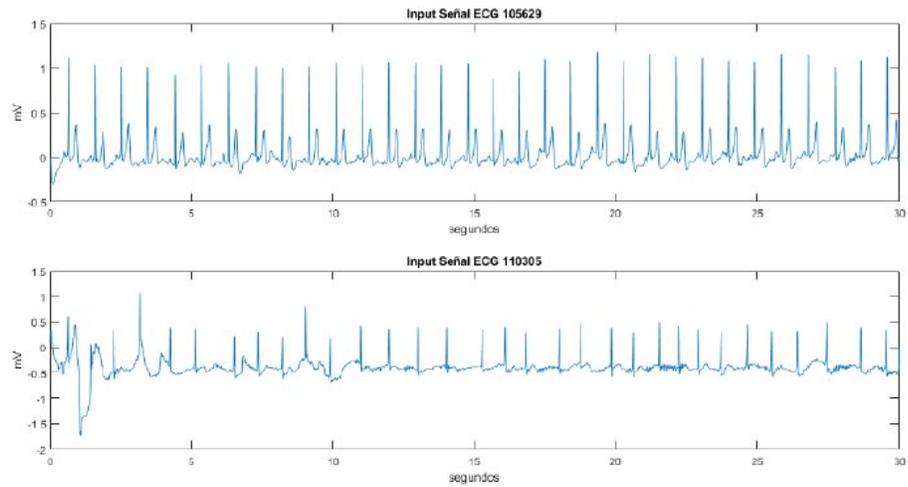


Figura 1.4: Cuadro superior: registro (105629) de ECG clasificado como normal por el DMTE y los expertos. Cuadro inferior: registro (110305) de ECG clasificado como FA por el dispositivo y los expertos.

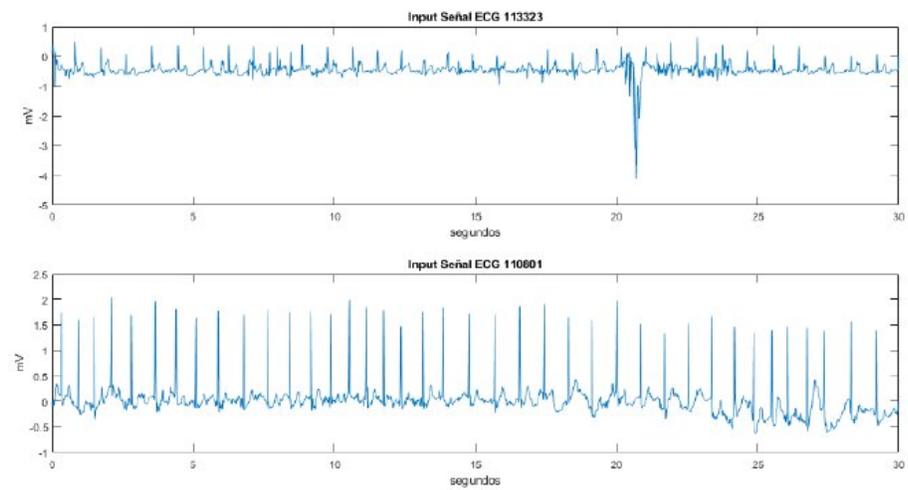


Figura 1.5: Cuadro superior: registro (113323) de ECG no clasificado por el dispositivo y clasificado como NO FA por los expertos. Cuadro inferior: registro (110801) de ECG no clasificado por el dispositivo y clasificado como FA por los expertos.

al conjunto de prueba del banco de datos del plan piloto nacional descrito anteriormente.

En este trabajo se introducen las principales características para el análisis de señales ECG de una derivación y de corta duración con la finalidad de detectar automáticamente un tipo de arritmia, la fibrilación auricular (FA). En la presente Sección 1 se ha planteado el problema de interés y la descripción del banco nacional de datos del plan piloto. La Sección 2 contiene la descripción del banco internacional de datos de entrenamiento y de los aspectos metodológicos esenciales que caracterizan este estudio. En la Sección 3 se presentan los resultados obtenidos empleando dos algoritmos de clasificación supervisada implementados en R [7]. Por último, las conclusiones del estudio.

1.2. Metodología

Se considera un conjunto de entrenamiento de 3326 registros de ECG de una sola derivación de duración 30 segundos (frecuencia de muestreo 300 Hz) seleccionados a partir del banco público de entrenamiento internacional de 8528 registros constituido para la competencia 2017 “PhysioNet/Computing in Cardiology (CinC)”, <https://physionet.org/content/challenge-2017/1.0.0/>, Clifford et al. [8]. De estos 3326 registros de ECG, 2932 son etiquetados como normales, los restantes 394 como FA.

1.2.1. Detección del complejo QRS

A los efectos de proponer un conjunto de rasgos característicos adecuado para discriminar entre registros de ECG normales y registros con FA, es necesario detectar el ciclo cardíaco, lo cual corresponde a la detección del complejo QRS de cada latido. La detección del complejo QRS, que permite ubicar el punto (o pico) R de cada latido, puede llevarse a cabo aplicando el algoritmo de Pan y Tompkins (1985) [9]. Este algoritmo consiste primero en una etapa de preprocesamiento de la señal ECG y en otra etapa decisional basadas en umbrales adaptativos. La etapa de preprocesamiento consiste en los siguientes cuatro pasos:

- Filtrado pasa-banda: pasa-abajo y pasa-alto en cascada, para aislar la energía QRS predominante centrada en 10 Hz, atenuando las bajas frecuencias características de las ondas P y T y la deriva de la línea base.
- Filtro derivador: destacar las pendientes rápidas de la señal, que, en el caso de la señal ECG, coincide con el complejo QRS.
- Transformación no lineal: se eleva al cuadrado la señal, convirtiéndola en positiva. Se destacan las frecuencias más altas en la señal, que se deben principalmente al complejo QRS.
- Integrador con ventana móvil para incluir una medida del ancho del complejo QRS en la señal procesada.

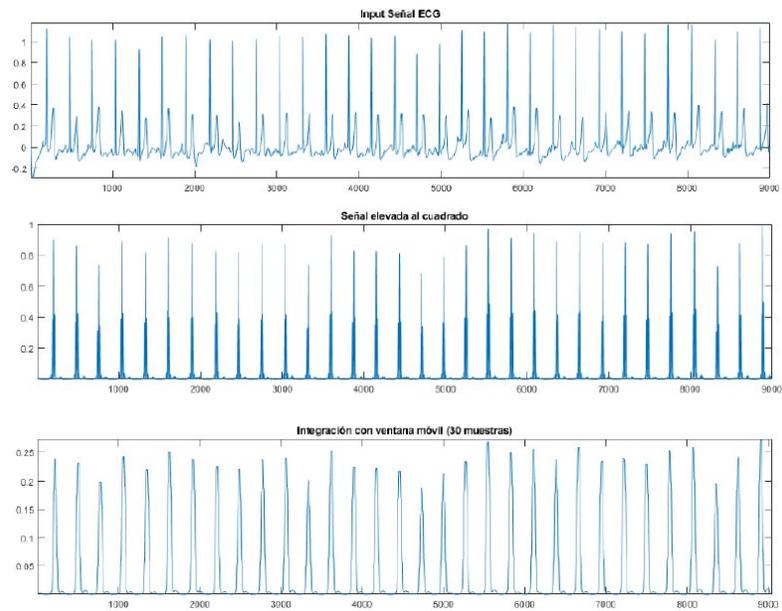


Figura 1.6: Etapa de preprocesamiento del algoritmo de Pan y Tompkins.

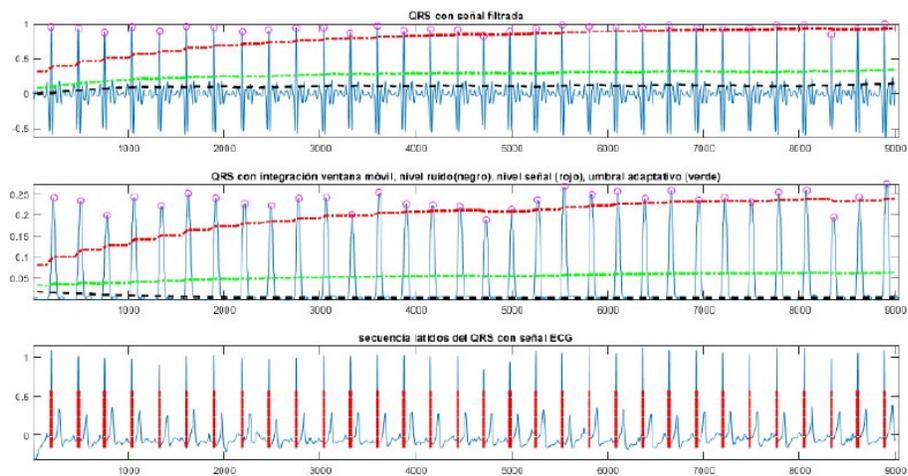


Figura 1.7: Detección de los picos R a través del algoritmo de Pan y Tompkins.

1.2.2. Conjunto de rasgos característicos y técnicas de clasificación supervisada

Una vez ubicados los puntos R que corresponden a cada latido, se puede obtener un conjunto de rasgos característicos de cada señal ECG basados en los intervalos RR (medidos en milisegundos (ms)) y en las diferencias primeras de los intervalos RR. En este estudio se han considerado los siguientes ocho rasgos:

- Proporción de intervalos RR que difieren por más de 50 ms del intervalo precedente;
- máximo, mínimo y desviación típica de los intervalos RR;
- cociente entre mínimo y máximo intervalo RR;
- media de los intervalos RR que tienen una duración mayor al percentil 90;
- media de los intervalos RR comprendidos entre el percentil 50 y el percentil 80;
- diferencia entre las dos medias anteriores.

Adicionalmente, al conjunto de rasgos característicos basados en los intervalos RR y en sus diferencias primeras, se han incorporado otros aspectos de la señal ECG obtenidos a partir del análisis en el dominio de frecuencia (periodograma).

El conjunto de rasgos característicos así determinado constituye la información de entrada para dos algoritmos de clasificación supervisada, árboles generados por partición recursiva (paquete R “rpart”, [10], [11]) y bosques aleatorios (paquete R “randomForest”, [12], [13]) que se entienden adecuado aplicar, en primera instancia, al conjunto de entrenamiento seleccionado de Physionet 2017 y, en segunda instancia, al conjunto de prueba formado por los registros de ECG del plan piloto nacional, descrito en la Introducción.

1.3. Resultados y discusión

Se aplica el modelo de árbol de clasificación empleando el paquete R “rpart” a todo el conjunto de rasgos característicos descrito en la sección anterior. La importancia de cada variable se visualiza en el siguiente gráfico:

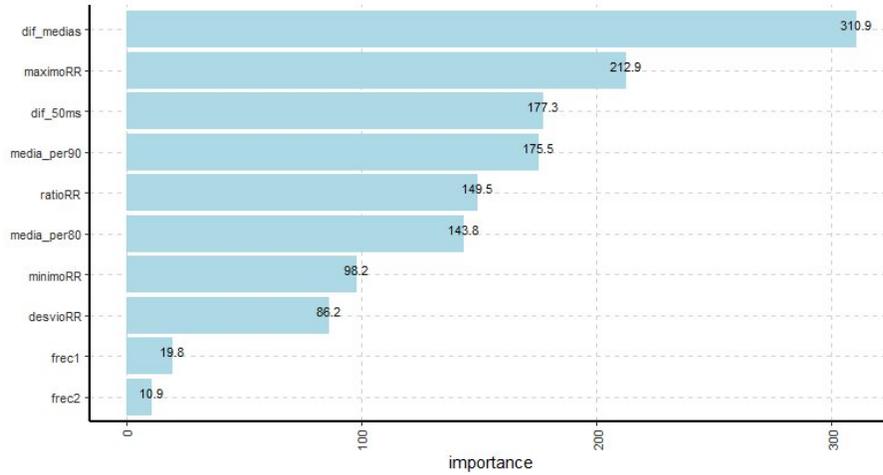


Figura 1.8: Importancia de las variables en el modelo árbol de clasificación.

La siguiente tabla resume el desempeño del modelo árbol de clasificación aplicado al banco de datos de entrenamiento:

Cuadro 1.2: Desempeño del árbol de clasificación en el conjunto de entrenamiento.

	Clase verdadera	
	Normal	FA
Resultados del clasificador	FA	338
	Normal	56

El puntaje F1 respecto de FA definido como

$$F_{1,FA} = \frac{2 \times \text{\#verdaderos positivos}}{2 \times \text{\#verdaderos positivos} + \text{\#falsos positivos} + \text{\#falsos negativos}}$$

es igual a 0,9001.

El desempeño predictivo del algoritmo árbol de clasificación para los registros de ECG en el plan piloto respecto de la clasificación adoptada por el DMTE y respecto del diagnóstico de los cardiólogos (basado en el ECG de 12 derivaciones) se resume, respectivamente, en las dos siguientes tablas:

Cuadro 1.3: Predicción árbol de clasificación vs diagnóstico del DMTE.

		Resultado DMTE		
		Normal	Posible FA	Sin clasificar
Resultados del clasificador	FA	1	4	2
	Normal	85	3	19

Cuadro 1.4: Predicción árbol de clasificación vs diagnóstico de los cardiólogos.

		Resultado cardiólogos	
		Normal	FA
Resultados del clasificador	FA	3	4
	Normal	106	1

Se aplica el modelo de bosques aleatorios empleando “randomForest” en R a todo el conjunto de rasgos característicos descrito en la sección anterior. La importancia de cada variable se visualiza en el siguiente gráfico:

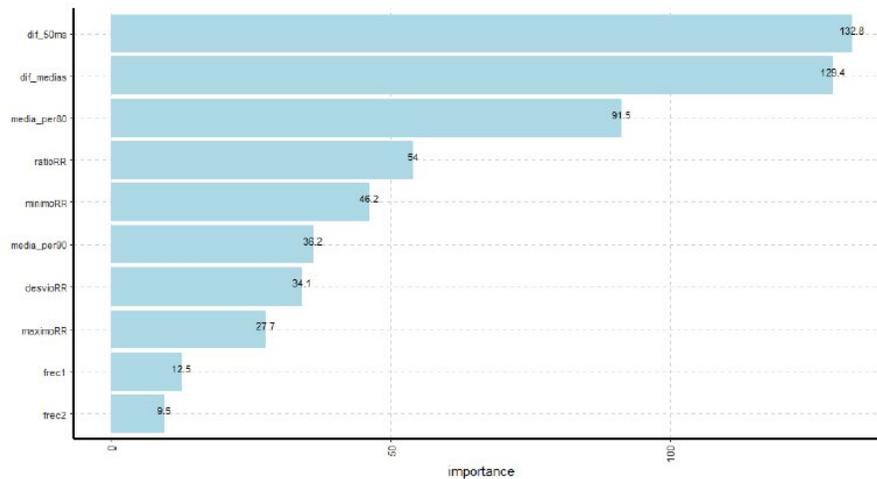


Figura 1.9: Importancia de las variables en el modelo bosques aleatorios.

Las dos siguientes tablas resumen el desempeño predictivo del algoritmo de clasificación basado en bosques aleatorios para los registros de ECG en el plan piloto respecto de la clasificación adoptada por el DMTE y respecto del diagnóstico de los cardiólogos:

Cuadro 1.5: Predicción bosques aleatorios vs diagnóstico del DMTE.

		Resultado DMTE		
		Normal	Posible FA	Sin clasificar
Resultados del clasificador	FA	1	5	2
	Normal	85	2	19

Cuadro 1.6: Predicción bosques aleatorios vs diagnóstico de los cardiólogos.

		Resultado cardiólogos	
		Normal	FA
Resultados del clasificador	FA	4	4
	Normal	105	1

Los resultados evidencian el potencial de técnicas automáticas de detección de FA basadas en un número relativamente pequeño de características extraídas de una señal de ECG de una derivación y de corta duración, y en la aplicación de técnicas de aprendizaje automático.

1.4. Conclusiones

Los resultados muestran que el desempeño predictivo de los dos algoritmos de clasificación supervisada aquí empleados y aplicados al conjunto seleccionado de rasgos característicos de señales ECG convertidas de manera automática de la salida de un DMTE, genera únicamente un falso negativo. De hecho, se trata de un registro que resultó difícil de interpretar también para los cardiólogos.

El estudio aquí presentado considera únicamente los registros de ECG obtenidos en el ámbito de un plan piloto que precedió un diseño de muestreo de carácter nacional llevado a cabo en Uruguay en una colaboración entre la CHSCV y el Plan Ibirapitá. En la actualidad, se está realizando la etapa de calibración y validación de los diagnósticos informados por los cardiólogos basados en la salida del DMTE. De esta manera, una vez construidos procedimientos automáticos de clasificación de los registros de ECG con elevada capacidad predictiva, se entiende posible poner las premisas para un estudio de la estimación de la prevalencia de la FA a nivel nacional.

Bibliografía

- [1] CHUGH S.S., HAVMOELLER R., NARAYANAN K., SINGH D., RIENSTRA M., BENJAMIN E.J., GILLUM R.F., ET AL., Worldwide Epidemiology of Atrial Fibrillation: A Global Burden of Disease 2010 study. *Circulation*, 129(8), 837-847 (2014). <https://doi.org/10.1161/CIRCULATIONAHA.113.005119>
- [2] KISHORE A., VAIL A., MAJID A., DAWSON J., LEES K.R., TYRRELL P.J., SMITH C.J., Detection of Atrial Fibrillation After Ischemic Stroke or Transient Ischemic Attack. *Stroke*, 45(2), 520-526 (2014). <https://doi.org/10.1161/STROKEAHA.113.003433>
- [3] SERRA C.M.J., El Electrocardiograma en la Práctica Médica, segunda edición, editorial Atlante (2013). ISBN: 9509539155
- [4] CHEE J., SEOW S.-C., The Electrocardiogram. In: Acharya U.R., Suri J.S., Spaan J.A.E., Krishnan S.M. (eds) *Advances in Cardiac Signal Processing*, 1-53. Springer, Berlin, Heidelberg (2007). https://doi.org/10.1007/978-3-540-36675-1_1
- [5] PLATONOV P.G., CORINO V.D.A., A Clinical Perspective on Atrial Fibrillation. In: Sörnmo L. (eds) *Atrial Fibrillation from an Engineering Perspective. Series in BioEngineering*. Springer, Cham (2018). https://doi.org/10.1007/978-3-319-68515-1_1
- [6] ESTRAGÓ V., MUÑOZ, M., ÁLVAREZ-VAZ R., REYES, X., REYES, W., Utilización de un dispositivo móvil de tecnología electrónica para tamizaje de fibrilación auricular. Estudio piloto. *Revista Uruguaya de Cardiología*, 36(2), e201 (2021). <http://dx.doi.org/10.29277/cardio.36.2.7>
- [7] R CORE TEAM. R, A Language and Environment for Statistical Computing. R Foundation for Statistical Computing, Vienna, Austria, 2021.
- [8] CLIFFORD G.D., LIU C., MOODY B., LEHMAN L.H., SILVA I., LI Q., JOHNSON A.E., AND MARK R.G., AF Classification from a Short Single Lead ECG Recording: the PhysioNet/Computing in Cardiology Challenge 2017. *Computing in Cardiology*, 44 (2017). <https://doi.org/10.22489/CinC.2017.065-469>
- [9] PAN J. AND TOMPKINS W.J., A Real-Time QRS Detection Algorithm. *IEEE Transactions on Biomedical Engineering*, BME-32(3), 230-236 (1985). <https://doi.org/10.1109/TBME.1985.325532>

- [10] THERNEAU T., ATKINSON B., rpart: Recursive Partitioning and Regression Trees. R package version 4.1-15 (2019). <https://CRAN.R-project.org/package=rpart>
- [11] BREIMAN L., FRIEDMAN J.H., OLSHEN R.A., STONE, C.J., Classification and Regression Trees. Routledge, Boca Raton (1984). <https://doi.org/10.1201/9781315139470>
- [12] LIAW A., WIENER M., Classification and Regression by randomForest. R News 2(3), 18-22 (2002). https://CRAN.R-project.org/doc/Rnews/Rnews_2002-3.pdf
- [13] BREIMAN L., Random Forests. Machine Learning, 45(1), 5-32 (2001). <https://doi.org/10.1023/A:1010933404324>