

Aplicación de redes neuronales para predicción de señales cardiovasculares

Application of neural networks for the prediction of cardiovascular signals

Presentación: 05/08/2024

Doctorando:

Norberto SANABRIA

Grupo de Investigación y Desarrollo en Bioingeniería, Facultad Regional Buenos Aires, Universidad Tecnológica Nacional - Argentina
nosanabria@frba.utn.edu.ar

Director:

Leandro CYMBERKNOP

Codirector:

Jorge MONZON

Resumen

Los parámetros del sistema cardiovascular en general brindan información vinculada al normal funcionamiento fisiológico y pueden ser utilizadas en la predicción de singularidades propias enfermedades. En particular, se estudiaron registros eléctricos y biomecánicos en relación con el sistema integrado cardio-respiratorio-vascular. Se aplicaron métodos de aprendizaje profundo a éstos registros, en secuencias de datos provenientes de la red vascular sistémica mediante el uso de una red neuronal dinámica: Long-Short Term Memory, para la predicción de series temporales como la presión aórtica y el electrocardiograma utilizando herramientas de análisis computacional. Se lograron comparar errores entre las predicciones y los conjuntos de entrenamiento y de validación de las señales reales obtenidas de un protocolo clínico de medición, consiguiendo resultados con optimizadores como adam o adagrad.

Palabras clave: Red neuronal, series temporales cardiovasculares, predicción

Abstract

The parameters of the cardiovascular system in general provide information related to normal physiological functioning and can be used in the prediction of disease-specific singularities. In particular, electrical and biomechanical records were studied in relation to the integrated cardio-respiratory-vascular system. Deep learning methods were applied to these records, in data sequences from the systemic vascular network through the use of a dynamic neural network: Long-Short Term Memory, for the prediction of time series such as aortic pressure and electrocardiogram using computational analysis tools. Errors were compared between the predictions and the training and validation sets of the real signals obtained from a clinical measurement protocol, obtaining results with optimizers such as adam or adagrad.

Keywords: Neural network, cardiovascular time series, prediction

Introducción

El estudio convencional de la variabilidad de parámetros fisiológicos conlleva un proceso con capacidad de evaluar las fluctuaciones que se manifiestan a través de diferentes intervalos temporales. La variación de parámetros del sistema cardiovascular (CV), como la presión arterial (PA) o la frecuencia cardíaca (FC) entre otros, proporcionan información útil para la predicción de anomalías hemodinámicas y pueden ser relacionadas con la fisiología del movimiento (Młynczak, 2020). Bajo dicha premisa, el concepto de fisiología de red se basa en la suposición de que varios sistemas se combinan. Una combinación multidireccional puede verse en la respiración, la actividad vascular y la actividad cardíaca, moduladas por el sistema nervioso (Młynczak y Krysztofiak, 2018). En este sentido, la variabilidad de las propiedades biomecánicas está asociada a su estado de reposo o intensidad de movimiento, su aptitud física general y la relación del sistema integrado de red cardio-respiratorio-vascular (Młynczak y Krysztofiak, 2019).

El estudio del registro electrocardiográfico (ECG) aún es el método más conveniente para diagnosticar arritmias. Las señales ECG que reflejan la actividad eléctrica del corazón son una herramienta no invasiva y eficaz para estudiar el ritmo cardíaco y para el diagnóstico del estado patológico cardiovascular (Zhang et al., 2021).

El estudio de la variabilidad de la frecuencia cardíaca (VFC) permite cuantificar la interacción entre la actividad simpática y parasimpática del sistema nervioso. En otro estudio de la PA y su variabilidad, pueden evaluarse modificaciones instantáneas en el gasto cardíaco y en las resistencias periféricas (Phan et al., 2021), secundarios a un fino ajuste neuro-cardio-vascular en el corto plazo o su comportamiento circadiano en el largo plazo, pueden asociarse por ejemplo con un daño del órgano blanco o diana (Parati et al., 2015).

Del análisis morfológico de las señales de Presión Arterial (PA), emergen herramientas valiosas de detección de enfermedades cardiovasculares (ECV) en estas señales (Kullo et al., 2017). En este contexto, las técnicas de aprendizaje automático (ML, por sus siglas en inglés) posibilitan el estudio de modelos algorítmicos de aprendizaje progresivo. Estos permiten el uso de una gran cantidad de variables para un análisis independiente de cualquier hipótesis, identificando similitudes y diferencias en series temporales complejas (Kumar et al., 2020). Se pueden ajustar estas variables y optimizar las predicciones de las señales por medio de redes neuronales (RN) a través de diversas técnicas computacionales, detectando detalles más sutiles y cambios del entorno. En particular, la técnica de aprendizaje profundo (DL, por sus siglas en inglés), constituye una técnica de ML que requiere un mayor volumen de información para llevar a cabo tareas de aprendizaje (Vorobioff, 2021).

DL es una técnica del ML, la cual precisa muchos más datos de entrada y aprende funciones o tareas directamente a partir de datos de entrada. Como ejemplo de ello, una red neuronal (RN) dinámica como la Long-Short Term Memory (LSTM) puede ser utilizada para trabajar con datos de secuencias y series temporales en tareas de clasificación y regresión. El componente distintivo de la red es la capa secuencial de series de entrada. Esta aprende dependencias a largo plazo entre pasos de tiempo de datos secuenciales. Puede predecir etiquetas de clase por medio de una capa totalmente conectada, una función de activación para normalizar la salida anterior y una capa de salida. Su diseño permite manejar señales temporales a largo plazo de manera más efectiva que otras RN tradicionales. Internamente cuentan con tres compuertas. Una de olvido donde se decide qué información anterior se debe mantener, una de entrada que permite que la red aprenda cuándo actualizar la memoria con nuevos datos, y otra de salida que puede usarse en un instante actual (Vorobioff et al., 2022).

Habida cuenta que el objetivo general del plan de tesis consiste en la determinación de alteraciones fisiológicas inducidas por el ejercicio a través de la evaluación de la variabilidad de parámetros biomecánicos arteriales y cardíacos, se consideró apropiada una evaluación de la aplicación de herramientas del aprendizaje profundo (DL) basadas en RN de base de datos reales en seres vivos, obtenidas simultáneamente mediante protocolos de adquisición continua, en intervalos de uno, dos, cinco y diez minutos, con el propósito de predecir, contrastar y evaluar el comportamiento de distintas señales cardiovasculares y respiratorias.

Materiales y Métodos

Se utilizó una base de datos del Grupo de Investigación y Desarrollo en Bioingeniería (GIBIO), constituida por series temporales de seis parámetros diferentes en canales simultáneos, separadas en catorce recolecciones de muestras y adquiridas por métodos invasivos en animales (ovejas) a una frecuencia de muestreo a 500Hz.

A éstos se agrega la relación presión / diámetro de la arteria aorta. Los registros corresponden a ECG, presión aórtica, diámetro aórtico, diámetro de la aurícula derecha, respiración en el tórax y electrocardiograma de la aurícula derecha. Se trabajó con los registros completos de diez minutos (300.000 valores por canal), aplicando la red LSTM con herramientas computacionales (Python 3.10.12).

Archivo	Frec_Muestreo [Hz]	Muestras [#]	Hora [hh/mm/ss]	Adquisición [minutos]
jgbctl.txt	500	30000	10:33:16	1
jgb001.txt	500	300000	16:29:36	10
jgb002.txt	500	300000	16:56:52	10
jgb003.txt	500	300000	16:29:14	10
jgb004.txt	500	300000	16:49:29	10
jgb005.txt	500	30000	10:37:48	1
jgb006.txt	500	30000	10:49:53	1
jgb008.txt	500	30000	11:18:56	1
jgb009.txt	500	150000	11:24:12	5
jgb010.txt	500	30000	11:30:58	1
jgb011.txt	500	300000	11:36:13	10
jgb012.txt	500	30000	11:48:31	1
jgb013.txt	500	300000	11:57:45	10
jgb014.txt	500	60000	12:11:31	2

Tabla 1: Descripción de los archivos de recolección de la base de datos

Inicialmente se importaron las librerías necesarias para llevar a cabo el procesamiento de las señales de origen biológico. Los datos fueron almacenados en un dataframe (Pandas 2.1.4). Posteriormente se implementó la RN (Keras 3.4.1 y tensor flow 2.17.0) para la importación de las capas, tales como Dense y LSTM. Para evaluar la predicción de errores se debieron implementar las funciones (sklearn 1.3.2). Se aplicó a cada canal un filtro digital de fase nula. Se implementaron ventanas para trabajar por fragmentos de las señales originales (Fig. 1).

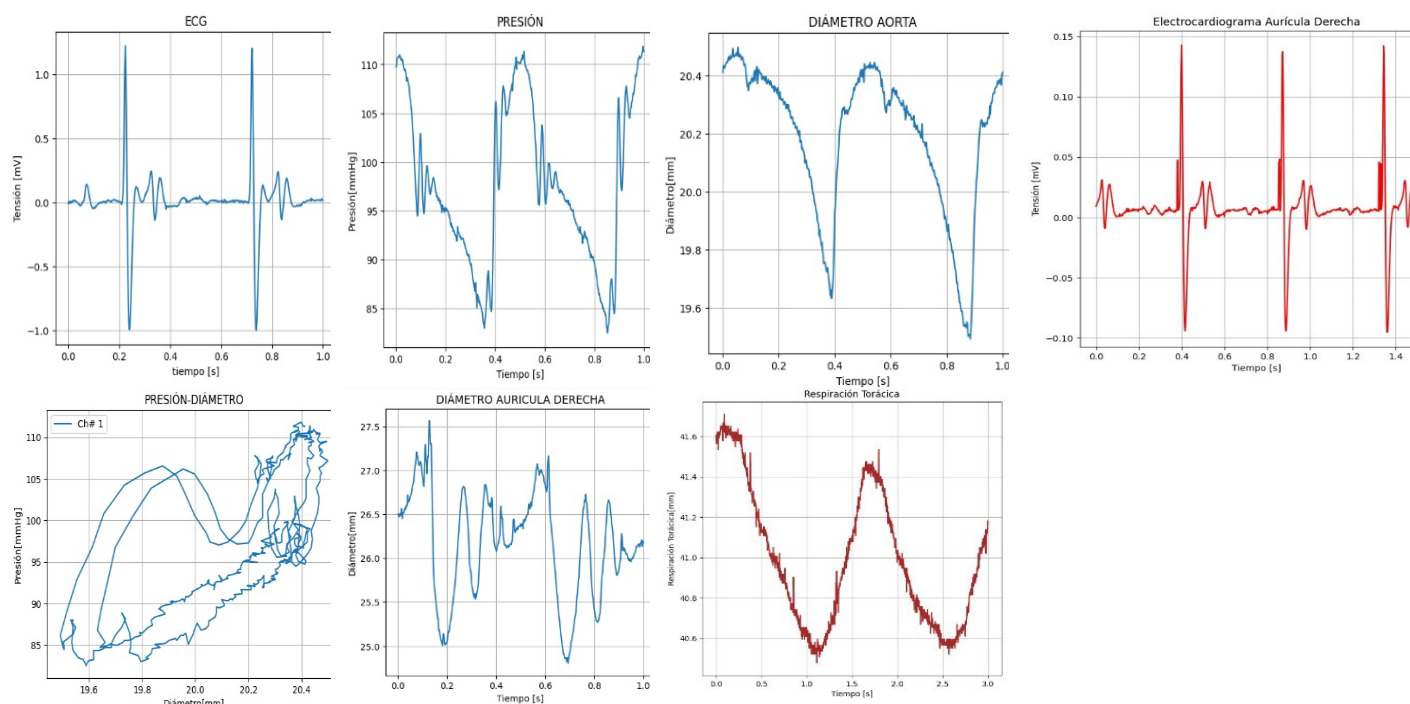


Fig. 1: Señales originales de los 7 canales correspondientes a adquisiciones de 10min.

Predicción DL basado en RN

Los modelos de predicción fueron utilizados para pronosticar el comportamiento de las señales de cada canal. Estos podrían utilizarse durante un monitoreo continuo, en la detección de eventos anormales y su aplicación en sistemas de estudio de la variabilidad de los parámetros biomecánicos y eléctricos cardiovasculares.

Los `dataX` y `dataY` se cargaron como listas de entrada y salida de entrenamiento. Mediante bucles se iteró a lo largo de la serie temporal, y en cada iteración, se creó una ventana deslizante de tamaño `look_back` en pasos temporales consecutivos. Las series se agruparon en 2D. Luego se añadieron ventanas a la salida para llevar a cabo las predicciones. El modelo devolvió dos arreglos que contenían las ventanas deslizantes para las entradas, y los valores de salida objetivo. Estos arreglos se pudieron utilizar directamente para entrenar el modelo de DL, como una red neuronal recurrente (RNN) o secuenciales. Se normalizó en el rango (0, 1) y se dividió el conjunto normalizado en subconjuntos de entrenamiento al 67% y de prueba con el 33% respectivamente.

Para crear la predicción en la red LSTM, se estableció un modelo secuencial en Keras; se adicionó una capa LSTM con cuatro neuronas y una forma de entrada especificada como (1, look_back); se agregó una capa densa totalmente conectada con una sola neurona realizar la predicción en la salida; luego se compiló el modelo especificando la función de pérdida y el optimizador. Para entrenar se especificaron los números de épocas y el tamaño de lote. Durante el entrenamiento, el modelo ajustó sus pesos para predecir la salida. Se utilizó una función de pérdida para calcular el error entre lo predicho y las salidas reales, y con un optimizador se ajustaron los pesos con el fin de minimizar esta pérdida. Luego se invirtió la transformación de escala para obtener las predicciones en la misma escala que los datos originales. Se calculó el error cuadrático medio (RMSE) usado en regresión para las predicciones. La función de pérdida se utilizó para calcular el error entre las predicciones y las salidas, y el optimizador ajustó los pesos del modelo para minimizar esta pérdida.

Además, se utilizaron herramientas de descarga compartida (gdown 4.7.3) por el volumen de datos, entrenando por tramos o ventanas de 2,5 a 40 segundos a las señales ECG, presión aórtica y electrocardiograma de la aurícula derecha. Primeramente se utilizó un optimizador de estimación de momento adaptativo para DL (adam), y se fueron variando las épocas entre 50 a 20.000. Para la presión aórtica, el optimizador de algoritmo de gradiente adaptativo (adagrad) permitió reducir en número de épocas de entrenamiento debido a su ajuste automático de la tasa de aprendizaje para estos parámetros.

Resultados

Los resultados obtenidos son satisfactorios, ya que proporcionan la predicción de los parámetros de salida de las señales. A continuación se exponen los valores alcanzados. En las Fig. 2 y 3 se muestran las comparaciones de Presión Aórtica original, entrenada y de predicción y de la señal de ECG original, entrenada y la predicha, respectivamente.




Fig. 2: Comparación de la señal de Presión Aórtica original, entrenada y la predicción.




Fig. 3: Comparación de la señal de ECG original, entrenada y la predicción.

Las puntuaciones de RMSE para el entrenamiento de la red y los de prueba, obtenidos para DL en RN con optimizadores de estimación de momento adaptativo y de algoritmo de gradiente adaptativo se exhiben en la Tabla 2.

Optimizador	Puntuación RMSE	Presión aórtica	ECG	Tensión aurícula derecha
adam	Entrenamiento	0,85	0,86	0,76
	Prueba	0,87	0,87	0,76
adagrad	Entrenamiento	0,89	0,88	0,79
	Prueba	0,91	0,89	0,81

Tabla 2: Valores obtenidos en la evaluación del modelo predictivo

Conclusiones

Para el presente trabajo se utilizó un set de datos compuesto por series temporales de parámetros CV en seis canales simultáneos, correspondiente a catorce recolecciones de muestra adquiridas por en animales a una frecuencia de muestreo a 500Hz. Los registros analizados fueron ECG, presión y diámetro aórtico, diámetro de la aurícula derecha, respiración torácica y tensión de la aurícula derecha. Se aplicó DL en el desarrollo de redes neuronales LSTM para predicción de señales. En virtud de los resultados obtenidos se advierte que para este tipo o set de datos in vivo con el uso del optimizador de algoritmo de gradiente adaptativo se obtuvieron en general mejores resultados para la predicción de las señales analizadas, incluso con menos épocas. Sin embargo con el optimizador de estimación de momento adam, el proceso de aprendizaje fue notablemente más rápido para grandes volúmenes de datos respecto al adagrad, lo que sugiere la acumulación significativa de los gradientes. La aplicación de herramientas de DL en RN de base de datos reales en seres vivos, obtenidas de forma simultánea mediante protocolos clínicos de medición continua, para predecir y evaluar el comportamiento de distintas señales cardiovasculares y respiratorias, tiene estrecha vinculación con los objetivos del plan de tesis, que busca abordar la estimación de la variabilidad de parámetros cardiovasculares desde la creación de bases propias del laboratorio, a partir de señales adquiridas en sujetos en forma dinámica y simultánea.

Referencias

- Kullo, I.J., y Malik, A.R. (2017). Arterial ultrasonography and tonometry as adjuncts to cardiovascular risk stratification. *Journal of American College of Cardiology*, 49(133),1413-1426. doi:10.1016/j.jacc.2006.11.039
- Kumar, N.K., Sindhu, G.S., Prashanthi, D.K., y Sulthana, A.S. (2020). Analysis and Prediction of Cardio Vascular Disease using Machine Learning Classifiers. 6th International Conference on Advanced Computing and Communication Systems (ICACCS), 15-21. doi:10.1109/ICACCS48705.2020.9074183
- Młynczak, M. (2020). Temporal orders and causal vector for physiological data analysis. 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC), 750-753. doi:10.1109/EMBC44109.2020.9176842
- Młynczak, M. y Krysztofiak, H. (2018) Discovery of causal paths in cardiorespiratory parameters: a time-independent approach in elite athletes. *Frontiers in Physiology*, 9:1455. doi:10.3389/fphys.2018.01455
- Młynczak, M. y Krysztofiak, H. (2019) Cardiorespiratory temporal causal links and the differences by sport or lack thereof. *Frontiers in Physiology*, 10:45,1-14. doi:10.3389/fphys.2019.00045.
- Parati, G., Saúl, J.P., Di Rienzo, M. y Manía, G. (1995) Spectral analysis of blood pressure and heart rate variability in evaluating cardiovascular regulation: a critical appraisal. *Hypertension*, 25(6):1276-86. doi: 10.1161/01.hyp.25.6.1276
- Phan, T., Lau, Z.J., Chen, S.H.A y Makowski, D. (2021) Heart Rate Variability in Psychology: A Review of HRV Indices and an Analysis Tutorial. *Sensors*, 21,3998. doi:10.3390/s21123998
- Vorobioff, J. (2021) Procesamiento avanzado de señales en sistemas adaptativos y redes neuronales. ISBN 978-987-4998-66-8. EdUTecNe.
- Vorobioff, J., Cerrotta, S., Morel, N.E y Amadio, A. (2022) Inteligencia artificial y redes neuronales. Fundamentos, ejercicios y aplicaciones con Python y Matlab. ISBN 978-987-4998-82-8. EdUTecNe.
- Zhang, P. Hang, Y., Ye, X., Guan, P., Jiang, J., Tan, J. & Hu, W. (2021). A United CNN-LSTM Algorithm Combining RR Wave Signals to Detect Arrhythmia in the 5G-Enabled Medical Internet of Things. *Internet of Things Journal*, DOI 10.1109/JIOT.2021.3067876