

Análisis de datos de acelerometría para la detección de tipos de actividades

Sandro Hurtado-Requena¹, Cristóbal Barba-González¹, Maciej Rybiński¹,
Francisco J. Barón-López², Julia Wärnberg³, Ismael Navas-Delgado¹, and José
F. Aldana-Montes¹

¹ Grupo de investigación Khaos, Dpto. Lenguajes y Ciencias de la Computación
jfam@lcc.uma.es

² Unidad de Bioestadística, Dpto. de Salud Pública. Facultad de Medicina.

³ Dpto. de Enfermería, Facultad de Ciencias de la Salud
Universidad de Málaga, Málaga, España.

Resumen La inactividad física es uno de los principales factores de riesgo de mortalidad y su relación con las principales enfermedades crónicas es objeto de intensas investigaciones médicas. Un método objetivo de la evaluación de la actividad de las personas es el uso de acelerómetros. En este trabajo se presenta un experimento para evaluar la viabilidad de la detección automática de algunos tipos de actividades a través de algoritmos supervisados de Deep Learning.

Keywords: Deep Learning, classification, HAR, wearable sensors

1. Introducción

La inactividad física es uno de los principales factores de riesgo de padecer enfermedades crónicas como las cardiovasculares, el cáncer y la diabetes. Conocer los hábitos y tipos de actividades realizadas por las personas y su relación con estas enfermedades es clave para diseñar estrategias y recomendaciones para prevenirlas. La evaluación de la actividad física diaria en estudios epidemiológicos requiere una metodología fiable, precisa y de bajo coste. El uso de acelerómetros o monitores de movimiento, es un método ampliamente usado en estudios científicos de actividad física.

Este artículo presenta un trabajo emergente para la clasificación de tipos de actividades capturadas con un acelerómetro de pulsera, con el propósito de su posterior aplicación en un ensayo de campo de prevención de enfermedad cardiovascular⁴. En este proyecto, la Universidad de Málaga coordina la recogida

⁰ Trabajo parcialmente financiado por los proyectos TIN2017-86049-R y TIN2014-58304-R (Ministerio de Economía, Industria y Competitividad), P12-TIC-1519 (Plan Andaluz de Investigación, Desarrollo e Innovación), PI0458-2013 y PS0358-2016 (Consejería de Salud de la Junta de Andalucía) y PI16-00662 (Instituto de Salud Carlos III) co-financiados por el Fondo Europeo de Desarrollo Regional (FEDER).

⁴ PREDIMED-PLUS, registrado en el International Standard Randomized Controlled Trial con el número 89898870 <http://www.isrctn.com/ISRCTN89898870>

y el análisis de los datos de acelerometría recogidos en este ensayo multicéntrico. El trabajo emergente presentado en este artículo forma parte de un proyecto multidisciplinar entre el Departamento de Salud Pública, el Departamento de Enfermería y el grupo de investigación Khaos. El objetivo es validar si se puede diferenciar entre 11 tipos de actividades (una mezcla de actividades deportivas y de 'vida normal') a partir de datos registrados por un acelerómetro de muñeca, usando modelos de aprendizaje computacional: dos modelos *establecidos* de Deep Learning y un modelo híbrido propuesto en este trabajo.

Trabajos relacionados: El descubrimiento de patrones de actividad humana (*Human Activity Recognition*, HAR) ha derivado en varios estudios sobre como analizar los datos recogidos mediante pulseras de actividad, relojes inteligentes y smartphones. En [5], se realiza un estudio del estado del arte del uso de algoritmos de Deep Learning en HAR. El trabajo [1] presenta un nuevo clasificador de Deep Learning en el que se clasifica la actividad realizada mediante algoritmos de *Deep Convolutional Neural Networks* (una modalidad de ConvNet [6]) bi-dimensional sobre imágenes construidas base de los datos del sensor. Algoritmos de Machine Learning como Extra Trees, AdaBoost, Random Forest, Naive Bayes, k-NN o SVM también han sido usados para este propósito [2,3]. Nuestros experimentos se han centrado en el uso de los modelos neuronales (ConvNets y LSTM[4]), ya son los que presentan en el estado del arte actual la mejor precisión en cuanto a la clasificación de patrones de actividad humana.

2. Metodología

El conjunto de datos está formado por los valores capturados con un acelerómetro⁵ llevado en la muñeca no dominante durante 11 actividades dirigidas (dormir, andar, correr, estar de pie, montar bicicleta, nadar, bailar, desplazarse con transporte publico, estar asentado, sensor en reposo, gimnasia, 'on the go'). Los resultados se han registrado a 100 Hz, es decir, son series temporales de 100 medidas por segundo. Se ha registrado cada actividad durante al lo menos 2 minutos, anotando de esta forma las medidas tomadas con el tipo de actividad realizada. Cada medida de esta pulsera contiene 3 valores reales sobre cada uno de los ejes del sensor ('x-y-z').

En cuanto al pre-procesamiento, dividimos los datos en tramos de 10 segundos (1.000 medidas), pasando una ventana por los datos que representan cada una de las actividades, con un paso de 0.1 segundos. Nos quedamos con ventanas completas, es decir, de 1.000 medidas. Nuestro conjunto de datos tras el pre-procesamiento contiene 114.520 muestras clasificadas manualmente.

Para evaluar el clasificador dividimos el conjunto de datos ya pre-procesados en una proporción 9:1 (90% entrenamiento, 10% validación). A continuación, hacemos una división aleatoria y estratificada en cada clase (*stratified shuffle*

⁵ MEMS triaxial (*GeneActiv*, *Activinsights Ltd*, *Kimbolton*, *Cambs*, *Reino Unido*, <http://www.geneactiv.org/>)

Cuadro 1. Estructura de las redes neuronales evaluadas

DNN	ConvNet	Bidirectional LSTM	ConvNet + LSTM
Entrada	1.000×3	1.000×3	1.000×3
Capas ocultas	1D conv. (256) Max pool 1D 1D conv. (256) Max pool 1D Capa densa (50) Regularización	LSTM bidireccional (50) Max pool 1D Capa densa (50) Regularización	1D conv. (256) Max pool 1D LSTM bidireccional (50) Capa densa (50) Regularización
Salida	Capa densa (11)	Capa densa (11)	Capa densa (11)

split). Tras los estudios preliminares, hemos encontrado tres arquitecturas prometedoras. La arquitectura más *estándar* que estamos evaluando es la ConvNet de relativamente poca profundidad, con dos capas convolutivas unidimensionales. Como alternativa se hace uso de un modelo LSTM bidireccional. Finalmente, evaluamos también un modelo híbrido entre ConvNet y LSTM, en el cual las características generadas por la primera capa convolutiva están interpretadas con una capa LSTM bidireccional. Los detalles de las tres arquitecturas se presentan en Tabla 1.




Figura 1. Calidad de la predicción y matrices de confusión

La validez en la clasificación la valoramos usando la calidad de la predicción (*accuracy*). Para completar los resultados presentamos también las matrices de confusión correspondientes a cada uno de los modelos. Las matrices de confusión de los experimentos realizados se muestran en la Figura 1: ConvNet (a), LSTM (b) y el modelo híbrido (c). Los tres modelos proporcionan buenos resultados, alcanzando valores de calidad de 0.9918, 0.9798 y 0.9931 en los experimentos realizados. Aunque se trate de un experimento sobre un conjunto de datos relativamente pequeño (una muestra de cada tipo de actividad), el modelo combinado parece dar resultados bastante prometedores. La arquitectura de ConvNet es la más utilizada en el estado del arte actual, por lo cual podemos esperar que la

del modelo combinado sea suficientemente robusta para dar un buen rendimiento con un conjunto de datos más grande, con más personas y/o categorías de actividades.

3. Conclusiones y trabajo futuro

Con el experimento presentado hemos demostrado la viabilidad para clasificar los datos del sensor GeneActiv para el problema HAR usando redes neuronales profundas. Ya que el estudio clínico incluye más de 50 sujetos, el paso siguiente va a ser valorar las posibles estrategias para abordar el problema de clasificación con datos de diferentes personas. Para ello será necesario obtener un conjunto mayor de datos anotados, para mejorar el conjunto de entrenamiento. Otros escenarios viables incluyen un paso de calibración individual (por sujeto del estudio). Una estrategia intermedia podría ser una combinación de las dos, recogiendo datos para entrenar un clasificador 'universal' usando datos clasificados automáticamente con clasificadores 'calibrados'.

Los resultados obtenidos con nuestros modelos superan, en cuanto los valores absolutos, a los resultados aportados en la literatura. Sin embargo, hay que tener en cuenta que nuestro experimento constituye una tarea de clasificación simplificada. En cuanto la evaluación de nuestro enfoque, el siguiente paso será evaluar nuestros clasificadores con un *benchmark* abierto, para obtener una comparativa más directa. También, vamos a poder evaluar los métodos actuales con nuestros datos mientras avanza el proyecto y el conjunto de datos va aumentando.

Además, la estrategia hasta ahora usada para el pre-procesamiento de datos está adaptada para obtener un conjunto de datos relativamente grande a partir de las pocas muestras de actividades que actualmente disponemos. Es probable que se tenga que ajustar el paso de muestreo para poder usar nuestro clasificador en casos reales, ya que esto va a implicar un manejo de grandes volúmenes de datos.

Referencias

1. Jiang, W., Yin, Z.: Human activity recognition using wearable sensors by deep convolutional neural networks. Proceedings of the 23rd ACM international conference on Multimedia. ACM, 1307–1310 (2015)
2. Saez, Y., Baldominos, A., Isasi, P.: A comparison study of classifier algorithms for cross-person physical activity recognition. *Sensors*, 17 (1), 66 (2016)
3. Anguita, D., Ghio, A., Oneto, L., Parra, X., Reyes-Ortiz, J. L.: A Public Domain Dataset for Human Activity Recognition using Smartphones. In ESANN (2013)
4. Hochreiter, S., Schmidhuber, J.: Long short-term memory. *Neural computation*, 9(8), 1735–1780 (1997).
5. Wang, J., Chen, Y., Hao, S., Peng, X., Hu, L.: Deep learning for sensor-based activity recognition: A survey. arXiv preprint arXiv:1707.03502 (2017).
6. LeCun, Y., Bottou, L., Bengio, Y., Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278–2324.