

Limpieza y etiquetado de datos de marcha: un algoritmo automático basado en el análisis de la trayectoria de los marcadores

Cleaning and labeling gait data: an automatic marker-wise algorithm

Presentación: 4 y 5 de Octubre de 2022

Doctoranda:

Magalí Sganga

Universidad Maimónides – Centro de Estudios Biomédicos Básicos, Aplicados y Desarrollo (CEBBAD)
CONICET -Argentina
Sganga.magali@maimonides.edu

Director:

Lucas Eduardo Ritacco

Codirector:

Emiliano Pablo Ravera

Resumen

La captura de movimiento (*MoCap*) óptico es un proceso a través del cual graba la ubicación de marcadores reflectivos colocados sobre la piel del paciente para analizar su biomecánica a través de diferentes modelos. La captura de estos marcadores puede presentar oclusiones y ruidos que hace que la limpieza de los datos crudos y su etiquetado no pueda ser de forma automática. Este proceso le demanda al operador mucho tiempo. No existe en la bibliografía una solución que aborde ambos problemas en simultáneo. En este trabajo proponemos un algoritmo que limpia los marcadores fantasmas y espurios, completa los gaps de estos y los etiqueta en función de una plantilla cargada previamente. Se estudio su robustez con datos simulados aumentando el ruido de las adquisiciones y los gaps con falta de información. Los resultados obtenidos son muy promisorios, demostrando la robustez del algoritmo y su factible aplicación en un entorno clínico disminuyendo los tiempos de procesamiento.

Palabras clave: Captura de movimiento, análisis clínico de la marcha, procesamiento automático de registros

Abstract

Optic motion capture (*MoCap*) is a process that captures the location of reflective markers placed on the patient's skin to analyze their biomechanics through different models. The record of these markers can present occlusions and noise that makes the raw data cleaning and its labeling impossible to be automatized. This process is time consuming for the operator. There is no solution in the literature that addresses both problems simultaneously. In this work we propose an algorithm that cleans up ghost and spurious markers, fills in their gaps and labels them based on a previously loaded template. Its robustness with simulated data was studied by increasing the noise of the acquisitions and the gaps with lack of information. The results obtained are

promising, demonstrating the robustness of the algorithm and its feasible application in a clinical environment, reducing processing times.

Keywords: Motion capture, clinical gait analysis, automatic gait trial processing.

Introducción

La captura de movimiento (MoCap por su abreviación en inglés) es el proceso de grabar movimientos del cuerpo humano con el fin de crear modelos matemáticos que permitan cuantificarlo y analizarlo con diferentes aplicaciones biomecánicas. A través de la captura óptica de movimiento se puede reconstruir un punto en el espacio en 3D. Los sistemas actuales no cuentan con un algoritmo de procesamiento que permita reconstruir la trayectoria de un marcador y etiquetarlo de forma automática. El rotulado de los marcadores es imprescindible para el modelado biomecánico y actualmente es un proceso manual que requiere de mucho tiempo, especialmente si la adquisición es ruidosa o cuenta con *gaps* donde falta información de la ubicación del marcador. Este inconveniente ha sido abordado en la bibliografía especializada desde distintos enfoques y de forma separada. Por un lado, se encuentran los algoritmos que buscan limpiar y reconstruir la trayectoria del marcador, por el otro los algoritmos para etiquetarlos automáticamente.

Skuroski et al. (2021) detalla que los métodos de reconstrucción de los marcadores se pueden agrupar en tres grandes grupos: basados en el uso de *skeletons*, basados en coordenadas y enfocados en el movimiento de los marcadores. El primer grupo se basa en el uso de modelos de *skeletons* y de cinemática inversa (Herda, Fua, Plankers, Boulic & Thalmann, 2000; Aristidou & Lasenby, 2013; Perepichka, Holden, Mudur & Popa, 2019) el segundo grupo, los métodos de manejo de datos que consideran la dirección del movimiento en base a secuencias registradas previamente, requieren un conjunto de entrenamiento para cada movimiento analizado. Debido al aumento de las bases de datos de movimiento, estas técnicas son factibles de aplicar, pero todas necesitan una gran cantidad de datos de entrenamiento para mejorar la reconstrucción de brechas (Xia, Sun, Zhang & Feng, 2016; Xiao, Feng & Hu, 2011). El tercer grupo se basa en el análisis de movimientos de marcadores individuales sin necesidad de un modelo de esqueleto, donde la clave son las correlaciones entre marcadores y el movimiento articulado alto (Wu & Boulanger, 2018; Gløersen & Federolf, 2016; Jiménez Bascones, Graña & López-Guede, 2011).

Una vez que se obtiene trayectorias limpias y completas de los marcadores y la cantidad correcta de los mismos en función del protocolo a utilizar, es necesario asignar una etiqueta a cada marcador para poder procesarlo. Las últimas publicaciones resuelven este paso a través del uso de algoritmos de Deep Learning (Jiménez Bascones, Graña & López-Guede, 2011; Clouthier, Ross, Mavor, Coll, Boyle & Graham, 2021). Estas soluciones no requieren de muchos datos etiquetados previamente para el entrenamiento de la red, a la vez que no son capaces de eliminar los marcadores fantasmas generados por reflexiones aleatorias en el campo de visión de las cámaras.

A pesar de que se proponen varios métodos para completar los huecos faltantes con buenos resultados, algunos de ellos necesitan datos previos para poder funcionar donde otros demandan operaciones complejas. En cualquier caso, ninguna de estas técnicas es capaz de eliminar los marcadores fantasmas o etiquetar el conjunto de marcadores final, por lo que no existe hasta nuestro conocimiento una solución completa al problema. Por ende, nuestro objetivo es desarrollar un algoritmo que limpie automáticamente los datos (eliminar los marcadores fantasmas y espurios, y rellenar *gaps*) y que etiquete un conjunto completo de marcadores utilizando un enfoque de basado en el movimiento de los marcadores.

Desarrollo

El algoritmo tiene dos objetivos principales: limpiar los datos sin procesar y luego etiquetar los marcadores siguiendo el protocolo de la Figura 1. Para lograr el primer objetivo, el algoritmo elimina marcadores con poca información y luego unifica la trayectoria de los marcadores hasta obtener la cantidad correcta de marcadores en base al protocolo propuesto. El segundo objetivo, se alcanza identificando el marcador más alto (generalmente C7) y la cintura escapular, y etiqueta las extremidades inferiores mediante una discriminación lineal en el cuadro donde se encuentra la mayor proyección en el plano transversal. Los datos se trabajan en el formato típico para biomecánica “.c3d” en Python 3.6.

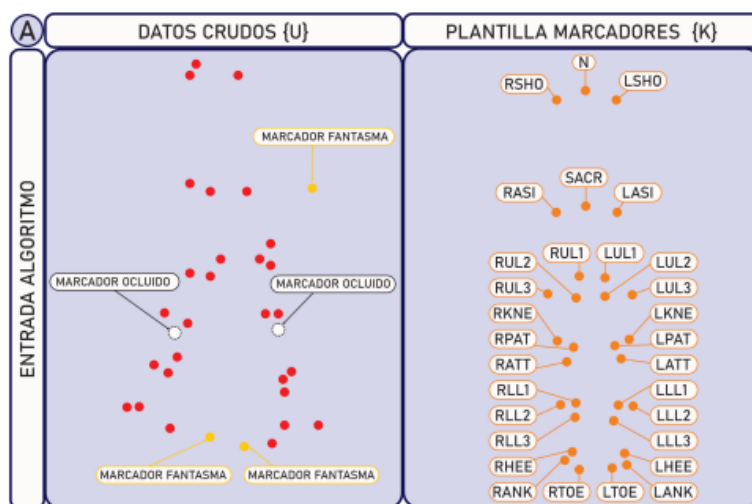


Figura 1: Izq: Datos crudos simulados. Der: Plantilla de marcadores del protocolo utilizado.

Datos experimentales

Se trabajó con un conjunto de datos simulados que incluían 720 adquisiciones elaborados a través de los datos experimentales de un sujeto sin impedimentos físicos o patologías siguiendo a (Skurowski & Pawlyta, 2021). Se colocaron 30 marcadores reflectivos sobre la piel del participante en distintos puntos anatómicos. Programáticamente se generaron distorsiones en la trayectoria de los marcadores que simularan *gaps* debido a oclusiones en la adquisición. Estas distorsiones variaron entre un 10% y un 40% de la longitud de los datos. Los saltos fueron de a 10%.

Algoritmo propuesto

El algoritmo consta de dos bloques que persiguen diferentes objetivos. El bloque 1 (figura 2), parte de un conjunto de marcadores crudos y finaliza cuando se cuenta con la información completa de la trayectoria de la misma cantidad de marcadores que tiene el protocolo. Primero se realiza un filtro rápido que elimina aquellos marcadores que cuentan con información menor al 15% de la adquisición. Luego se eliminan los marcadores espurios a través del método de suavizado propuesto por Burke et al (2016) al realizar una reconstrucción secuencial sobre el conjunto de todos los marcadores empezando por aquellos que tienen mayor cantidad de información. Como resultado de este proceso se obtiene una matriz ordenada de forma decreciente de la trayectoria completa de todos los marcadores. Sin embargo, debido a la aparición de marcadores espurios y a oclusiones de las cámaras, un marcador puede ser interpretado como varios marcadores que contienen información complementaria. Con el fin de unificar las trayectorias, aquellos marcadores identificados como equivalentes (menor distancia euclídea entre sí) se concatenan manteniendo la información “real” obtenida (datos capturados con *MoCap*) y los espacios restantes se rellenan con la media de los valores estimados (con el filtro de Kalman). Para limitar la cantidad de marcadores a los mismos con los que cuenta el protocolo se crea un “*auto-marcador*” (EM) de la matriz de trayectorias a través de una aproximación de primer orden de una descomposición singular de valores. Se calcula la coordenada x de cada marcador con el EM y se eliminan aquellos marcadores más alejados. De esta manera se obtiene una matriz de trayectorias completa de un conjunto de marcadores igual a la cantidad que determina el protocolo.

```

Algoritmo: Limpieza y etiquetado de marcadores
Require:  $T_n$ : datos crudos '.c3d'
Ensure:  $U_i$ : datos etiquetados '.c3d'
1:  $n$ : número total de marcadores
2:  $k$ : número de marcadores repetidos
3:  $l$ : cantidad de marcadores a etiquetar
4: for  $n \leftarrow 1, i$  do
5:     if % faltante de datos  $\geq 85\%$  then
6:         Eliminar marcador[ $i$ ]:  $m = n - i$ 
7:     if % faltante de datos  $\leq 85\%$  then
8:         Reconstruir marcador[ $i$ ] siguiendo [4]
9: Identificar y unificar marcadores repetidos:  $m = n - k$ 
10: if  $m \geq l$  then
11:     Eliminar marcadores fantasmas:  $m = l$ 
12: Identificar marcador más alto
13: Etiquetar marcador ( $N$ : séptima vértebra cervical)
14: Identificar marcadores cercanos  $N$ 
15: Etiquetar la cintura escapular
16: Identificar marcadores cercanos a la cintura escapular
17: Etiquetar la pelvis
18: while Usuario  $\neq$  OK do
19:     Dividir marcadores del miembro derecho o izquierdo
20:     for lado  $\leftarrow$  derecho, izquierdo do
21:         for segmento  $\leftarrow$  muslo, pierna do
22:             Identificar posición óptima del segmento
23:             Emparejamiento de marcadores
24:             Etiquetar segmento
25:             Etiquetar segmento pie
26: Mostrar resultado a Usuario (OK o Nos  $\neq$ OK).

```

Figura 2: Algoritmo de limpieza y etiquetado de marcadores.

El etiquetado automático consiste en asignar un nombre a cada marcador con el fin de poder identificarlos y procesarlos. El bloque 2 hace coincidir la plantilla de una adquisición estática de un hombre adulto etiquetado con los marcadores procesados. Primero se ajusta la plantilla a la altura del sujeto, luego se identifica la dirección de avance para determinar izquierda y derecha. El etiquetado comienza desde el marcador más alto identificándolo como C7 y se continúa con aquellos que presentan la menor distancia euclídea y se los nombra hombro derecho e izquierdo. Se realiza el mismo procedimiento para la cintura pelviana. Para identificar los miembros inferiores, primero se utiliza un discriminador lineal para separar izquierda de derecha en el cuadro en el que exista la mayor dispersión en el plano coronal. Con cada uno de estos grupos se busca el cuadro en el que haya menor dispersión para alinearlos con la plantilla y de esta forma identificar muslo, pierna y pie. Finalmente, el usuario verifica que el etiquetado haya sido el correcto, de ser así se finaliza el proceso, sino se busca otro cuadro desde el cual iniciar el etiquetado de c7.

Análisis de datos

Se estudió la robustez del algoritmo para limpiar y etiquetar adquisiciones de diferente calidad en función de la cantidad de *gaps* presentes.

Resultados

Los resultados obtenidos se pueden ver en la Figura 3. Se observa que el algoritmo limpia y etiqueta de forma correcta la mayor cantidad de marcadores. En el gráfico se representa la media (línea sólida) y los valores máximos y mínimos (líneas punteadas) de las 720 simulaciones evaluadas. Se puede observar que el rendimiento disminuye a medida que es mayor la cantidad de marcadores afectados (líneas de colores). En el eje horizontal podemos visualizar el rendimiento del algoritmo a medida que se generan *gaps* más prolongados en el tiempo, llegando a eliminar el 40% de la información del marcador.

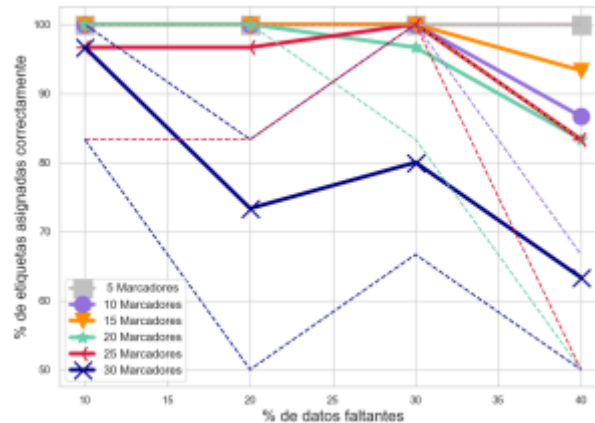


Figura 3: Porcentaje de etiquetado correcto vs. apariciones de lagunas en los datos simulados a medida que varía la cantidad de marcadores que contienen estas lagunas. Se presenta la media (líneas solidas) y los valores máximos y mínimos (líneas punteadas) de todos los marcadores agrupados de a cinco.

En línea azul observamos que el peor rendimiento que se obtiene es con gaps extensos afectando al total de los 30 marcadores. Sin embargo, es de rescatar que en la condición más extrema el algoritmo igual puede etiquetar de forma correcta más del 60% de los marcadores.

Conclusiones

El algoritmo propuesto es una innovación a una problemática diaria que se presenta en entornos clínicos. La adquisición de los movimientos del paciente muchas veces se ve afectado por oclusiones en la zona de adquisición y por reflejos aleatorios que aparecen formando marcadores fantasmas. La limpieza y el etiquetado de la adquisición cruda le lleva al profesional mucho tiempo y no existe un algoritmo que resuelva ambos inconvenientes de forma conjunta.

La solución que se propone resuelve automáticamente estos dos problemas. Una de las grandes ventajas que presenta es que no requiere de entrenamiento previo a diferencia de Clouthier et. al (2021) lo que simplifica muchísimo su aplicación y permitiría, en teoría, catalogar cualquier movimiento sin necesidad que éste haya sido evaluado con anterioridad. El desempeño que se encontró es el esperado, ya que disminuye a medida que aumentan los marcadores afectados y los *gaps* de estos. El peor de los casos, donde se obtiene un etiquetado correcto superior al 60%, es una adquisición que desde la práctica se descartaría debido a la cantidad de ruido que presenta. Considerando este peor entorno, el algoritmo igualmente obtiene resultados aceptables.

Como futuras líneas de investigación se buscará estudiar su desempeño en sujetos reales con distintos grados de patología, así como también en movimientos diferentes a la marcha.

Referencias

- Aristidou, A., & Lasenby, J. (2013). Real-time marker prediction and CoR estimation in optical motion capture. *The Visual Computer*, 29(1), 7-26.
- Clouthier, A. L., Ross, G. B., Mavor, M. P., Coll, I., Boyle, A., & Graham, R. B. (2021). Development and Validation of a Deep Learning Algorithm and Open-Source Platform for the Automatic Labelling of Motion Capture Markers. *IEEE Access*, 9, 36444-36454.
- Gløersen, Ø., & Federolf, P. (2016). Predicting missing marker trajectories in human motion data using marker intercorrelations. *PloS one*, 11(3), e0152616.
- Herda, L., Fua, P., Plankers, R., Boulic, R., & Thalmann, D. (2000, May). Skeleton-based motion capture for robust reconstruction of human motion. In *Proceedings Computer Animation 2000* (pp. 77-83). IEEE.
- Bascones, J. J., Graña, M., & Lopez-Guede, J. M. (2019). Robust labeling of human motion markers in the presence of occlusions. *Neurocomputing*, 353, 96-105.
- Liu, G., & McMillan, L. (2006). Estimation of missing markers in human motion capture. *The Visual Computer*, 22(9), 721-728.
- Skurowski, P., & Pawlyta, M. (2021). Gap Reconstruction in Optical Motion Capture Sequences Using Neural Networks. *Sensors*, 21(18), 6115.
- Wu, Q., & Boulanger, P. (2011, May). Real-time estimation of missing markers for reconstruction of human motion. In *2011 XIII Symposium on Virtual Reality* (pp. 161-168). IEEE.

- Xia, G., Sun, H., Zhang, G., & Feng, L. (2016). Human motion recovery jointly utilizing statistical and kinematic information. *Information Sciences*, 339, 189-205.
- Xiao, J., Feng, Y., & Hu, W. (2011). Predicting missing markers in human motion capture using l1-sparse representation. *Computer Animation and Virtual Worlds*, 22(2-3), 221-228.