

Estimación de carga muscular mediante imágenes

Leandro Abraham¹²³, Facundo Bromberg¹³ y Raymundo Forradellas²

¹ Laboratorio DHARMA, DISI, Universidad Tecnológica Nacional, FRM
leandro.abraham@frm.utn.edu.ar y fbromberg@frm.utn.edu.ar

² CEAL, Universidad Nacional de Cuyo, Facultad de Ingeniería ceal@fing.uncu.edu.ar

³ Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET)

Resumen Un problema de gran interés en disciplinas como la ocupacional, ergonómica y deportiva, es la medición de variables biomecánicas involucradas en el movimiento humano (como las fuerzas musculares internas y torque de articulaciones). Actualmente este problema se resuelve en un proceso de dos pasos. Primero capturando datos con dispositivos poco prácticos, intrusivos y costosos. Luego estos datos son usados como entrada en modelos complejos para obtener las variables biomecánicas como salida. El presente trabajo representa una alternativa automatizada, no intrusiva y económica al primer paso, proponiendo la captura de estos datos a través de imágenes. En trabajos futuros la idea es automatizar todo el proceso de cálculo de esas variables. En este trabajo elegimos un caso particular de medición de variables biomecánicas: el problema de estimar el nivel discreto de carga muscular que están ejerciendo los músculos de un brazo. Para estimar a partir de imágenes estáticas del brazo ejerciendo la fuerza de sostener la carga, el nivel de la misma, realizamos un proceso de clasificación. Nuestro enfoque utiliza Support Vector Machines para clasificación, combinada con una etapa de pre-procesamiento que extrae características visuales utilizando variadas técnicas (Bag of Keypoints, Local Binary Patterns, Histogramas de Color, Momentos de Contornos) En los mejores casos (Local Binary Patterns y Momentos de Contornos) obtenemos medidas de performance en la clasificación (Precision, Recall, F-Measure y Accuracy) superiores al 90 %.

Keywords: biomechanical variables, muscle arm load, support vector machine, local binary patterns, bag of key points, contour moments, color histograms

1. Introducción

La biomecánica es una disciplina científica que tiene por objeto el estudio de las estructuras de carácter mecánico, modelos, fenómenos y leyes que sean relevantes al movimiento y al equilibrio de los seres vivos; fundamentalmente del cuerpo humano. Las variables biomecánicas más estudiadas al momento de analizar el movimiento humano son: las fuerzas internas ejercidas por los músculos involucradas en los mismos y los torques que se producen en las articulaciones al ejecutarse estos movimientos. El análisis de las variables biomecánicas permite identificar: movimientos perjudiciales para la salud, situaciones de sobre esfuerzo, posiciones in/ade cuadas, movimiento óptimo, entre otras situaciones. Esto conlleva a que tenga gran impacto en disciplinas como la ocupacional [5], la ergonómica [13] y el deporte [16].

Para encontrar las fuerzas musculares y torques de articulaciones actuantes en un movimiento, comúnmente se aplican modelos dinámicos complejos [15,19,21]. La in-

formación de entrada para estos modelos es obtenida mediante dispositivos como: electromiografos (EMG) que miden nivel de activación muscular de forma eléctrica (requiere adhesión de electrodos cableados al cuerpo o introducción de agujas en los músculos), goniómetros que miden ángulos de las partes del cuerpo (implica adherir sensores y elementos al cuerpo de las personas), sistemas de captura de movimiento para medir posiciones y ángulos de las partes del cuerpo (requiere adherir marcadores y montar sistemas multicámaras), entre otros. Los dispositivos utilizados para capturar la información necesaria en estos modelos son costosos e intrusivos. Además no son aptos para utilizarlos fuera del entorno de un laboratorio ya que requieren el montaje de dispositivos especiales (cableados) sobre el cuerpo de las personas (electrodos o agujas en el cuerpo, traje con marcadores, goniómetros) y en el entorno (sistema de múltiples cámaras).

En este trabajo proponemos el punto de partida de una investigación cuyo objetivo final consiste en poder automatizar lo más posible la medición no intrusiva de las variables biomecánicas de interés involucradas en un movimiento humano, y de las variables intermedias que necesiten ser usadas en el proceso. Como primer paso, proponemos en este trabajo una solución al problema de estimar el nivel discreto de carga muscular que se encuentra realizando un brazo humano levantando un objeto de peso conocido, solamente utilizando información visual extraída desde fotografías del brazo. Tanto el problema particular, como la línea de investigación a la que pertenece y también la solución que se propone, mejoran y simplifican a las técnicas existentes ya que consisten en un enfoque automático y no intrusivo. Hasta donde los autores conocemos, no se han presentado soluciones que estimen nivel de carga o variables biomecánicas sólo a partir de información de imágenes como se podrá observar en la Sección 4 lo que hace novedoso nuestro enfoque.

Con el objetivo de resolver el problema planteado es que presentamos en este trabajo un procedimiento que permite estimar el nivel de peso discreto levantado por el brazo de una persona a partir de una imagen en la Sección 2. Este procedimiento consiste en utilizar una técnica de aprendizaje de máquinas supervisado para clasificar las imágenes, combinada con una etapa de pre-procesamiento que caracteriza las mismas utilizando variadas técnicas de extracción de características visuales. Posteriormente en la Sección 3 presentamos experimentación y resultados que demuestran de forma inicial el buen funcionamiento del procedimiento propuesto. Con el motivo de encuadrar este trabajo en el estado del arte y dimensionar su impacto es que en la Sección 4 presentamos un breve repaso y discusión sobre los trabajos más relacionados al problema y al tema de investigación en general. Finalmente presentamos nuestras conclusiones y nuevos lineamientos para seguir trabajando en la Sección 5.

2. Enfoque

2.1. Captura de las imágenes y Preprocesamiento de los datos

Se procede de la siguiente manera para capturar las imágenes: 1) el sujeto de prueba sostiene una carga de peso P_i con el brazo estirado, a piel descubierta; 2) se toma una fotografía solamente del brazo (sin capturar el objeto) con un fondo azul para facilitar posteriormente el proceso de segmentación del brazo; 3) para un P_i dado se repiten los pasos 1 y 2, N veces para obtener N ejemplos del ese nivel de carga; 4) se repite el proceso anterior con el resto de los pesos.

Luego de capturar las imágenes es necesario un realizar la segmentación del brazo. Para ello se propone un proceso semiautomático de segmentación que consiste en identificar en la imagen los píxeles que son del color del fondo (azul) y eliminarlo como background. La segmentación se realizó aplicando el algoritmo de clustering K-Means [8] tomando como datapoints los valores RGB de cada píxel de las imágenes. Posteriormente se aplicó una operación morfológica de erosión para remover posible ruido. Finalmente a los píxeles del background en la imagen original se les asignó el valor cero.

2.2. Extracción de características visuales

El próximo paso es extraer un vector de características de las imágenes para usarlo como entrada en el proceso de aprendizaje. Las técnicas que presentaremos en esta sección se usaron para tal fin y se programaron usando las versiones de los algoritmos implementadas en la librería OpenCV [4]. Como resultado de esta etapa se obtuvieron un dataset por cada técnica de extracción de características implementada. Los vectores de características de cada imagen se etiquetaron con el tipo de objeto levantado, lo que tiene una relación directa con el nivel de carga, ya que cada tipo de objeto tiene un peso distinto. De esta forma cada dataset contiene un datapoint por imagen que consiste en una tupla formada por el vector de características extraídas para la imagen, y la clasificación correcta de la imagen.

Bag of Keypoints (BKP) Un enfoque para extraer características visuales muy utilizado en categorización visual es el de BKP [10]. Con este enfoque primero se encuentran porciones de la imagen que presentan características que pueden ser igualmente detectadas bajo variación de escala, iluminación o ruido (puntos de interés). Generalmente se caracterizan por ser zonas de gran contraste en la imagen. En nuestro trabajo utilizamos el algoritmo SURF [2] para encontrar estos puntos de interés. Cada uno se caracteriza mediante un vector que contiene información del mismo (posición, orientación, entre otras). Posteriormente se entrena una técnica de clustering para agrupar los puntos de interés en un diccionario de porciones de imágenes según sus vectores de características, en una cantidad definida de clusters. En nuestro caso el tamaño del diccionario es de 800 grupos y se obtuvo aplicando la técnica de clusterización KMeans a los vectores descriptivos de los puntos de interés. Luego se analizan todas las imágenes para obtener un histograma de aparición de cada punto de interés en cada imagen nueva. Este histograma se calcula para cada imagen sobre los distintos clusters, por lo que tendrá 800 intervalos para nuestro caso. Finalmente se devuelven estos histogramas como vectores de características. En nuestro caso entonces la cantidad de variables del vector de características por imagen es de $n = 800$.

Local Binary Patterns (LBP) Otra forma de extraer características de imágenes muy utilizada es LBP [18], que extrae información de textura de la imagen, y ha sido muy utilizada para caracterización de la piel en el área de reconocimiento de expresiones faciales [25]. Este enfoque es invariante a rotaciones y robusto a variaciones en escala de grises.

El proceso consiste en los siguientes pasos: 1) dividir cada imagen en una grilla de tamaño $N \times N$, obteniendo así $N \times N$ regiones de interés (ROI); 2) generar un código binario de 8 bits para cada píxel en una ROI comparando el píxel con sus 8 píxeles vecinos (superior, inferior, derecho, izquierdo y diagonales) y decidiendo por el valor 0

si el píxel central es mayor a su vecino y 1 en caso contrario; 3) estos códigos posteriormente son transformados a un valor decimal y cuantizados en un histograma por ROI (que tiene 59 intervalos en nuestro caso); 4) los histogramas de cada ROI se concatenan en un nuevo vector que representa la imagen completa dando como resultado un vector de características de tamaño $n = N * N * 59$. En nuestro caso particionamos la imagen en 3×3 por lo que el vector tiene un tamaño $n = 3 * 3 * 59 = 531$.

Histograma de color (HC) Otra técnica utilizada comúnmente en caracterización de imágenes para clasificación [6] y para recuperación de imágenes [24], son los histogramas de color. Esta técnica consiste en cuantizar los valores de los píxeles de una ROI en histogramas de tamaño definido.

En nuestro caso calculamos los histogramas de color de los dos primeros (HS) canales del espacio HSV (Hue Saturation Value [23]) de una imagen particionada en celdas. Para nuestros experimentos la imagen se particiona en una grilla de 3×3 celdas o ROI y se usan 5 intervalos para cada canal del histograma. De esta forma el valor de cada píxel de cada canal aporta a la suma de uno de los 5 intervalos del histograma del canal según corresponda. Esta técnica genera un vector de características de tamaño $n = 3 * 3 * 5 * 5 = 225$. El hecho de trabajar sobre el espacio de color HSV provee a la técnica robustez a los cambios en iluminación.

Momentos de contornos (MC) Otra forma de caracterizar una imagen es a través de información de su contorno. Una de las formas más simples de comparar contornos es a través de sus momentos. El momento de un contorno es un promedio pesado de las intensidades de los píxeles. Definimos el momento m_{pq} de un contorno como :

$$m_{p,q} = \sum_{i=1}^n I(x, y) x^p y^q$$

A p y q se los denomina órdenes del momento. La sumatoria es sobre todos los píxeles del contorno (n). $I(x, y)$ es el valor de intensidad del píxel (x, y) de la imagen. Los contornos de la imagen se obtienen con un algoritmo de detección de bordes.

Es posible definir distintos tipos de momentos. Los momentos espaciales son 10 y se encuentran variando los órdenes de x e y (p y q) en la fórmula anterior. Los momentos centrales son 7 y se obtienen agregando información de los momentos de orden 0 y 1 en la fórmula original. Los momentos normalizados son 7 y se estiman a partir de los momentos centrales divididos por una potencia del momento m_{00} . Finalmente los Hu Invariant moments [12] son 7 y se estiman como combinaciones lineales de los momentos centrales. Estos últimos son muy útiles ya que permiten caracterizar el contorno de forma invariante a escala, rotación y reflexión. Concatenando todos estos momentos generamos un vector de $n = 10 + 7 + 7 + 7 = 31$ características.

2.3. Procedimiento de aprendizaje

En este paso se aprende el modelo subyacente en los datasets de entrenamiento mediante la aplicación de una técnica de aprendizaje de máquinas supervisado de manera de poder clasificar el nivel de carga muscular de nuevos ejemplos. Nosotros utilizamos la técnica de Support Vector Machine (SVM) [9,3] debido a que es robusta y muy usada para tareas de clasificación. Utilizamos la función correspondiente (`svm`) implementada en el paquete `e1071` del lenguaje de programación R [17], con los valores por defecto

para sus parámetros (kernel de tipo radial con $\gamma=0.0018$). Debido a que se obtuvieron 4 datasets distintos (resultado del proceso de la Sección 2.2), el proceso de entrenamiento y clasificación se realizó 4 veces. Finalmente, usando la misma técnica de aprendizaje predecimos los valores o niveles de carga realizando clasificación tri-clase sobre cada dataset de testeo a partir del modelo aprendido (consideramos imágenes levantando solo tres cargas diferentes)

3. Experimentación y resultados

Realizamos el proceso de aprendizaje y clasificación sobre un conjunto de 92 imágenes segmentadas, de brazos sosteniendo 3 pesos distintos. Los pesos y objetos utilizados son: el objeto O0 que pesa 0Kgs, el objeto O5 que pesa 2.25Kgs y el objeto O6 que pesa 5Kgs. Estos pesos corresponden con las clases 0, 5 y 6 respectivamente. Se tienen 30 instancias de la clase 0, 33 instancias de la clase 5 y 29 instancias de la clase 6. Cada dataset se fragmentó en un conjunto de entrenamiento conformado por el 70 % del dataset original y el conjunto de testeo conformado por el 30 % restante tomadas al azar del dataset completo. En distintas instancias del experimento se entrenó el clasificador usando datos extraídos con los 4 tipos de características presentadas, se reportaron las medidas de rendimiento que presentaremos en breve y se realizó un análisis comparativo de las mismas.

Como medidas de rendimiento se consideraron *Precision* (P), *Recall* (R), *F-Measure* (FM) y *Accuracy* (A), para el caso multi-clase para cada experimento. Para la *i*-ésima clase, la P_i corresponde a la cantidad de ejemplos de la *i*-ésima clase clasificados correctamente, dividido por la cantidad de ejemplos de otras clases clasificados incorrectamente como pertenecientes a la *i*-ésima clase. En términos de la matriz de confusión, estas cantidades corresponden a la cantidad reportada en la diagonal del *i*-ésimo renglón y la suma de las cantidades del *i*-ésimo renglón, respectivamente. El R_i de la *i*-ésima clase es similar, solo que el denominador corresponde al total de ejemplos de la clase clasificados incorrectamente como pertenecientes a alguna otra clase, i.e., la suma de las cantidades de la *i*-ésima columna. El cálculo de la FM_i se computa de igual manera que el caso binario pero usando los valores P_i y R_i , i.e., $FM_i = 2 * ((P_i * R_i) / (P_i + R_i))$. Por último, la A_i , que corresponde a la fracción de ejemplos clasificados correctamente como pertenecientes a la clase *i*-ésima, se computa como la suma de las cantidades de la diagonal (i.e., clasificados correctamente como pertenecientes a la clase) mas la suma de las cantidades no pertenecientes ni al *i*-ésimo renglón ni a la *i*-ésima columna (i.e., clasificados correctamente como no pertenecientes a la *i*-ésima clase), dividida por la suma de todas las cantidades de la matriz (i.e., el número total de ejemplos).

Además para cada experimento es calculado el promedio de estas medidas (\hat{P} , \hat{R} , \hat{FM} y \hat{A}) sobre todas las clases, junto con la Overall Accuracy (OvA). Esta última medida es la accuracy sobre toda la matriz de confusión y se calcula sumando los elementos de la diagonal de la matriz dividido por la suma de todos los elementos de la misma).

Resumimos en el Cuadro 1 los valores promedio y de OvA obtenidos para cada medida de rendimiento sobre cada dataset obtenido con las distintas técnicas de extracción de características.

Presentamos los resultados por clases sobre cada dataset en el Cuadro 2 y realizamos un breve análisis. Los resultados de la técnica BKP para cada clase muestran que para

Exp.	OvA	\hat{A}	\hat{P}	\hat{R}	\hat{FM}
BKP	82.14 %	88.09 %	80.83 %	82.78 %	80.83 %
LBP	100 %	100 %	100 %	100 %	100 %
HC	75 %	83.33 %	76.06 %	73.56 %	73.29 %
MC	92.85 %	95.23 %	93.93 %	93.93 %	93.93 %

Cuadro 1: Resultados generales

estos datos la clase 6 es la que más le costó identificar. Los resultados de la técnica LBP para cada clase son muy alentadores ya que demuestran un excelente desempeño. Los resultados de la técnica HC para cada clase muestran que no pudo distinguirse muy acertadamente las clases 5 y 6. Los resultados de la técnica MC para cada clase permiten ver que para este conjunto de datos se puede identificar de forma ideal la clase 0.

Feature Extraction	Clase	A	P	R	FM
BKP	0	92.85 %	80 %	100 %	88.88 %
BKP	5	89.28 %	100 %	76.92 %	86.95 %
BKP	6	82.14 %	62.5 %	71.42 %	66.66 %
LBP	0	100 %	100 %	100 %	100 %
LBP	5	100 %	100 %	100 %	100 %
LBP	6	100 %	100 %	100 %	100 %
HC	0	92.85 %	100 %	81.81 %	90 %
HC	5	78.57 %	66.66 %	50 %	57.14 %
HC	6	78.57 %	61.53 %	88.88 %	72.72 %
MC	0	100 %	100 %	100 %	100 %
MC	5	92.85 %	100 %	81.81 %	90 %
MC	6	92.85 %	81.81 %	100 %	90 %

Cuadro 2: Resultados de cada técnica de extracción de características para cada clase

Algunas conclusiones que podemos extraer de los resultados son: 1) LBP es la técnica que presenta mejores resultados en este conjunto de datos ya que todas sus medidas son superiores al resto; lo que nos dice que la información local de textura tiene altas probabilidades de servir para caracterizar una imagen en base a su nivel de carga muscular; 2) los segundos mejores resultados fueron obtenidos por la técnica MC, lo que nos indica que también la información de contorno sirve para esta caracterización; 3) todos los resultados son superiores al 70 % y muchos de ellos mayores al 90 % lo que indica que las técnicas presentadas de extracción de características en combinación con la técnica de clasificación elegidas son útiles para estimar de forma discreta en 3 valores el nivel de carga a partir de imágenes estáticas; 4) tenemos la intuición de que la causa del buen desempeño de LBP sea que la información de textura caracteriza mejor variaciones en la piel.

4. Trabajos relacionados

Hasta donde los autores hemos podido relevar no se han encontrado trabajos en la literatura que resuelvan el problema de estimación de carga muscular mediante imágenes

de la piel, pero presentaremos en esta sección los trabajos más relacionados, principalmente en cuanto a la aplicación de Visión Computacional para sensado muscular.

Encontramos en la literatura una serie de trabajos relacionados al sensado muscular a partir de imágenes de ultrasonido. Entre los problemas que resuelven los trabajos relevados podemos ver el de estimación de desplazamientos y movimientos musculares [20,14]; estimación de medidas internas del músculo (volumen, tamaño, diámetro, largo, área, fuerza de contracción máxima voluntaria, entre otros) así también como la relación de estas medidas con los distintos niveles de actividad muscular [7,1,11] y finalmente identificar flexión de los dedos y momento de ocurrencia ([22]). Como se observa, los problemas que resuelven puntualmente estos trabajos estiman una gran cantidad de variables musculares, entre ellas medidas que son correlativas a la carga muscular. A pesar de que estos problemas son similares al que nosotros resolvemos, estos autores no atacan el problema puntual de estimar carga o esfuerzo muscular mediante imágenes de la piel. El uso de imágenes de ultrasonido no siempre es posible. Estas imágenes se deben capturar con dispositivos especiales, costosos y que requieren contacto directo con la piel imposibilitando el sensado a distancia. Una ventaja de nuestro enfoque sobre estos trabajos es el uso de imágenes que si pueden ser capturadas a distancia y con una cámara convencional.

Además, en la literatura es posible encontrar trabajos que realizan sensado muscular aplicando visión computacional a imágenes externas como en [26,27]. Estos trabajos resuelven el problema de estimar el nivel de contracción muscular en sanguijuelas a partir de imágenes de movimiento microscópicas de su piel. El problema resuelto por los autores mencionados esta relacionado con el que resolvemos en este trabajo, en cuanto a que tratan de cuantizar o caracterizar la contracción de un músculo en base a imágenes externas. De todos modos si bien ellos resuelven un problema similar, no trabajan sobre piel humana y lo hacen a partir de videos utilizando técnicas que caracterizan el movimiento de los píxeles realizando un seguimiento de un cuadro a otro del video. Estos trabajos pueden ser un buen antecedente para caracterizar movimiento de texturas, y sus resultados podrían ser aplicables a piel humana para caracterizar la contracción muscular en personas y posteriormente estimar el nivel de carga.

Como se puede observar, no se han encontrado trabajos en la literatura que resuelvan el problema puntual de estimar el nivel de carga muscular mediante imágenes de la piel.

5. Conclusiones y trabajo futuro

En este trabajo presentamos un enfoque que permite decidir con un alto grado de certeza qué nivel de carga muscular de entre 3 posibles está ejerciendo una persona a partir de una imagen de su brazo a piel descubierta. Esto fue posible realizando aprendizaje supervisado (SVM) sobre vectores de características visuales de las imágenes obtenidos aplicando diversas técnicas para tal fin (BKP, LBP, HC, MC). Para el conjunto de imágenes utilizadas en este trabajo, las técnicas de LBP y de MC dieron los mejores resultados. Sin embargo, todas las técnicas presentan una performance (Prec., Rec., F-M. y Acc.) aceptable y superiores al 70 % (llegando al 100 % en el mejor caso). Cabe aclarar que el buen desempeño obtenido por todas las técnicas puede estar influenciado por la uniformidad en iluminación, escala, posición y ventana de recuadro impuesta a la captura de las imágenes de forma intencional con el objetivo de controlar lo mejor posible los datos de entrada. Cuando se implemente esta solución en entornos

más realistas, puede ser necesario realizar normalizaciones en escala, iluminación y posición a las imágenes o aplicar técnicas para extraer características que sean lo más invariantes posible a cambios en estas propiedades.

Como trabajo futuro nos enfocaremos en mejorar la resolución del enfoque, realizando clasificación en 5 niveles de carga discreta, para posteriormente intentar realizar regresión, estimando así el peso real del objeto concreto que se está levantando. A más largo plazo se tiene como objetivo lograr predecir el nivel de la señal de EMG sólo a partir de información visual, ya que es de mucha utilidad en el estudio de la biomecánica. Además mejoraremos el setting de experimentación trabajando sobre más de un sujeto y realizando cross-validation para mejorar la validez de los resultados y la significancia estadística.

Agradecimientos El presente trabajo se llevo a cabo gracias a la financiación del autor Leandro Abraham a través de una beca de doctoral del CONICET bajo la dirección de beca del Dr. Raymundo Forradellas (dedicación full time en Facultad de ingeniería de UNCuyo), en conjunto con la dirección de tesis del Dr. Facundo Bromberg (dedicación full time en UTN-FRM y miembro de carrera de CONICET).

Referencias

1. Barber, L., Barrett, R., Lichtwark, G.: Validation of a freehand 3d ultrasound system for morphological measures of the medial gastrocnemius muscle. *J Biomech* 42(9), 1313–1319
2. Bay, H., Tuytelaars, T., Van Gool, L.: Surf: Speeded up robust features. In: *Computer Vision–ECCV 2006*, pp. 404–417. Springer (2006)
3. Bishop, C.: *Pattern recognition and machine learning*. Springer (2009)
4. Bradski, G.: *Dr. Dobb's Journal of Software Tools*
5. Chaffin, D.B., Andersson, G., Martin, B.J., et al.: *Occupational biomechanics*. Wiley New York (1984)
6. Chapelle, O., Haffner, P., Vapnik, V.N.: Support vector machines for histogram-based image classification. *IEEE Trans. Neural Networks* 10(5), 1055–1064 (1999)
7. Chi-Fishman, G., Hicks, J.E., Cintas, H.M., Sonies, B.C., Gerber, L.H.: Ultrasound imaging distinguishes between normal and weak muscle. *Archives of physical medicine and rehabilitation* 85(6), 980–986 (2004)
8. Chitade, A.Z., Katiyar, S.: Colour based image segmentation using k-means clustering. *IJEST* 2(10), 5319–5325 (2010)
9. Cortes, C., Vapnik, V.: Support-vector networks. *MACH LEARN* 20(3), 273–297
10. Csurka, G., Dance, C., Fan, L., Willamowski, J., Bray, C.: Visual categorization with bags of keypoints. In: *Workshop on statistical learning in computer vision, ECCV*, vol. 1, pp. 1–2
11. De Oliveira, L.F., Luporini Menegaldo, L.: Individual-specific muscle maximum force estimation using ultrasound for ankle joint torque prediction using an emg-driven hill-type model. *J Biomech* 43(14), 2816–2821 (2010)
12. Hu, M.K.: Visual pattern recognition by moment invariants. *Information Theory, IRE Transactions on* 8(2), 179–187
13. Kumar, S.: *Biomechanics in ergonomics*. CRC Press (1999)
14. Li, J., Zhou, Y., Ivanov, K., Zheng, Y.P.: Estimation and visualization of longitudinal muscle motion using ultrasonography: A feasibility study. *Ultrasonics* 54(3), 779–788 (2014)
15. Manal, K.T., Buchanan, T.S.: *Biomechanics of human movement*. Standard handbook of biomedical engineering & design p. 26 (2004)
16. McGinnis, P.: *Biomechanics of sport and exercise*. Human Kinetics (2013)
17. Meyer, D.: Support vector machines. The Interface to libsvm in package e1071.
18. Ojala, T., Pietikäinen, M., Harwood, D.: A comparative study of texture measures with classification based on featured distributions. *Pattern recognition* 29(1), 51–59
19. Pandy, M.G., Barr, R.E.: *Biomechanics of the musculoskeletal system*. Standard Handbook of Biomedical Engineering and Design (2004)
20. Peng, Q., Jones, R.C., Constantinou, C.E.: 2d ultrasound image processing in identifying responses of urogenital structures to pelvic floor muscle activity. *ANN BIOMED ENG* 34(3), 477–493 (2006)
21. Qi, S., Buchanan, T.S.: Electromyography as a tool to estimate muscle forces. Standard handbook of biomedical engineering & design (2004)
22. Shi, J., Hu, S.x., Liu, Z., Guo, J.Y., Zhou, Y.j., Zheng, Y.p.: Recognition of finger flexion from ultrasound image with optical flow: A preliminary study. In: *ICBECS*, pp. 1–4. IEEE
23. Smith, A.R.: Color gamut transform pairs. In: *ACM Siggraph Computer Graphics*, vol. 12, pp. 12–19. ACM (1978)
24. Sural, S., Qian, G., Pramanik, S.: Segmentation and histogram generation using the hsv color space for image retrieval. In: *Image Processing. 2002. Proceedings. 2002 International Conference on*, vol. 2, pp. II–589. IEEE (2002)
25. Zhao, G., Pietikainen, M.: Dynamic texture recognition using local binary patterns with an application to facial expressions. *Pattern Analysis and Machine Intelligence, IEEE Transactions on* 29(6), 915–928 (2007)
26. Zoccolan, D., Giachetti, A., Torre, V.: The use of optical flow to characterize muscle contraction. *Journal of neuroscience methods* 110(1), 65–80 (2001)
27. Zoccolan, D., Torre, V.: Using optical flow to characterize sensory-motor interactions in a segment of the medicinal leech. *The Journal of neuroscience* 22(6), 2283–2298 (2002)