

JORNADAS de ROBÓTICA, EDUCACIÓN y BIOINGENIERÍA 2022

XII Jornadas Nacionales de Robótica
VIII Seminario de Educación en Automática
XIII Simposio CEA de Bioingeniería

Málaga, 18-20 de mayo, 2022



Colaboran



Libro de actas

de las

JORNADAS de ROBÓTICA, EDUCACIÓN y BIOINGENIERÍA 2022

XII Jornadas Nacionales de Robótica
VIII Seminario de Educación en Automática
XIII Simposio CEA de Bioingeniería

Málaga, 18-20 de mayo, 2022

Edita: Dpto. de Ingeniería de Sistemas y Automática
Universidad de Málaga

ISBN: 978-84-09-41095-8

Organiza

**Departamento de Ingeniería de
Sistemas y Automática**

www.uma.es/isa



Universidad de Málaga

www.uma.es



UNIVERSIDAD
DE MÁLAGA

Índice

COMUNICACIONES

UNA NUEVA OPORTUNIDAD DE ATENCIÓN A LAS PERSONAS MAYORES MEDIANTE ROBÓTICA SOCIAL EN LAS RESIDENCIAS LACORT (UNO MÁS) <i>Eduardo Zalama, Jaime Gómez-García-Bermejo, Pablo Francisco Viñas, Luis Cobo Hurtado, José María Delgado Sanz, Beatriz Vielba</i>	4
ROBOT DE CABLES PARA LA LIMPIEZA DE VENTANAS <i>S. Santamaría, E. Zalama, J. Gómez</i>	12
HACIA LA RECOGIDA DE RESIDUOS DOMESTICOS EN EXTERIORES: ENFOQUE VISUAL-TACTIL <i>P. Gil, S.T. Puente, J. Castaño-Amorós, I. L. Páez-Ubieta</i>	17
SISTEMA ROBOTICO INTELIGENTE DE EXPLORACION TERMICA PARA MISIONES DE BUSQUEDA Y RESCATE <i>Christyan Cruz Ulloa, Guillermo Prieto, Jaime del Cerro, Antonio Barrientos</i>	25
APLICANDO HERRAMIENTAS PSICOLÓGICAS PARA INCREMENTAR EL VÍNCULO ENTRE LOS USUARIOS Y LOS ROBOTS SOCIALES <i>Fernando Alonso Martín, Sara Carrasco Martínez, Marcos Maroto Gómez, Javier Sevilla Salcedo, Miguel Á. Salichs</i>	32
ROMERIN: ORGANISMO ROBÓTICO ESCALADOR BASADO EN PATAS MODULARES CON VENTOSAS ACTIVAS <i>Carlos Prados, Miguel Hernando, Ernesto Gambao, Alberto Brunete</i>	40
SISTEMA ROBÓTICO MÓVIL PARA EL ANÁLISIS DE LA MARCHA HUMANA SIN MARCADORES E IDENTIFICACIÓN DE PATOLOGÍAS NEUROLÓGICAS, ROBOGAIT <i>Diego Guffanti, Alberto Brunete, Miguel Hernando, Ernesto Gambao, David Álvarez</i>	50
CREACIÓN DE MAPAS DE NAVEGACIÓN PARA UN ROBOT TREPADOR DE ESTRUCTURAS RETICULARES <i>F.J. Soler, A. Peidró, M. Fabregat, L. Payá, O. Reinoso</i>	57
ANÁLISIS Y VALIDACIÓN DE UN EXOESQUELETO HÍBRIDO PARA REHABILITACIÓN DE LAS EXTREMIDADES SUPERIORES <i>J. Carrillo-Ríos, D. Cantalejo-Escobar, D. Pont-Esteban, A. Contreras González, M. A. Sánchez-Urán, M. Ferre</i>	64
ORIGAMI KRESLING PATTERN AS SOFT SCALABLE LINK <i>L. Mena, C.A. Monje, C. Balaguer</i>	70
SISTEMA DE MONITORIZACIÓN NO INTRUSIVA PARA EL RECONOCIMIENTO DE ACTIVIDADES DE LA VIDA DIARIA EN ENTORNOS MULTIUSUARIO <i>R.G. Ramos, J.D. Domingo, E. Zalama, J. G. García-Bermejo</i>	75
MÉTODO DE ODOMETRÍA BASADA EN PLANOS PARA CÁMARAS DE PROFUNDIDAD <i>Andres Galeote-Luque, Jose-Raul Ruiz-Sarmiento, Javier Gonzalez-Jimenez</i>	83
INTEGRACIÓN DE SMARTPHONES 5G EN REDES DE SENSORES DISTRIBUIDAS PARA ROBÓTICA DE EXTERIORES MEDIANTE ROS Y ANDROID <i>Germán Ruiz Mudarra, Juan Bravo Arrabal, J.J. Fernández Lozano, Alfonso García Cerezo</i>	91

SEGMENTACIÓN SEMÁNTICA DE ELEMENTOS MECÁNICOS EN ENTORNOS AUMENTADOS DE REHABILITACIÓN

Guillermo Sánchez-Brizuela, David Sierra-Rodriguez

ITAP (Instituto de las Tecnologías Avanzadas de la Producción), Universidad de Valladolid, Paseo del Cauce 59, 47011 Valladolid, España, guillermo.sanchez.brizuela@uva.es, david.sierra@uva.es

Eusebio de la Fuente-López, Juan-Carlos Fraile, Javier Pérez-Turiel

ITAP (Instituto de las Tecnologías Avanzadas de la Producción), Universidad de Valladolid, Paseo del Cauce 59, 47011 Valladolid, España, efuente@uva.es, turiel@eii.uva.es, jcfraile@eiii.uva.es

Resumen

La inclusión de elementos virtuales (realidad mixta) en entornos de rehabilitación reales muchas veces requiere detectar elementos físicos concretos en una señal de vídeo. Para evitar el uso de marcadores u otros tipos de elementos localizadores, en este trabajo presentamos una metodología que habilita la segmentación de elementos mecánicos en entornos controlados con un conjunto de datos reducido. Además, presentamos resultados cuantitativos y cualitativos de la aplicación de esta metodología en dos casos reales con robots de rehabilitación.

Palabras clave: Rehabilitación, Segmentación Semántica, Visión artificial, Exoesqueleto.

1 INTRODUCCIÓN

Las terapias de rehabilitación son, por naturaleza, repetitivas, y muchas veces tediosas e incluso dolorosas. Para tratar de mitigar estas sensaciones en el paciente, en los últimos años se han propuesto distintas “gamificaciones” de las terapias [1, 12, 7], que consisten en incluir elementos artificiales característicos de los videojuegos a través de distintos interfaces virtuales. Dentro de estos interfaces se encuentran los visores o dispositivos de realidad mixta, una tecnología que incluye elementos virtuales en el mundo real para crear entornos aumentados que contienen objetos con los que el usuario (en este caso, paciente), puede interactuar. Dada la flexibilidad que ofrecen estas tecnologías y el grado de inmersión que es posible conseguir, han surgido múltiples propuestas enfocadas a la rehabilitación que utilizan este tipo de técnicas.

Estas propuestas, abarcan distintos tipos de tecnologías de visualización como pueden ser proyectores [11, 3], pantallas [14, 6] o visores montados en la cabeza (HMDs) [19, 18]. Por otro lado, para hacer posible la interacción de los pacientes con

los elementos virtuales, las investigaciones existentes emplean sensores [5, 19] o técnicas de procesamiento de imagen [13, 14].

Las técnicas de procesamiento de imagen utilizadas normalmente tienen como finalidad definir la posición del paciente identificando el miembro a rehabilitar [16], o localizar otros elementos mecánicos que intervienen en la terapia de rehabilitación, por ejemplo, máquinas que ofrecen resistencia, objetos para facilitar la realización de ciertos movimientos, o dispositivos que asisten al paciente durante la realización de las terapias.

Para implementar estos algoritmos de detección/localización, las publicaciones existentes documentan el empleo de marcadores de referencia [10, 16] que pueden ser localizados fácilmente por los algoritmos de visión artificial. No obstante, esto requiere la colocación de dichos marcadores, que introduce etapas adicionales en el proceso de rehabilitación y resta flexibilidad a la realización de la terapia.

Por otro lado, la aplicación de técnicas de aprendizaje profundo (subcampo del aprendizaje automático donde los modelos cuentan con un número muy alto de parámetros - *Deep Learning*) al procesamiento de imágenes ha presentado durante la última década un increíble crecimiento, proponiendo soluciones a problemas prácticamente imposibles de resolver con técnicas de procesamiento de imágenes tradicionales, como, por ejemplo, la detección y localización de objetos.

Más concretamente, dentro de la detección de objetos, están las técnicas de segmentación semántica, que clasifican a nivel de píxel la presencia de objetos, proporcionando una máscara que indica que partes de la imagen pertenecen a un objeto previamente aprendido. En este artículo, presentamos una metodología centrada en la utilización de arquitecturas de aprendizaje profundo para segmentar elementos mecánicos en un entorno de rehabilitación controlado

con un número de ejemplos anotados muy reducido. Tras esta presentación, aplicamos la propuesta a dos casos concretos de dispositivos mecánicos para rehabilitación de miembros superiores.

2 MATERIALES Y MÉTODOS

2.1 MATERIALES

2.1.1 Computación

Para el desarrollo de los modelos y las pruebas llevadas a cabo durante la realización de este trabajo se ha empleado un ordenador equipado con un procesador Intel® i5-11600K @ 3.90 GHz y una tarjeta gráfica dedicada NVIDIA RTX 3060 con 12 GB de VRAM.

La captura de las imágenes presentadas en este artículo, utilizadas tanto para entrenar como para evaluar los distintos modelos, se ha llevado a cabo con una cámara Logitech® C920 (1080p/30fps, 3MP, 78° dFoV).

2.1.1 Elementos mecánicos

Tal y como se ha comentado en la introducción de este documento, el objetivo principal de este estudio es segmentar distintos elementos mecánicos en un entorno de rehabilitación de miembros superiores. Pese a que esta metodología es generalizable y aplicable a cualquier otro tipo de elemento mecánico, en este trabajo se utilizan los siguientes dos dispositivos mecatrónicos.

- RobHand: El primero de los elementos empleados es un robot de rehabilitación de mano tipo exoesqueleto [2] que proporciona asistencia en diferentes terapias enfocadas a la rehabilitación de la mano mediante el movimiento de los dedos. Para ello, funciona tanto de forma activa (replicando el movimiento de la extremidad sana) como de forma pasiva. La estructura mecánica del dispositivo está compuesta por una base sólida y por un conjunto de motores y uniones mecánicas encargadas de abrir y cerrar los dedos de la mano.
- M3Rob: El segundo de los elementos es otro robot de rehabilitación, una evolución de RobHand, que incluye un módulo de rehabilitación de muñeca con los elementos mecánicos necesarios para permitir los 3 grados de libertad de la misma: flexión-extensión, pronación-supinación y abducción-aducción. Además, incluye sensores adicionales para la realización de

terapias (sensor EMG y sensor de fuerza). No obstante, estos sensores no influyen en los resultados presentados en este documento.

2.1.2 Software

Para programar los scripts encargados de entrenar y evaluar los modelos, se ha utilizado Python 3.9. Dentro de dicho entorno de desarrollo, se han utilizado las librerías OpenCV para la carga y procesamiento de imágenes, PyTorch y timm para el desarrollo de las arquitecturas de aprendizaje profundo y, por último, Kornia para las operaciones de aumentación de datos.

2.1.2 Conjuntos de datos

Para poder entrenar los distintos modelos de segmentación y evaluarlos correctamente, se han recogido una serie de imágenes en un entorno de rehabilitación con los dos dispositivos mecatrónicos: RobHand y M3Rob (30 imágenes para cada dispositivo de tamaño 1920x1080 píxeles). A la hora de capturar estas imágenes, se han empleado tanto escenas donde solo está presente el dispositivo de rehabilitación, como escenas donde también aparecen las extremidades superiores de un paciente.

Debido a la naturaleza de las técnicas empleadas para llevar a cabo la segmentación de los elementos mecánicos (basadas en aprendizaje profundo), es necesario disponer de una máscara que clasifique realmente cada píxel de las imágenes en función de si pertenecen o no al elemento mecánico estudiado. Estas máscaras, son trazadas a mano para maximizar su calidad, y se emplean tanto como para obtener una medida del error, que se retropropagará para ajustar los parámetros de los modelos (entrenamiento), como para evaluar la calidad de los resultados producidos por los modelos entrenados. Una muestra de estas imágenes del exoesqueleto RobHand y de M3Rob, y sus correspondientes anotaciones se muestra en la Figura 1.

Además de estas imágenes, en este trabajo también se emplea (de forma indirecta) el conjunto de imágenes ImageNet [4], ya que los modelos presentados en este documento han sido preentrenados en dicho *dataset* para ajustar sus filtros y parámetros correspondientes de forma que sean capaces de extraer características generales, que posteriormente se ajustan (fine tuning) a nuestras tareas específicas.




Figura 1: Imágenes y anotaciones de muestra de los conjuntos de datos.

2.2 MÉTODOS

2.2.1 Data Augmentation

Uno de los problemas principales de la segmentación semántica en imágenes, es el coste asociado con la anotación de los objetos en las imágenes empleadas para ajustar los parámetros de los modelos. En este trabajo, se estudian los resultados que se pueden obtener con un número muy reducido de imágenes (30), limitado por la cantidad de tiempo requerida para anotar cada una de ellas.

Para tratar con este número reducido de ejemplos, se incluyen en el proceso de entrenamiento una serie de transformaciones para aumentar el número de imágenes (Data Augmentation). Estas operaciones, tienen como objetivo alterar el valor de los píxeles de las imágenes de forma que tanto las imágenes de entrada como las anotaciones sean distintas a sus respectivos originales, poniendo a disposición de la red neuronal “nueva” información a partir de la cual aprender.

Estas transformaciones se seleccionan teniendo en cuenta la aplicación final, que en este caso es un entorno controlado en el que la mayoría de los cambios son geométricos (posición del elemento mecánico y de las extremidades) y visuales (luces, sombras, tonos).

- Transformaciones geométricas: Dentro de las operaciones geométricas que se aplican en el flujo de aumentación de datos, se incluyen transformaciones proyectivas y transformaciones afines junto con volteos horizontales y verticales. Igualmente, se llevan a cabo recortes aleatorios, así como operaciones de escalado para simular distintas posiciones de la cámara.
- Transformaciones ópticas y de color: Además de las transformaciones que representan operaciones geométricas,

también se incluyen operaciones que modifican los valores de los píxeles sin alterar sus posiciones. Dentro de este grupo de transformaciones, se incluyen filtros gaussianos, filtros que simulan el emborronamiento característico de capturar objetos en movimiento, filtros que afectan a la nitidez de la imagen, y variaciones en distintos canales de la imagen previamente transformada a otros espacios de color (por ejemplo, la saturación en HSV).

Estas alteraciones, se parametrizan aleatoriamente y se aplican sobre todo el *dataset* en cada una de las épocas, es decir, cada vez que se itera sobre todas las imágenes del conjunto de datos.

2.2.2 Arquitecturas

Los modelos entrenados y presentados en este trabajo están basados en una arquitectura de tipo UNet [15], que está formada por un *encoder* y un *decoder*. El primero, extrae características y reduce progresivamente el tamaño de la entrada, mientras que el segundo, construye la máscara de la segmentación en base a la salida de la capa anterior y de las características extraídas por el *encoder* en su nivel correspondiente, aumentando progresivamente el tamaño de la salida.

En cuanto al modelo empleado como extractor de características para la arquitectura tipo UNet, se han evaluado las siguientes tres opciones:

- MobileNet: Propuesta en [9], esta arquitectura emplea convoluciones separables para reducir la complejidad de la operación de convolución, permitiendo que la inferencia de resultados sea más rápida, especialmente en dispositivos con recursos limitados (dispositivos móviles y embebidos).

- ResNet50: Parte de la familia de redes presentada por He. et al. [8], donde se introducen las conexiones residuales, que comunican las entradas de las capas convolucionales con sus salidas, facilitando el entrenamiento de redes con un número de capas mucho mayor.
- EfficientNet-B4: Propuesta como parte del trabajo publicado por Tan. et al. [17], es parte de una familia de redes que siguen una metodología de parametrización de la anchura y profundidad de sus filtros junto con capas de tipo *Mobile Inverted Bottleneck Residual* y bloques *Squeeze-and-Excitation*.

2.2.3 Entrenamiento

Para llevar a cabo el proceso de entrenamiento, se ha empleado el optimizador Adam con una tasa de aprendizaje de $1e-4$ y unos parámetros β_1 y β_2 de, respectivamente, 0,9 y 0,999 durante 100 épocas.

En cuanto a las imágenes, originalmente de 1920×1080 píxeles, se han reducido a un tamaño de 1280×704 píxeles que permite acelerar la inferencia de resultados sin sacrificar la posibilidad de segmentar correctamente pequeños detalles de la estructura mecánica. En cuanto al tamaño de los lotes empleados durante el entrenamiento, se ha elegido un *batch size* de 2 debido al tamaño de las imágenes en memoria y al efecto regularizador que puede tener un tamaño de lote reducido (mayor ruido en la optimización, que puede traducirse en la evasión de mínimos locales).

Por otro lado, la función de pérdida empleada para ajustar los parámetros de los modelos ha sido la función *Dice Loss*, dada por la Ecuación 1, donde p corresponde a la predicción, g a la anotación, y N al total de los píxeles.

$$L(p, g) = \frac{2 \sum_i^N p_i g_i}{\sum_i^N p_i^2 + \sum_i^N g_i^2} \quad (1)$$

2.2.3 Validación

El proceso de validación, de suma importancia, está seriamente limitado por el reducido número de imágenes disponibles. En base a esta problemática, se lleva a cabo una separación (en cada conjunto de datos) en tres paquetes de 10 imágenes cada uno.

Una vez dividido el dataset en estas tres partes, se lleva a cabo una validación cruzada donde se cogen dos de las tres partes para entrenar y la parte restante para validar. Este proceso, se repite tres veces iterando sobre los conjuntos, de forma que, en cada iteración, el conjunto de validación (que no se emplea para

entrenar) sea distinto. Los resultados finales, son el promedio de estas tres iteraciones.

2.2.2 Métricas de evaluación

En cuanto a las métricas que se reportan en la fase aplicada de este trabajo, se encuentran: El número de parámetros de cada uno de los modelos empleados; el número de imágenes (de tamaño 1280×704) que es capaz de procesar el modelo en un segundo de forma individual (sin considerar *batch sizes* mayores que uno) (*frames per second* – FPS); y por último, el IoU (*Intersection over Union*), que representa el resultado de dividir el área de la intersección de la predicción y la anotación entre el área de la unión de ambos (en caso de que coincidan exactamente, el valor es la unidad).

3 RESULTADOS Y DISCUSIÓN

Durante el procedimiento de entrenamiento se lleva a cabo la validación tanto en el conjunto de imágenes de RobHand como en el de M3Rob. De estas pruebas de validación, se calculan los valores de IoU promedio para cada una de las arquitecturas planteadas. Estas métricas están disponibles en la Tabla 1, correspondiente al conjunto de datos de RobHand, y en la Tabla 2, cuyos valores corresponden a las imágenes de M3Rob.

Tabla 1: Resultados en el conjunto de imágenes de RobHand.

Arquitectura	IoU
EfficientNet-B4	0.9338
MobileNetV3	0.9203
ResNet50	0.9108

Tabla 2: Resultados en el conjunto de imágenes de M3Rob.

Arquitectura	IoU
EfficientNet-B4	0.9186
MobileNetV3	0.8973
ResNet50	0.9099

Además de estas medidas cuantitativas de los resultados de los modelos, presentamos a continuación resultados cualitativos de cada uno de los tres modelos en los dos conjuntos de datos.




Figura 2: Resultados obtenidos por cada uno de los modelos en el conjunto de datos de RobHand. Fila superior: EfficientNet. Fila central: MobileNet. Fila inferior: ResNet.




Figura 3: Resultados obtenidos por cada uno de los modelos en el conjunto de datos de M3Rob. Fila superior: EfficientNet. Fila central: MobileNet. Fila inferior: ResNet.

Para poder poner en relación los resultados obtenidos previamente, es importante también disponer de medidas que nos indiquen la velocidad a la que se pueden inferir resultados, ya que este tipo de procesamientos suelen tener que llevarse a cabo de manera online (idealmente, a más de 30 FPS) en señales de vídeo. La Tabla 3, organiza estas medidas en función de la arquitectura empleada, sin distinguir en este caso entre conjuntos de datos, ya que el tamaño de las imágenes es el mismo en ambos.

Tabla 3: Velocidad de inferencia de las arquitecturas en *frames* por segundo. Medida promediada de 100 inferencias.

Arquitectura	FPS
EfficientNet-B4	34.28
MobileNetV3	170.51
ResNet50	41.13

Estas medidas, demuestran que las tres arquitecturas planteadas son capaces de procesar las imágenes de forma online, pero que, sin embargo, existe una gran diferencia entre el modelo con MobileNetV3 y los otros dos modelos. Esta diferencia, está directamente relacionada con el número de parámetros de los modelos, disponible en la Tabla 4. No obstante, a pesar de que el número de parámetros de MobileNetV3 es mucho más reducido, los resultados cuantitativos nos indican que su rendimiento en términos de precisión es totalmente equiparable con el de las otras dos arquitecturas, llegando incluso a superar a la ResNet50 en el caso del conjunto de datos de RobHand.

Tabla 4: Número de parámetros de las arquitecturas.

Arquitectura	Parámetros
EfficientNet-B4	17M
MobileNetV3	0.75M
ResNet50	23M

4 CONCLUSIONES

En este trabajo, se presenta una metodología que permite segmentar elementos mecánicos en un entorno de rehabilitación controlado. Este flujo de operaciones se centra en habilitar la segmentación semántica con un número muy reducido de imágenes, aumentando su variabilidad mediante diversas técnicas de *data augmentation*.

Además, se han presentado dos casos de estudio aplicando dicha aumentación de datos a la segmentación de dos robots de rehabilitación. En estos casos de estudio, se han evaluado y comparado, tanto a nivel de calidad de resultados como a nivel de velocidad de inferencia tres arquitecturas ampliamente extendidas basadas en redes neuronales convolucionales, que han demostrado que es posible segmentar este tipo de elementos a una velocidad idónea para el procesamiento online (más de 170FPS) con calidad suficiente para una gran parte de las potenciales aplicaciones (entorno a un 0.90 IoU).

Estos resultados, abren las puertas a varias líneas de investigación futuras, como son la inclusión y desarrollo de terapias aumentadas en base a la información extraída de la señal de vídeo, la

evaluación del rendimiento del paciente durante el periodo de rehabilitación, o el uso de la información como entrada para otros algoritmos de procesamiento de vídeo más sofisticados (p. ej. *Image Inpainting*).

Agradecimientos

Este trabajo ha sido financiado por el Ministerio de Ciencia e Innovación, a través del proyecto Retos Colaboración: Plataforma para la rehabilitación neuromotora cognitiva mediante terapias activas, en personas que han sufrido un accidente cerebrovascular (M3Rob) – RTC2019-007350-1, y por la empresa TICCYL Digital S.L.U.

English summary

SEMANTIC SEGMENTATION OF MECHANICAL ELEMENTS IN AN AUGMENTED REHABILITATION ENVIRONMENT

Abstract

The addition of virtual elements (augmented reality) in real rehabilitation environments often requires the detection of specific physical elements in a video signal. To avoid using markers or any other type of localization element, in this work, we introduce a methodology that enables the segmentation of mechanical elements in controlled environments with a reduced dataset. Furthermore, we present quantitative and qualitative results of the application of this methodology in two real cases with rehabilitation robots.

Keywords: Rehabilitation, Semantic Segmentation, Computer Vision, Exoskeleton.

Referencias

- [1] Afyouni, I. et al. 2017. A therapy-driven gamification framework for hand rehabilitation. User Modeling and User-Adapted Interaction. Springer Science and Business Media LLC.
- [2] Císnal, A. et al. 2020. Robhand, un exoesqueleto de mano para la rehabilitación neuromotora aplicando terapias activas y pasivas. Actas de las XXXIX Jornadas de Automática, Badajoz, 5-7 de septiembre de 2018. Universidade da Coruña. Servizo de Publicacións.
- [3] Colomer, C. et al. 2016. Effect of a mixed reality-based intervention on arm, hand, and finger function on chronic stroke. Journal of NeuroEngineering and Rehabilitation. Springer Science and Business Media LLC.
- [4] Deng, J. et al. 2009. ImageNet: A large-scale hierarchical image database. 2009 IEEE Conference on Computer Vision and Pattern Recognition. IEEE.
- [5] Held, J.P.O. et al. 2020. Augmented Reality-Based Rehabilitation of Gait Impairments: Case Report. JMIR mHealth and uHealth. JMIR Publications Inc.
- [6] Hoermann, S. et al. 2017. Computerised mirror therapy with Augmented Reflection Technology for early stroke rehabilitation: clinical feasibility and integration as an adjunct therapy. Disability and Rehabilitation. Informa UK Limited.
- [7] Janssen, J. et al. 2017. Gamification in Physical Therapy: More Than Using Games. Pediatric Physical Therapy. Ovid Technologies (Wolters Kluwer Health).
- [8] He, K. et al. 2016. Deep Residual Learning for Image Recognition. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE.
- [9] Howard, A.G. et al. 2017. MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications. arXiv.
- [10] Montaña-Murillo, R. et al. 2013. Design and Assessment of a Remote Vibrotactile Biofeedback System for Neuromotor Rehabilitation Using Active Markers. Procedia Technology. Elsevier BV.
- [11] Mousavi Hondori, H. et al. 2015. Choice of Human-Computer Interaction Mode in Stroke Rehabilitation. Neurorehabilitation and Neural Repair. SAGE Publications.
- [12] Mubin, O. et al. 2019. Exoskeletons With Virtual Reality, Augmented Reality, and Gamification for Stroke Patients' Rehabilitation: Systematic Review. JMIR Rehabilitation and Assistive Technologies. JMIR Publications Inc.
- [13] Phan, H.L. et al. 2019. Wrist Rehabilitation System Using Augmented Reality for Hemiplegic Stroke Patient Rehabilitation: A Feasibility Study. Applied Sciences. MDPI AG.

- [14] Regenbrecht, H. et al. 2014. Manipulating the Experience of Reality for Rehabilitation Applications. Proceedings of the IEEE. Institute of Electrical and Electronics Engineers (IEEE).
- [15] Ronneberger, O. et al. 2015. U-Net: Convolutional Networks for Biomedical Image Segmentation. Lecture Notes in Computer Science. Springer International Publishing.
- [16] Sousa, M. et al. 2016. SleeveAR. Proceedings of the 21st International Conference on Intelligent User Interfaces. ACM.
- [17] Tan, M. and Le, Q.V. 2019. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. arXiv. (2019).
- [18] Trojan, J. et al. 2013. An augmented reality home-training system based on the mirror training and imagery approach. Behavior Research Methods. Springer Science and Business Media LLC.
- [19] Vidrios-Serrano, C. et al. 2015. Development of a haptic interface for motor rehabilitation therapy using augmented reality. 2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). IEEE.



© 2022 by the authors.
Submitted for possible
open access publication
under the terms and conditions of the Creative
Commons Attribution CC BY-NC-SA 4.0 license
(<https://creativecommons.org/licenses/by-ncsa/4.0/deed.es>).

Libro de actas de las **Jornadas de Robótica, Educación
y Bioingeniería 2022** (JREB-22)

Málaga, 18-20 de mayo, 2022

Edita: Dpto. de Ingeniería de Sistemas y Automática

ISBN: 978-84-09-41095-8