

Evaluación en un paciente con ictus en fase crónica de un sistema autoadaptativo de neurorehabilitación robótica

Ricardo Morales^{a,*}, Francisco J. Badesa^a, Nicolas Garcia-Aracil^a, Joan Aranda^b, Alicia Casals^b

^a*Virtual Reality and Robotics Lab, Biomedical Neuroengineering Universidad Miguel Hernandez de Elche, 03202, Elche, Alicante, Spain*

^b*Institute for Bioengineering of Catalonia and Universitat Politècnica de Catalunya. BarcelonaTech*

Resumen

Este artículo presenta un nuevo sistema de rehabilitación capaz de adaptarse al estado psicofisiológico del paciente durante tareas de rehabilitación robótica. Con este tipo de terapia se puede maximizar la motivación y participación del paciente durante la actividad de rehabilitación. En este trabajo se extienden los resultados del estudio presentado en (Badesa et al., 2014b), realizado con sujetos sanos, a su utilización con pacientes que hayan sufrido un accidente cerebrovascular. En una primera parte del artículo se presentan los distintos componentes del sistema adaptativo, y se realiza una comparativa de distintas técnicas de aprendizaje automático para clasificar el estado psicofisiológico del paciente entre tres estados posibles: estresado, nivel de excitación media y relajado. Finalmente, se muestran los resultados del sistema autoadaptativo con un paciente con ictus en fase crónica, que modifica el comportamiento del robot de rehabilitación y de la tarea virtual en función de las medidas de las señales fisiológicas. *Copyright © 2015 CEA. Publicado por Elsevier España, S.L. Todos los derechos reservados*

Palabras Clave: Estado fisiológico, interfaces multimodales, robótica de rehabilitación, control.

1. Introducción

El daño cerebral sobrevenido (DCS) es un concepto clínico heterogéneo asociado a una afectación del Sistema Nervioso Central (SNC) de etiología variable, cuyo denominador común consiste en una lesión cerebral que irrumpe de forma brusca y decisiva en el desarrollo vital de la persona (Castellanos-Pinedo et al., 2012). Sus etiologías más frecuentes son el accidente cerebrovascular cerebral (ACV), más comúnmente conocido como ictus, y el traumatismo craneoencefálico (TCE).

Según la Organización Mundial de la Salud, el número de personas mayores de 65 años aumentará en un 73 % en los países industrializados, y en un 207 % por todo el mundo. Para 2050, el porcentaje de la población europea mayor de 65 años casi se duplicará, pasando de 12,3 % al 20,6 % (de 40 a 80 millones). Este grupo de edad es particularmente propenso a sufrir algún tipo de ACV. La incidencia relativa de ACV se duplica cada década para mayores de 55 años. De hecho, el ACV es la principal causa de incapacidad permanente en los países industrializados. Cada año, más de 920.000 europeos y

700.000 norteamericanos tienen un ACV el cual supone, en la mayor parte de los casos, una transición desde la normalidad a la pérdida de la autonomía y la independencia repercutiendo por tanto, en la calidad de vida del paciente y en su relación con el entorno más cercano. Los datos más recientes del Instituto Nacional de Estadística indican que en España residen 420.064 personas con DCS, de las cuales un 78 % han sufrido un ictus (Quezada, 2011).

El ACV es una de las causas principales del deterioro crónico en la función del brazo y puede afectar a muchas actividades cotidianas. Sin embargo, a pesar de los esfuerzos intensivos de rehabilitación, sólo aproximadamente del 5 % al 20 % alcanzan una recuperación funcional completa (Nakayama et al., 1994); en otras palabras, cuatro de cinco pacientes dejan la rehabilitación con una función del miembro superior limitada. Por lo tanto, todavía existe una necesidad urgente de alcanzar nuevas estrategias de rehabilitación y entrenamiento de hospitalizados y ambulatorios que satisfagan o mejoren las necesidades específicas de los pacientes.

Del mismo modo que los avances tecnológicos han mejorado nuestra forma de vida en todos los sentidos, la tecnología y en concreto la robótica permite el desarrollo de nuevas estrategias terapéuticas. El uso de dispositivos robóticos, como posible estrategia de rehabilitación para lograr la recuperación de la capacidad motora, se puede justificar debido a su potencial impacto sobre la mejora del tratamiento terapéutico y el aprendizaje

* Autor en correspondencia

Correos electrónicos: rmorales@umh.es (Ricardo Morales), fbadesa@umh.es (Francisco J. Badesa), nicolas.garcia@umh.es (Nicolas Garcia-Aracil), joan.aranda@upc.edu (Joan Aranda), alicia.casals@upc.es (Alicia Casals)

motor (Aisen et al., 1997, Krebs et al., 1998, Volpe et al., 1999, Fasoli et al., 2003, M. Bayón, 2010). Recientemente, se ha publicado las mejores evidencias y recomendaciones actuales por la American Heart Association(AHA) para el manejo interdisciplinario de la rehabilitación posterior al ACV, incluyendo la terapia asistida con robot (Miller et al., 2010). En concreto, la rehabilitación asistida por dispositivos robóticos del miembro superior afectado ya se considera como Clase I, nivel de evidencia A para la atención al ictus en pacientes ambulatorios y centros de atención de pacientes crónicos, y se considera como Clase IIa, nivel de evidencia A para la atención al ictus en el paciente hospitalizado. El significado de las clases y el nivel de evidencia se definen según AHA: Clase I se define como “procedimiento / tratamiento debería ser realizado/administrado”; Clase IIa se define como “Es razonable realizar el procedimiento/administrar el tratamiento”, y el nivel de Evidencia A se define como “Evaluado en poblaciones múltiples. Datos derivados de múltiples ensayos clínicos aleatorizados o meta-análisis”.

A pesar del éxito relativo de la rehabilitación asistida por dispositivos robóticos aplicada a la recuperación del miembro superior, los investigadores están ya desarrollando una nueva generación de sistemas de rehabilitación robótica. La principal novedad de los nuevos sistemas de rehabilitación es considerar al paciente en el lazo de control del sistema y utilizar información multisensorial (tales como posición/orientación, fuerzas, actividad muscular, ritmo cardíaco, conductancia de la piel, etc.) para modificar de forma adaptativa y dinámica los movimientos y tareas rehabilitadoras y los entornos de realidad virtual inmersiva asociados a ellas con el objetivo de: (i) maximizar la motivación y la participación del paciente en la terapia (ii) evaluar continuamente el progreso de la recuperación desde el punto de vista clínico y neurológico. Hasta la fecha no hay muchos ejemplos de sistemas de rehabilitación robótica que consideren al paciente en el lazo de control del sistema. El primer trabajo publicado que tiene en cuenta la información proveniente del paciente para ajustar el nivel de asistencia proporcionado por el robot fue publicado por Krebs et al. en 2003 (Krebs et al., 2003). Cabe destacar que el uso de señales psicofisiológicas para adaptar dinámicamente el comportamiento de un sistema automático no es una nueva idea, sino que Byrne et al. (Byrne y Parasuraman, 1996) presentó una revisión sobre distintos trabajos en este campo. Recientemente, se ha publicado una revisión sobre métodos de fusión de datos y de adaptación de sistemas automáticos utilizando las respuestas del sistema nervioso autónomo (Novak et al., 2012). Otros trabajos de Novak (Novak et al., 2010) y Koenig (Koenig et al., 2011) proponen el uso de medidas psicofisiológicas y el análisis del rendimiento de la tarea para ajustar la dificultad de una tarea realizada con la asistencia del robot Haptic Master.

El presente trabajo extiende los resultados del estudio presentado en (Badesa et al., 2014b), realizado con sujetos sanos, a su utilización con pacientes que hayan sufrido un accidente cerebrovascular. En concreto, el entrenamiento de los clasificadores utilizados se realiza mediante la adquisición del comportamiento del propio sujeto ante distintas sesiones de evaluación. Los resultados obtenidos permiten la selección del clasificador que proporciona los mejores porcentajes de acierto para poste-

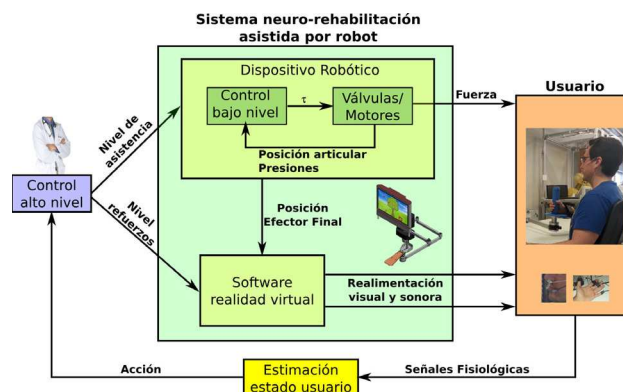


Figura 1: Esquema del sistema autoadaptativo de rehabilitación robótica

riormente implementar una autoadaptación dinámica de la terapia usando dicho clasificador. Los resultados presentados son prometedores y nos llevan a pensar que estos sistemas se pueden adaptar tanto a sujetos sanos como a sujetos con daño cerebral adquirido.

2. Sistema autoadaptativo de rehabilitación robótica

El objetivo final del sistema autoadaptativo de rehabilitación robótica es la incorporación de información proveniente del usuario dentro del lazo de control del sistema. Para ello, se va a hacer uso de la información extraída de las señales fisiológicas del usuario para estimar su estado psicofisiológico y usar esta información para modificar automáticamente el nivel de dificultad de la tarea.

2.1. Descripción del sistema

En la Figura 1 se muestra un esquema del concepto de sistema autoadaptativo de rehabilitación robótica. En esta figura se pueden observar cuatro bloques diferenciados:

- Bloque del sistema de neuro-rehabilitación asistida por robot. Este bloque está compuesto por el conjunto dispositivo robótico y software de realidad virtual (Badesa et al., 2014a).
- Control a alto nivel. En este bloque se definen los niveles de asistencia y resistencia del dispositivo robótico así como niveles en los refuerzos visuales y sonoros del entorno de realidad virtual.
- Estimación del estado del usuario. Este es el bloque principal del sistema de control autoadaptativo, ya que es el que proporciona la información del usuario que se va a utilizar en el lazo de control.
- Usuario. Este bloque representa al usuario del sistema de neuro-rehabilitación asistida por robot, el cual interactúa con el sistema y del cual se adquieren las distintas señales fisiológicas según se describe en nuestro trabajo previo (Badesa et al., 2012).

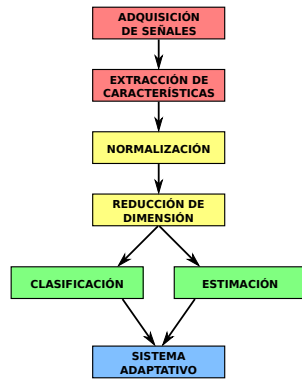


Figura 2: Proceso general del uso de señales fisiológicas en sistemas informatizados.

La Figura 2 muestra el proceso general de la medida, interpretación y uso de la respuesta fisiológica para su uso en sistemas informatizados (Novak et al., 2012). Este proceso se puede dividir en cuatro fases. En la primera, se realizan tareas de adquisición, procesamiento y extracción de características de las señales fisiológicas del usuario. Basándonos en trabajos anteriores (Badesa et al., 2012), se han seleccionado las señales de pulso, respuesta galvánica de la piel, respiración y temperatura superficial de la piel. El procesamiento para la extracción de las características más importantes de estas señales se puede consultar de forma detallada en (Badesa, Enero 2014).

La segunda fase la componen los bloques de normalización de las señales y de reducción de dimensión del espacio de entrada. La normalización es principalmente un intento de reducir el efecto de la variabilidad, intra e interindividual, que muestran las características fisiológicas como resultado de parámetros como la edad, el género, la hora del día y otros factores. Por ejemplo, si un conjunto de datos de entrenamiento contiene medidas de varios sujetos, algunos pueden mostrar respuestas mucho mayores que otros, o tener diferentes valores de reposo para las mismas señales fisiológicas (la frecuencia cardíaca en reposo, por ejemplo, puede estar fácilmente en cualquier lugar entre 60 y 80 latidos por minuto). Cuando se miden varias respuestas fisiológicas, es posible obtener un número muy grande de características. Según aumenta el número de características (dimensión), el espacio de características crece en volumen tan rápidamente que puede resultar difícil encontrar patrones y similitudes en los datos. Para las técnicas de aprendizaje automático, tanto para clasificación como para estimación, el tamaño del conjunto de datos de entrenamiento puede crecer de forma exponencial con el número de características. Por lo tanto puede ser beneficioso reducir el número de características. Además, la reducción de dimensión también puede ayudar a reducir el coste y complejidad de la aplicación informática.

Los bloques de clasificación y estimación forman la tercera fase, que tratan de la selección y entrenamiento de los algoritmos de aprendizaje automático. Finalmente, en el último bloque se implementa el sistema adaptativo que hace uso de la información extraída de las señales fisiológicas.

2.2. Técnicas de aprendizaje automático

Para el bloque de estimación del estado del usuario se han estudiado distintas técnicas de aprendizaje automático. Todas las técnicas que se han seleccionado, se tratan de algoritmos de aprendizaje supervisado. Estos algoritmos son técnicas para deducir una función a partir de datos de entrenamiento. Los datos de entrenamiento consisten en pares de objetos (normalmente vectores): una componente del par son los datos de entrada y la otra, los resultados deseados. La salida de la función puede ser un valor numérico (como en los problemas de regresión) o una etiqueta de clase (como en los de clasificación). El objetivo del aprendizaje supervisado es el de crear una función capaz de predecir el valor correspondiente a cualquier objeto de entrada válida después de haber visto una serie de ejemplos, los datos de entrenamiento. Para ello, tiene que generalizar a partir de los datos presentados a las situaciones no vistas previamente.

En este trabajo, se ha decidido utilizar algoritmos de clasificación para la estimación del estado fisiológico. Estos algoritmos son técnicas donde el sistema de aprendizaje trata de etiquetar (clasificar) una serie de vectores de entrada utilizando una entre varias categorías (clases). Finalmente, se han utilizado los 9 algoritmos supervisados de clasificación implementados en (Badesa et al., 2014b):

- Perceptron Learning Algorithm (PLA)
- Logistic Regresión (LR)
- Linear Discriminant Analysis (LDA)
- Quadratic Discriminant Analysis (QDA)
- Support Vector Machine lineal (SVML)
- Support Vector Machine con RBF kernel (SVMK)
- Naïve Bayes (NB)
- K-Nearest Neighbor (KNN)
- K-Center con Radial Basis Functions (RBF)

Muchas de las técnicas de clasificación, como el caso de SVM, se tratan de técnicas de clasificación binaria, esto es, que sólo clasifican distinguiendo entre dos posibles clases. Para el caso de estas técnicas, se ha implementado la estrategia para clasificación multi-clase One vs One (OvO). Esta estrategia consiste en construir $(\frac{N}{2})$ clasificadores, un clasificador para distinguir entre cada par de clases i y j . Cuando un dato nuevo tiene que ser clasificado, se realiza un cuento de votos a lo largo de todos los $(\frac{N}{2})$ clasificadores implementados, y la clase que mayor número de votos consiga es la clase a la que pertenece el nuevo dato. Esta clasificación se puede generalizar según la siguiente expresión:

$$f(x) = \arg \max_i \left(\sum_j f_{ij}(x) \right) \quad (1)$$

Siendo f_{ij} el clasificador donde la clase i se refiere a los ejemplos positivos y la clase j a los negativos ($f_{ji} = -f_{ij}$).

3. Resultados experimentales

La experimentación realizada se divide en dos partes. En una primera parte, se realiza una serie de toma de medidas, durante varios días, de las señales fisiológicas del paciente realizando un mismo ejercicio con tres diferentes grados de dificultad. Con los datos obtenidos, se entrenan distintos algoritmos de clasificación, que se utilizarán para la segunda parte de la experimentación. Mediante la técnica de aprendizaje automático seleccionada se pretende distinguir entre tres estados: paciente realizando una tarea demasiado sencilla (relajado); paciente realizando una tarea demasiado difícil (estresado); y paciente realizando una tarea de dificultad adecuada.

En la segunda parte, se implementa un sistema de adaptación automática de la dificultad de la terapia, incluyendo al paciente en el lazo de control mediante la estimación de su estado psicofisiológico, calculado a partir de los datos de las señales fisiológicas. Mediante este sistema se realiza una experimentación, con el mismo usuario, en el que de forma automática se modificará la distancia de los objetivos en función de las señales fisiológicas.

3.1. Descripción de la Experimentación

La experimentación fue llevada a cabo en una sala dedicada en el Instituto de Bioingeniería de la Universidad Miguel Hernández, donde el usuario no recibía molestias de estímulos externos. Dos personas estaban presentes durante la experimentación: el sujeto y el supervisor del experimento. Antes de empezar con el experimento, el usuario fue informado del propósito y del procedimiento a seguir del experimento, firmando el usuario un informe de consentimiento.

El sujeto es un hombre de 67 años que tuvo un accidente cerebrovascular hace tres años que le produjo hemiplejía en el lado izquierdo y presenta un alto grado de espasticidad en su brazo. Se han realizado un total de tres experimentaciones para la adquisición de las señales fisiológicas, y posterior entrenamiento de los algoritmos de clasificación.

Como dispositivo robótico de rehabilitación se ha utilizado el sistema PUPArm (Badesa et al., 2014a), desarrollado por el grupo de investigación de Neuroingeniería Biomédica de la Universidad Miguel Hernández, ahora comercializado por Instea Technologies. Este robot de rehabilitación permite la movilización del brazo del paciente sobre un plano horizontal, proporcionando una fuerza progresiva en la dirección adecuada en cada momento para ayudar al paciente a la realización del movimiento. El sistema PUPArm está compuesto también por un software de realidad virtual que dispone de un conjunto de actividades que sirven al usuario como realimentación visual de los movimientos que está realizando con el brazo, además de disponer de distintos refuerzos sonoros y visuales para aumentar la motivación del paciente.

La actividad seleccionada para la realización de esta experimentación es una de las actividades proporcionadas con el dispositivo robótico, denominada “Ruleta”, que consiste en un punto central de radio 1 centímetro y ocho objetivos periféricos




Figura 3: Usuario durante la experimentación.

(de 1 centímetro de radio) alejados una cierta distancia del punto central distribuidos de manera que forman una circunferencia alrededor del punto central (ver Figura 3). En esta actividad el paciente debe mover un círculo blanco mostrado en pantalla desde el punto central hasta el objetivo periférico que se ilumine, intentando realizar un movimiento lo más recto posible.

Para el caso de este paciente concreto se ha aplicado la máxima asistencia por parte del robot en todas las actividades de la experimentación, debido a su alto grado de espasticidad y su baja movilidad, siendo el parámetro de distancia de objetivos el parámetro modificado para crear distintos niveles de dificultad a lo largo de la experimentación.

3.2. Adquisición de señales fisiológicas

Las señales fisiológicas, que servirán para el entrenamiento de los algoritmos de clasificación, fueron adquiridas mediante sensores y amplificador proporcionados por g.tec utilizando una configuración hardware similar a la expuesta en (Badesa et al., 2012). Para el procesamiento y extracción de las características de estas señales, se ha utilizado los softwares Matlab® y Simulink®, de Mathworks. Las características extraídas y utilizadas en la experimentación han sido el ritmo cardíaco, ritmo respiratorio, nivel de conductancia de la piel (SCL), la respuesta de conductancia de la piel (SCR) y la temperatura superficial.

El objetivo principal del sistema de aprendizaje automático implementado en la siguiente sección, es poder distinguir entre tres estados: paciente realizando una tarea demasiado sencilla (relajado); paciente realizando una tarea demasiado difícil (estresado); y paciente realizando una tarea de dificultad adecuada. Por ello, en el sistema de realidad virtual se han definido distintos niveles de dificultad de la actividad de rehabilitación para inducir al usuario a los estados fisiológicos comentados.

- Distancia de 5 centímetros entre el círculo central y los objetivos periféricos, resultando una actividad que el paciente puede realizar de forma sencilla con la máxima asistencia por parte del robot.
- Distancia de 10 centímetros entre el círculo central y los objetivos periféricos, resultando una actividad adecuada

para la movilidad del paciente y la máxima asistencia por parte del robot.

- Distancia de 15 centímetros entre el círculo central y los objetivos periféricos, lo que supone una dificultad excesiva para el paciente incluso con la máxima asistencia por parte del robot.

Utilizando un procedimiento similar al expuesto en (Badesa et al., 2014b), en la experimentación realizada para la adquisición de señales fisiológicas se siguieron los siguientes pasos:

1. Se informó al paciente del propósito y procedimiento de la experimentación.
2. El usuario invierte unos minutos en practicar las actividades.
3. El usuario descansa cinco minutos para obtener una medida de las señales en reposo.
4. Se realiza la primera tarea (aleatoria) durante cinco minutos.
5. El usuario realiza el test Self-Assessment Manikin (SAM) para la evaluación de su estado anímico y de excitación, y después el usuario descansa tres minutos. Bradley y Lang (1994)
6. Se realiza la segunda actividad (aleatoria y distinta a la anterior) durante cinco minutos.
7. El usuario realiza el test SAM, y después descansa cinco minutos.
8. Se realiza la tercera actividad (la restante) durante cinco minutos.
9. El usuario realiza el test SAM, y después el usuario descansa cinco minutos.

El paciente realizó esta experimentación un total de tres veces en sendos días, para poder obtener un número de datos adecuado para el entrenamiento de los algoritmos de aprendizaje automático.

3.3. Entrenamiento y selección de los algoritmos de aprendizaje automático

El primer paso una vez obtenidos los datos de las distintas señales fisiológicas, es realizar una normalización. El enfoque realizado para esta experimentación, se basa en una normalización basada en el nivel neutral, o baseline, de cada individuo. Existen distintas técnicas para llevar a cabo este tipo de normalización, como por ejemplo restar el valor del nivel neutral medido durante un periodo de reposo al valor de las señales fisiológicas medidas durante una actividad. En la normalización implementada, a los datos de las señales fisiológicas primero se le resta el valor de reposo, y el resultado se divide entre el valor de reposo. Restando el valor de reposo a los datos medidos, se consigue reducir la variabilidad interindividual debida a distintos valores de reposo. Dividiendo por el valor de reposo, se reduce la variabilidad debida a las distintas amplitudes en las respuestas fisiológicas.

Antes de utilizar los algoritmos de clasificación, se ha realizado un Análisis de Componentes Principales (PCA) con los

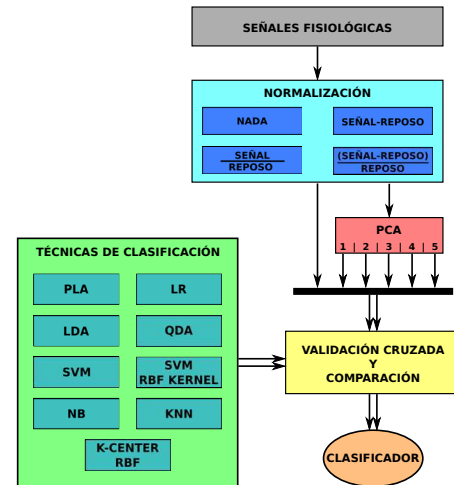


Figura 4: Proceso de selección de clasificador.

Tabla 1: Porcentajes de acierto de LOOCV de los algoritmos de clasificación

| | PCA 2 PC | PCA 3 PC | PCA 4 PC | PCA 5 PC | SIN PCA | Media |
|-------------|-------------|-------------|-------------|-------------|------------|-------|
| PLA | 45.95 | 58.38 | 67.03 | 67.57 | 65.41 | 57.30 |
| LR | 54.05 | 62.16 | 62.16 | 54.05 | 54.05 | 55.85 |
| LDA | 56.76 | 67.57 | 70.27 | 62.16 | 62.16 | 61.26 |
| QDA | 59.46 | 62.16 | 64.86 | 48.65 | 48.65 | 54.05 |
| SVML | 54.05 | 67.57 | 67.57 | 59.46 | 59.46 | 58.56 |
| SVMK | 59.46 | 67.57 | 67.57 | 67.57 | 67.57 | 63.06 |
| NB | 56.76 | 62.16 | 51.35 | 56.76 | 51.35 | 53.15 |
| KNN | 43.24 | 48.65 | 45.95 | 45.95 | 45.95 | 43.69 |
| RBF | 47.57 | 47.57 | 40.54 | 44.86 | 47.57 | 47.03 |

datos extraídos de las distintas señales fisiológicas. Aunque el número de características fisiológicas adquiridas no es elevado se hace uso de PCA para estudiar si es posible reducir más aún el número de características a la entrada de los algoritmos de clasificación, eliminando características que no sean relevantes. Los datos de entrada expresados en el nuevo espacio vectorial definido por las componentes principales, serán utilizados como datos de entrada para el entrenamiento de los algoritmos de clasificación.

Para la selección del clasificador más idóneo, se ha realizado el proceso mostrado en la Figura 4.

Para escoger los parámetros más adecuados para cada algoritmo, y para poder comparar estos entre sí, se ha utilizado la validación cruzada Leave-one-out cross-validation (LOOCV). En esta estrategia de validación cruzada se usa una sola observación de los datos de entrada originales como dato de validación, y las demás observaciones como datos de entrenamiento. Esto se repite tantas veces como observaciones haya en los datos de entrada. Los resultados obtenidos en la validación cruzada LOOCV se muestran en la Tabla 1.

3.4. Adaptación automática de la dificultad de la terapia

En este apartado se va a realizar una experimentación para comprobar el funcionamiento de un algoritmo de clasificación para adaptar de forma automática los niveles de dificultad de una tarea utilizando un robot de rehabilitación. Observe la Tabla 1 y los resultados mostrados en (Badesa et al., 2014b), el uso de más de tres componentes principales no proporciona una mejora significativa en los porcentajes de acierto obtenidos en la validación cruzada. Finalmente, se ha optado por utilizar el algoritmo de clasificación SVM con una función RBF como kernel, usando las tres primeras componentes principales obtenidas mediante el algoritmo PCA.

De acuerdo con Novak et al. (Novak et al., 2012), los sistemas de adaptación utilizando la respuesta fisiológica se pueden clasificar en tres categorías: adaptación automática, ajuste del nivel de dificultad de la actividad, y ajuste de las realimentaciones visuales y sonoras de la aplicación. La experimentación llevada a cabo se va a basar en la adaptación del nivel de dificultad de la actividad.

La actividad a realizar es la misma que en la adquisición de datos para el entrenamiento de los algoritmos de clasificación, pero en lugar de definir tres niveles de dificultad con salto de 5 centímetros entre cada nivel, se han implementado 11 niveles de tal manera que los saltos entre niveles sean de 1 centímetro, siendo la distancia de los objetivos de 5 centímetros en el primer nivel y 15 centímetros en el último nivel. El objetivo a priori del experimento será mantener la distancia de los objetivos periféricos en un valor intermedio.

La experimentación se realizó siguiendo los siguientes pasos:

1. Se explica el procedimiento del experimento al usuario y se le presentan la actividad a realizar.
2. El usuario invierte unos minutos en practicar las actividades.
3. El usuario descansa cinco minutos para obtener una medida de las señales en reposo.
4. Se realiza la tarea durante diez minutos comenzando desde el nivel más sencillo.

Tanto el sistema de procesamiento y extracción de características como el sistema de estimación del estado del usuario, han sido implementados en el software Simulink®. Las comunicaciones entre estos dos sistemas y el software de realidad virtual se ha realizado mediante el protocolo UDP. El bloque de estimación del estado fisiológico envía cada 30 segundos una de las siguientes acciones al software de realidad virtual: si el usuario está estresado, se envía una acción para reducir el nivel de dificultad actual; si el usuario tiene un nivel medio de excitación, la acción a enviar es la de no modificar el nivel de dificultad; finalmente, si el usuario está relajado, se envía la acción de aumentar el nivel de dificultad.

En la Figura 5 se muestra el resultado de la experimentación del sistema adaptativo para el paciente. En estas gráficas se puede observar como el nivel de dificultad de la actividad varía según aumentan y disminuyen los niveles de las distintas características de las señales fisiológicas, de acuerdo con la

predicción del estado del usuario en el sistema de control de la plataforma de rehabilitación. En cada una de estas figuras se muestran dos señales: en color azul se representa la media de los últimos 30 segundos de la señal fisiológica normalizada en cada instante de tiempo; en color verde los cambios del nivel de dificultad de la actividad; y las líneas verticales negras muestran los instantes de tiempo en los que el control biocooperativo envía las acciones de cambios de nivel.

Finalmente, en la gráfica inferior izquierda de la figura, se muestra la relación entre las tres primeras componentes principales del análisis PCA y los cambios en el nivel de dificultad. Como ya se ha comentado anteriormente, cada 30 segundos se realiza una estimación del estado fisiológico con su correspondiente acción de cambio de nivel, representado por el color del fondo de la gráfica.

4. Conclusiones

En este trabajo se han mostrado los primeros resultados, en pacientes que han sufrido un ictus, del sistema adaptativo de cambio de nivel implementado. En la experimentación realizada se han comparado nueve técnicas de aprendizaje automático para la clasificación del estado psicofisiológico del paciente, seleccionando un modelo SVM con una función RBF como kernel, y el uso de las 3 primeras componentes principales del algoritmo PCA sobre los datos de entrada del clasificador. Con esta configuración se ha obtenido un 67,57 % de acierto en la validación cruzada LOOCV.

Se ha realizado una experimentación del uso del sistema adaptativo durante una sesión de terapia de rehabilitación robótica, presentando unos resultados prometedores que nos llevan a pensar en estos sistemas como tareas complementarias en las terapias de rehabilitación de sujetos con daño cerebral adquirido.

English Summary

Autoadaptive neurorehabilitation robotic system assessment with a post-stroke patient.

Abstract

This paper presents a new rehabilitation system that is able to adapt its performance to patient's psychophysiological state during the execution of robotic rehabilitation tasks. Using this approach, the motivation and participation of the patient during rehabilitation activity can be maximized. In this paper, the results of the study with healthy subjects presented in (Badesa et al., 2014b) have been extended for using them with patients who have suffered a stroke. In the first part of the article, the different components of the adaptive system are exposed, as well as a comparison of different machine learning techniques to classify the patient's psychophysiological state between three possible states: stressed, average excitation level and relaxed are presented. Finally, the results of the auto-adaptive system which modifies the behavior of the rehabilitation robot and

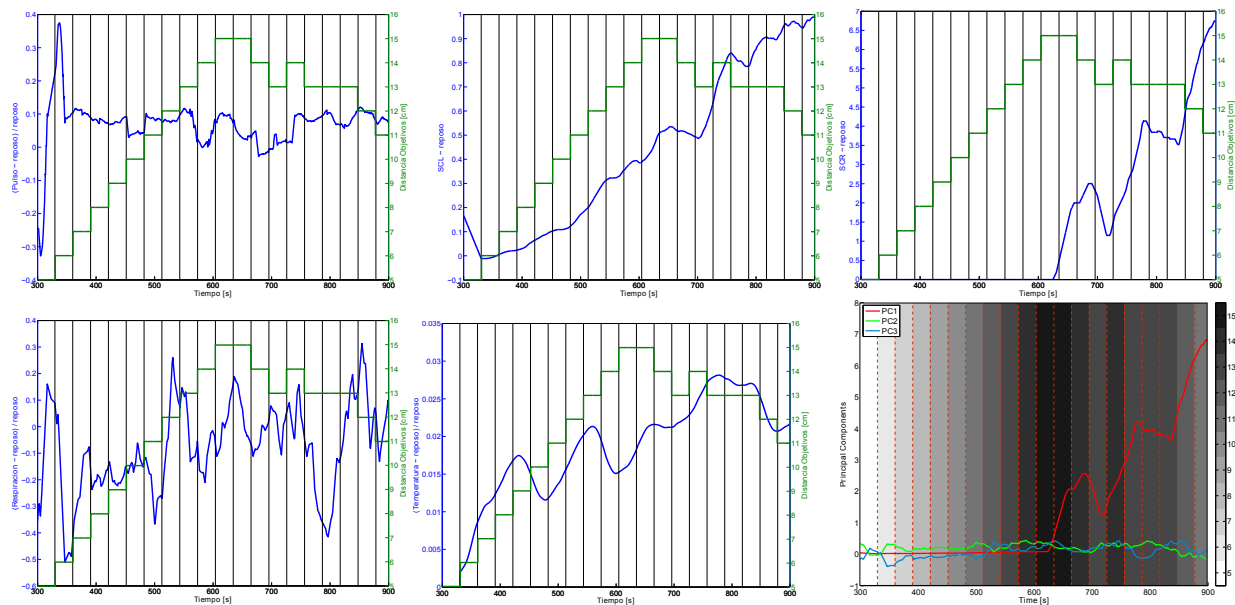


Figura 5: Resultado del control biocooperativo con SVM.

virtual task in function of measured physiological signals are shown for a patient in the chronic phase of stroke.

Keywords:

Physiological state multimodal interfaces rehabilitation robotics control.

Agradecimientos

Este trabajo ha sido financiado por el Plan Nacional de I+D+i a través de los proyectos, “Interpretación de la intención y actuación humana mediante señales biomédicas y el análisis cinemático y dinámico del movimiento” (DPI2011-29660-C04-04) y “Interacción Persona Robot en entornos semiestructurados bajo criterios de permitividad” (DPI2011-29660-C04-01).

Referencias

- Aisen, M. L., Krebs, H. I., Hogan, N., McDowell, F., Volpe, B. T., 1997. The effect of robot-assisted therapy and rehabilitative training on motor recovery following stroke. *Archives of Neurology* 54 (4), 443–446.
- Badesa, F. J., Enero 2014. Interfaz multimodal y control biocooperativo para sistemas de neuro-rehabilitación asistida por robots. Tesis Doctoral.
- Badesa, F. J., Llinares, A., Morales, R., García-Aracil, N., Sabater, J. M., Pérez-Vidal, C., 2014a. Pneumatic planar rehabilitation robot for post-stroke patients. *Journal of Biomedical Engineering: Applications, Basis and Communications* 26 (02), 1450025.
- Badesa, F. J., Morales, R., Aracil, N. G., Sabater, J. M., Pérez-Vidal, C., Fernández, E., 2012. Multimodal interfaces to improve therapeutic outcomes in robot-assisted rehabilitation. *IEEE Transactions on Systems, Man, and Cybernetics, Part C* 6 (42), 1152–1158.
- Badesa, F. J., Morales, R., García-Aracil, N., Sabater, J., Casals, A., Zollo, L., 2014b. Auto-adaptive robot-aided therapy using machine learning techniques. *Computer Methods and Programs in Biomedicine* 116 (2), 123–130.
- Bradley, M. M., Lang, P. J., 1994. Measuring emotion: The self-assessment manikin and the semantic differential.
- Bradley, M. M., Lang, P. J., 1994. Measuring emotion: The self-assessment manikin and the semantic differential.
- Byrne, E., Parasuraman, R., 1996. Effects of robotic therapy on motor impairment and recovery in chronic stroke. *Biological Psychology* 42, 249–268.
- Castellanos-Pinedo, F., Cid-Gala, M., Duque, P., Ramírez-Moreno, J., Zurdo-Hernández, J., 2012. Daño cerebral sobrevenido: propuesta de definición, criterios diagnósticos y clasificación. *Rev Neurol* (54), 357–366.
- Fasoli, S. E., Krebs, H. I., Stein, J., Frontera, W. R., Hogan, N., 2003. Effects of robotic therapy on motor impairment and recovery in chronic stroke. Tech. Rep. 4, Department of Mechanical Engineering, Massachusetts Institute of Technology, Cambridge, MA 02139, USA.
- Koenig, A., Novak, D., Omlin, X., Pulfer, M., Perreault, E., Zimmerli, L., Mihelj, M., Riener, R., 2011. Real-time closed-loop control of cognitive load in neurological patients during robot-assisted gait training. *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 19, 453–464.
- Krebs, H., Palazzolo, J., Dipietro, L., Ferraro, M., Krol, J., Rannekleiv, K., Volpe, B., Hogan, N., 2003. Rehabilitation robotics: performance-based progressive robot-assisted therapy. *Autonomous Robots* (15), 7–20.
- Krebs, H. I., Hogan, N., Aisen, M. L., Volpe, B. T., 1998. Robot-aided neuro-rehabilitation. *IEEE Trans Rehabil Eng* 6 (1), 75–87.
- M. Bayón, J. M., 2010. Rehabilitación del ictus mediante realidad virtual. *Rehabilitación* 44 (3), 256–260.
- Miller, E., Murray, L., Richards, L., Zorowitz, R., Bakas, T., Clark, P., Billinger, S., 2010. Comprehensive overview of nursing and interdisciplinary rehabilitation care of the stroke patient: A scientific statement from the American heart association. *Stroke* 41 (11), 2402–2448.
- Nakayama, H., Jørgensen, H., Raaschou, H., Olsen, T., 1994. Recovery of upper extremity function in stroke patients: the copenhagen stroke study. *Archives of Physical Medicine and Rehabilitation* 75, 394–398.
- Novak, D., Mihelj, M., Muni, M., 2012. A survey of methods for data fusion and system adaptation using autonomic nervous system responses in physiological computing. *Interacting with Computers* 24 (3), 154–172.
- Novak, D., Zihler, J., Olensek, A., Milavec, M., Podobnik, J., Mihelj, M., Muni, M., 2010. Psychophysiological responses to robotic rehabilitation tasks in stroke. *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 18, 351–361.
- Quezada, M., 2011. El daño cerebral adquirido (dca) en España: principales resultados a partir de la encuesta edad-2008. *Boletín del Observatorio Estatal de la Discapacidad* (3), 39–59.
- Volpe, B. T., Krebs, H. I., Hogan, N., Edelstein, L., Diels, C. M., Aisen, M. L., 1999. Robot training enhanced motor outcome in patients with stroke maintained over 3 years. Tech. Rep. 8, Cornell University Medical College, Department of Neurology and Neuroscience, Burke Medical Research Institute, White Plains, NY 10605, USA.