

Trabajo Fin de Máster

Diseño de modelos basados en aprendizaje para la estimación de pares articulares para la rehabilitación motora mediante exoesqueletos

Autor

Santiago Redondo Salvo

Directores

Luis Montano Gella
Diana Ruiz Bueno

Máster en Ingeniería Biomédica
Escuela de Ingeniería y Arquitectura
Universidad de Zaragoza



Santiago Redondo Salvo, 2015

© Santiago Redondo Salvo, 2015. «Diseño de modelos basados en aprendizaje para la estimación de pares articulares para la rehabilitación motora mediante exoesqueletos»

El presente documento ha sido licenciado bajo una licencia Creative Commons Attribution-NonCommercial-ShareAlike 4.0 International. Para ver una copia de dicha licencia visite <http://creativecommons.org/licenses/by-nc-sa/4.0/> o diríjase por carta a Creative Commons, PO Box 1866, Mountain View, CA 94042, USA.

A toda la gente extraordinaria que habéis ayudado a hacerlo posible.

Any sufficiently advanced magic is indistinguishable from technology.
Variación de la 3^a ley de A. C. Clarke



DECLARACIÓN DE AUTORÍA Y ORIGINALIDAD

(Este documento debe acompañar al Trabajo Fin de Grado (TFG)/Trabajo Fin de Máster (TFM) cuando sea depositado para su evaluación).

D./Dª. Santiago Redondo Salvo,

con nº de DNI 17448577H en aplicación de lo dispuesto en el art. 14 (Derechos de autor) del Acuerdo de 11 de septiembre de 2014, del Consejo de Gobierno, por el que se aprueba el Reglamento de los TFG y TFM de la Universidad de Zaragoza,

Declaro que el presente Trabajo de Fin de (Grado/Máster) Máster, (Título del Trabajo)

Diseño de modelos basados en aprendizaje para la estimación de pares articulares para la rehabilitación motora mediante exoesqueletos

es de mi autoría y es original, no habiéndose utilizado fuente sin ser citada debidamente.

Zaragoza, a 1 de septiembre de 2015

Fdo: Santiago Redondo Salvo

Diseño de modelos basados en aprendizaje para la estimación de pares articulares para la rehabilitación motora mediante exoesqueletos

Resumen

El presente Trabajo Fin de Máster se enmarca en el proyecto HYPER-Consolider, en el que el Grupo de Robótica de la Universidad de Zaragoza pretende desarrollar exoesqueletos robóticos que ayuden a la rehabilitación funcional de pacientes con trastornos motores. En este sentido, uno de los elementos necesarios para su consecución es la estimación del par de fuerzas producido durante el movimiento de las articulaciones a partir de las señales de electromiografía superficial (sEMG) generadas por la activación de los músculos. La razón de ello es que, una vez conseguido predecir el movimiento voluntario que pretende realizar el paciente, se posibilita el que pueda ser ajustado por el exoesqueleto de forma que contribuya más eficientemente a su rehabilitación.

En este trabajo se han desarrollado modelos de *caja negra* basados en redes neuronales y otras técnicas de aprendizaje automático, diseñando su estructura y definiendo sus variables de entrada, de forma que se permita comparar el rendimiento de las distintas opciones con el obtenido anteriormente a partir de un modelo paramétrico basado en las técnicas de Hill. Como conclusión final se propondrá el modelo que mejor se ajuste a las necesidades del proyecto, valorándose sus posibilidades de generalización e indicándose sus limitaciones.

Índice general

1 Introducción	1
2 Descripción de los datos experimentales disponibles	5
3 Reducción de dimensionalidad en los datos de entrada	11
3.1 Principal Component Analysis (PCA)	12
3.2 Sinergias musculares	13
4 Métodos de predicción del momento articular	17
4.1 Multilayer Perceptron (MLP)	18
4.2 Radial Basis Network (RBN)	20
4.3 Support Vector Machine (SVM)	22
5 Configuración de los hiperparámetros y predicción del par	25
5.1 Averaged Output MLP (aoMLP)	26
5.1.1 Optimización de los hiperparámetros	26
5.1.2 Predicciones de validación del escenario ESU	26
5.1.3 Predicciones de validación del escenario ESM	29
5.2 Radial Basis Network (RBN)	36
5.2.1 Optimización de los hiperparámetros	36
5.2.2 Predicciones de validación	36
5.3 Support Vector Machine (SVM)	40
5.3.1 Optimización de los hiperparámetros	40
5.3.2 Predicciones de validación	40
6 Comparación de los modelos propuestos	45
6.1 Comparación de los modelos propuestos para el escenario ESU	46
6.2 Comparación de los modelos propuestos para el escenario ESM	47
6.3 Variaciones de las configuraciones propuestas	48

7 Conclusiones y líneas futuras	51
7.1 Líneas de desarrollo futuro	53
A Prácticas en el entorno clínico	55
B Listado de los datos disponibles	57
B.1 Señales del Escenario de Sujeto Único (ESU)	60
B.2 Señales del Escenario de Sujetos Múltiples (ESM)	60
C Reducción de dimensionalidad en los datos de entrada: Self-organizing Map (SOM)	73
D Predicción del momento articular: Modelo de Hill	77
E Predicciones de validación del escenario ESU	81
E.1 Averaged Output MLP (aoMLP)	81
E.2 Radial Basis Network (RBN)	82
E.3 Support Vector Machine (SVM)	82
F Predicciones de validación del escenario ESM	107
F.1 Averaged Output MLP (aoMLP)	107
F.2 Radial Basis Network (RBN)	107
F.3 Support Vector Machine (SVM)	108
G Tablas complementarias de resultados obtenidos	121
G.1 Modelos propuestos para el escenario ESU	121
G.2 Modelos propuestos para el escenario ESM	121
G.3 Variaciones de las configuraciones propuestas	121
Bibliografía	137
Siglas	143
Glosario	145
Índice de algoritmos	149
Índice de tablas	151
Índice de figuras	153

CAPÍTULO 1

Introducción

El ámbito de HYPER-Consolider [21], proyecto en el que se enmarca el presente Trabajo de Fin de Máster (TFM), es la investigación y desarrollo de dispositivos neurorrobóticos y neuroprotésicos que ayuden a pacientes afectados por dolencias funcionales motoras en su rehabilitación o, al menos, promuevan la compensación funcional de sus trastornos motores en las diversas actividades de la vida diaria. El objetivo de HYPER es validar, funcional y clínicamente, el empleo de novedosos sistemas robóticos híbridos con interacción hombre-máquina en el ámbito fisioterapéutico bajo un nuevo paradigma, el de la asistencia personalizada bajo demanda. En dicho paradigma las terapias de rehabilitación explotarían los diferentes niveles de actividad neural y muscular del paciente para poder adecuarse completamente a sus necesidades. En lugar de obviarse, se incorpora al propio modelo de rehabilitación la inherente variabilidad del cuerpo humano, mejorando su eficacia y posibilitando nuevas funcionalidades como es su adaptación automática con la evolución del paciente.

En la práctica HYPER supone la creación de un exoesqueleto que, respondiendo a distintos tipos de estímulos neuronales y musculares, potencie y ayude a restablecer las capacidades de personas con trastornos motores, tanto en los miembros inferiores como superiores, proporcionando capacidades que pueden ir desde el simple apoyo estructural hasta su uso como prótesis funcional. El único requisito para conseguirlo es la existencia de actividad neuronal latente asociada a actividades motoras que pueda ser adecuadamente detectada como con la electromiografía superficial (sEMG). Debido a ello HYPER tiene clara aplicación con las causas más comunes de trastornos motores, los accidentes cerebrovasculares y las lesiones de médula espinal, sin descartar que también sea factible con otras causas como la parálisis cerebral o la miastenia.

La importancia de esta labor se pone en perspectiva al considerar la prevalencia e incidencia de dichas causas. Por ejemplo, se estima que en EE.UU. las lesiones medulares tienen una prevalencia de 270 000 casos y una incidencia de entre 12 000 y 20 000 casos anuales, lo que supone unos costos totales estimados en 14,5 millardos de dólares. Por su parte, la prevalencia de los accidentes cerebrovasculares alcanza los 6,8 millones (un 2,8 % de la población) y su incidencia es de 795 000 nuevos casos, de los que la mitad sufrirán trastornos motores y una cuarta parte terminarán siendo dependientes para las actividades de su vida diaria. Los costes totales asociados se estiman, en este caso, de 34,3 a 65,5 millardos de dólares [29]. Aunque

en España las incidencias estimadas sean menores, con 8 casos por millón para las lesiones de medula espinal [37] y 187 por cada 100 000 para los accidentes cerebrovasculares [15], los efectos económicos y personales de la discapacidad asociada no dejan de ser cuantiosas.

El elemento clave para el éxito de HYPER es el Neuroestimador, una interfaz cerebro-máquina que, en el marco de la rehabilitación fisioterapéutica, predice el movimiento que pretende realizar el paciente a partir del nivel de actividad neuromuscular capturada, lo caracteriza y, según las demandas específicas para su rehabilitación, modifica el nivel de participación del paciente en dicho movimiento mediante el apoyo o la oposición a este por el exoesqueleto. Para alcanzar un fino control sobre la ayuda proporcionada es necesario una estimación precisa y adaptativa del movimiento que quiere realizar el paciente, con la dificultad de que dicho movimiento no está realmente constreñido si no que es libre y ha de procesarse en tiempo real. El presente TFM se centra en la caracterización del movimiento, lo que supone en la práctica, por la arquitectura y construcción del exoesqueleto, la predicción del momento que debería producirse en las articulaciones del paciente durante su ejecución.

Los métodos para la realización de dicha predicción están clasificados según el modelo del sistema neuromusculosquelético en que se basan. Los modelos fisiológicos, como el modelo de Hill [17], parametrizan las estructuras internas del sistema (huesos, tendones y músculos) realizando la predicción mediante un proceso de Dinámica Directa (Forward Dynamics, FD) [7]. De esta forma proporcionan un grado de conocimiento muy elevado sobre el comportamiento real del sistema motor, sin duda una de las razones por las que un TFM previo implementó el bloque predictor del Neuroestimador con un modelo de Hill optimizado [8].

Por otro lado, los métodos basados en aprendizaje automático, o de caja negra, recurren a redes neuronales artificiales (Artificial Neural Networks, ANNs) o a técnicas de aprendizaje estadístico como las máquinas de vectores soporte (Support Vector Machines, SVMs) para realizar la predicción. Entre la literatura relacionada podemos citar el estudio de ROSEN et ál. [32] que compara el rendimiento en la predicción del momento ejercido en el codo entre un modelo de Hill y un modelo basado en el perceptrón multicapa (Multilayer Perceptron, MLP), un tipo de ANN, a partir de las señales de activación muscular y la cinemática de las secciones del brazo. SONG et ál. [38] utilizaron para su estudio, también referido al codo, una Recurrent ANN (RANN) comparando, además, su rendimiento cuando se elimina la señal de cinemática. Por su parte, LOCONSOLE et ál. [28] predijeron el momento en hombro y codo mediante dos Time Delayed ANN (TDANN) independientes. Si nos referimos a la muñeca, tenemos estudios independientes realizados por CASTELLINI et ál. [9] o YANG et ál. [46] que, aparte de comparar diversos métodos como MLP o Support Vector Regression (SVR), muestran como el rendimiento del estimador disminuye conforme pasa el tiempo entre que se produjo el entrenamiento y la captura de las muestras empleadas en la nueva predicción.

Menos frecuentes son los estudios que, en lugar de emplear sujetos sanos como los anteriores, se han realizado con pacientes afectados por parálisis. AU et ál. [3] utilizaron otra TDANN para predecir la cinemática a partir de la sEMG en pacientes con parálisis C5. Dicho trabajo fue continuado por HINCAPIE et ál. [18] que, a partir de la sEMG, determinaron la estimulación muscular a ejercer para que el paciente pueda volver a mover voluntariamente los músculos del brazo que dejó de controlar por efecto de la lesión.

Nuestro cometido es diseñar e implementar un predictor basado en un modelo de caja negra alternativo al modelo previo basado en Hill. De este modo, al permitir su sustitución directa, se facilitará su integración con el sistema existente. La figura 1.1 muestra el diagrama de

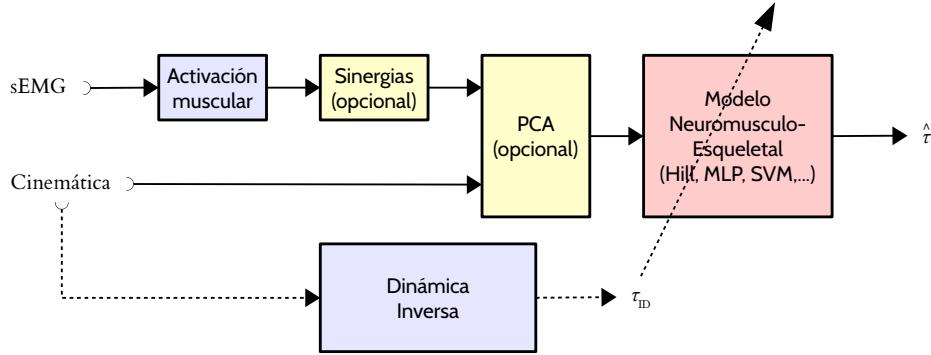


Figura 1.1: Diagrama de bloques del proceso de predicción. Se predecirá el par articular $\hat{\tau}$ partiendo de la cinemática de la extremidad y la activación muscular y utilizando el momento calculado por Dinámica Inversa τ_{ID} como referencia durante el proceso de aprendizaje

bloques que seguirá el proceso de predicción propuesto. En concreto se propondrán diferentes implementaciones para un predictor capaz de estimar conjuntamente el momento en hombro, codo y muñeca, valorándose sus ventajas e inconvenientes y comparándose sus resultados con los del modelo existente basado en Hill. Por los resultados obtenidos por SONG et ál. [38] se usará tanto la activación muscular como la cinemática como entradas al predictor propuesto, aunque también se estudiarán los efectos en el rendimiento del modelo de las variaciones en la selección de datos de entrada.

La estructura de la memoria es la siguiente: el capítulo 2 presenta los métodos empleados en la captura de los datos disponibles junto con el proceso de Dinámica Inversa (Inverse Dynamics, ID) [6] empleado para obtener el momento que utilizaremos como referencia (bloques azules de la figura 1.1). Los métodos para reducir la dimensionalidad de la entrada se ven en el capítulo 3 (bloques amarillos). El capítulo 4 expone los fundamentos de los modelos de aprendizaje automático propuestos para la estimación del par articular detallándose, en el capítulo 5, los pasos necesarios para configurar los modelos propuestos optimizando la capacidad de generalización de su aprendizaje y mostrándose algunos de los resultados obtenidos experimentalmente (bloque rojo de la figura 1.1). Finalmente, en el capítulo 6 se comparan los distintos modelos propuestos mientras que en el capítulo 7 se presentan las conclusiones alcanzadas junto con posibles líneas futuras para continuar el trabajo presentado.

Adicionalmente, en el apéndice A se comentan las prácticas realizadas en el entorno clínico. Por su parte, el apéndice B incluye información detallada de las señales disponibles, mostrándose los resultados de utilizar mapas auto-organizados (Self-organizing Maps, SOMs) para la reducción de la dimensionalidad en los datos de entrada en el apéndice C y revisándose brevemente el proceso de Dinámica Directa y el modelo de Hill en que se basa el Neuroestimador existente en el apéndice D. Finalmente, en los apéndices E, F y G, se muestran de forma detallada los resultados obtenidos durante la validación de los diversos modelos propuestos y variaciones.

CAPÍTULO 2

Descripción de los datos experimentales disponibles

El Neuroestimador, para poder realizar su función de predicción del movimiento voluntario que desea ejercer un sujeto, necesita tener acceso a señales fisiológicas que contengan dicha información. El electroencefalograma (EEG) ha demostrado su potencial para la predicción del movimiento de un sujeto [1] pero es el sEMG la señal más utilizada actualmente para el control de prótesis o dispositivos robóticos [9, 23, 26, 46]. La evaluación del rendimiento del predictor en estas fases preliminares se ha realizado usando datos proporcionados por el Hospital Nacional de Parapléjicos de Toledo (HNPT) siguiendo un protocolo de adquisición que, aunque no emplee del sistema sensorial del propio exoesqueleto, simula el entorno de trabajo real.

Naturalmente, dicho protocolo está avalado por el Comité Ético de Investigación Clínica del Hospital. En su realización han colaborado, tras firmar el preceptivo consentimiento informado, 19 sujetos de ambos sexos (12 pacientes y 7 controles) y edades entre 22 y 60 años (véase la tabla B.1). Los pacientes seleccionados padecen una lesión medular cervical de nivel metamérico C6-C7, pero están capacitados para realizar las actividades requeridas sin asistencia.

El protocolo establece un patrón de movimiento del miembro superior realizando la tarea de beber de un vaso y en cuya elección influyó la experiencia previa del HNPT con un estudio sobre la cinemática de dicho patrón [31]. A grandes rasgos el ejercicio, mostrado en la figura 2.1, parte de un estado de reposo con el sujeto sentado en una silla y el brazo en el respaldo, continua con la fase de alcance y agarre del vaso situado en una mesa para, a continuación, acercarlo a la boca y simular el acto de beber. Finalmente el sujeto deja el vaso de vuelta en su sitio y regresa a la posición de reposo. Un ejercicio de estas características, además de permitir a un fisioterapeuta la evaluación funcional de las capacidades del sujeto, supone un paso más en la complejidad del movimiento evaluado en estudios similares [9, 32, 38, 46] y posibilitando una estimación general del rendimiento del sistema en un entorno complejo.

Las variables disponibles para la realización del experimento son (véase el apéndice B para una información más detallada):

sEMG Electromiograma de 9 músculos del hombro, brazo y antebrazo (correspondientes al trapecio superior, deltoides posterior medio y anterior, pectoral mayor, bíceps y tríceps braquiales y los flexores y extensores del antebrazo)

Activación (Normalizada) Nivel de activación del músculo correspondiente. Variable con 9 componentes que se usarán como entrada del predictor

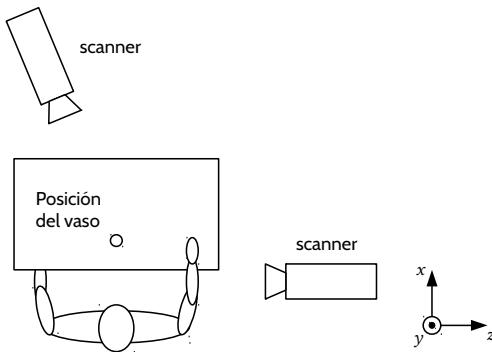


Figura 2.1: Vista esquemática cenital de la actividad de beber de un vaso por un sujeto diestro. Dicho sujeto se encuentra sentado en una silla de ruedas situada a entre 18 cm o 20 cm de distancia de la mesa. Las alturas de ambas se pueden regular para que, en la posición inicial de reposo, todos los sujetos tengan el brazo pegado al tronco formando un ángulo de 90° respecto al antebrazo con la muñeca reposando sobre la mesa y la palma perpendicular a esta y hacia adentro. El vaso de plástico duro con 1 dl de agua se ha situado enfrente del sujeto a 18 cm de distancia del borde de la mesa. También se muestra el sistema de coordenadas XYZ convenido para el experimento

Cinemática Posición angular tridimensional de tronco, hombro, codo y muñeca. Son 12 (4×3) variables que se usarán como entrada del predictor

Fuerza Fuerza tridimensional ejercida en hombro, codo y muñeca. Son 9 (3×3) variables derivadas que se pueden usar como referencia para la salida del predictor

Momento Par de fuerzas ejercido en hombro, codo y muñeca. Son 9 (3×3) variables derivadas que se usarán como referencia para la salida del predictor

Para la captura de los datos cinemáticos de la extremidad de cada sujeto se empleó un equipo de análisis de movimiento tridimensional CodaMotion® muestreando a 200 Hz. El análisis de cinemática inversa, para el cálculo de los ángulos de las articulaciones a partir de las posiciones de marcadores, y el de dinámica inversa, para el cálculo de momentos netos en las articulaciones y las fuerzas externas, se realizó mediante el software OpenSim [13], un sistema de simulación y análisis del movimiento humano. Para ello se creó un modelo biomecánico con las dimensiones y características iniciales de la extremidad de cada sujeto, simulándose la interacción con el vaso mediante una carga adicional de 0,3 kg. La figura 2.2 muestra el uso de las diversas variables en el diagrama de bloques del proceso.

Precisamente, la señal de momento τ_{ID} obtenida fruto de dicho proceso de ID será la utilizada como referencia o función objetivo en los procesos de optimización asociados tanto al aprendizaje de los modelos de caja negra como a la calibración del modelo basado en Hill, de forma que gracias a este proceso de optimización se minimice el error cometido entre la referencia utilizada τ_{ID} y la predicción realizada por el modelo $\hat{\tau}$.

Los datos de sEMG se capturaron con electrodos adhesivos bipolares Ag-AgCl mediante un equipo Noraxon® muestreando a 1500 Hz, aunque sincronizados temporalmente con los datos cinemáticos. Posteriormente se remuestrearon a 200 Hz para que el conjunto de variables que forman cada muestra de entrada de nuestro modelo correspondan a un mismo instante temporal. Más aún, un estudio de la densidad espectral de potencia de las distintas señales nos confirmó

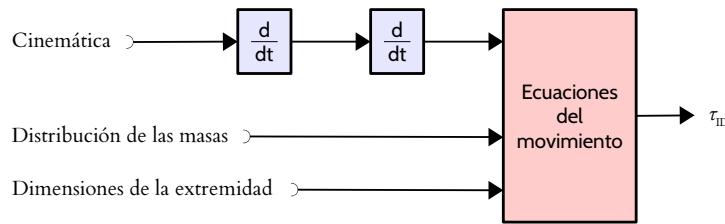


Figura 2.2: Diagrama de bloques del proceso de cálculo de Dinámica Inversa realizado por OpenSim

que otra opción es diezmar todas las señales a una frecuencia común de 20 Hz, reduciéndose así los requerimientos computacionales de los algoritmos de aprendizaje empleados.

La señal de activación muscular se extrajo mediante un proceso de acondicionado empleado habitualmente [7, 26, 27, 32, 38, 39]. Un primer filtrado paso alto (Butterworth de 4.^o orden con frecuencia de corte de 30 Hz) elimina el ruido producto del movimiento de los electrodos, y un rectificado y posterior filtrado paso bajo (Butterworth de 4.^o orden con $f_c = 6$ Hz) proporciona la envolvente de la señal. Como el sistema final trabajará en tiempo real, se ha optado por una implementación causal del filtrado en lugar de una con retardo de fase nulo.

Es habitual normalizar la señal de activación con el nivel de Máxima Contracción Voluntaria (MVC) del músculo correspondiente, es decir, el valor de activación muscular cuando se realiza un esfuerzo máximo con dicho músculo. Para ello el protocolo de adquisición establece la captura previa para cada sujeto de una serie de ejercicios específicos con los que obtener dichos máximos para los músculos implicados. Sin embargo, su ejecución se ha mostrado especialmente problemática con los pacientes, para los que ocasionalmente el nivel de activación detectado durante la tarea de beber es mayor que la MVC detectada durante el ejercicio específico. Además se ha establecido un umbral mínimo de activación muscular del 1 % para evitar situaciones de mal acondicionamiento numérico en los cálculos realizados con dicha señal.

Se han definido dos escenarios de pruebas distintos con los que verificar el comportamiento de los sistemas propuestos. El primero, que denominaremos Escenario de Sujeto Único (ESU), verifica el rendimiento del modelo cuando utiliza exclusivamente para el aprendizaje datos de varias iteraciones del movimiento realizadas por un mismo sujeto. Este escenario, caracterizado por facilitar el aprendizaje al restringir la variabilidad de las señales de entrada, requiere a cambio una fase de aprendizaje específica para cada sujeto. Se dispone de 5 repeticiones del movimiento realizadas por 8 sujetos (4 controles y 4 pacientes) realizándose, consiguientemente, 8 pruebas diferentes. Como muestra de los datos disponibles se representan las señales de un sujeto de control (figura 2.3) y un paciente (figura 2.4), incluyéndose el resto en el apéndice B.

El segundo escenario, denominado Escenario de Sujetos Múltiples (ESM), utilizará una única iteración por sujeto, simulando la creación de una base de datos que, si es suficientemente general, eliminaría la necesidad de entrenar previamente con cada sujeto. Este escenario determinará lo factible de la propuesta y el número de sujetos necesario para un correcto aprendizaje. Se podrán realizar 3 pruebas diferentes (empleando solo controles, solo pacientes o mezclando ambos), ya que se espera que una prueba con únicamente controles presente menor dificultad al aprendizaje.

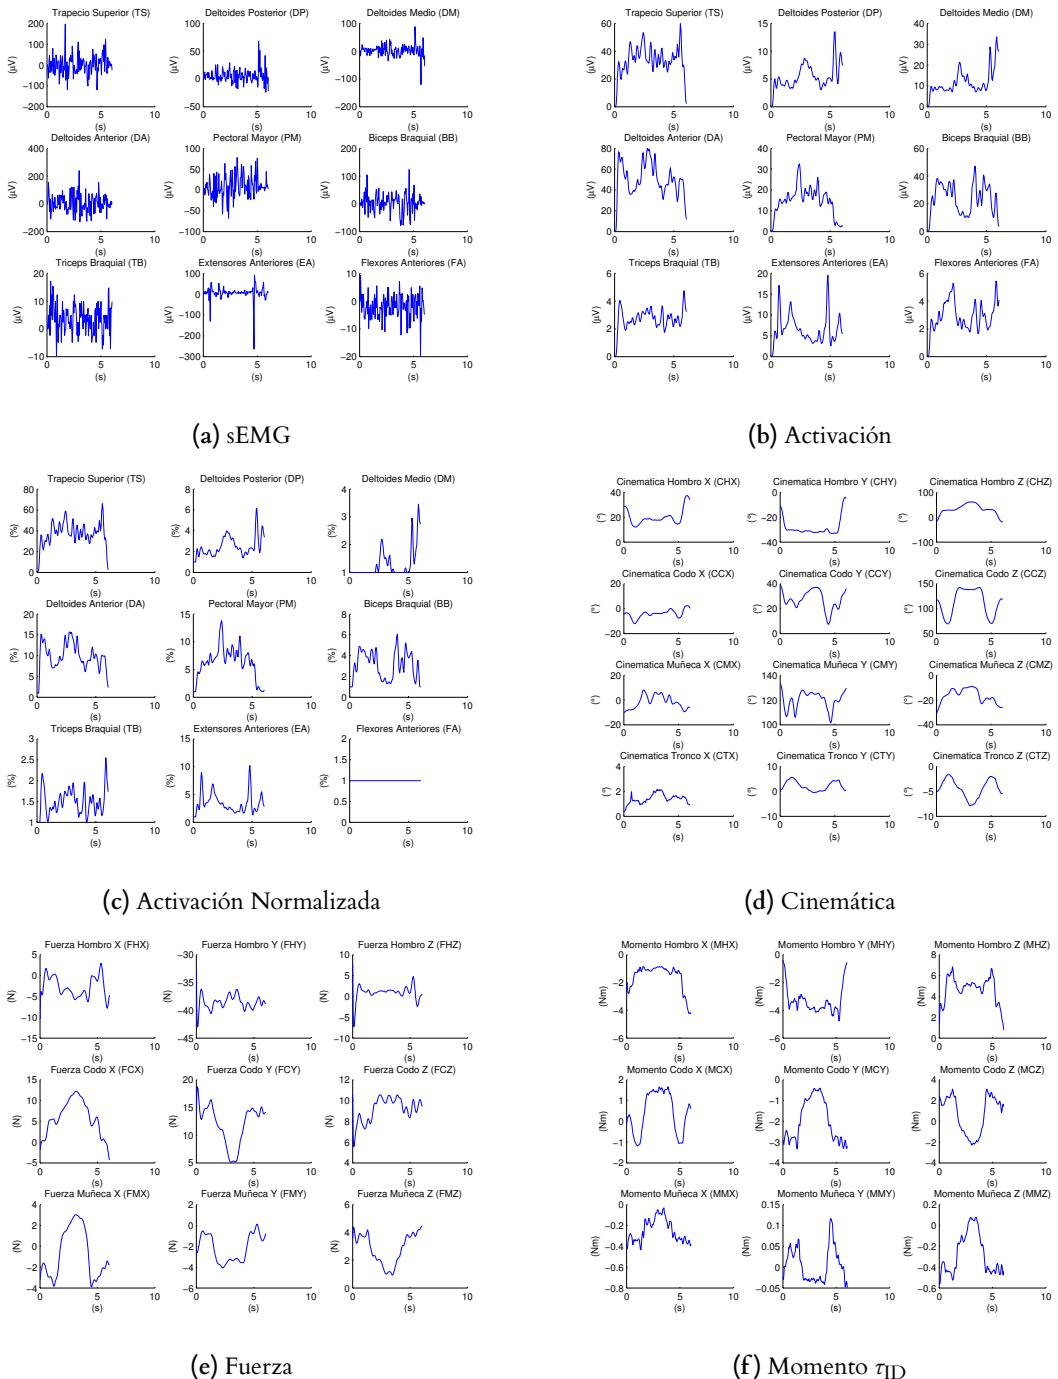


Figura 2.3: Representación temporal de las señales disponibles de una iteración del movimiento realizado por el sujeto C009 ($F_m = 20$ Hz)

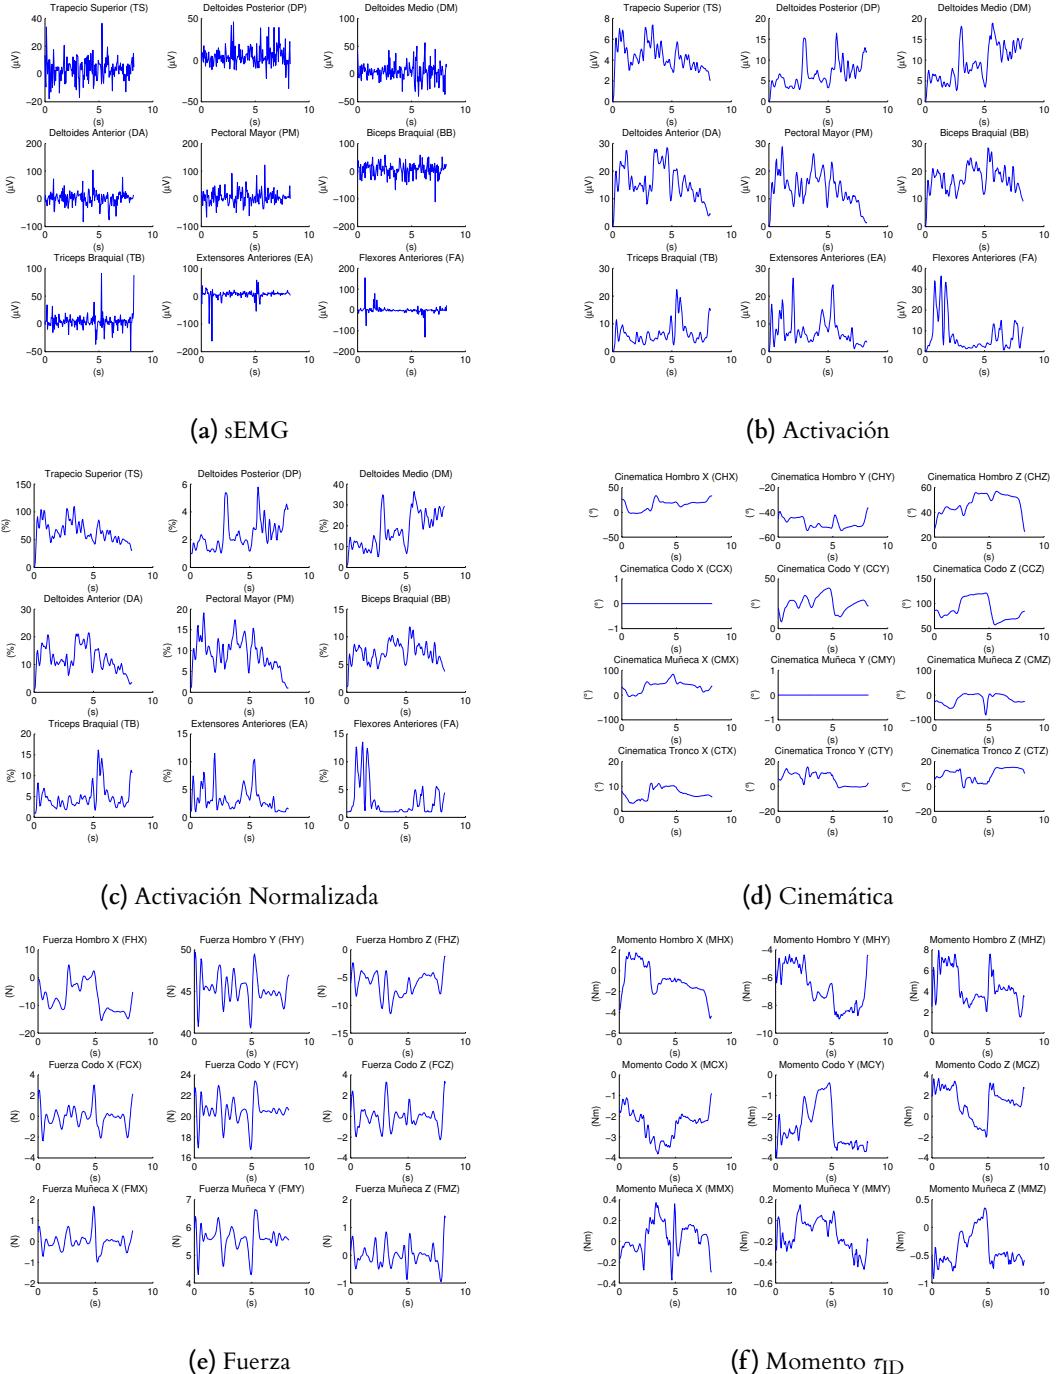


Figura 2.4: Representación temporal de las señales disponibles de una iteración del movimiento realizado por el sujeto P002 ($F_m = 20$ Hz)

CAPÍTULO 3

Reducción de dimensionalidad en los datos de entrada

Un aspecto destacable mostrado en el capítulo 2 es la elevada cantidad de información con la que se puede terminar trabajando. El principal parámetro del que depende la dimensionalidad en la entrada es el número de muestras que formaran la base de datos de aprendizaje, por ser el de mayor influencia en las requisitos computacionales de los algoritmos de entrenamiento de los modelos estudiados. En nuestro caso se corresponde con la frecuencia de muestreo de las señales y, naturalmente, es el motivo para usar el valor más bajo posible, ende los 20 Hz propuestos.

En el otro lado tenemos el número y tipo de las variables de entrada, algo que, en realidad, acabará siendo dependiente de las capacidades reales del propio exoesqueleto. Por ejemplo, en una fase inicial del desarrollo podría no implementarse el antebrazo del exoesqueleto, por lo que no se dispondrían de sus correspondientes datos de cinemática y sEMG. En el otro extremo, puede llegar a interesar mejorar la captura de la señal sEMG y proponerse cambiar los electrodos bipolares individuales por una solución en malla que cubra el miembro de forma más uniforme. Consecuentemente el número de variables de entrada aumentaría exponencialmente así como los requisitos computacionales. De cualquier manera, la elección de su número y, en definitiva, la dimensionalidad global de la entrada ha de hacerse teniendo en cuenta los requisitos del problema a resolver.

Por regla general, cuanta más información relevante se introduzca a un sistema de aprendizaje automático mayor será su rendimiento, aunque esto también provoca un aumento de la capacidad computacional requerida. Si bien es cierto que su efecto es mucho menor que el aumentar el número de muestras de aprendizaje, cuando se trata de sistemas en tiempo real podría llegar a ser apreciable. Más aún, el aumentar el número de variables de entrada no ha de hacerse con información irrelevante, y menos aún contradictoria, ya que esto conlleva el disminuir la capacidad de aprendizaje efectiva del modelo. Dicho de otro modo, el rendimiento del predictor dependerá de la calidad de la información con la que se alimenta.

Como el adaptarse a los requisitos computacionales puede suponer la necesidad de reducir el número de variables a la entrada, es muy interesante el comprobar la degradación del rendimiento final al eliminar información de forma controlada. Entre los métodos estudiados tenemos el genérico [análisis de componentes principales \(Principal Component Analysis, PCA\)](#) o las sinergias musculares, cuya aplicación es exclusiva a la señal de activación muscular.

3.1 Principal Component Analysis (PCA)

El concepto fundamental tras PCA es el de una simple transformación de bases [22]. Partiendo de la base original definida por las propias variables que forman la señal original, se define una nueva seleccionando cada nueva componente en la dirección que explique la máxima variabilidad de la parte de señal que todavía no ha sido explicada por las componentes anteriores. Dicho de otro modo, se define una nueva base cuyas componentes han sido ordenadas en función de la parte que explican de la variabilidad presente en la señal original. De esta forma, llegado el caso de necesitar reducir el número de componentes de una señal con el que se deba trabajar, se pueden eliminar aquellas que menos contribuyen en su variabilidad.

La figura 3.1 muestra la media, y desviación estándar correspondiente, del porcentaje de varianza explicada del conjunto de señales de Activación Normalizada disponibles para ambos escenarios de trabajo, ESU y ESM. Al estar implicadas para su realización un elevado número de iteraciones del movimiento es razonable que ambas gráficas presenten resultados similares. De ellas se deduce que, de las 9 componentes de activación muscular disponibles, suelen bastar 4 componentes de media para explicar un 80 % de la varianza de la señal original aunque, al considerar la desviación, se necesiten 5 para asegurarlo de forma práctica. De forma similar bastan 5 o 6 componentes para explicar el 90 % de la varianza de la Activación Normalizada.

Pero la verdadera potencia de PCA está en la generalidad del propio método al poderse aplicar mezclando tipos de señales. La figura 3.2 muestra los resultados para las señales conjuntas de Activación Normalizada y Cinemática donde se aprecia que, a pesar de haber añadido las 12 componentes correspondientes a la señal de cinemática, sólo se necesitan 1 o 2 componentes adicionales con respecto al caso anterior para alcanzar el porcentaje de varianza explicada requerido.

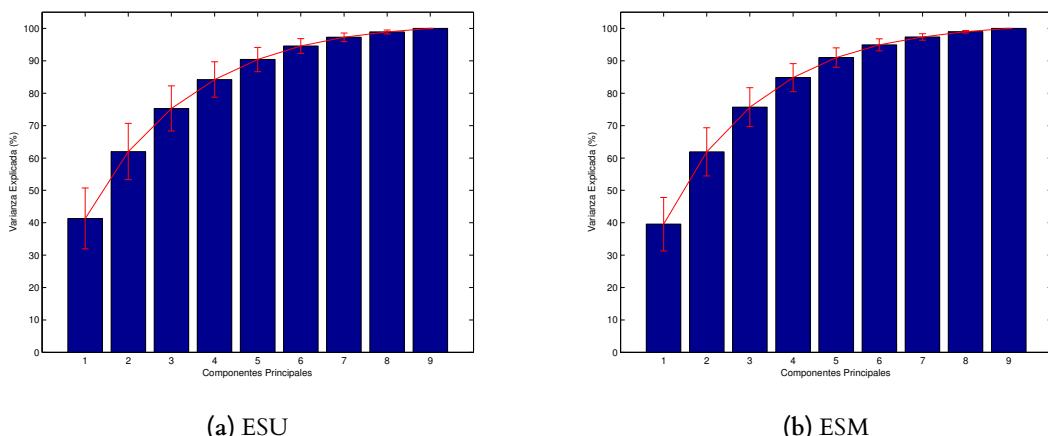


Figura 3.1: Promedio y desviación por componente del porcentaje de varianza explicada de la señal de Activación Normalizada ($F_m = 20$ Hz)

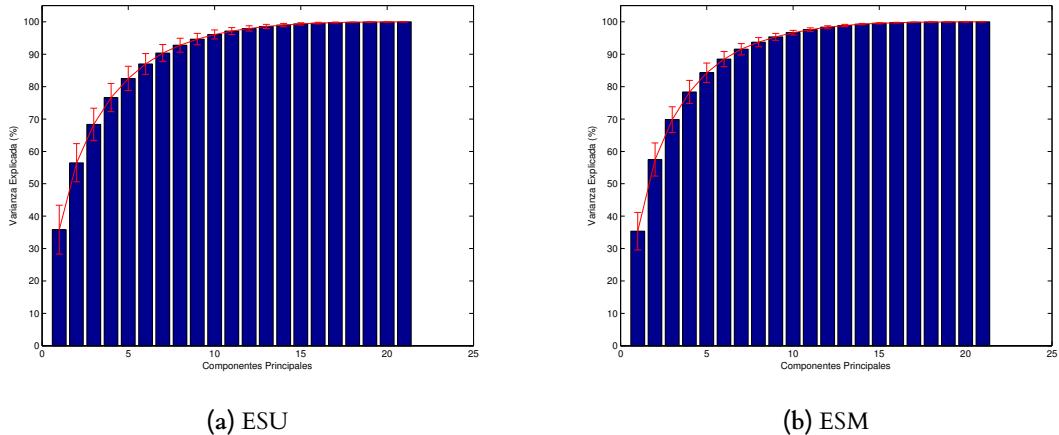


Figura 3.2: Promedio y desviación por componente del porcentaje de varianza explicada de las señales de Activación Normalizada y Cinemática ($F_m = 20$ Hz)

3.2 Sinergias musculares

El modelo de sinergias musculares ha sido propuesto en la literatura de control del sistema motor para explicar la coordinación existente entre diversos músculos durante la realización de movimientos voluntarios. En este modelo la activación de los músculos individuales se transforma, mediante algoritmos de análisis de componentes, en un número menor de agrupaciones musculares o sinergias. Estas representan subtareas motoras que el sistema nervioso combina de forma flexible para producir movimientos naturales complejos [34]. La ventaja de esta aproximación es la mayor facilidad en la interpretación funcional de la actividad muscular frente a la que se puede conseguir simplemente con las señales de activación normalizada aunque, lamentablemente, estos patrones son específicos de cada sujeto y cambian ostensiblemente con la existencia de trastornos motores. Sin embargo, y a pesar de lo plausible de su interpretación fisiológica, la dificultad de acceder al interior del sistema nervioso complica, no solo la verificabilidad de la propia teoría, sino también la determinación del número de sinergias con las que operar.

Para extraer las sinergias se han propuesto diversos métodos, como **PCA** o Independent Component Analysis (ICA), pero es la **factorización no-negativa de matrices (Nonnegative Matrix Factorization, NMF)** el que proporciona mejores resultados experimentales [41]. Más aún, la restricción que impone de no-negatividad facilita la reinterpretación de sus resultados como activaciones musculares. En esencia, **NMF** factorizará una matriz no-negativa $\mathbf{A} \in \mathbb{R}^{N \times M}$ en otras dos, $\mathbf{W} \in \mathbb{R}^{N \times P}$ y $\mathbf{H} \in \mathbb{R}^{P \times M}$ también no-negativas, tal que $\mathbf{W} \times \mathbf{H}$ es una aproximación de \mathbf{A} con rango $P < \min(M, N)$ calculada mediante la minimización iterativa de:

$$f(\mathbf{W}, \mathbf{H}) = \frac{1}{2} \|\mathbf{A} - \mathbf{WH}\|_F^2 \quad (3.1)$$

donde \mathbf{A} representa las N muestras de las señales de activación muscular de los M músculos, \mathbf{H} es la definición de las P sinergias como combinación lineal de los músculos y \mathbf{W} representa las señales de activación sinergiales.

Algoritmo 3.1 Algoritmo de actualización multiplicativa para NMF

```

 $W = \text{rand}(N, P)$                                 ▷ Inicializar  $W$  como una matriz densa aleatoria
 $H = \text{rand}(P, M)$                                 ▷ Inicializar  $H$  como una matriz densa aleatoria
for  $i = 1 : \text{max\_iter}$  do
     $H = H .*(W^T A) ./ (W^T W H + \text{epsilon})$           ▷ Paso de actualización (MU)
     $W = W .*(A H^T) ./ (W H H^T + \text{epsilon})$           ▷ Paso de actualización (MU)
end for

```

Algoritmo 3.2 Algoritmo Alternating Least-Squares (ALS) para NMF

```

 $W = \text{rand}(N, P)$                                 ▷ Inicializar  $W$  como una matriz densa aleatoria
for  $i = 1 : \text{max\_iter}$  do
    Resolver  $H$  en  $W^T W H = W^T A$                   ▷ Aplicar mínimos cuadrados (LS)
    Poner a 0 los elementos negativos de  $H$            ▷ Aplicar restricción (NONNEG)
    Resolver  $W$  en  $H H^T W^T = H A^T$                 ▷ Aplicar mínimos cuadrados (LS)
    Poner a 0 los elementos negativos de  $W$            ▷ Aplicar restricción (NONNEG)
end for

```

Existen múltiples algoritmos de actualización [4] pero, comúnmente, un primer paso de inicialización aleatoria tiene efectos en los resultados obtenidos. Por ello, para obtener un mejor resultado es habitual combinar dos de ellos, primero una serie de repeticiones del tradicional algoritmo de actualización multiplicativa (algoritmo 3.1) aproxima la localización del mínimo global, mientras que se aprovecha la rápida convergencia del algoritmo Alternating Least-Squares (ALS) (algoritmo 3.2) para encontrarlo propiamente. Aún así no está garantizado que se alcance el mínimo global, obteniéndose una solución que podría no ser óptima en el sentido de que, al aumentar el número de sinergias empleadas, disminuye el porcentaje de varianza explicada. En este caso se necesitaría repetir el proceso hasta alcanzar un resultado aceptable.

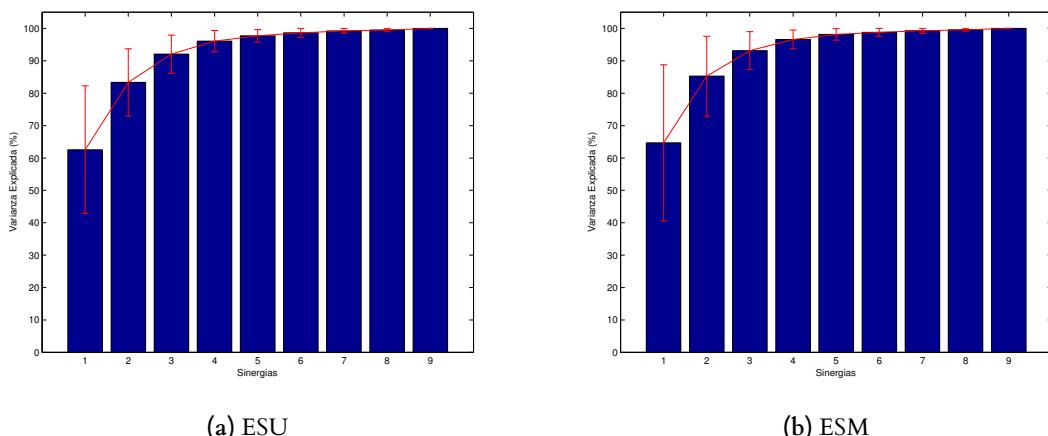


Figura 3.3: Promedio y desviación por número de Sinergias, o grupos musculares, del porcentaje de varianza explicada de la señal de Activación Normalizada ($F_m = 20$ Hz)

Un ejemplo de los resultados obtenidos se muestra en la figura 3.3. Frente a los resultados de **PCA** (figura 3.1) destaca la mayor cantidad de varianza explicada de media con un número pequeño de grupos musculares. Igualmente se aprecia su mayor variabilidad, lo que complica la elección de un número común de sinergias aceptable para toda la población. En este sentido 3 sinergias bastarían para explicar, prácticamente en todos los casos, el 80 % de la varianza presente originalmente, mientras que son 5 las necesarias para elevarlo al 90 %. Este número es inferior al necesario por **PCA**, aunque su mayor variabilidad implica tomarlo con cautela.

CAPÍTULO 4

Métodos de predicción del momento articular

Los modelos de aprendizaje automático realizan su modelado del sistema neuromusculoesqueletal en un plano superior al nivel en el que se sitúan los modelos basados en Hill (véase su descripción en el apéndice D). En lugar de situarse el foco en cada uno de los elementos que forman el sistema (músculos, tendones, etc.) se considera este en su conjunto, evitándose la complejidad del modelado individual de cada elemento a costa de perder la perspectiva fisiológica. De esta manera, se intercambia la dificultad del proceso de ajuste los distintos elementos del modelo por un uso apropiado de los algoritmos que definen el modelo de caja negra y la obligatoriedad de una fase de entrenamiento supervisado que lo adapte a diferentes movimientos. Adicionalmente, habrá de asegurarse la calidad de la base de datos de muestras de entrenamiento y que esta sea realmente representativa del problema.

En base a literatura relacionada [9, 32, 46] se ha decidido emplear modelos basados en MLP y SVR, incluyéndose adicionalmente un modelo basado en **redes de base radial** (Radial Basis Networks, RBNs) por su simplicidad. Todos los modelos han sido configurados para predecir el par de fuerzas en las articulaciones del hombro, codo y muñeca de forma conjunta a partir, inicialmente, de las señales de activación muscular normalizada y cinemática correspondientes, lo que en nuestro caso suponen 21 componentes disponibles para la entrada. En comparación, la sección 6.3 estudiará los efectos de la variación en la selección de las variables de entrada junto con la aplicación de los resultados obtenidos en el capítulo 3 para la reducción controlada del número de componentes de las variables de entrada.

Remarcando, además, que se han empleado datos provenientes tanto de sujetos sanos como de pacientes afectados de lesiones medulares a nivel C6-C7, lo que permitirá comparar los resultados obtenidos para ambos grupos. Por último, para estimar el rendimiento en entornos reales se ha optado por entrenar, no con un simple movimiento de flexión-extensión, sino con un movimiento complejo que permite caracterizar la capacidad funcional del sujeto como es la tarea de beber de un vaso.

El funcionamiento de los modelos de caja negra seleccionados está determinado por una serie de parámetros que influyen de diversas maneras en sus algoritmos de aprendizaje, pudiendo distinguirse entre parámetros e hiperparámetros. Los primeros serían los parámetros internos del algoritmo de aprendizaje y estarían calculados automáticamente por este durante la fase de aprendizaje representando, de esta forma, el conjunto de información aprendida por el modelo.

Sin embargo, los hiperparámetros corresponderían a la configuración del modelo seleccionado (como el algoritmo de aprendizaje propiamente dicho, el número de neuronas y estructura de la ANN, las condiciones de parada del entrenamiento, ...) y tanto podrían haber sido seleccionados previamente por criterios de diseño, como ser calculados durante la fase de aprendizaje.

4.1 Multilayer Perceptron (MLP)

La estructura de un MLP [33], siendo una ANN, es equiparable a la de una red neuronal biológica, con una primera capa de sensores, una o varias capas de neuronas de procesamiento y una capa final de neuronas de salida (figura 4.1b). Más aún, el comportamiento de sus neuronas, con una salida determinada por entradas altamente interconectadas y un coeficiente de bias, es equiparable al de las neuronas biológicas con sus dendritas y umbral de activación neuronal (figura 4.1a). Matemáticamente, para una neurona k genérica, su salida y_k es proporcional a sus L entradas ponderadas $w_{ki}x_i$ y al bias de la neurona θ_k (ecuación 4.1). La función de transferencia de la respuesta funcional más comúnmente empleada es la tangente hiperbólica o sigmoidea (ecuación 4.2), aunque las neuronas de salida de un MLP configurado para ajuste funcional han de ser lineales.

$$y_k = f \left(\sum_{i=1}^L w_{ki}x_i - \theta_k \right) \quad (4.1)$$

$$\text{tansig}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (4.2)$$

El MLP en el que nos basaremos dispondrá, inicialmente, de $L = 21$ entradas, correspondientes a las 12 componentes disponibles de cinemática y a las 9 de activación normalizada, y $S = 9$ neuronas lineales de salida correspondientes a las respectivas componentes del momento en las articulaciones de hombro, codo y muñeca. Además se ha configurado una capa intermedia u

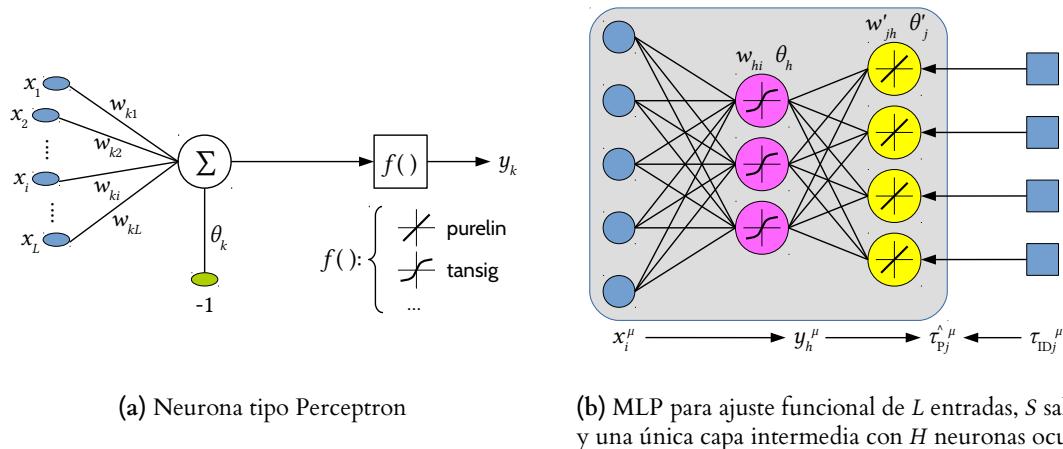


Figura 4.1: Descripción de un perceptrón multicapa (MLP)

oculta con H neuronas sigmoideas cuyo número definitivo será determinado por el proceso de optimización que se detallará en el capítulo 5.

A partir de la ecuación 4.1 que regula la salida de un neurona genérica se puede deducir la ecuación 4.3 que relaciona cada salida de la red con sus entradas. Denotando como x_i a la i -ésima entrada de la red, y_h a la salida de la h -ésima neurona oculta cuyos parámetros son w_{hi} y θ_h y, finalmente, \hat{r}_{pj} a la salida de la j -ésima neurona de salida con parámetros w'_{jh} y θ'_j y que corresponde a la j -ésima componente del momento predicho por el modelo, obtenemos:

$$\hat{r}_{pj} = \sum_{h=1}^H w'_{jh} y_h - \theta'_j = \sum_{h=1}^H w'_{jh} \text{tansig}\left(\sum_{i=1}^L w_{hi} x_i - \theta_h\right) - \theta'_j \quad (4.3)$$

Los parámetros de la red (pesos y bias), son establecidos durante el periodo de entrenamiento mediante el procedimiento llamado *back-propagation*. Este es un proceso que, partiendo de una inicialización aleatoria los actualiza iterativamente buscando minimizar, en cada iteración μ , el error de entrenamiento entre las salidas \hat{r}_{pj}^μ del MLP y sus valores objetivos correspondientes calculados por Dinámica Inversa $r_{ID_j}^\mu$. En lugar del habitual Levenberg-Marquardt se decidió emplear como método de entrenamiento Scaled Conjugate Gradient (SCG) [30] por ser la opción más rápida para el ajuste funcional con un elevado número de muestras [40].

El mayor problema de los métodos de aprendizaje automático es el llamado *overfitting* o sobreaprendizaje, consistente en que el modelo, en lugar de aprender el comportamiento general del sistema, memoriza el ruido o información espuria presente entre los datos de entrenamiento y disminuyendo así su capacidad de generalización ante entradas desconocidas. Por ejemplo, este aparece cuando el objetivo del entrenamiento se centra exclusivamente en minimizar el error de entrenamiento. Un método común para evitarlo es recurrir a *Early-Stopping*, por el que un subconjunto aleatorio de las muestras disponibles se reservan para validar el error cometido en el entrenamiento y señalar, cuando este crece, el momento en el que comienza el sobreaprendizaje (figura 4.2a). Otra situación en la que se puede incurrir en overfitting es al determinar los hiperparámetros del modelo [11], como el número de neuronas o el

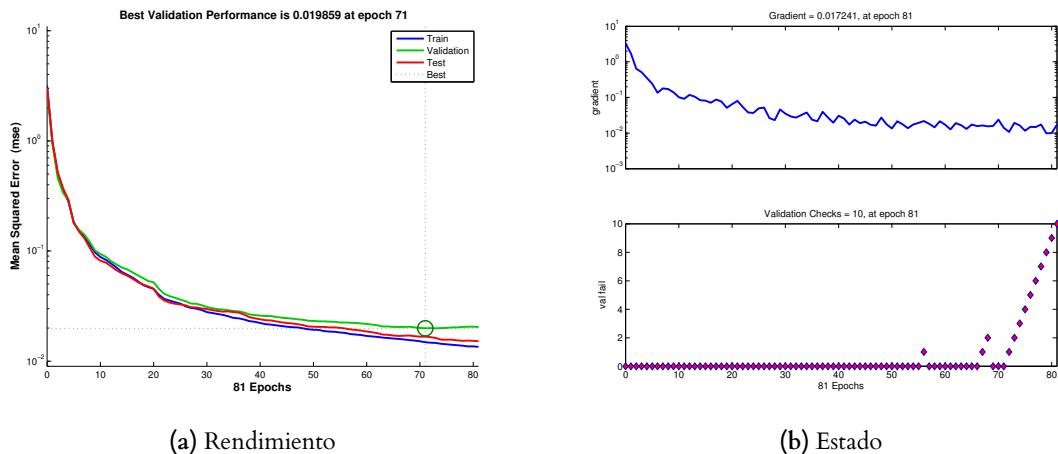


Figura 4.2: Rendimiento y estado de un MLP durante la fase de entrenamiento

algoritmo de entrenamiento. En nuestro caso ya ha sido fijado el algoritmo SCG por su rapidez pero habrá que tenerlo en cuenta al definir el número de neuronas ocultas.

Por otro lado, la aleatoriedad inherente en Early-Stopping habilita que se puedan obtener resultados distintos para un mismo entrenamiento. Más aún, la misma presencia de neuronas ocultas implica la existencia de mínimos locales en el hiperparaboloide solución [33] y, de nuevo, que no siempre se alcance el mejor rendimiento posible. Para evitarlo es habitual repetir el entrenamiento r veces y seleccionar el MLP con menor error de entrenamiento. Por ejemplo, CASTELLINI et ál. [9] escogieron para su estudio la mejor de $r = 10$ repeticiones, aunque habitualmente dicho número es menor.

Sin embargo, esta solución es proclive al sobreaprendizaje, por lo que nuestra propuesta, en lugar de descartar esos $r - 1$ MLP ya entrenados, es considerar como modelo el conjunto de los r MLP y tomar como su salida el promediado (con la media o incluso la mediana para hacerlo más robusto frente a valores atípicos) de sus salidas individuales. Para ayudar a distinguir este modelo del MLP habitual lo denotaremos como **Averaged Output MLP (aoMLP)** teniendo en cuenta que, en realidad, representa una forma básica de *ensemble learning* en la que la variación se produce en la inicialización de los pesos y, por efecto del Early-Stopping, en la selección de las muestras de entrenamiento [36]. Naturalmente, conforme se incrementa el número de realizaciones r del ensamblaje, se reduce la variabilidad en su salida a costa de incrementar linealmente el tiempo de entrenamiento. En el presente TFM se ha escogido $r = 30$ para tener un alto grado de confianza de encontrar la media real de la salida, aunque también comprobaremos que es factible usar un número menor.

Para finalizar, y aunque de menor importancia, indicar que como criterios de parada del entrenamiento se configuró en 10 el número máximo de incrementos consecutivos del error de validación y en 20 000 el número máximo de épocas de entrenamiento (correspondientes a las iteraciones con las N muestras de entrenamiento). Al incrementarse los valores por defecto aumenta la probabilidad de obtener un buen entrenamiento con entradas complicadas a costa de un mayor riesgo de overfitting. El rendimiento de la red se computó mediante el error cuadrático medio (Mean Square Error, MSE) optándose por normalizar su valor entre las distintas salidas para tener en cuenta la distinta magnitud del momento en hombro y codo frente al ejercido en la muñeca.

4.2 Radial Basis Network (RBN)

Las RBN son redes neuronales que, en su formulación más generalizada, utilizan para sus neuronas intermedias cuya respuesta es una función de base radial (Radial Basis Function, RBF) aunque, mayoritariamente, estas son directamente neuronas de tipo gaussiano [5]. Dichas neuronas (figura 4.3a) tienen dos parámetros, el centroide c_{ki} y la anchura del kernel σ_k o *spread*, mientras que su salida es proporcional a la distancia entre entrada y centroide (ecuación 4.4). Finalmente, y utilizando la nomenclatura vista en la sección 4.1, la relación entre una salida y las entradas de la red viene dada por la ecuación 4.5.

$$y_k = e^{-\sum_{i=1}^L (x_i - c_{ki})^2 / 2\sigma_k^2} \quad (4.4)$$

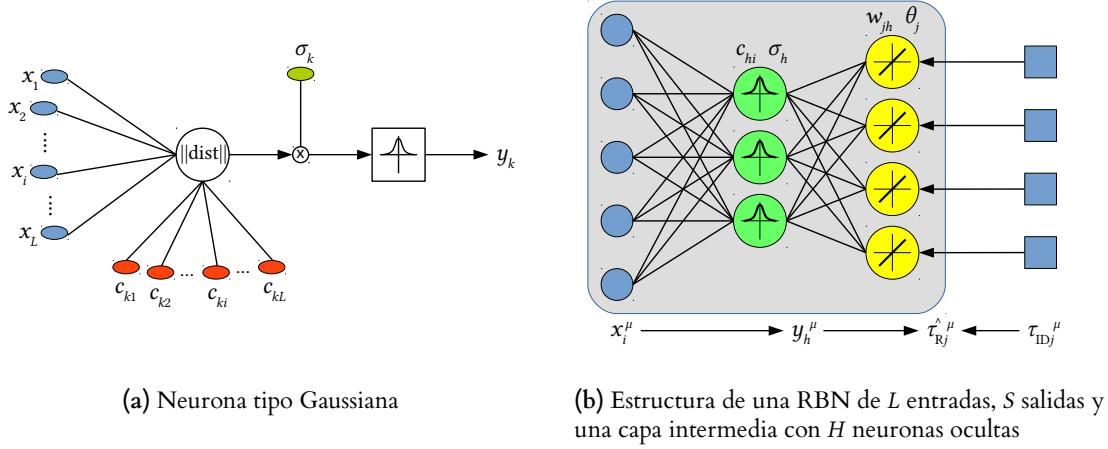


Figura 4.3: Descripción de una red de base radial (RBN)

$$\hat{r}_{Rj} = \sum_{h=1}^H w_{jh} y_h - \theta_j = \sum_{h=1}^H w_{jh} \left(e^{-\sum_{i=1}^L (x_i - c_{hi})^2 / 2\sigma_h^2} \right) - \theta_j \quad (4.5)$$

En esta ocasión el algoritmo de entrenamiento está basado en añadir, con cada iteración, un nueva neurona oculta que minimize el error resultante. Para ello simplemente sitúa el centroide de la nueva neurona en el punto en el que se encuentra el error máximo, continuando el proceso de entrenamiento hasta que se alcanza el rendimiento requerido (algoritmo 4.1). Como la implementación del algoritmo empleado asigna idéntico *spread* a todas las neuronas, este será uno de los hiperparámetros del modelo. El otro será, por determinar la duración del entrenamiento tal y como muestra la figura 4.4, el nivel de error deseado o *goal*.

Un último parámetro que se configuró, aunque de menor importancia, fue el número máximo de neuronas intermedias (1000) que, en la práctica, permite detener el entrenamiento cuando el rendimiento alcanzado tarda en llegar al valor deseado. Aunque es posible encontrarse en dicha situación al configurar un *goal* muy exigente, es más habitual que se produzca cuando los datos de entrenamiento disponibles no permiten un aprendizaje efectivo.

Algoritmo 4.1 Algoritmo de entrenamiento de RBN

Inicializar a cero los pesos y bias de la capa de salida	▷ $w_{jh} = 0$ y $\theta_j = 0$
for $h = 1 : max_neurons$ do	$\triangleright max_neurons \leq N$
Simular la configuración actual de la red	
Salir si ya se ha alcanzado el error deseado	▷ $MSE < goal?$
Encontrar el vector de entrada x_n con mayor error	
Añadir neurona gaussiana en la posición del vector	▷ Determina c_{hi}
Actualizar la capa de salida minimizando el error	▷ Actualiza w_{jh} y θ_j
end for	

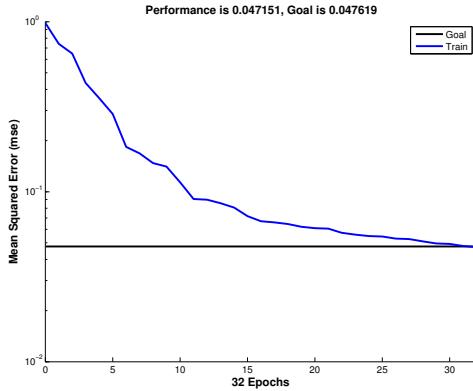


Figura 4.4: Rendimiento de una RBN durante la fase de entrenamiento

4.3 Support Vector Machine (SVM)

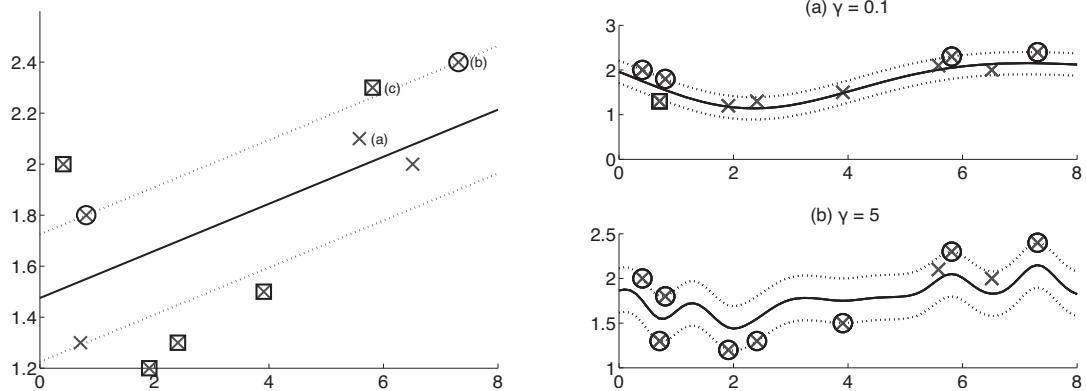
La predicción del par articular impone, al tratarse de su ajuste funcional, implementar el modelo **SVM** mediante la modalidad **SVR**. Concretamente se utilizará la formulación ϵ -**SVR** proporcionada por el software LibSVM [12]. Aunque la interpretación geométrica de **SVM** difiere según se realice regresión o clasificación, en general su algoritmo se divide en dos partes diferenciadas.

En primer lugar el espacio muestral se transforma, mediante una transformación de kernel, en un nuevo espacio de características (EC) que, usualmente, estará caracterizado por una alta dimensionalidad que facilitará la linealización del problema. Un proceso subsecuente de optimización buscará, de entre todos los datos de entrenamiento, los *vectores soporte* que definen el tubo asociado a la línea de ajuste de regresión que minimiza el error empírico de predicción cometido [43]. Lo interesante es que por su construcción, al mismo tiempo, se maximiza el margen geométrico entre la línea de ajuste y la frontera del tubo (figura 4.5). Esta es la razón por la que **SVM** se considera una extensión de las **ANN**, cuya solución no proporciona necesariamente ese margen óptimo.

ϵ -**SVR** dispone para su configuración de dos hiperparámetros, la tolerancia del criterio de terminación $\epsilon > 0$ y el parámetro de coste o regularización del error $C > 0$. Además, se eligió un kernel **RBF** por combinar una respuesta no lineal con la sencillez de requerir un único hiperparámetro adicional $\gamma > 0$ [16, 20]. Considerando que se disponga de N muestras de entrenamiento $\mathbf{x}_n \in \mathbb{R}^L$, con sus correspondientes salidas objetivo $\tau_{ID_n} \in \mathbb{R}^1$, el kernel elegido vendrá dado por:

$$K(\mathbf{x}_n, \mathbf{x}_k) = e^{(-\frac{1}{2\sigma^2} \|\mathbf{x}_n - \mathbf{x}_k\|^2)} = e^{(-\gamma \|\mathbf{x}_n - \mathbf{x}_k\|^2)} \quad (4.6)$$

Por otro lado, teniendo en cuenta que dicho kernel está definido en función de la función de transformación del EC como $K(\mathbf{x}_n, \mathbf{x}_k) \equiv \phi(\mathbf{x}_n)^T \phi(\mathbf{x}_k)$, y que la solución se puede definir, como cualquier hiperplano, por el conjunto de puntos \mathbf{x} que satisfacen $\mathbf{w} \cdot \mathbf{x} - b = 0$ (con \mathbf{w} el



(a) SVR con kernel lineal e hiperparámetros $\epsilon = 0,25$ y $C = 10$. Se representa la línea de ajuste de regresión a las muestras de datos (\times) junto a los márgenes del tubo asociado. Las muestras tipo (a), al quedar dentro del tubo sin alcanzar la frontera, no contribuyen a la solución, al contrario que los vectores soporte. Se representan inscritos en un círculo los vectores soporte tipo (b), que están situados en la frontera del tubo definiéndola, e inscritos en un cuadrado los tipo (c), que al quedar fuera corresponden a datos espurios

(b) SVR con kernel RBF e hiperparámetros $\epsilon = 0,25$ y $C = 10$. Se representa, para diferentes valores de γ , la línea de ajuste de regresión a las muestras de datos (\times) junto a los márgenes del tubo asociado. También se representan, inscritos en un círculo, los vectores soporte situados en la frontera del tubo, e inscritos en un cuadrado los datos espurios de fuera del tubo. Se observa como al decrementar γ se suavizan las fronteras que definen la solución

Figura 4.5: Interpretación geométrica de la regresión por vectores soporte (SVR). Reproducido de *Introduction to Machine Learning* [2]

vector normal y b su offset), se puede obtener la forma estándar o primaria de ϵ -SVR:

$$\begin{aligned} \min_{\mathbf{w}, b, \xi, \xi'} & \quad \frac{1}{2} \mathbf{w}^T \mathbf{w} + C \sum_{n=1}^N \xi_n + C \sum_{n=1}^N \xi'_n \\ \text{sujeto a} & \quad \mathbf{w}^T \phi(\mathbf{x}_n) + b - \tau_{IDn} \leq \epsilon + \xi_n, \quad n = 1, \dots, N, \\ & \quad \tau_{IDn} - \mathbf{w}^T \phi(\mathbf{x}_n) - b \leq \epsilon + \xi'_n, \quad n = 1, \dots, N, \\ & \quad \xi_n, \xi'_n \geq 0, \quad n = 1, \dots, N \end{aligned} \tag{4.7}$$

donde las variables $\xi, \xi' \in \mathbb{R}^N$ representan a las llamadas variables de *slack*, que habilitan la existencia vectores erróneamente clasificados o los casos en que la linealización del EC no ha sido totalmente efectiva.

Técnicamente la ecuación 4.7 representa un problema de optimización de programación cuadrática con una restricción lineal, por lo que se puede construir su forma dual en el espacio

de los multiplicadores de Lagrange usando los multiplicadores $\boldsymbol{\alpha}, \boldsymbol{\alpha}' \in \mathbb{R}^N$:

$$\begin{aligned} \min_{\boldsymbol{\alpha}, \boldsymbol{\alpha}'} \quad & \frac{1}{2}(\boldsymbol{\alpha} - \boldsymbol{\alpha}')^\top Q(\boldsymbol{\alpha} - \boldsymbol{\alpha}') + \epsilon \sum_{n=1}^N (\alpha_n + \alpha'_n) + \sum_{n=1}^N \tau_{IDn} (\alpha_n - \alpha'_n) \\ \text{sujeto a} \quad & \mathbf{e}^\top (\boldsymbol{\alpha} - \boldsymbol{\alpha}') = 0, \quad \text{con } \mathbf{e} = [1, \dots, 1]^\top, \\ & 0 \leq \alpha_n, \alpha'_n \leq C, \quad n = 1, \dots, N \end{aligned} \quad (4.8)$$

donde $Q_{nk} = K(\mathbf{x}_n, \mathbf{x}_k)$ representa el kernel seleccionado. Lo interesante es que, mientras que la solución de la forma primaria depende del número de dimensiones del EC y este puede ser infinito, en la forma dual depende únicamente del número de vectores soporte.

Una vez resuelta la ecuación 4.8, y obtenido $\boldsymbol{\alpha}' - \boldsymbol{\alpha}$, se podrán realizar predicciones mediante la función aproximación [12, 44]:

$$\hat{\tau}_V = \sum_{n=1}^N (-\alpha_n + \alpha'_n) K(\mathbf{x}_n, \mathbf{x}) + b \quad (4.9)$$

Señalar finalmente que **SVR** se ha desarrollado para el análisis de regresión de una única variable. Consecuentemente, para nuestro caso con S variables de salida a estimar $\hat{\tau}_{Vj}$, cada una de ellas requerirá la utilización de un modelo **SVR** independiente.

CAPÍTULO 5

Configuración de los hiperparámetros y predicción del par

Una vez seleccionados los métodos de aprendizaje automático bajo estudio, el siguiente paso es configurar aquellos hiperparámetros sobre los que, durante la fase previa, no se ha podido tomar una decisión evidente. El objetivo es evitar el riesgo de overfitting primando la capacidad de generalización del estimador de forma que el rendimiento con entradas desconocidas sea similar al del entrenamiento aunque, naturalmente, el límite estaría en que durante la fase de producción las entradas presenten características estadísticas similares a las del entrenamiento. Por ello CAWLEY et ál. [11] recomiendan determinar automáticamente los hiperparámetros a la vez que se produce el entrenamiento. Sin embargo, para las situaciones en que esto no es posible o deseable, como cuando los requerimientos computacionales son excesivos, habrá que realizarlo manualmente durante la fase de diseño.

Tanto en el proceso manual como el automático el paso crítico será la estimación, a partir de los datos de entrenamiento únicamente, del rendimiento del predictor con muestras desconocidas. De este modo se podrán configurar los hiperparámetros optimizando dicha capacidad de generalización del estimador. Más aún, este mismo concepto de generalización aparecerá al caracterizar el rendimiento real de un predictor cuando se pretenden comparar varios de ellos. De nuevo se busca generalizar la estimación de dicha capacidad de predicción de forma que se pueda evaluar su efectividad con muestras diferentes a las del entrenamiento.

La estrategia para lograr dicha generalización de los resultados es la aplicación de validación cruzada o *cross-validation* [11]. En su versión más común, *k-fold cross-validation* (*k*-fold CV), toda la información de entrenamiento disponible se divide aleatoriamente en *k* grupos, de forma que un grupo se usa para validar los cálculos realizados utilizando el resto. Repitiendo el proceso *k* veces, para obtener resultados validados por cada uno de los grupos, y promediando se obtendrá un valor del rendimiento que tiene en cuenta dicha capacidad de generalización. Sin embargo, si se tiene en cuenta que las muestras de datos disponibles forman, ya de por sí, iteraciones de movimientos, se puede aprovechar para obtener el rendimiento del estimador por iteración en lugar de por muestra. En este caso, el limitado número de movimientos disponibles (solo 5 por sujeto en el escenario ESU) impone recurrir a la variante *leave-one-out cross-validation* (LOOCV), en la que cada que hay tantos grupos como elementos seleccionables y, consecuentemente, cada iteración asumirá el papel de un grupo.

5.1 Averaged Output MLP (aoMLP)

5.1.1 Optimización de los hiperparámetros

El procedimiento habitual para optimizar el número de neuronas intermedias es representar conjuntamente la variación del rendimiento de entrenamiento y el de validación en función de dicho número de neuronas. De forma similar a Early-Stopping, el error cuadrático medio de validación mínimo determinará el número óptimo de neuronas para la iteración que está siendo validada, mientras que la aplicación de LOOCV posibilitará una selección razonable de la configuración del modelo. Sin embargo, en ocasiones los resultados parciales de validación cruzada pueden ser incompatibles entre ellos y su promediado proporcionará, simplemente, una solución de compromiso.

La figura 5.1 muestra algunos resultados obtenidos durante el proceso de optimización. En el escenario ESU, de los 40 casos posibles, el 82,5 % presentan una respuesta como la de la figura 5.1a, en la que el rendimiento alcanza un nivel estable y, sorprendentemente, independiente del número de neuronas ocultas en el rango estudiado. Este resultado contrasta con el obtenido sin ensamble, apreciándose claramente la atenuación en la variabilidad del rendimiento resultante tanto en entrenamiento como validación (figura 5.1b).

En el resto de casos, el rendimiento de validación empeora con el número de neuronas y, a pesar del promediado, presenta mayor variabilidad (figura 5.1c). Precisamente, son estos casos los que restringirán el rango óptimo de neuronas ocultas y, en su mayoría, se asocian fácilmente a la presencia de datos erróneos o contradictorios en, lo que podría considerarse, una falta de calidad en los datos. Afortunadamente, en 6 casos (el 15 % del total) la red es capaz de paliar razonablemente estos problemas, como indica el bajo valor del MSE mínimo alcanzado. Sin embargo, en casos extremos en los que esto no sucede, el error de validación alcanza directamente cotas elevadísimas. La única ocasión en que esta situación ha acaecido en el escenario ESU se muestra en la figura 5.1d. Toda esta información sugiere que, no solo para un sujeto si no para todos, 10 neuronas ocultas es un valor razonable evitándose, además, su cálculo automático con cada entrenamiento.

En el escenario ESM, sin embargo, los resultados no son tan positivos. Esto era esperado por la mayor dificultad impuesta por su planteamiento, pero tampoco se obtienen resultados mucho mejores en la prueba exclusiva para controles. Desafortunadamente, los rendimientos obtenidos en las tres pruebas empeoran ostensiblemente respecto al escenario ESU, tanto en entrenamiento como validación, implicando peores predicciones en la validación. Además, hay muchos más casos en los que el proceso de optimización no es el ideal, tanto casos similares al de la figura 5.1d como, simultáneamente, otros que necesitan de un mayor número de neuronas ocultas, dificultando su selección manual e imponiendo su búsqueda automatizada.

5.1.2 Predicciones de validación del escenario ESU

Para el diseño del estimador aoMLP propuesto se ha configurado un ensamblaje cuya salida es la media de 30 MLP independientes constando, cada uno de ellos, de 10 neuronas ocultas y empleando SCG como algoritmo de aprendizaje junto a Early-Stopping, con un máximo de 10 fallos de validación consecutivos, para evitar el sobreaprendizaje. De este modo, la instancia particular a implementar en producción se entrenaría con las 5 iteraciones disponibles.

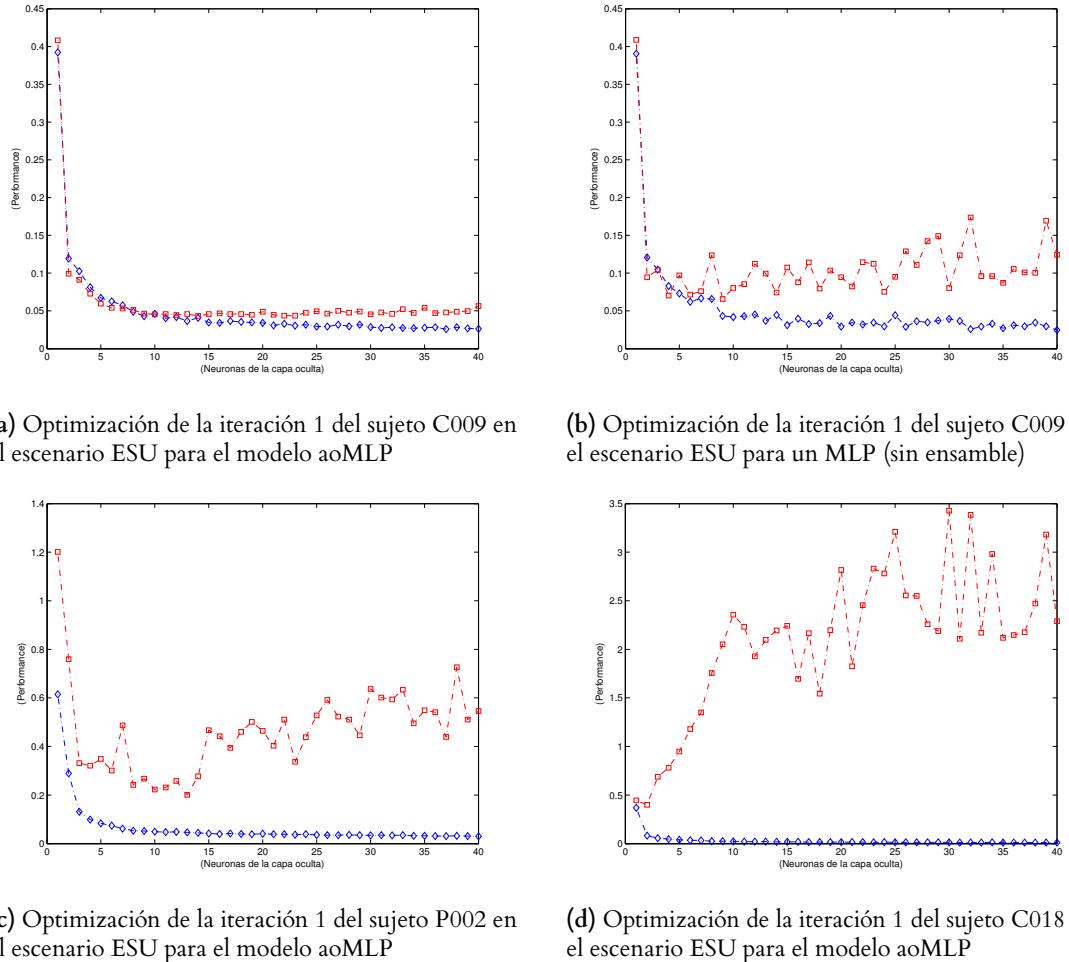
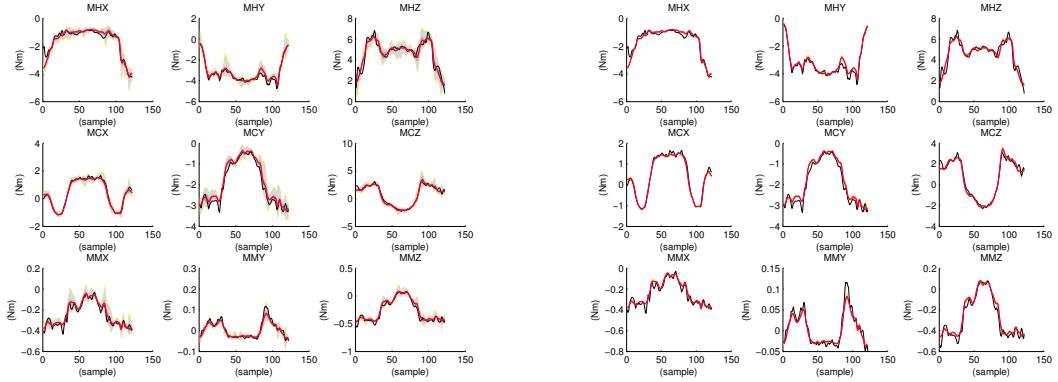


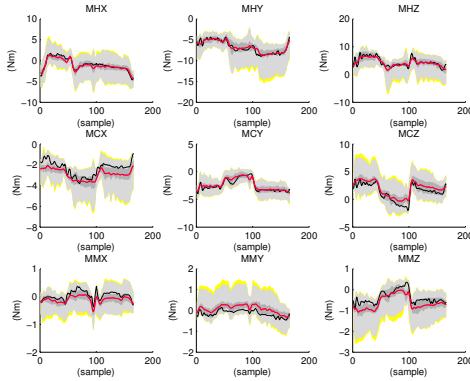
Figura 5.1: Casos de la variación del rendimiento en función del número de neuronas ocultas durante el proceso de optimización para el modelo aoMLP. Se muestra en azul el rendimiento conseguido, medido como MSE, para las iteraciones del movimiento utilizadas en el entrenamiento frente al rendimiento alcanzado, en rojo, con la iteración de validación

Para valorar su comportamiento se muestran, para tres casos representativos, dos representaciones complementarias de las respectivas predicciones de validación (figura 5.2). En el primer panel, además de mostrarse la referencia τ_{IDk} y la predicción $\hat{\tau}_{Pk}$ (es decir, la media de las predicciones de los submódulos), se visualiza la variabilidad de las estimaciones de dichos submódulos mediante los rangos de los percentiles de dichas estimaciones calculados punto a punto. Por su parte, el segundo panel muestra los intervalos de confianza, también calculados punto a punto y usando una distribución t de Student, en el que se situará la media de las estimaciones individuales y, por tanto, la predicción del modelo aoMLP $\hat{\tau}_{Pk}$.

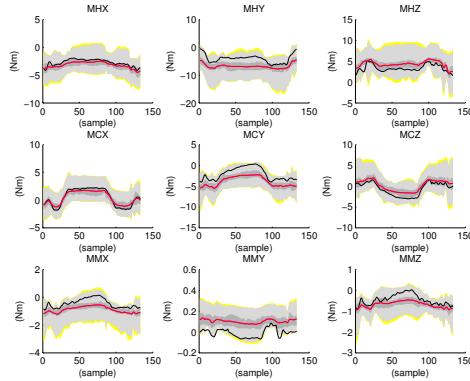
Para el primero de los ejemplos, el correspondiente al caso habitual, la mínima dispersión de los percentiles (figura 5.2a) sugiere que la utilización de un ensamble es innecesaria. Este hecho se desmiente, sin embargo, al considerar la variabilidad existente en cualquiera de los casos problemáticos y cuya aplicación paliará sus efectos permitiendo la obtención de mejores



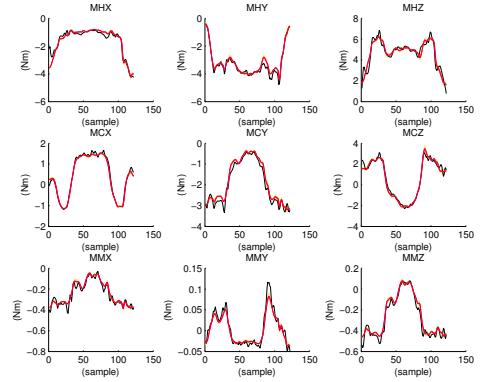
(a) Iteración 1 del sujeto C009 – Percentiles



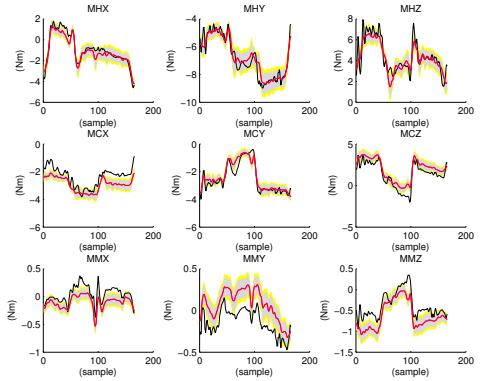
(c) Iteración 1 del sujeto P002 – Percentiles



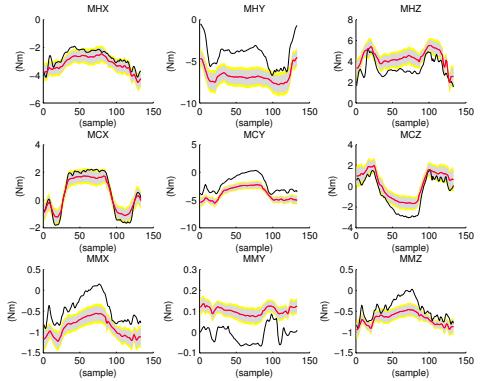
(e) Iteración 1 del sujeto C018 – Percentiles



(b) Iteración 1 del sujeto C009 – Intervalos de conf.



(d) Iteración 1 del sujeto P002 – Intervalos de conf.



(f) Iteración 1 del sujeto C018 – Intervalos de conf.

Figura 5.2: Percentiles e intervalos de confianza de las predicciones de validación por el modelo aoMLP del momento articular para algunas iteraciones seleccionadas del escenario ESU. Se representa la predicción $\hat{\tau}_{pk}$ en rojo con la correspondiente función objetivo τ_{IDk} en negro. Además, para las 30 estimaciones individuales de los respectivos submódulos MLP y tomadas punto a punto, se muestran, según el panel, los rangos de los respectivos percentiles P_{50} (sombreado gris oscuro), P_{95} (sombreado gris claro) y P_{99} (sombreado amarillo) o los intervalos de confianza, usando una distribución t de Student, de la media de las estimaciones al 95 % (sombreado gris) y 99 % (sombreado amarillo)

predicciones (figura 5.2d). En este sentido, la elección del tamaño del ensamblaje nos permitirá estrechar el intervalo de confianza de la predicción final a costa, naturalmente, de mayores requerimientos computacionales. Desafortunadamente, tal y como muestra la figura 5.2f, su aplicación no garantiza la obtención de predicciones óptimas en todos los casos.

Finalmente, y para proporcionar una valoración completa del rendimiento alcanzado en función del sujeto, las figuras 5.3 y 5.4 muestran las 5 predicciones de validación para un sujeto de control y un paciente (el apéndice E.1 incluye todos). Una forma aproximada de visualizar dicho rendimiento para un sujeto se muestra en la figura 5.3a, donde las diferentes predicciones se superponen al rango de variación de las referencias expresado como su desviación estándar. El problema de esta visualización es su sensibilidad a la variación de las funciones objetivo, como cuando los pacientes, por la inherente dificultad de controlar su movimiento, tardan diferente tiempo en realizar una fase del movimiento de una iteración a otra (figura 5.4a).

De cualquier manera, la representación individual de cada predicción de validación evidencia un gran rendimiento alcanzado para el escenario ESU, tanto para controles como pacientes, con un intervalo de confianza para la predicción apenas perceptible. Los casos en que no es así coinciden con aquellos en los que la búsqueda del hiperparámetro no obtenía los resultados ideales de la figura 5.1a. Esta mayor variabilidad se explica, en ciertos casos, por una perdida de referencia de algunos marcadores del sistema VICON, que provoca la captura nula de las señales CCX y CMY de las variables de Cinemática (véanse las figuras B.3c, B.3d, B.4a y B.4b). Cuando este problema sucede en varias iteraciones es posible que la red pueda paliarlo, como para el paciente P003, pero no así con solo una. Durante la validación de estos casos la red, que no espera las entradas nulas al haber entrenado solamente con datos correctos, encontrará dificultades para generalizar y, consiguientemente, la figura del rendimiento esperado empeorará artificiosamente. A pesar de ello, se ha optado por mantener estos datos para mostrar el comportamiento del modelo bajo estas circunstancias.

5.1.3 Predicciones de validación del escenario ESM

El diseño del estimador aoMLP para este escenario se ha configurado, a diferencia del ESU, para el cálculo automático en cada entrenamiento del número óptimo de neuronas ocultas. Además, en este caso, la selección de su número para la instancia particular de producción se realizaría aplicando validación cruzada a nivel de muestra con los datos de todas las iteraciones disponibles.

Por otro lado, para valorar el error esperado sigue siendo más interesante pensar a nivel de iteración, por lo que los resultados que se comentan a continuación para las tres pruebas realizadas, mostrando el proceso de optimización y la predicción finalmente obtenida, se han obtenido aplicando LOOCV.

La figura 5.5, correspondiente a la prueba con solo controles, compara un buen resultado de la prueba con uno malo y otro intermedio, y lo mismo sucede para la prueba con solo pacientes y la figura 5.6. Indudablemente, el rendimiento esperado que se puede conseguir para los controles es mayor que para los pacientes. Lo interesante, sin embargo, es la cantidad de casos en que se observa una mejora del rendimiento obtenido cuando se emplean todos los sujetos disponibles (figuras 5.7 y 5.8). Aunque esta circunstancia no ocurra en todos los casos, el hecho de que se produzca de forma suficientemente generalizada invita a pensar que con un número adecuado de sujetos se pueda lograr un predictor universal para toda la población.

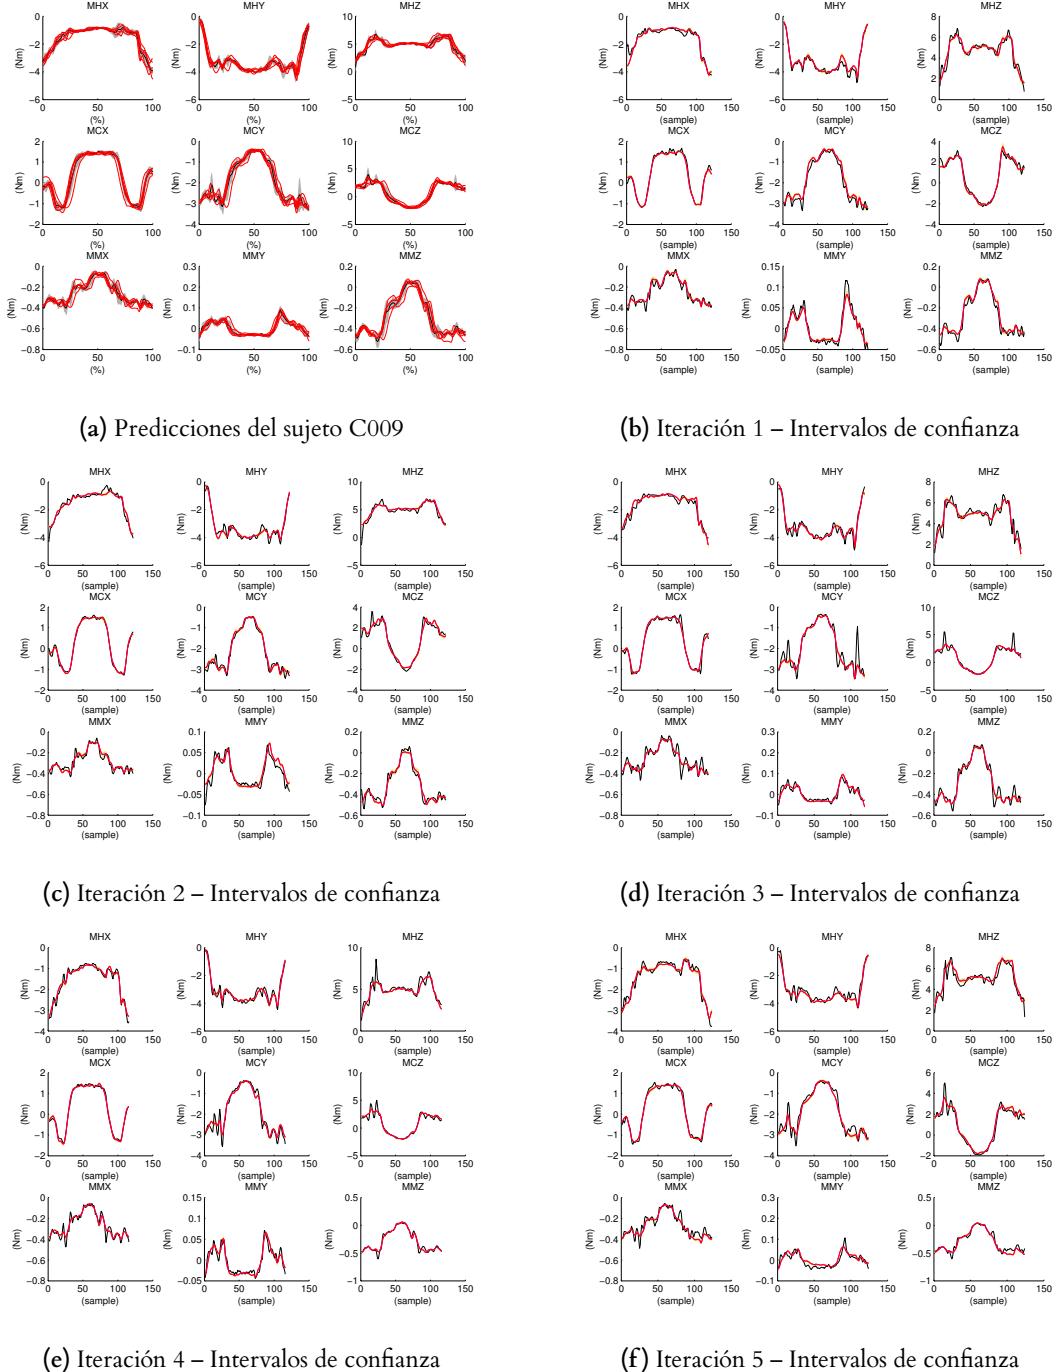


Figura 5.3: Predicciones de validación por el modelo aoMLP del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto C009. El primer panel muestra en negro (sombreado gris) la media (desviación estándar) de las 5 iteraciones del momento de referencia τ_{IDk} junto con las 5 estimaciones $\hat{\tau}_{Pk}$ realizadas por el modelo (en rojo). El resto de paneles comparan, separadamente para cada una de las 5 iteraciones, la predicción en rojo con la correspondiente función objetivo en negro, añadiéndose los intervalos de confianza de dicha estimación al 95 % (sombreado gris) y 99 % (sombreado amarillo) calculados punto a punto usando la distribución t de Student

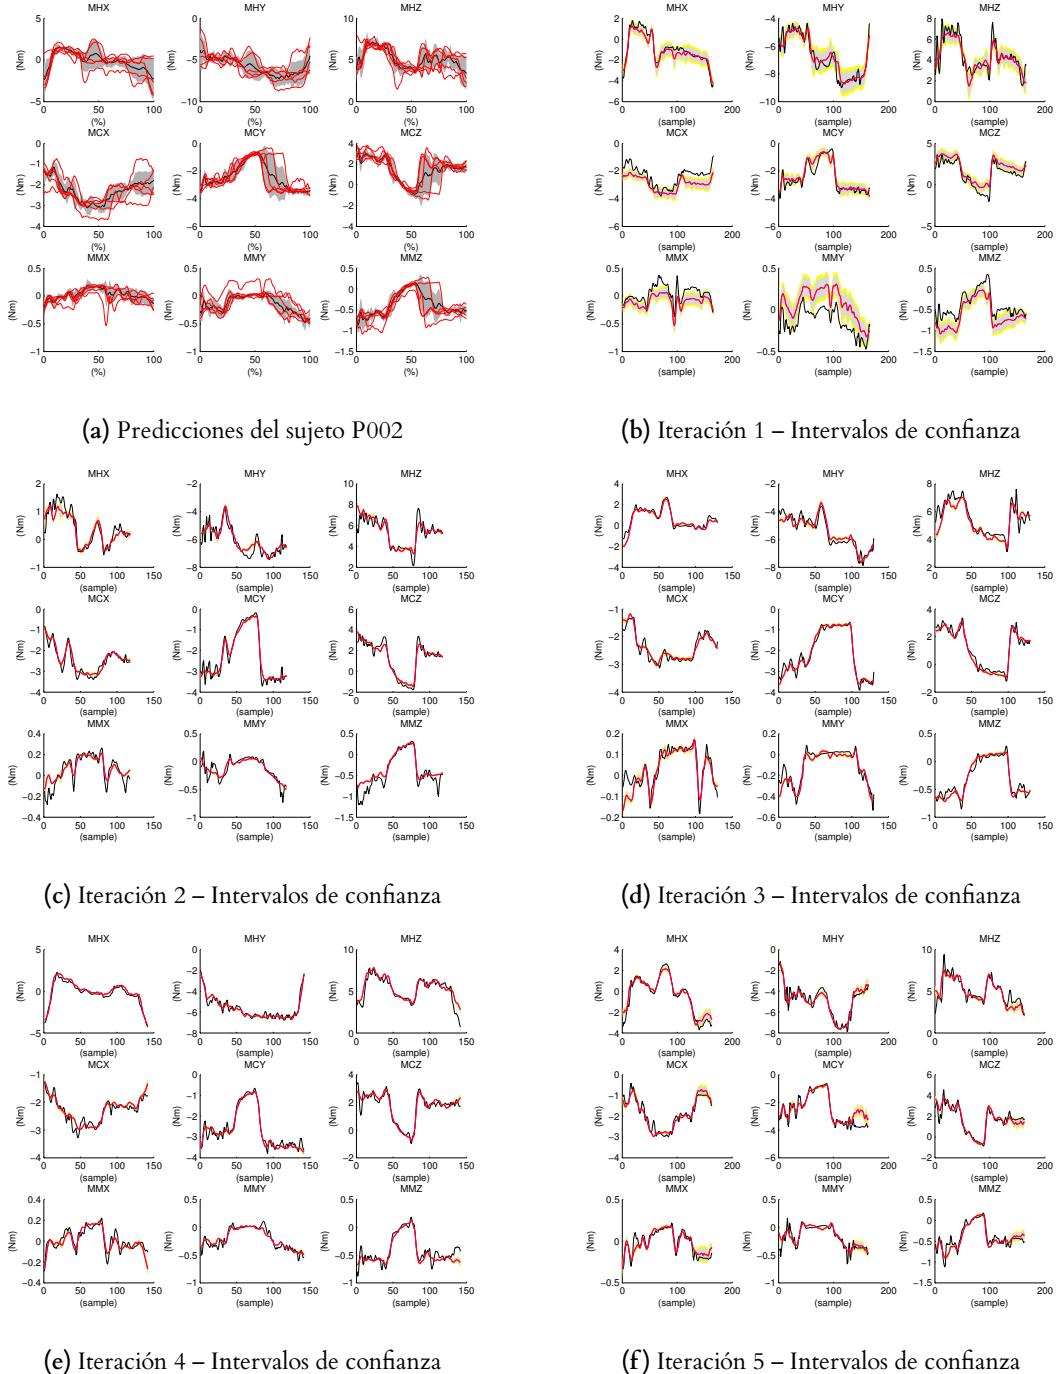


Figura 5.4: Predicciones de validación por el modelo aoMLP del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto P002. El primer panel muestra en negro (sombreado gris) la media (desviación estándar) de las 5 iteraciones del momento de referencia τ_{IDk} junto con las 5 estimaciones $\hat{\tau}_{P_k}$ realizadas por el modelo (en rojo). El resto de paneles comparan, separadamente para cada una de las 5 iteraciones, la predicción en rojo con la correspondiente función objetivo en negro, añadiéndose los intervalos de confianza de dicha estimación al 95 % (sombreado gris) y 99 % (sombreado amarillo) calculados punto a punto usando la distribución t de Student

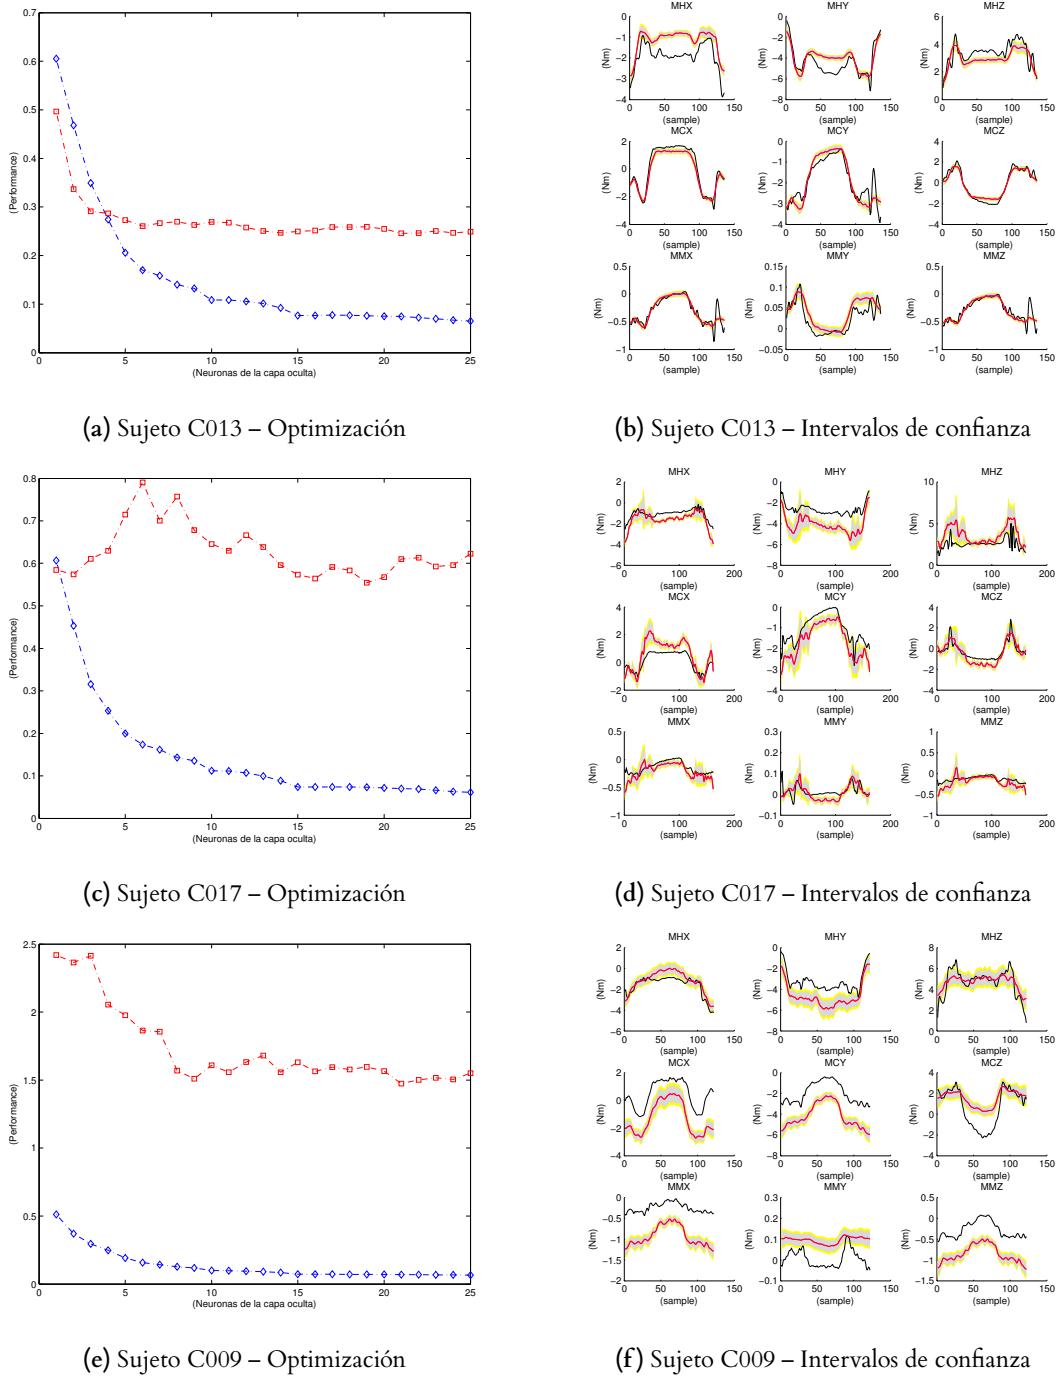


Figura 5.5: Optimización automática del número de neuronas ocultas y predicción de validación por el modelo aoMLP del momento articular para el escenario ESM – solo Controles. Los paneles de optimización muestran el rendimiento MSE del entrenamiento (en azul) frente al de validación (en rojo). Los paneles de predicción muestran la predicción $\hat{\tau}_{pk}$ en rojo con la correspondiente función objetivo τ_{IDk} en negro, añadiéndose los intervalos de confianza de dicha estimación al 95 % (sombreado gris) y 99 % (sombreado amarillo) calculados punto a punto usando la distribución t de Student

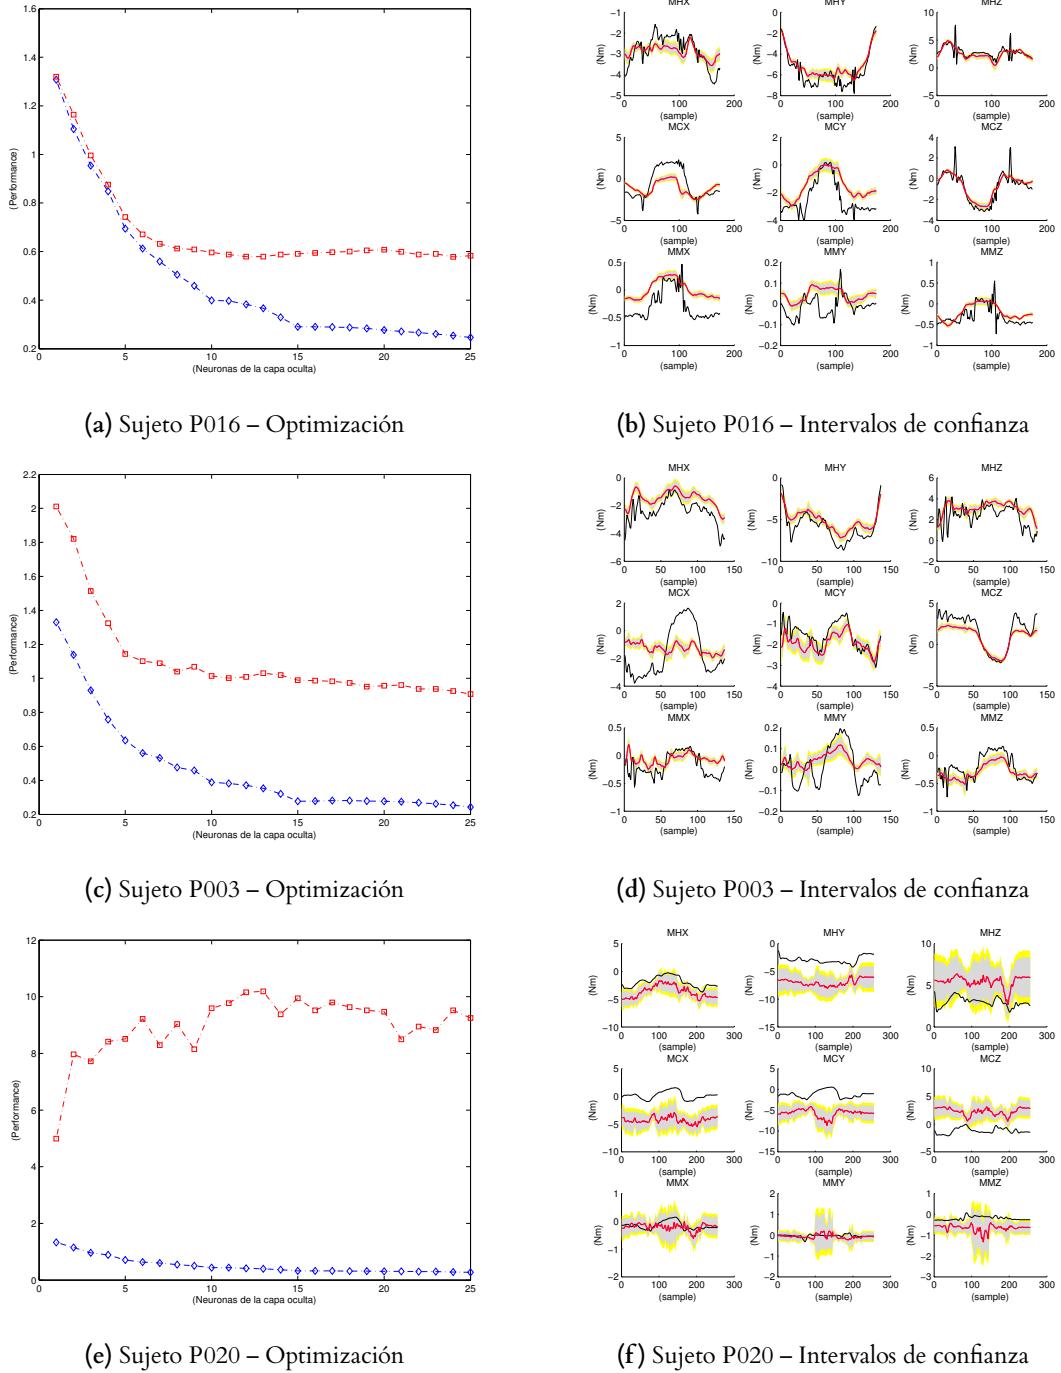


Figura 5.6: Optimización automática del número de neuronas ocultas y predicción de validación por el modelo aoMLP del momento articular para el escenario ESM – solo Pacientes. Los paneles de optimización muestran el rendimiento MSE del entrenamiento (en azul) frente al de validación (en rojo). Los paneles de predicción muestran la predicción $\hat{\tau}_{pk}$ en rojo con la correspondiente función objetivo τ_{IDk} en negro, añadiéndose los intervalos de confianza de dicha estimación al 95 % (sombreado gris) y 99 % (sombreado amarillo) calculados punto a punto usando la distribución t de Student

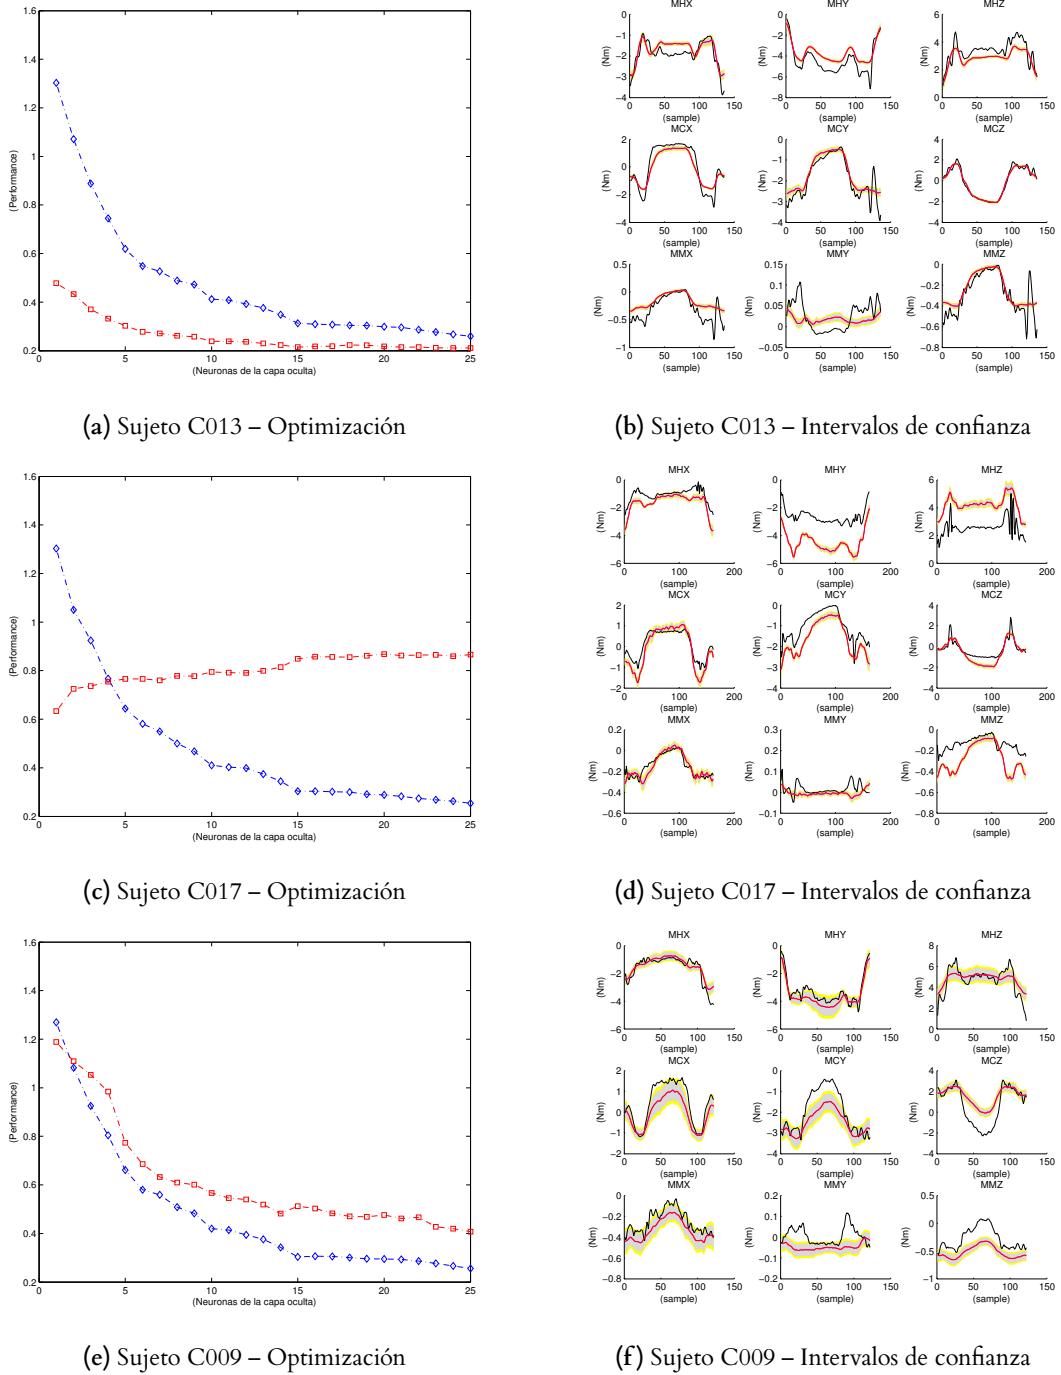


Figura 5.7: Optimización automática del número de neuronas ocultas y predicción de validación por el modelo aoMLP del momento articular para el escenario ESM – Población (Controles). Los paneles de optimización muestran el rendimiento MSE del entrenamiento (en azul) frente al de validación (en rojo). Los paneles de predicción muestran la predicción $\hat{\tau}_{pk}$ en rojo con la correspondiente función objetivo τ_{IDk} en negro, añadiéndose los intervalos de confianza de dicha estimación al 95 % (sombreado gris) y 99 % (sombreado amarillo) calculados punto a punto usando la distribución t de Student

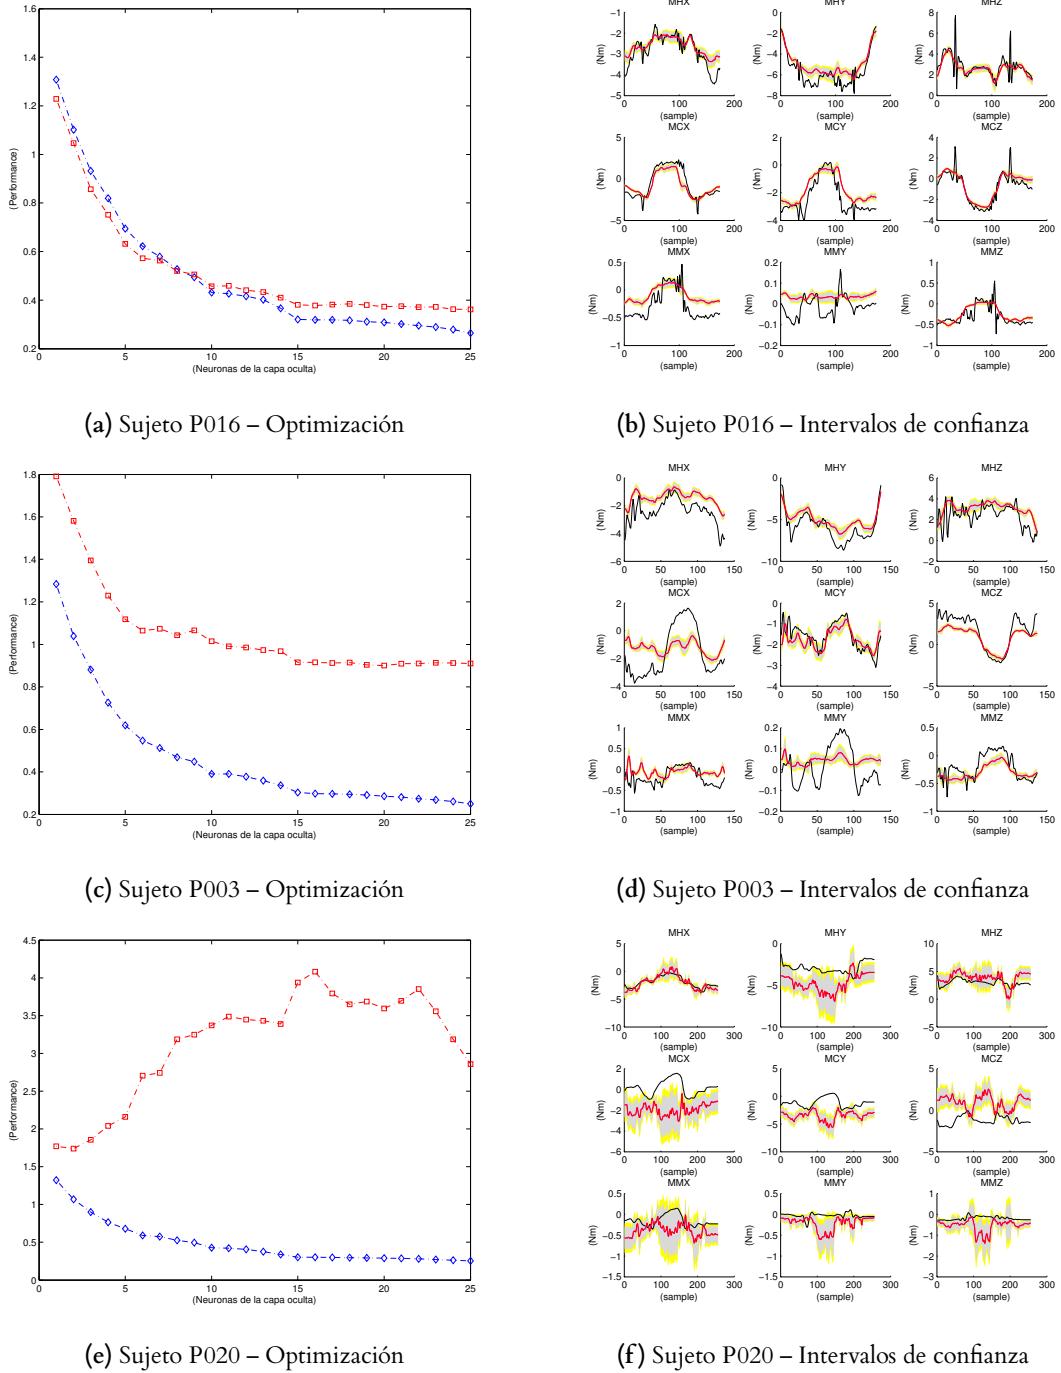


Figura 5.8: Optimización automática del número de neuronas ocultas y predicción de validación por el modelo aoMLP del momento articular para el escenario ESM – Población (Pacientes). Los paneles de optimización muestran el rendimiento MSE del entrenamiento (en azul) frente al de validación (en rojo). Los paneles de predicción muestran la predicción $\hat{\tau}_{pk}$ en rojo con la correspondiente función objetivo τ_{IDk} en negro, añadiéndose los intervalos de confianza de dicha estimación al 95 % (sombreado gris) y 99 % (sombreado amarillo) calculados punto a punto usando la distribución t de Student

5.2 Radial Basis Network (RBN)

5.2.1 Optimización de los hiperparámetros

Para **RBN** tenemos dos hiperparámetros que optimizar, el goal del entrenamiento y el spread de la **RBF**. Aunque escoger el menor goal posible sea lo natural, hacerlo tenderá al sobreaprendizaje. Por su parte, un bajo spread incrementará la resolución disminuyendo el nivel de error pero aumentará el riesgo de overfitting y los requisitos computacionales. Aumentándolo, por contra, mejorará la generalización a costa de deteriorar el rendimiento alcanzable.

Para su selección se adaptará la estrategia de **MLP**, es decir, la búsqueda del mínimo MSE de entrenamiento y validación, a una rejilla bidimensional con los hiperparámetros como ejes. Para facilitar dicha búsqueda es habitual escalarlos por el logaritmo base 2, paso que se ha reutilizado para la visualización de la magnitud del propio rendimiento tomando su logaritmo base 10.

La figura 5.9 muestra algunos ejemplos seleccionados, donde el marcador amarillo indica la localización del MSE de entrenamiento mínimo y el magenta la solución óptima según el error de validación. Para el mapa de entrenamiento se verifica como, por la propia naturaleza del hiperparámetro, el mínimo recae siempre en el lateral de menor goal (figura 5.9a). En validación, por contra, el área de menor error recae en la zona inferior derecha, sugiriendo que un goal bajo y spread ancho mejoran la capacidad de predicción (figura 5.9b).

Sin embargo, para los pacientes P002 y P003 este área de error mínimo está desplazada y forma un valle, indicando overfitting y un goal máximo recomendable (figura 5.9c). Estos cambios en la estructura del mapa respecto al considerado normal son consecuencia de las dificultades de la red en generalizar el aprendizaje, aunque es más sencillo intuirlo por el nivel de profundidad del error de validación mínimo. Precisamente son los casos más difíciles para el modelo **aoMLP** los que presentan cambios más radicales en ambos aspectos, tanto para el escenario ESU (figura 5.9d) como para el ESM en el que son la norma (figuras 5.9e y 5.9f).

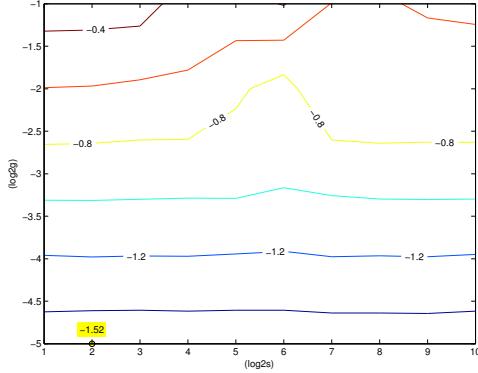
La dispersión de los mínimos de validación resultantes recomienda una selección automática de los hiperparámetros. Sin embargo, al no existir una relación evidente entre los mínimos de ambos mapas no es posible automatizarlo de modo sencillo sin recurrir a una validación cruzada que incrementaría los tiempos de cómputo en varios ordenes de magnitud. Una selección manual, por su parte, favorecerá unas predicciones sobre otras, pero es la opción propuesta por mantener los tiempos de cómputo en niveles razonables.

Empíricamente se observa que el inverso del número de variables de entrada proporciona una aproximación inicial razonable al valor óptimo del goal cuando la calidad de los datos de entrada no es la óptima. Con 9 variables musculares y 12 cinemáticas se ha tomado como goal $g = 1/21$ (o $\log_2 g = -4,39$). Para el spread, por su parte, los mapas sugieren un $s = 2^7$.

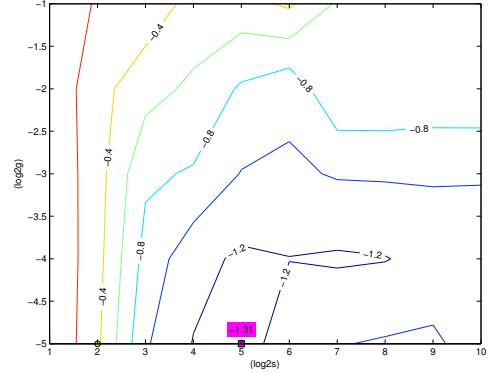
5.2.2 Predicciones de validación

Las figuras 5.10 y 5.11 muestran las predicciones de validación para dos sujetos del escenario ESU. En concreto la figura 5.11a muestra como la predicción de validación usando la 1.^a iteración del paciente P002 queda fuera del rango del par de fuerzas objetivo τ_{ID} , sin que sean paliados los efectos de la mala captura por el sistema VICON como si pudo el modelo **aoMLP**.

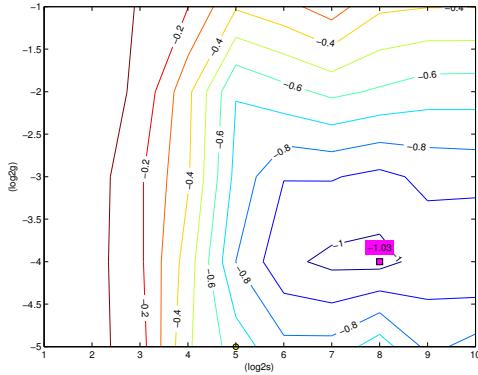
Para el escenario ESM el apéndice F.2 muestra como los resultados obtenidos con **RBN** no mejoran a los de **aoMLP**, algo lógico considerando su menor optimización.



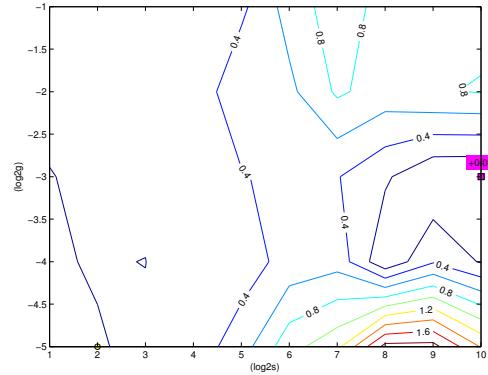
(a) Rendimiento de entrenamiento para la iteración 1 del sujeto C009 en el escenario ESU



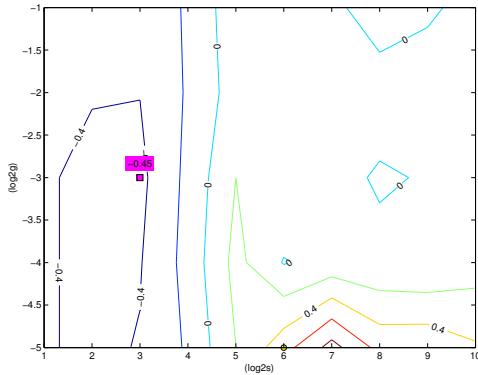
(b) Rendimiento de validación para la iteración 1 del sujeto C009 en el escenario ESU



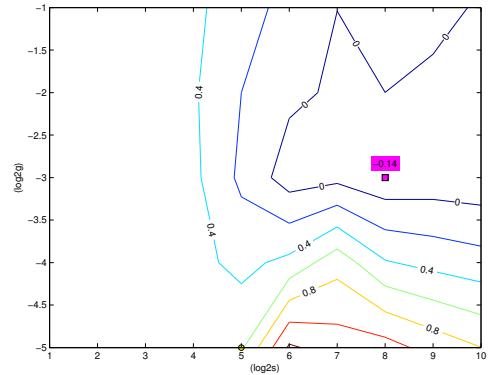
(c) Rendimiento de validación para la iteración 2 del sujeto P002 en el escenario ESU



(d) Rendimiento de validación para la iteración 1 del sujeto P002 en el escenario ESU



(e) Rendimiento de validación para el sujeto C017 en la prueba de población mixta del escenario ESM



(f) Rendimiento de validación para el sujeto P003 en la prueba de población mixta del escenario ESM

Figura 5.9: Casos de la variación de los rendimientos de entrenamiento y validación durante el proceso de optimización para el modelo RBN. El marcador amarillo indica la localización del mínimo del MSE de entrenamiento, con el magenta indicando la localización del mínimo del MSE de validación

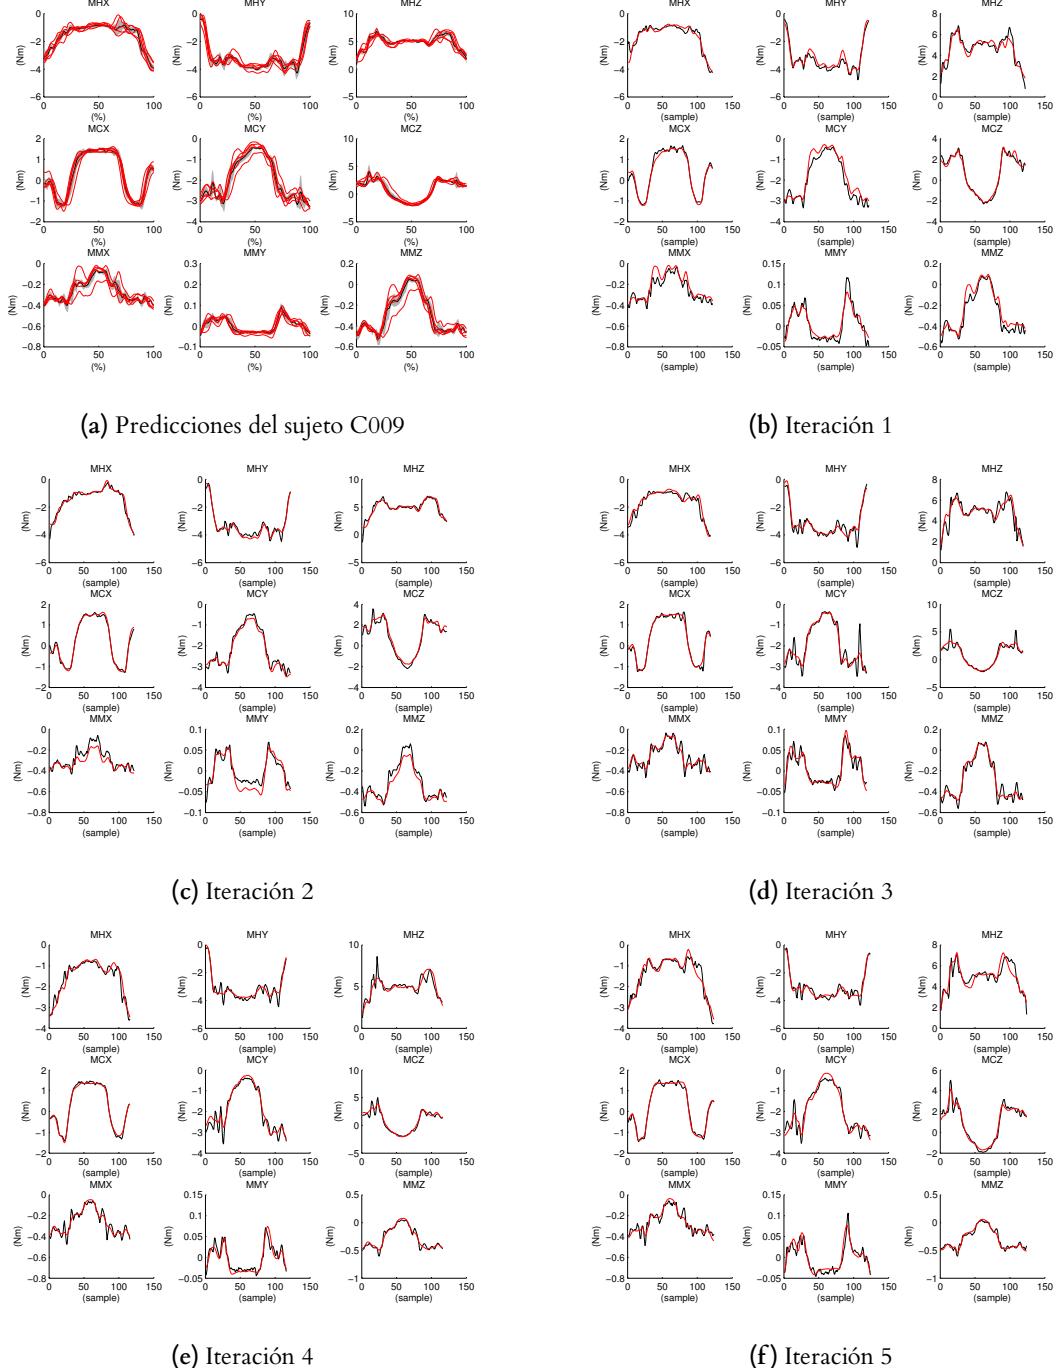


Figura 5.10: Predicciones de validación por el modelo RBN del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto C009. El primer panel muestra en negro (sombreado gris) la media (desviación estándar) de las 5 iteraciones del momento de referencia τ_{IDk} junto con las 5 estimaciones $\hat{\tau}_{Rk}$ realizadas por el modelo (en rojo). El resto de paneles comparan, separadamente para cada una de las 5 iteraciones, la predicción en rojo con la correspondiente función objetivo en negro

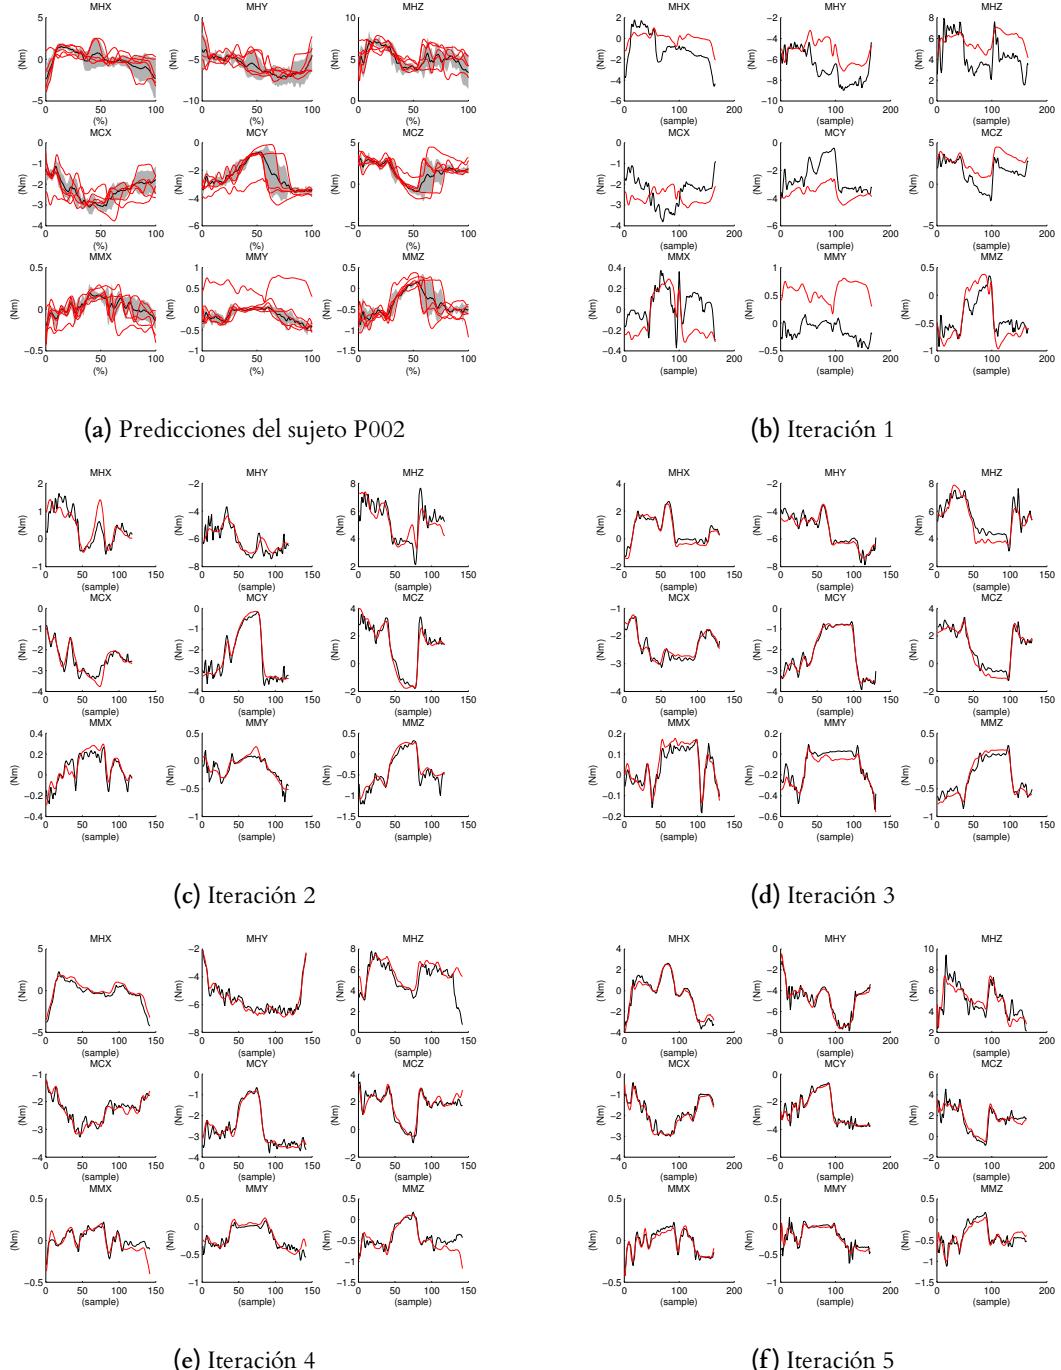


Figura 5.11: Predicciones de validación por el modelo RBN del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto P002. El primer panel muestra en negro (sombreado gris) la media (desviación estándar) de las 5 iteraciones del momento de referencia τ_{IDk} junto con las 5 estimaciones $\hat{\tau}_{Rk}$ realizadas por el modelo (en rojo). El resto de paneles comparan, separadamente para cada una de las 5 iteraciones, la predicción en rojo con la correspondiente función objetivo en negro

5.3 Support Vector Machine (SVM)

5.3.1 Optimización de los hiperparámetros

El procedimiento de selección de hiperparámetros recomendado para LibSVM [20] prescribe una búsqueda en rejilla similar a la planteada para RBN. La diferencia estriba en que, en lugar de construir el mapa del rendimiento de entrenamiento a partir del propio error de entrenamiento, utiliza *k-fold CV*. De este modo, y para $k = 5$ grupos de muestras aleatorios, entrenando 4 grupos permite predecir la salida asociada al quinto y, repitiendo el proceso, se obtiene una estimación generalizada del error de entrenamiento que, al tener en cuenta la variabilidad de las entradas disponibles, permite estimar su comportamiento con entradas desconocidas.

Este paso, que no se pudo realizar con RBN por sus peores tiempos de entrenamiento promedio, integra la validación cruzada en el cálculo automático de los hiperparámetros de una forma natural, estimando sus valores óptimos usando únicamente los datos de entrenamiento disponibles. Sus efectos, mostrados en la figura 5.12, son los de restringir el área de error mínimo donde localizar los hiperparámetros óptimos. En la práctica se descartan valores altos de γ que, como sugería la figura 4.5b, proporcionan soluciones con menor capacidad de generalización. Por otra parte, tampoco interesan valores bajos de C ya que, al no penalizar suficientemente los errores de predicción, reducen la capacidad de aprendizaje produciendo *underfitting*.

Aún con todo ello, y al igual que con RBN como muestra la figura 5.13, estos hiperparámetros obtenidos a partir únicamente de los datos de entrenamiento no proporcionan necesariamente una solución óptima al validarlos con una iteración desconocida, tal y como se hace al aplicar LOOCV para estimar el error esperado del sistema. De nuevo, la dispersión de estos hiperparámetros óptimos de validación dificulta una selección óptima, con muchos casos en los que dicho rendimiento de validación empeora notablemente con los hiperparámetros favorecidos por el mapa de entrenamiento (compárense por ejemplo las figuras 5.13c y 5.13d). Naturalmente esto no ocurre siempre, normalmente el error de validación es lo suficientemente bajo como para que, aún sin acertar en la selección óptima, la predicción sea suficientemente buena. Son los casos que hemos dado en calificar como con baja calidad de entradas aquellos para los que los cambios del mapa de validación son más extremos.

Indicar finalmente que, en lugar de implementar un algoritmo de búsqueda en rejilla, se ha optado por el algoritmo Simplex de Nelder-Mead [25]. La decisión, con ciertos riesgos por la existencia de mínimos locales en el mapa de entrenamiento calculado con CV como evidencia la figura 5.12f, permite reducir el tiempo de entrenamiento mediante la limitación del número de pasos de búsqueda sin llegar a requerir la paralelización del problema. Obviamente, la paralelización ofrece unos recortes potenciales mucho mayores pero, considerando que el equipo empleado para su cálculo era un portátil, sus efectos se reducían bastante.

5.3.2 Predicciones de validación

Las figuras 5.14 y 5.15 muestran las predicciones de validación para dos sujetos del escenario ESU. Claramente, la figura 5.15a muestra como el modelo SVM tampoco consigue paliar de forma efectiva los efectos de una mala captura.

En el escenario ESM los resultados obtenidos (apéndice F.3) tampoco superan a los de aoMLP aunque se vuelve a apreciar mejoría al aumentar las iteraciones de entrenamiento empleadas.

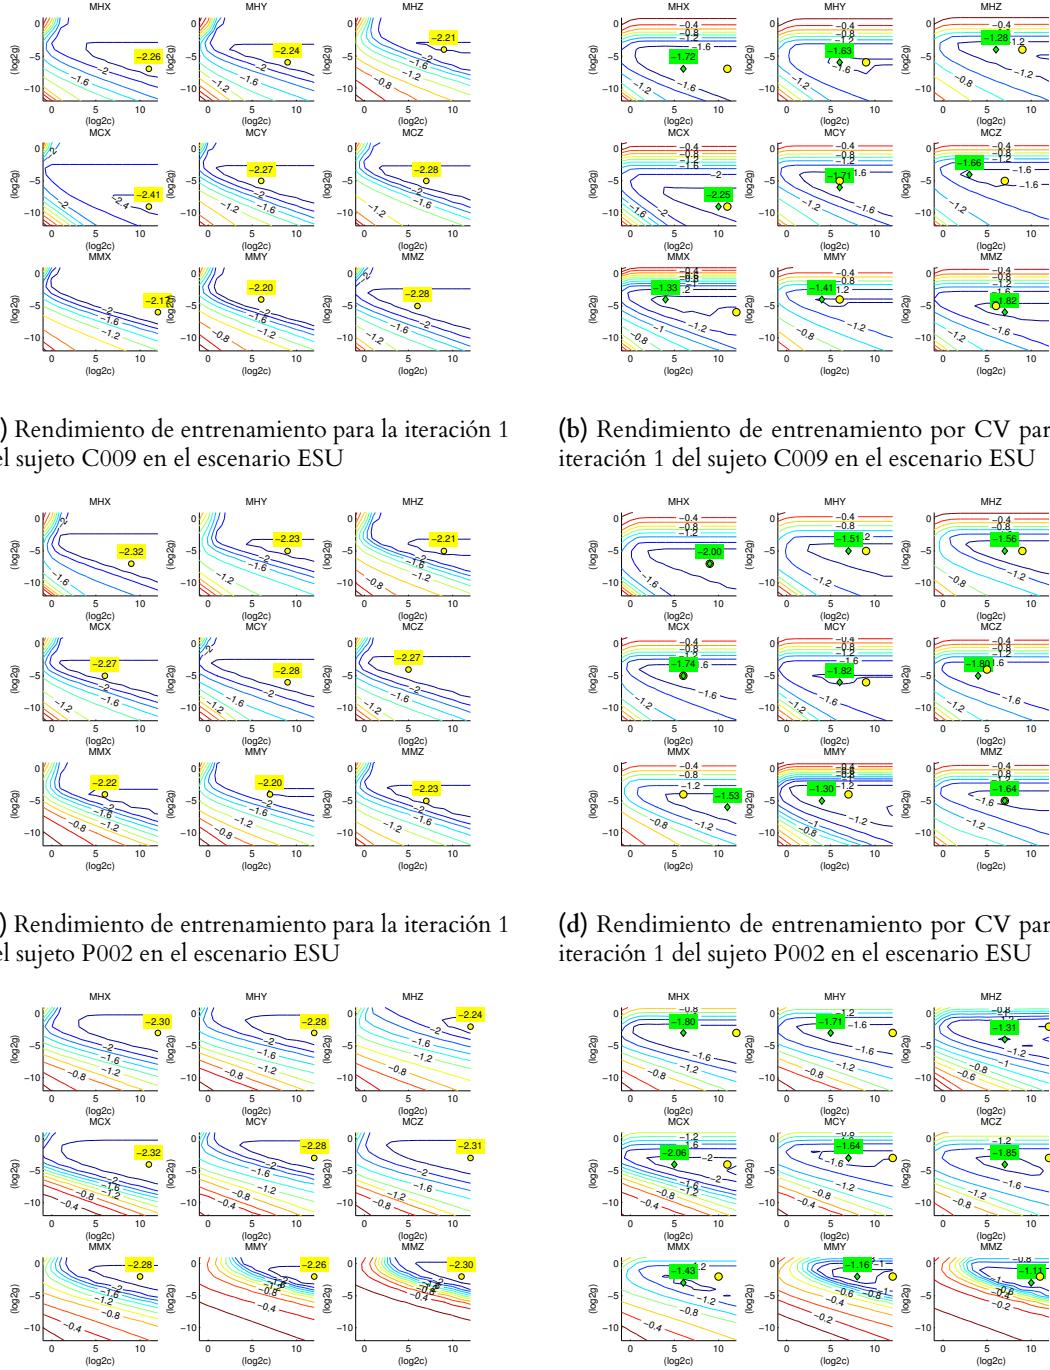
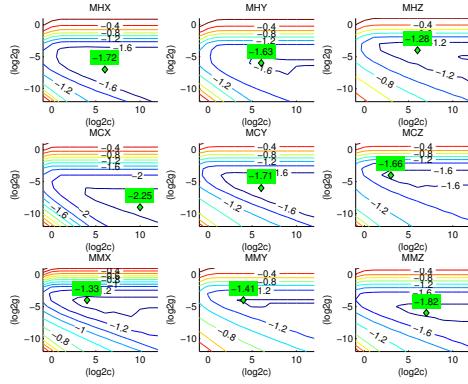
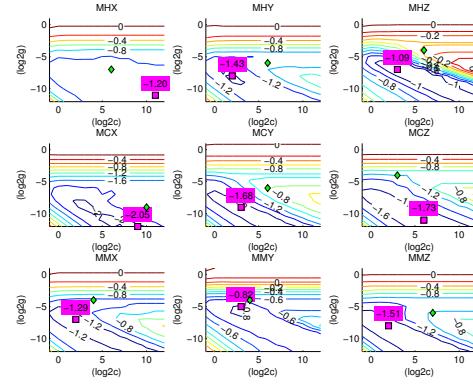


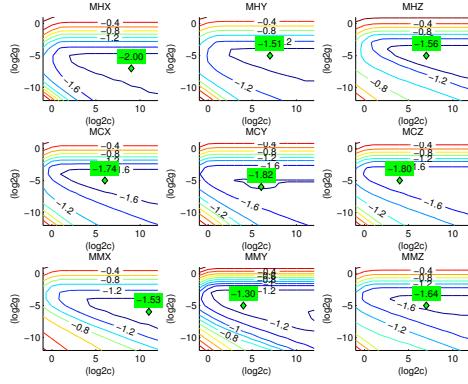
Figura 5.12: Casos de la variación de los rendimientos de entrenamiento, con y sin validación cruzada (CV), durante la optimización del modelo SVM. Los marcadores indican la localización del mínimo del MSE de entrenamiento sin emplear CV (amarillo) o empleándola (verde)



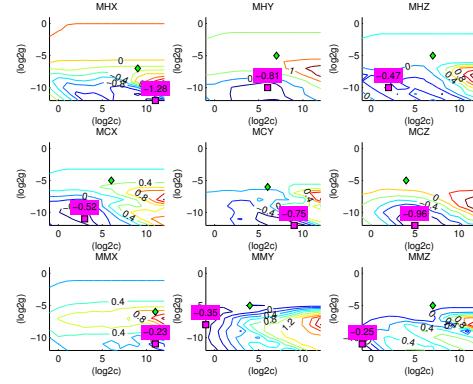
(a) Rendimiento de entrenamiento por CV para la iteración 1 del sujeto C009 en el escenario ESU



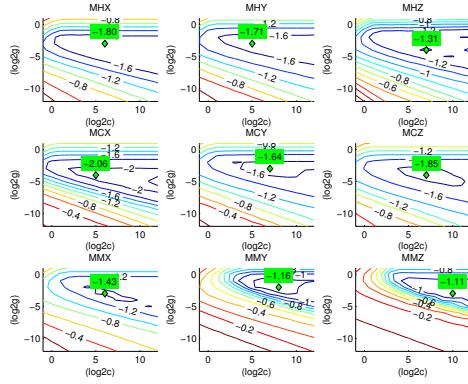
(b) Rendimiento de validación para la iteración 1 del sujeto C009 en el escenario ESU



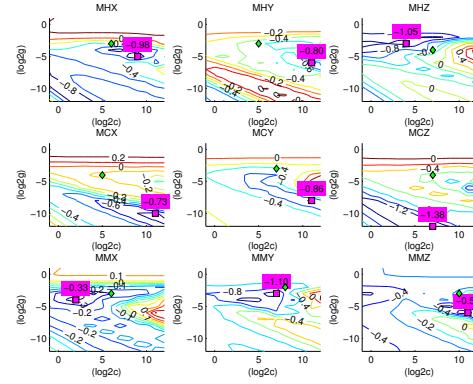
(c) Rendimiento de entrenamiento por CV para la iteración 1 del sujeto P002 en el escenario ESU



(d) Rendimiento de validación para la iteración 1 del sujeto P002 en el escenario ESU



(e) Rendimiento de entrenamiento por CV para el sujeto C015 en la prueba de población mixta del ESM



(f) Rendimiento de validación para el sujeto C015 en la prueba de población mixta del escenario ESM

Figura 5.13: Casos de la variación de los rendimientos de validación y entrenamiento por validación cruzada (CV) durante la optimización del modelo SVM. El marcador verde indica la localización del mínimo del MSE de entrenamiento por CV, con el magenta indicando la localización del mínimo del MSE de validación

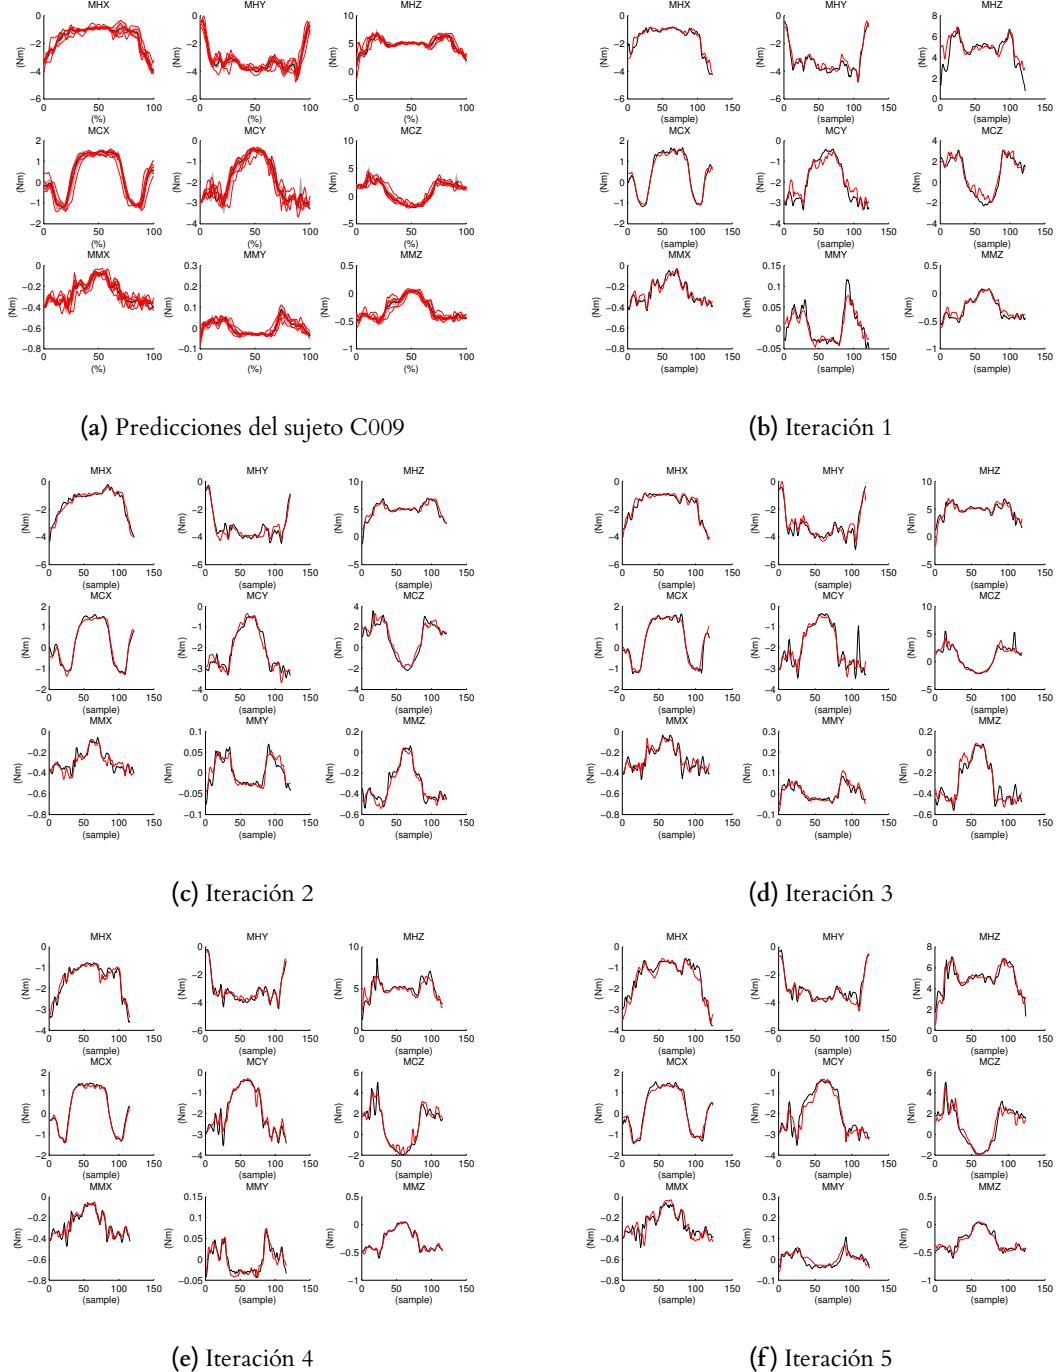


Figura 5.14: Predicciones de validación por el modelo SVM del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto C009. El primer panel muestra en negro (sombreado gris) la media (desviación estándar) de las 5 iteraciones del momento de referencia τ_{IDk} junto con las 5 estimaciones $\hat{\tau}_{V_k}$ realizadas por el modelo (en rojo). El resto de paneles comparan, separadamente para cada una de las 5 iteraciones, la predicción en rojo con la correspondiente función objetivo en negro

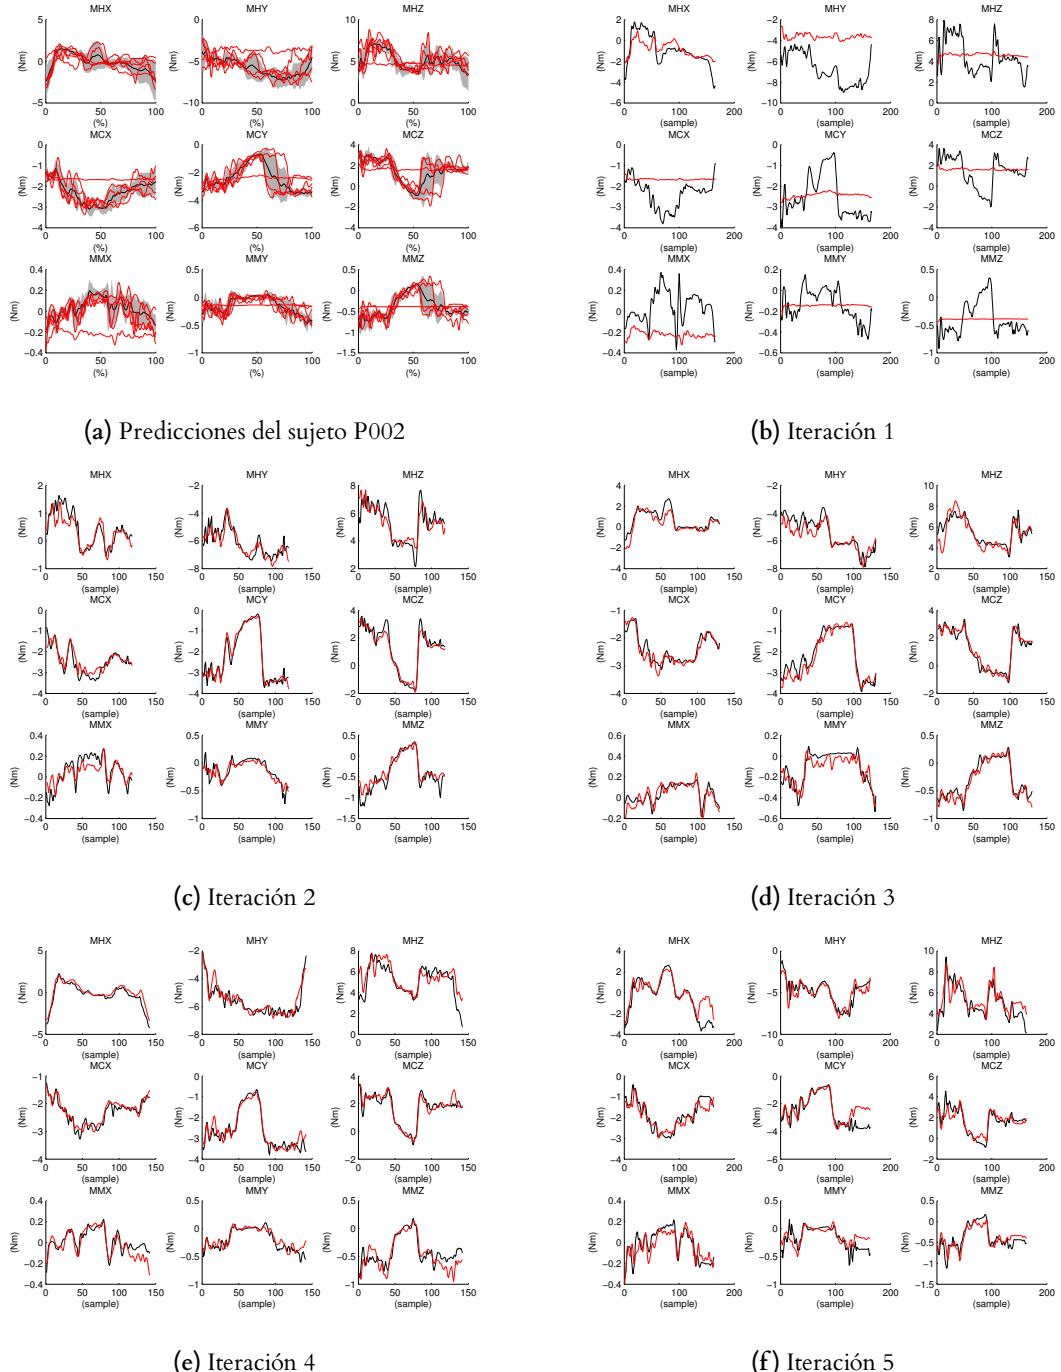


Figura 5.15: Predicciones de validación por el modelo SVM del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto P002. El primer panel muestra en negro (sombreado gris) la media (desviación estándar) de las 5 iteraciones del momento de referencia τ_{IDk} junto con las 5 estimaciones $\hat{\tau}_{V_k}$ realizadas por el modelo (en rojo). El resto de paneles comparan, separadamente para cada una de las 5 iteraciones, la predicción en rojo con la correspondiente función objetivo en negro

CAPÍTULO 6

Comparación de los modelos propuestos

En el capítulo 5 se ha visto como obtener distintas estimaciones del momento para una iteración del movimiento por los 3 modelos propuestos, específicamente $\hat{\tau}_p$ para el modelo aoMLP, $\hat{\tau}_R$ para el RBN y $\hat{\tau}_V$ para el SVM. Se puede valorar la calidad de dichas estimaciones, denotadas genéricamente por $\hat{\tau}$, comparando el error cometido con el correspondiente nivel de referencia τ_{ID} inferido por Dinámica Inversa tal y como se describió en el capítulo 2. Por completitud, esta misma valoración de calidad se puede realizar con las estimaciones $\hat{\tau}_H$ obtenidas por el modelo de Hill descrito en el apéndice D.

Naturalmente, no solo basta con comparar cualitativamente las distintas señales, aunque hacerlo también proporcione información importante, si no que ha de cuantificarse su similitud. Para ello se han empleado parámetros habituales como el error máximo absoluto E_{max} , la raíz del error cuadrático medio E_{rms} y, para facilitar la comparación entre sujetos y de señales con distinta magnitud, su versión normalizada NRMSD y el coeficiente de determinación R^2 (es decir, el cuadrado del coeficiente de correlación de Pearson). Como definición de NRMSD se ha usado la propuesta por SARTORI et ál. [35]:

$$\text{NRMSD} = \frac{\sqrt{\frac{1}{N} \sum_{n=1}^N (\hat{\tau}_n - \tau_{ID,n})^2}}{\max(\hat{\tau} - \tau_{ID}) - \min(\hat{\tau} - \tau_{ID})} \quad (6.1)$$

donde N representa, en este caso, la duración en muestras de la iteración del movimiento a comparar y n el índice de dicha muestra.

Por otro lado, al comparar conjuntos de resultados proporcionados por diversos métodos predictivos es importante usar test de hipótesis para estar seguros, estadísticamente hablando, de que la comparación es significativa. En lugar de emplear cualquier miembro de la familia ANOVA, DEMŠAR [14] recomienda usar sus contrapartes no-paramétricas al no poderse asegurar que las distintas poblaciones de errores producidas por los diversos métodos cumplan los requisitos de aplicación de ANOVA. Para la comparación de modelos se empleará el test Signed Rank de Wilcoxon y el de Friedman [19], tomando ventaja, cuando sea posible, de la estructura repetitiva por sujetos de las pruebas del escenario ESU.

6.1 Comparación de los modelos propuestos para el escenario ESU

Un resumen comparativo de los resultados obtenidos para cada sujeto del escenario ESU por los distintos modelos se muestra en la tabla 6.1 (el apéndice G.1 incluye todos). Los datos proporcionados muestran, una vez promediadas las 9 componentes del momento disponibles correspondientes a la predicción del momento neto tridimensional en las 3 articulaciones estudiadas, la media y desviación estándar de las 5 predicciones de validación posibles de aplicar LOOCV a nivel de iteración con los 3 modelos de caja negra propuestos. Estos resultados se comparan con los resultados obtenidos por el modelo de Hill descrito en el apéndice D y calculado como la media y desviación estándar de las 4 predicciones de validación obtenidas cuando el modelo se calibra con los datos de la 1.^a iteración del movimiento disponible.

Si nos centramos en los resultados por sujetos, se aprecia una clara diferencia entre los niveles de error esperados para los controles C001 y C009 frente a los de los controles C017 y C018. Dicha diferencia se explica por ser estos últimos los afectados por el fallo del sistema VICON. Esta misma razón es por la que hay que tomar con cautela el que un test de Kruskall-Wallis, aplicado a las predicciones del modelo **aoMLP** para los 8 sujetos, confirma la diferencia para al menos un sujeto en la mediana de la distribución de errores normalizados con un *p*-valor de $3,2 \cdot 10^{-3}$. Por otra parte, un test Signed Rank de Wilcoxon no llega a confirmar la diferencia de comportamiento entre el bloque de sujetos de control frente al de pacientes, aunque con un *p*-valor de solo 0,093.

Por otro lado, comparando los modelos estudiados, la tabla 6.1 también muestra como el modelo de Hill tiende a obtener resultados peores para las 4 características recogidas. Se puede apreciar como consistentemente tiende a obtenerse un valor de R^2 menor, indicando un menor parecido en la forma de la función predicha $\hat{\tau}_H$ y la que tomamos como referencia τ_{ID} . Del mismo modo, las figuras de error E_{max} , E_{rms} y $NRMSD$ tienden a alcanzar valores más altos,

Tabla 6.1: Comparativa cuantitativa de los modelos propuestos para el escenario ESU

		Controles				Pacientes			
		C001	C009	C017	C018	P002	P003	P020	P021
R^2	MLP	$0,92 \pm 0,01$	$0,93 \pm 0,02$	$0,76 \pm 0,08$	$0,93 \pm 0,04$	$0,88 \pm 0,02$	$0,90 \pm 0,01$	$0,70 \pm 0,09$	$0,80 \pm 0,15$
	RBN	$0,87 \pm 0,02$	$0,92 \pm 0,02$	$0,62 \pm 0,24$	$0,88 \pm 0,08$	$0,79 \pm 0,19$	$0,78 \pm 0,03$	$0,66 \pm 0,09$	$0,70 \pm 0,14$
	SVM	$0,88 \pm 0,04$	$0,89 \pm 0,01$	$0,67 \pm 0,14$	$0,81 \pm 0,23$	$0,67 \pm 0,30$	$0,80 \pm 0,06$	$0,48 \pm 0,04$	$0,68 \pm 0,08$
	Hill	$0,83 \pm 0,07$	$0,86 \pm 0,08$	$0,81 \pm 0,13$	$0,85 \pm 0,05$	$0,42 \pm 0,36$	$0,68 \pm 0,14$	$0,53 \pm 0,20$	$0,61 \pm 0,31$
$NRMSD$	MLP	$0,06 \pm 0,01$	$0,06 \pm 0,01$	$0,11 \pm 0,03$	$0,11 \pm 0,10$	$0,10 \pm 0,03$	$0,08 \pm 0,01$	$0,10 \pm 0,02$	$0,09 \pm 0,02$
	RBN	$0,09 \pm 0,01$	$0,07 \pm 0,01$	$0,17 \pm 0,11$	$0,12 \pm 0,10$	$0,13 \pm 0,10$	$0,13 \pm 0,04$	$0,12 \pm 0,03$	$0,11 \pm 0,02$
	SVM	$0,08 \pm 0,01$	$0,08 \pm 0,01$	$0,13 \pm 0,05$	$0,12 \pm 0,10$	$0,15 \pm 0,08$	$0,11 \pm 0,02$	$0,14 \pm 0,03$	$0,10 \pm 0,02$
	Hill	$0,24 \pm 0,01$	$0,25 \pm 0,16$	$0,14 \pm 0,12$	$0,14 \pm 0,34$	$0,24 \pm 0,05$	$0,25 \pm 0,04$	$0,27 \pm 0,05$	$0,23 \pm 0,04$
E_{rms} (N m)	MLP	$0,11 \pm 0,02$	$0,19 \pm 0,03$	$0,24 \pm 0,06$	$0,33 \pm 0,34$	$0,29 \pm 0,09$	$0,27 \pm 0,04$	$0,24 \pm 0,06$	$0,15 \pm 0,08$
	RBN	$0,17 \pm 0,03$	$0,21 \pm 0,03$	$0,42 \pm 0,28$	$0,36 \pm 0,37$	$0,47 \pm 0,38$	$0,60 \pm 0,27$	$0,30 \pm 0,12$	$0,20 \pm 0,08$
	SVM	$0,14 \pm 0,04$	$0,25 \pm 0,03$	$0,33 \pm 0,13$	$0,37 \pm 0,42$	$0,52 \pm 0,35$	$0,40 \pm 0,09$	$0,40 \pm 0,09$	$0,23 \pm 0,04$
	Hill	$0,43 \pm 0,16$	$0,65 \pm 0,17$	$0,47 \pm 0,25$	$0,65 \pm 0,34$	$0,97 \pm 0,19$	$1,45 \pm 0,39$	$1,04 \pm 0,23$	$0,95 \pm 0,31$
E_{max} (N m)	MLP	$0,36 \pm 0,10$	$0,75 \pm 0,16$	$0,96 \pm 0,22$	$0,75 \pm 0,46$	$0,91 \pm 0,21$	$0,96 \pm 0,21$	$1,44 \pm 0,70$	$0,91 \pm 0,82$
	RBN	$0,51 \pm 0,12$	$0,74 \pm 0,16$	$1,21 \pm 0,57$	$0,81 \pm 0,52$	$1,19 \pm 0,62$	$1,54 \pm 0,54$	$1,46 \pm 0,75$	$1,00 \pm 0,75$
	SVM	$0,49 \pm 0,22$	$0,90 \pm 0,20$	$1,10 \pm 0,28$	$0,89 \pm 0,64$	$1,36 \pm 0,57$	$1,19 \pm 0,24$	$2,05 \pm 0,99$	$1,52 \pm 0,44$
	Hill	$1,17 \pm 0,18$	$1,83 \pm 0,73$	$1,42 \pm 0,54$	$1,37 \pm 0,74$	$2,41 \pm 0,43$	$2,91 \pm 0,67$	$2,37 \pm 0,55$	$2,82 \pm 0,52$

indicando un error cometido mayor. Estos resultados se pueden comprobar visualmente en las figuras D.2 y D.3.

Del mismo modo, la comparación entre los 3 modelos de caja negra sugiere al modelo **aoMLP** como el que proporciona mejor rendimiento en los 4 parámetros medidos. Esto lo confirma un test de Friedman aplicado a los resultados de NRMSD de los tres modelos estudiados y que indica que la mediana de los errores esperados es estadísticamente diferente, para al menos uno de ellos, con un p -valor de $3,2 \cdot 10^{-6}$. Además, y con las precauciones habituales por las pocas iteraciones utilizadas y la gran cantidad de test de hipótesis realizadas, la interpretación de los intervalos producidos por el test sugiere que la distribución de los errores de validación normalizados de los modelos **RBN** y **SVM** tienen medianas idénticas, mientras que la del modelo **aoMLP** es claramente menor.

Los resultados experimentales muestran que los distintos modelos propuestos pueden predecir movimientos funcionales complejos como representa la tarea de beber utilizada en el experimento. Sin embargo, sorprenden por decepcionantes los resultados de **SVM** que, a pesar de sus a priori ventajas teóricas, no mejora apreciablemente los resultados de **RBN**. Por el contrario, ha sido el modelo **aoMLP** con el que mejor rendimiento esperado se obtiene, con un NRMSD del $(8,84 \pm 3,97) \%$ y un R^2 de $0,85 \pm 0,10$, sin duda alguna gracias a la existencia de un hiperparámetro óptimo único válido para todos los sujetos y a la ayuda del aprendizaje por ensamble para las predicciones más complicadas.

Una comparación de los resultados obtenidos por el modelo **aoMLP** con los de estudios previos similares muestra rendimientos comparables a pesar de estar siendo realizado simultáneamente para los 9 grados de libertad que representan las tres articulaciones del miembro superior y, más importante todavía, haber sido realizados con un movimiento funcional más complejo. Por ejemplo, en el estudio de SONG et ál. [38] el E_{rms} conseguido para sujetos sanos fue de $(0,35 \pm 0,06) \text{ N m}$, mientras que el rendimiento de **aoMLP** es superior incluso para pacientes. Por su parte, y aún a pesar de los problemas con la captura de datos de cinemática, nuestros resultados son similares a los obtenidos por CASTELLINI et ál. [9], que indicaron haber obtenido un NRMSD del $(7,89 \pm 0,09) \%$ para sujetos de control. Por último comentar que, a nuestro leal saber y entender, no existen estudios similares de predicción del momento articular para las extremidades superiores con pacientes. En su lugar, los estudios existentes son específicos de las extremidades inferiores complicando una comparación adecuada.

6.2 Comparación de los modelos propuestos para el escenario ESM

Los resultados obtenidos para cada modelo en las 3 pruebas realizadas se resumen en la tabla 6.2. Señalar que los modelos basados en Hill no tienen sentido en este escenario por estar necesariamente adaptados a la biométrica de cada persona. A simple vista parece claro que el rendimiento obtenido para los sujetos de control es mayor que el obtenido con los pacientes, tanto si se entrena con la población completa como si se hace solamente con los miembros de su grupo. También parece apreciarse en cada caso una mejora al pasar a entrenar con la población completa, pero esta situación no llega a ser confirmada por un test Signed Rank de Wilcoxon comparando los resultados obtenidos por el modelo **aoMLP** para los controles en las dos pruebas (con un p -valor de 0,469) o en la comparación correspondiente para los pacientes (0,204).

La comparación de los 3 modelos propuestos mediante un test de Friedman establece que el

Tabla 6.2: Comparativa cuantitativa de los modelos propuestos para el escenario ESM

		solo Controles	solo Pacientes	Población completa		
				Controles	Pacientes	Todos
R^2	MLP	0,72 ± 0,08	0,46 ± 0,16	0,73 ± 0,07	0,47 ± 0,15	0,56 ± 0,18
	RBN	0,64 ± 0,14	0,21 ± 0,09	0,54 ± 0,09	0,23 ± 0,09	0,34 ± 0,18
	SVM	0,45 ± 0,16	0,23 ± 0,15	0,54 ± 0,15	0,25 ± 0,18	0,35 ± 0,22
	Hill	-	-	-	-	-
NRMSD	MLP	0,24 ± 0,07	0,28 ± 0,09	0,22 ± 0,03	0,27 ± 0,08	0,25 ± 0,07
	RBN	0,28 ± 0,07	0,30 ± 0,10	0,25 ± 0,09	0,26 ± 0,08	0,26 ± 0,08
	SVM	0,27 ± 0,03	0,30 ± 0,08	0,23 ± 0,04	0,29 ± 0,07	0,27 ± 0,07
	Hill	-	-	-	-	-
E_{rms} (N m)	MLP	0,67 ± 0,21	1,14 ± 0,58	0,53 ± 0,11	0,99 ± 0,34	0,82 ± 0,36
	RBN	0,97 ± 0,45	4,81 ± 3,52	1,10 ± 0,46	3,51 ± 2,78	2,62 ± 2,49
	SVM	0,86 ± 0,20	1,17 ± 0,35	0,69 ± 0,13	1,09 ± 0,26	0,94 ± 0,29
	Hill	-	-	-	-	-
E_{max} (N m)	MLP	1,37 ± 0,26	2,54 ± 0,96	1,14 ± 0,14	2,29 ± 0,72	1,87 ± 0,80
	RBN	1,96 ± 1,01	13,50 ± 13,36	2,73 ± 1,57	10,19 ± 8,24	7,44 ± 7,48
	SVM	1,78 ± 0,20	2,71 ± 0,87	1,55 ± 0,31	2,51 ± 0,72	2,15 ± 0,76
	Hill	-	-	-	-	-

modelo **aoMLP** difiere, estadísticamente hablando, del **SVM** pero no del **RBN** con un *p*-valor de 0,021, aunque un resultado tan ajustado es mejor tomarlo con cautela. En este sentido, y hablando cualitativamente, sí que parece claro que el modelo **aoMLP** también presenta para este escenario un rendimiento mejor que el resto obteniendo, para la prueba con toda la población, un NRMSD del (25,07 ± 6,90) % y un R^2 de 0,56 ± 0,18. Esos valores mejoran teniendo solo en cuenta a los controles, con un NRMSD del (21,65 ± 3,40) % y un R^2 de 0,73 ± 0,07.

Para finalizar indicar que nuevamente, a nuestro leal saber y entender, este es el primer estudio que intenta predecir el momento articular asociado al movimiento de la extremidad superior de un sujeto a partir de datos de entrenamiento de sujetos diferentes y, por tanto, no se dispone de referencias con las que comparar los resultados obtenidos. Obviamente el rendimiento obtenido no llega a ser aceptable para su uso práctico, pero los resultados también sugieren que aumentando el número de sujetos empleados para el entrenamiento aumentará tal rendimiento. La incógnita que queda por responder es el número de sujetos necesarios y cuál será el rendimiento final alcanzado.

6.3 Variaciones de las configuraciones propuestas

Como complemento a los 3 modelos propuestos originales se han realizado una serie de estudios adicionales mediante la variación de elementos claves de las configuraciones propuestas, proporcionando así una perspectiva adicional del comportamiento del modelo original. Sin embargo, por no extender en demasiado el desarrollo, los elementos presentados se centrarán principalmente en el modelo **aoMLP** del escenario ESU por ser el que mejores prestaciones ha proporcionado. Un resumen de estos resultados se adjunta en la tabla 6.3.

Tabla 6.3: Resumen de los rendimientos obtenidos para el escenario ESU

Modelo o variación	E_{\max} (N m)	E_{rms} (N m)	NRMSD (%)	R^2	p -valor ¹
aoMLP	$0,88 \pm 0,49$	$0,23 \pm 0,14$	$8,84 \pm 3,97$	$0,85 \pm 0,10$	
RBN	$1,06 \pm 0,60$	$0,34 \pm 0,26$	$11,70 \pm 6,67$	$0,78 \pm 0,15$	$1,3 \cdot 10^{-7}$
SVM	$1,19 \pm 0,65$	$0,33 \pm 0,22$	$11,38 \pm 5,42$	$0,73 \pm 0,19$	$8,8 \cdot 10^{-8}$
Sin ensamble	$1,10 \pm 0,61$	$0,32 \pm 0,27$	$10,77 \pm 5,90$	$0,80 \pm 0,13$	$3,9 \cdot 10^{-8}$
Ensamble de 10 MLP	$0,90 \pm 0,49$	$0,23 \pm 0,14$	$9,03 \pm 4,05$	$0,85 \pm 0,10$	$1,1 \cdot 10^{-3}$
F_m de 200 Hz	$0,89 \pm 0,51$	$0,23 \pm 0,19$	$8,65 \pm 4,70$	$0,86 \pm 0,11$	$3,6 \cdot 10^{-2}$
Entrenamiento LM	$1,40 \pm 1,85$	$0,41 \pm 0,70$	$10,30 \pm 6,53$	$0,79 \pm 0,19$	$4,5 \cdot 10^{-1}$
Sin Cinemática	$1,41 \pm 0,38$	$0,44 \pm 0,13$	$16,77 \pm 2,67$	$0,55 \pm 0,14$	$2,6 \cdot 10^{-7}$
80 % PCA	$1,06 \pm 0,48$	$0,32 \pm 0,19$	$11,85 \pm 4,11$	$0,77 \pm 0,12$	$4,5 \cdot 10^{-8}$
90 % PCA	$1,02 \pm 0,51$	$0,30 \pm 0,20$	$10,97 \pm 4,80$	$0,80 \pm 0,12$	$1,2 \cdot 10^{-7}$
3 Sinergias	$0,89 \pm 0,48$	$0,23 \pm 0,14$	$9,04 \pm 3,84$	$0,85 \pm 0,10$	$4,8 \cdot 10^{-2}$
5 Sinergias	$0,91 \pm 0,48$	$0,24 \pm 0,12$	$9,24 \pm 3,62$	$0,84 \pm 0,11$	$1,9 \cdot 10^{-4}$

¹ p -valor del test Signed Rank de Wilcoxon comparando la similitud con la mediana de la distribución del NRMSD del modelo aoMLP propuesto.

Un aspecto clave del modelo **aoMLP** ha sido la aplicación de aprendizaje por ensamble para mejorar la calidad de la estimación realizada. Un test de Signed Rank de Wilcoxon, comparando los resultados obtenidos para el NRMSD al usar ensamble frente a no usarlo, favorece claramente su adopción con un p -valor de $3,9 \cdot 10^{-8}$. De este modo, el mayor tiempo de cómputo se justifica por un descenso del 1,92 % en el error esperado normalizado del escenario ESU.

Por otro lado, otra comparación entre un ensamble cuya salida es la media de 30 submódulos **MLP** frente a otro cuya salida es la mediana de solo 10 submódulos también encuentra diferencias estadísticamente hablando (el p -valor es de $1,1 \cdot 10^{-3}$) pero, como el error esperado normalizado sólo aumenta un 0,19 % se puede recomendar su aplicación para disminuir el tiempo de computo sin perjudicar apenas el rendimiento. Del mismo modo el utilizar una frecuencia de muestreo de 200 Hz frente a una de 20 Hz vuelve a producir diferencias significativas con un p -valor de 0,036, pero en la práctica esto simplemente equivale a una disminución del 0,20 %.

Otra variación considerada ha sido el cambiar a un algoritmo de aprendizaje de Levenberg-Marquardt. En este caso el p -valor de un test de Signed Rank de Wilcoxon es de 0,452, por lo que en cuanto al rendimiento no se encontrarían diferencias significativas en los resultados, no así en el tiempo de cómputo que sí que es apreciable.

También ha sido estudiado el efecto del cambio de entradas a la red como la diferencia entre usar o no datos de cinemática junto a las de activación muscular. Este cambio supone en la práctica la disminución a solo 9 neuronas de entrada (por las 9 componentes disponibles de activación muscular) en contraposición con las 21 neuronas de entrada del modelo propuesto (correspondientes a las 9 componentes disponibles de activación muscular y a las 12 de la señal de cinemática de tronco, hombro, codo y muñeca). En este caso un test de Signed Rank de Wilcoxon nos confirma, con un p -valor de $2,6 \cdot 10^{-7}$, que el aumento del 7,92 % en el error esperado normalizado es ciertamente significativo estadísticamente, tal y como indica la literatura existente.

Naturalmente es lógico obtener una perdida en el rendimiento de la red cuando se elimina información importante de su entrada. Sin embargo, el capítulo 3 proporciona métodos para

reducir el número de componentes de entrada sin desechar completamente la información disponible. Por ejemplo, la aplicación de PCA a las entradas conjuntas de cinemática y activación normalizada para eliminar las componentes correspondientes al 10 % menos significativo de la varianza explicada permite reducir a únicamente 7 el número de componentes a la entrada. Este cambio, que supone una reducción de $\frac{2}{3}$ en el número de neuronas de entrada, supone un incremento del 2,13 % del error esperado normalizado con un p -valor de $1,2 \cdot 10^{-7}$ calculado por el test de Wilcoxon.

Del mismo modo, la utilización de 3 y 5 sinergias musculares en lugar de la señal de activación muscular normalizada también permite, aunque en menor grado, la reducción del número de entradas a la red. Un test de Friedman con los 3 modelos (es decir, comparando la utilización de las 9 componentes de activación muscular frente a la utilización de 3 o 5 componentes de sinergias) no confirma diferencia apreciable al haberse obtenido un p -valor de 0,198, con un aumento del error esperado normalizado que siquiera llega al 0,5 % en el peor de los casos. Este resultado contrasta con el mostrado en la tabla 6.3 donde la comparación se ha realizado de forma individual aunque, en cualquier caso, el incremento del error es tan somero como para no resultar un problema la utilización de sinergias musculares en lugar de la activación en caso de estar disponible este tipo de entradas.

CAPÍTULO 7

Conclusiones y líneas futuras

El objetivo del presente TFM era la selección y configuración de un modelo de estimador del momento producido en las articulaciones de un sujeto de manera que pudiese ser implementado en el control de un exoesqueleto dedicado a la rehabilitación motora bajo un paradigma de asistencia bajo demanda. En el entorno descrito será clave combinar sencillez de operación para su uso en un entorno no especializado junto con precisión en las predicciones del movimiento de pacientes para conseguir una rehabilitación personalizada a las necesidades de cada paciente.

En estas circunstancias, un resultado positivo del estudio realizado para el escenario ESM hubiese sido altamente relevante por no necesitar de una fase de entrenamiento específica para cada paciente. Desafortunadamente, las figuras del rendimiento alcanzado en este escenario no han sido suficientemente satisfactorias para habilitarlo como propuesta factible. Sin embargo, la tendencia subyacente de mejora del rendimiento al incrementarse la cantidad de sujetos disponible para el entrenamiento deja abierta la puerta a poder alcanzar los rendimientos necesarios con la disponibilidad de las capturas de un número suficiente de sujetos para el entrenamiento.

Afortunadamente el estudio del escenario ESU sí ha obtenido resultados satisfactorios, con el modelo [aoMLP](#) presentando las mejores características. Este modelo combina precisión en las predicciones con un R^2 esperado de $0,85 \pm 0,10$ y un NRMSD del $(8,84 \pm 3,97)\%$, junto con la mayor robustez frente a fallos en el proceso de captura de los datos de entrada. Además, al menos para los sujetos disponibles, no se aprecia sensibilidad aparente en la selección del hiperparámetro óptimo, siendo válido el mismo tanto para pacientes como sujetos de control. Por último, y a pesar de necesitar un proceso de entrenamiento específico para cada sujeto, los tiempos de entrenamiento son bajos y estables (en el sentido de que no hay mucha variabilidad entre los tiempos de cada sujeto), habilitando que su implantación en el ámbito clínico no sea onerosa para el paciente.

La tabla 7.1 permite la comparación de las características principales de los distintos modelos propuestos. En relación al modelo propuesto, el modelo de Hill presenta la desventaja de su peor rendimiento en la estimación de pacientes a pesar de un mayor tiempo de calibración. Por su parte, para los modelos [RBN](#) y [SVM](#) no se ha logrado encontrar un hiperparámetro óptimo compartido entre todos los sujetos como sucedió con el modelo [aoMLP](#), perjudicando su capacidad de generalización o aumentando la complejidad de su diseño.

Tabla 7.1: Comparativa cualitativa de los modelos propuestos para el escenario ESU

Categoría	Característica	Modelo de caja negra			Modelo de Hill
		aoMLP	RBN	SVM	
Tipo		Red neuronal	Red neuronal	Aprendizaje estadístico	Fisiológico / Biomecánico
	Formulación	Simple	Simple	Simple	Compleja
	Significado fisiológico de los (hiper-)parámetros	No	No	No	Sí
	Número de parámetros	319 (× el número de submódulos MLP)	846 parámetros (para una media de 27 neuronas ocultas ¹)	1876 vectores soporte de media ²	64
Arquitectura	Valor de los parámetros	Ajustable	Ajustable	Ajustable	Ajustable
	Número de hiperparámetros	1 (número de neuronas intermedias)	2 (goal y spread)	2 (gamma y coste) (× 9 salidas)	No
	Valor de los hiperparámetros	Un valor óptimo común para todos los sujetos	No hay un valor único y común para todos	No hay un valor único y común para todos	No
Ajuste de los parámetros	Tipo	Entrenamiento	Entrenamiento	Entrenamiento	Calibración
	Tiempo	6 min para los 8 sujetos ³	4 min para los 8 sujetos ³	1 h para los 8 sujetos ³	6 h por sujeto ⁴
Ajuste de los hiperparámetros	Tiempo	14 h para los 8 sujetos ⁵	15 h para los 8 sujetos ⁵	11 h para generar los mapas de los 8 sujetos ⁵	No
Uso de memoria		Bajo	Alto ⁶	Bajo	Alto ⁷
Rendimiento	Entrenamiento	Control	Medio	Medio	Alto
		Paciente	Medio	Medio	Bajo
	Validación	Control	Alto	Medio	Aceptable
		Paciente	Alto	Medio	Bajo

¹ El número de neuronas ocultas, desconocido a priori, depende del entrenamiento.² El número de vectores soporte, desconocido a priori, depende del entrenamiento.³ Depende de la duración de los movimientos entrenados y la configuración de las condiciones de parada del algoritmo de entrenamiento.⁴ Depende de la duración del movimiento calibrado y la configuración de las condiciones de parada del algoritmo de calibración.⁵ Depende, además, del rango de la rejilla de búsqueda de hiperparámetros.⁶ Dependiendo de la duración de los movimientos entrenados.⁷ Dependiendo de la duración del movimiento calibrado.

7.1 Líneas de desarrollo futuro

La novedad asociada a un estudio del rendimiento de modelos neuromusculoesqueléticos para la predicción de un movimiento funcional complejo realizado por pacientes de lesiones medulares junto con el interés de los resultados obtenidos para el escenario ESU, sobretodo en relación a que dicho rendimiento es suficientemente equiparable al obtenido para sujetos de control cuando se utilizan modelos de aprendizaje automático frente a modelos basados en Hill, ha motivado la preparación de un artículo titulado «An evaluation of EMG-driven muscle models for assistive exoskeletons» para su publicación en la revista *Journal of Neuroengineering and Rehabilitation*. Sin embargo, los modelos propuestos corresponden simplemente a una primera aproximación en la implementación de un Neuroestimador basado en modelos de caja negra, existiendo todavía un amplio margen de mejora a estudiar en desarrollos futuros.

A partir de lo conseguido en el presente TFM se propone, como línea de desarrollo más evidente, aumentar el número de iteraciones del movimiento disponibles para el entrenamiento del escenario ESM. Lamentablemente no hay una forma de conocer el número de sujetos de los que sería necesario disponer nuevos datos para obtener un rendimiento suficiente ni, incluso, si esto llegaría a ser posible, pero la ventaja en la sencillez de implementación de un predictor basado en este escenario sería notable.

En un sentido más teórico, otra posible vía de desarrollo sería la utilización de modelos que tengan en cuenta la característica temporal de los datos utilizados. Modelos como RANN o TDANN, en el caso de las redes neuronales, o el uso de Dynamic Least Squares **SVM** (DLS-SVM) tienen en cuenta que estamos tratando con series temporales, por lo que presentan un mayor potencial para alcanzar mejores rendimientos a costa de añadir complejidad al diseño. Un estudio comparado de los resultados obtenidos por las nuevas implementaciones y los presentados en este TFM establecería una buena base para avanzar en la mejora del bloque de control del exoesqueleto.

Una última línea de desarrollo futuro radicaría en el tratamiento de la señal sEMG capturada y que sirve como entrada al estimador. En lugar de un procesamiento de la señal basado en un filtrado temporal, se podría estudiar el empleo de formas más modernas de procesamiento como transformadas Wavelet (WT) o, simplemente, mediante el uso de características representativas de la señal como Higher Order Statistics (HOS). La ventaja de esta aproximación se encontraría en la reducción del ruido introducido al estimador de forma que aumentase el rendimiento potencial obtenido.

APÉNDICE A

Prácticas en el entorno clínico

Durante la realización del Trabajo Fin de Máster se han mantenido reuniones con diversos miembros de la Unidad de Investigación en Fisioterapia (UIF) de la Universidad de Zaragoza con el fin de encontrar vías de cooperación mutuas con el Grupo de Robótica de la Escuela de Ingeniería y Arquitectura (EINA) de la propia Universidad. La idea inicial por el Grupo de Robótica para esta colaboración era desarrollarla en el ámbito de la rehabilitación y el seguimiento de la evolución de pacientes por ser éste el ámbito en el que está centrando sus proyectos actuales. Sin embargo, la descripción de los proyectos en los que está embarcada la UIF puso de manifiesto el potencial existente en extenderlo al ámbito de la mejora del rendimiento deportivo. En la práctica los retos serían similares, si no más sencillos, pero aumentarían ostensiblemente las posibilidades de encontrar financiación.

Fue en este proceso de puesta en común de pareceres en el que se pudo constatar lo sencillo que es introducir, inadvertidamente, malentendidos y dificultades en la comunicación por las diferencias en el lenguaje utilizado por ambos grupos. Sin llegar a haber transcurrido un minuto en la presentación del proyecto HYPER y los trabajos realizados con el modelo del exoesqueleto disponible, se requirió que se clarificara el concepto empleado como par. Y es que, por circunstancias que podían considerarse históricas, en el ámbito de la fisioterapia el concepto de par puede sobreentenderse, o considerarse incluso más afín, al concepto de activación muscular empleado en el presente TFM que al concepto de momento de par de fuerzas que se pretendía trasmitir.

En este mismo proceso también se pudo apreciar de primera mano las diferencias de visión existentes entre grupos que, aún siguiendo el mismo método científico, provienen de diferentes *backgrounds*. Mientras que en el caso de la ingeniería la motivación puede ser más difusa como el simple afán de conocimiento o el deseo de resolver un problema presente en el mundo real, en el caso de la fisioterapia todo gira en torno a la funcionalidad motora del cuerpo humano y siempre con el objetivo de recuperarla, mantenerla o simplemente mejorarla. La presencia de dificultades en la validación de resultados de sus proyectos de investigación estaría relacionada, al menos en parte, con esta focalización en la capacidad funcional del sujeto. Precisamente, alcanzar una mayor capacidad de objetivar dichos resultados sería uno de sus frutos deseados de dicha colaboración.

Naturalmente, llegar a conseguirlo no es sencillo ya que, en un entorno clínico, las dificultades

prácticas son absolutamente diferentes. Por un lado hay que tener en cuenta que la respuesta a estímulos por parte de músculos, tendones y, en definitiva, el cuerpo humano es muy variable y dependiente del sujeto, por lo que es muy difícil conseguir una adecuada repetibilidad en los resultados. Aunque este no sea un problema exclusivo de las disciplinas más biológicas, lo cierto es que en el ámbito de la ingeniería se puede paliar acudiendo a métodos como simulaciones o modelado, mientras que en el ámbito fisioterapéutico las posibilidades son más limitadas. Además, el trato directo con pacientes incrementa los problemas éticos existentes y obliga a utilizar métodos cómodos y que no sean excesivamente onerosos con ellos. Más aún, el personal en el entorno clínico no tiene por qué ser especialista por lo que se deben de primar métodos sencillos e intuitivos.

La verdad es que todas las dificultades mencionadas anteriormente se comentaron en relación a la electromiografía. Y es que éste puede ser un caso paradigmático, aun cuando la sEMG contenga gran cantidad de información a nivel muscular y, sin duda alguna, al menos parte de ella será relevante en el ámbito de la fisioterapia, su uso a nivel práctico es residual debido a las dificultades de manejo que presenta. La gran variabilidad presente, ya no solo entre distintos sujetos, sino para un mismo sujeto, dificulta enormemente correlacionar sus variaciones con los efectos motrices producidos. Este hecho imposibilita su interpretación práctica de forma generalizada y, menos aún, por personal no especializado. Más aún, los parámetros derivados existentes, como Integrated EMG (IEMG), Mean Absolute Value (MAV), Root Mean Square(RMS) o Waveform Length (WL), suelen ser poco prácticos ya que o proporcionan información demasiado estática, o no son suficientemente flexibles o son, directamente, excesivamente técnicos. Precisamente, es por este cúmulo de circunstancias por el que la UIF ha iniciado la búsqueda de nuevas parametrizaciones que eliminen las deficiencias de los parámetros actuales.

Como experiencia complementaria al trabajo desarrollado en el presente TFM se dedicó una jornada a tomar contacto con el proceso de captura de los datos electromiográficos y de movimiento, tanto desde el punto de vista de la organización del proceso como el que experimenta un sujeto de pruebas. Una primera fase de reconocimiento del entorno de pruebas, en la que también se explicaron las capacidades de los distintos equipos a utilizar, sirvió para familiarizarse con el papel desarrollado por los distintos actores del proceso.

En la siguiente fase se procedió a revisar la documentación de un protocolo de captura de datos para un experimento similar al empleado en el presente TFM, de forma que permitiese seguir más fácilmente su desarrollo cuando se presenció su puesta en práctica por parte de la persona que dirigía la captura. A pesar de todo esto, fue revelador la cantidad de dudas y veces que hubo que revisar la documentación cuando, con un compañero, se procedió a repetir el protocolo de pruebas, comprobándose la gran cantidad de atención al detalle necesaria a la hora de elaborar este tipo de documentos y, más aún, cuando pueden ser otras personas las que tengan que encargarse de su aplicación y desarrollo en un futuro.

Otro aspecto a destacar fruto de esta experiencia es la dificultad en la realización de las contracciones musculares asociadas a la captura de la máxima contracción voluntaria (MVC) de cada músculo. Cada una de estas capturas requiere la realización de una contracción tetánica del músculo en cuestión procurando mantener el resto en reposo, situación facilitada en cierto grado por la existencia de unas posturas establecidas. Vista la dificultad asociada no es de extrañar que sea en los datos de los pacientes, con las dificultades de movimiento propias de sus dolencias, en las que se aprecia claramente como la MVC capturada no se corresponde con la capacidad de contracción real del individuo, situación menos evidente para los sujetos de control.

APÉNDICE B

Listado de los datos disponibles

Se dispone de datos de un total de 7 sujetos de control y 12 pacientes para la realización del presente TFM. Un listado con el resumen de las características más relevantes de dichos voluntarios se muestra en la tabla B.1.

Con el fin de proporcionar una visión completa del conjunto de datos disponibles se representan a continuación las señales capturadas a los distintos sujetos. Por simplicidad, los datos disponibles se han dividido en función del escenario al que pertenecen, el Escenario de Sujeto Único (ESU) o el de Sujetos Múltiples (ESM). Indicar que para nombrar las distintas variables

Tabla B.1: Características de los sujetos

Sujeto	Capturas	Lesión	Edad	Sexo	Altura (m)	Peso (kg)
C001	5	control	22	M	1,6	65
C009	5	control	22	H	1,8	79
C011	1	control	27	M	1,68	57
C013	1	control	45	H	1,79	78
C015	1	control	28	H	1,88	81,5
C017	5	control	26	M	1,63	48,5
C018	5	control	27	M	1,64	66
P002	5	C6	31	H	1,8	95
P003	5	C6	26	H	1,9	89
P005	1	C6	34	M	1,55	50
P006	1	C7	26	H	1,9	89
P007	1	C6	31	H	1,8	95
P008	1	C6	36	H	1,75	90
P010	1	C7	35	H	1,84	79
P012	1	C7	25	H	1,8	76,9
P016	1	C7	35	H	1,84	79
P019	1	C6	34	M	1,75	70
P020	5		35	H	1,81	90
P021	5		60	M	1,65	51

biomecánicas se ha empleado la codificación mostrada en la tabla B.2, y su listado completo junto con su descripción se indican en las tablas B.3 (variables de cinemática), B.4 (variables de fuerza) y B.5 (variables de momento). Por su parte, las variables de origen electromiográfico se han denominado en función de la abreviatura del músculo correspondiente y han sido listadas en la tabla B.6.

Tabla B.2: Codificación de las variables biomecánicas

Tipo de variable	Segmento / Articulación	Dirección del eje del segmento
C Cinemática	H Hombro	X Antero-posterior
F Fuerzas	C Codo	Y Eje longitudinal
M Momentos	M Mano	Z Medio-lateral
	T Tronco	

Tabla B.3: Listado de las variables biomecánicas de cinemática

Cinemática (°)	
Tronco	
CTX	Balanceo lateral (derecha positivo)
CTY	Rotación de tronco (izquierda positivo)
CTZ	Flexión-extensión de tronco (extensión positivo)
Hombro	
CHX	Abducción-aducción de hombro (abducción positivo)
CHY	Rotación interna del húmero (positivo)
CHZ	Flexión-extensión de hombro (extensión positivo)
Codo	
CCX	Abducción-Aducción de codo (valor nulo)
CCY	Pronación-supinación del antebrazo (supinación positivo)
CCZ	Flexión-extensión de codo (extensión positivo)
Muñeca	
CMX	Desviación ulnar-radial de muñeca (desviación ulnar positivo)
CMY	Rotación interna de la muñeca (Valor nulo)
CMZ	Flexión palmar-dorsal de muñeca (flexión palmar positivo)

Tabla B.4: Listado de las variables biomecánicas de fuerza

Fuerza (N)	
Hombro	
FHX	Fuerza sobre el eje antero-posterior del hombro (sentido anterior positivo)
FHY	Fuerza sobre el eje longitudinal del hombro (sentido vertical positivo)
FHZ	Fuerza sobre el eje medio-lateral del hombro (sentido lateral positivo)
Codo	
FCX	Fuerza sobre el eje antero-posterior del codo (sentido anterior positivo)
FCY	Fuerza sobre el eje longitudinal del codo (sentido vertical positivo)
FCZ	Fuerza sobre el eje medio-lateral del codo (sentido lateral positivo)
Muñeca	
FMX	Fuerza sobre el eje antero-posterior de la muñeca (sentido anterior positivo)
FMY	Fuerza sobre el eje longitudinal de la muñeca (sentido vertical positivo)
FMZ	Fuerza sobre el eje medio-lateral de la muñeca (sentido lateral positivo)

Tabla B.5: Listado de las variables biomecánicas de momento

Momento (N m)	
Hombro	
MHX	Momento en el eje antero-posterior del hombro (sentido anterior positivo)
MHY	Momento en el eje longitudinal del hombro (sentido vertical positivo)
MHZ	Momento en el eje medio-lateral del hombro (sentido lateral positivo)
Codo	
MCX	Momento en el eje antero-posterior del codo (sentido anterior positivo)
MCY	Momento en el eje longitudinal del codo (sentido vertical positivo)
MCZ	Momento en el eje medio-lateral del codo (sentido lateral positivo)
Muñeca	
MMX	Momento en el eje antero-posterior de la muñeca (sentido anterior positivo)
MMY	Momento en el eje longitudinal de la muñeca (sentido vertical positivo)
MMZ	Momento en el eje medio-lateral de la muñeca (sentido lateral positivo)

Tabla B.6: Listado de las variables electromiográficas

Electromiografía (μ V)
Activación, Activación Normalizada y sEMG

TS	Trapecio superior
DP	Deltoides posterior
DM	Deltoides medio
DA	Deltoides anterior
PM	Pectoral mayor
BB	Bíceps braquial
TB	Tríceps braquial
EA	Extensores antebrazo
FA	Flexores antebrazo

B.1 Señales del Escenario de Sujeto Único (ESU)

El escenario ESU está compuesto por las señales de 5 repeticiones del movimiento realizadas por cuatro sujetos de control (C001, C009, C017 y C018) y cuatro pacientes (P002, P003, P020 y P021). Se incluyen la activación y la cinemática junto con la fuerza y el momento derivadas por Dinámica Inversa. Las señales de las iteraciones se muestran concatenadas en el eje temporal para poder apreciar las diferencias en sus amplitudes dependiendo del sujeto y repetición.

Activación Normalizada véanse las figuras [B.1](#) (controles) y [B.2](#) (pacientes)

Cinemática véanse las figuras [B.3](#) (controles) y [B.4](#) (pacientes)

Fuerza véanse las figuras [B.5](#) (controles) y [B.6](#) (pacientes)

Momento véanse las figuras [B.7](#) (controles) y [B.8](#) (pacientes)

B.2 Señales del Escenario de Sujetos Múltiples (ESM)

Por su parte este escenario está compuesto por las señales de una única iteración del movimiento realizadas por cada uno de los 7 sujetos de control (C001, C009, C011, C013, C015, C017 y C018) y los 12 pacientes (P002, P003, P005, P006, P007, P008, P010, P012, P016, P019, P020 y P021). Como se pueden realizar tres pruebas diferentes según se agrupen los datos (específicamente en solo controles, solo pacientes o con la población completa mezclando ambos tipos de sujetos) se han mostrado las tres posibles agrupaciones aunque, obviamente, esto significa que los datos se encuentran duplicados. Las señales de las iteraciones se muestran concatenadas en el eje temporal con los controles primero y seguidamente los pacientes.

Activación Normalizada véase la figura [B.9](#)

Cinemática véase la figura [B.10](#)

Fuerza véase la figura [B.11](#)

Momento véase la figura [B.12](#)

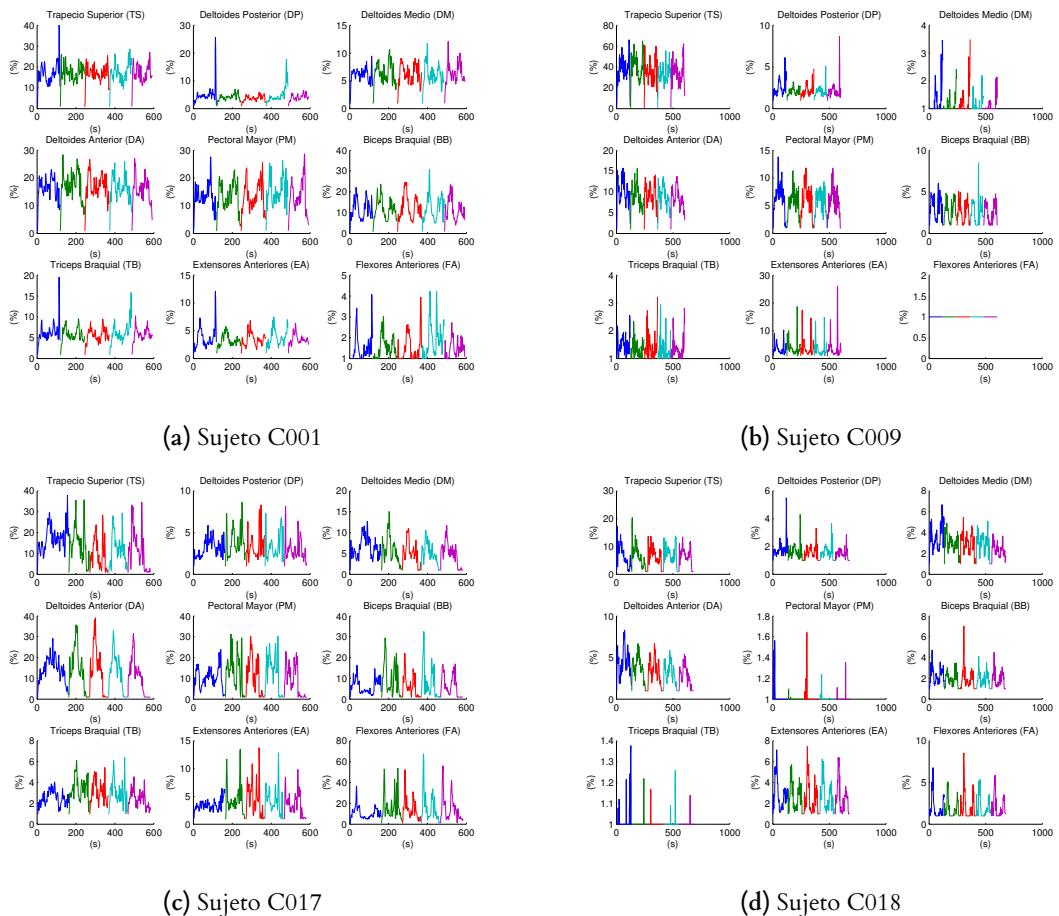


Figura B.1: Concatenación de las 5 iteraciones de las señales de Activación Normalizada (Escenario de Sujeto Único – Controles, $F_m = 20$ Hz)

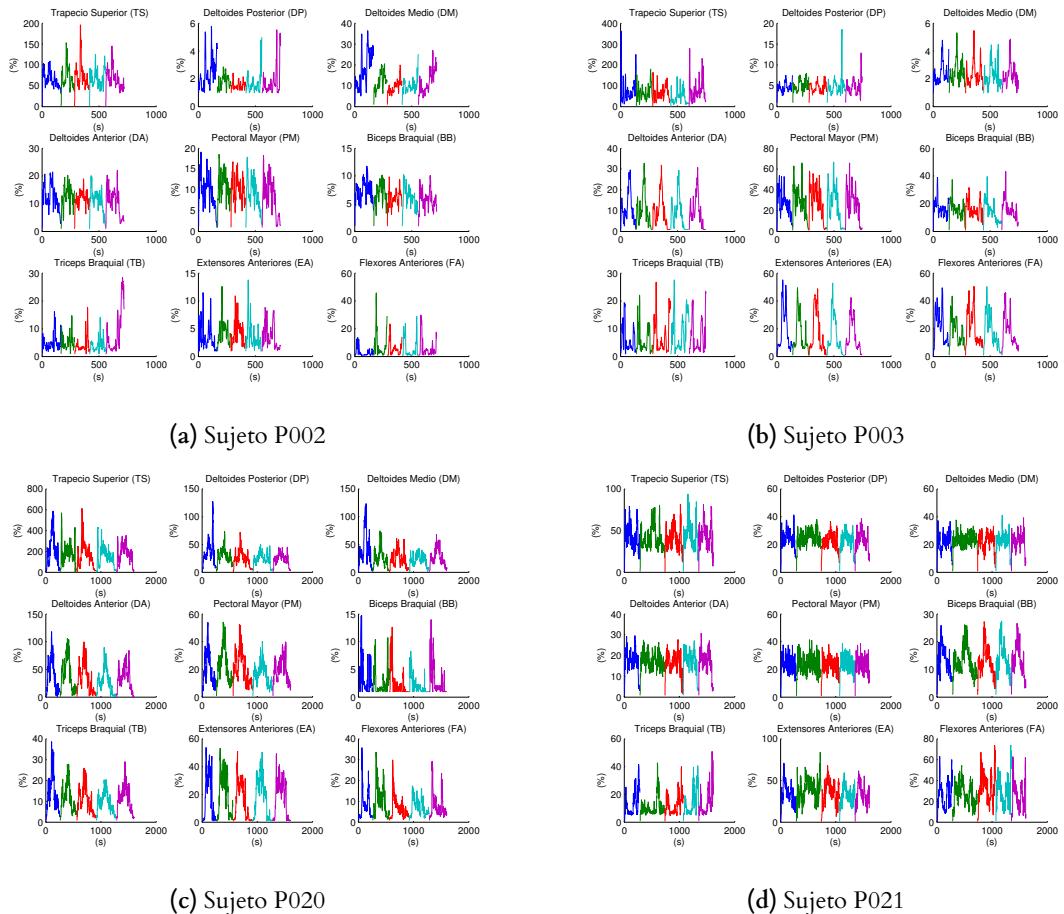


Figura B.2: Concatenación de las 5 iteraciones de las señales de Activación Normalizada (Escenario de Sujeto Único – Pacientes, $F_m = 20$ Hz)

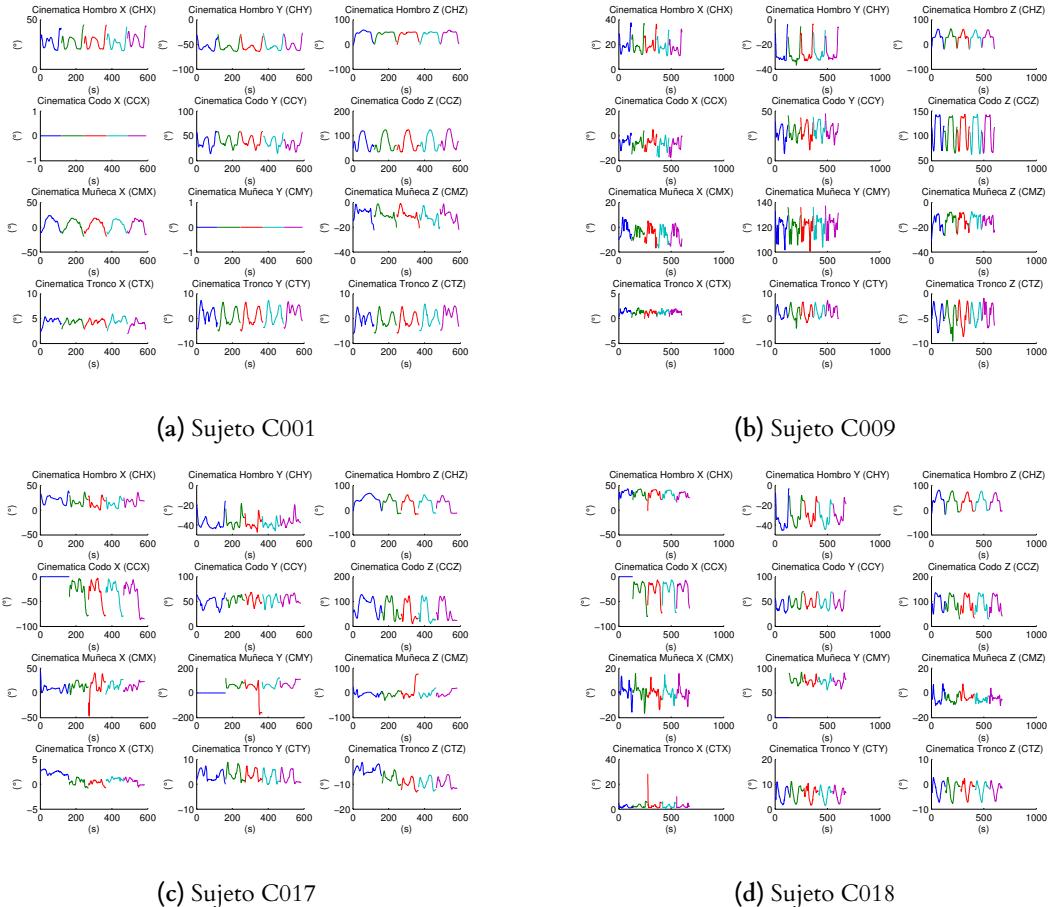


Figura B.3: Concatenación de las 5 iteraciones de las señales de Cinemática (Escenario de Sujeto Único – Controles, $F_m = 20$ Hz)

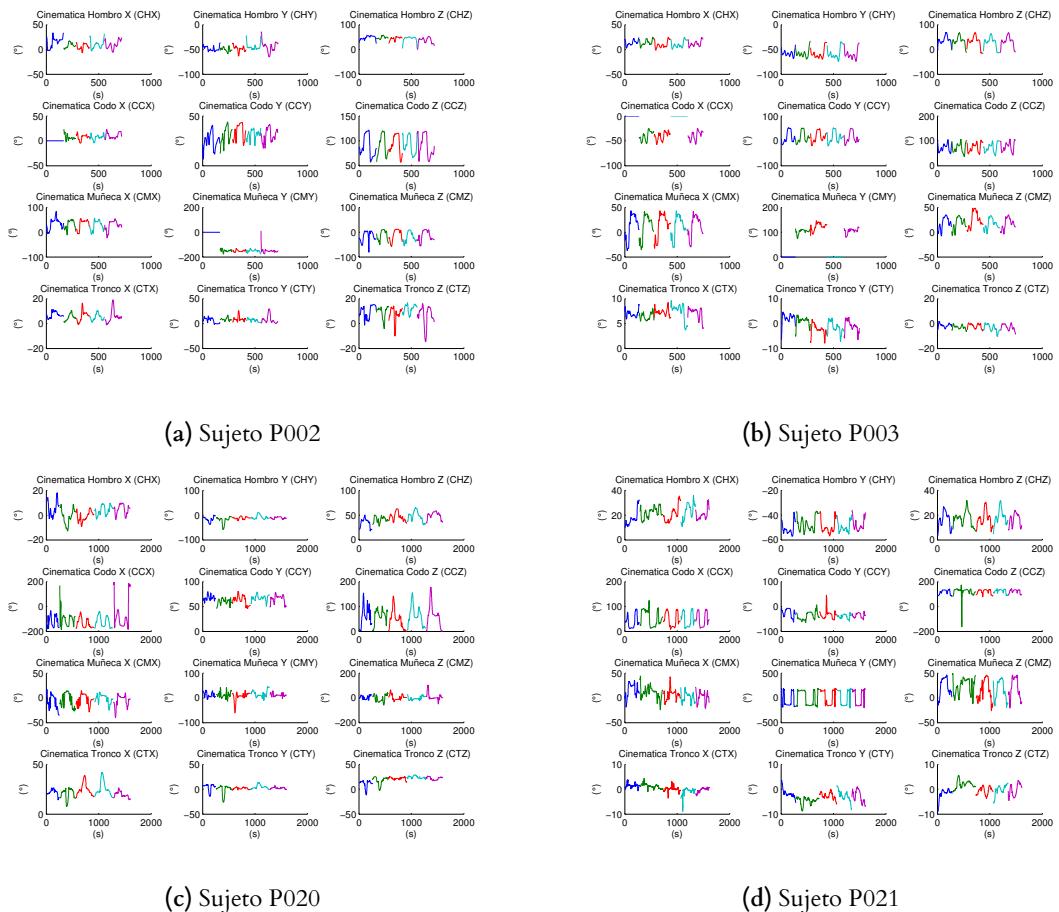


Figura B.4: Concatenación de las 5 iteraciones de las señales de Cinemática (Escenario de Sujeto Único – Pacientes, $F_m = 20$ Hz)

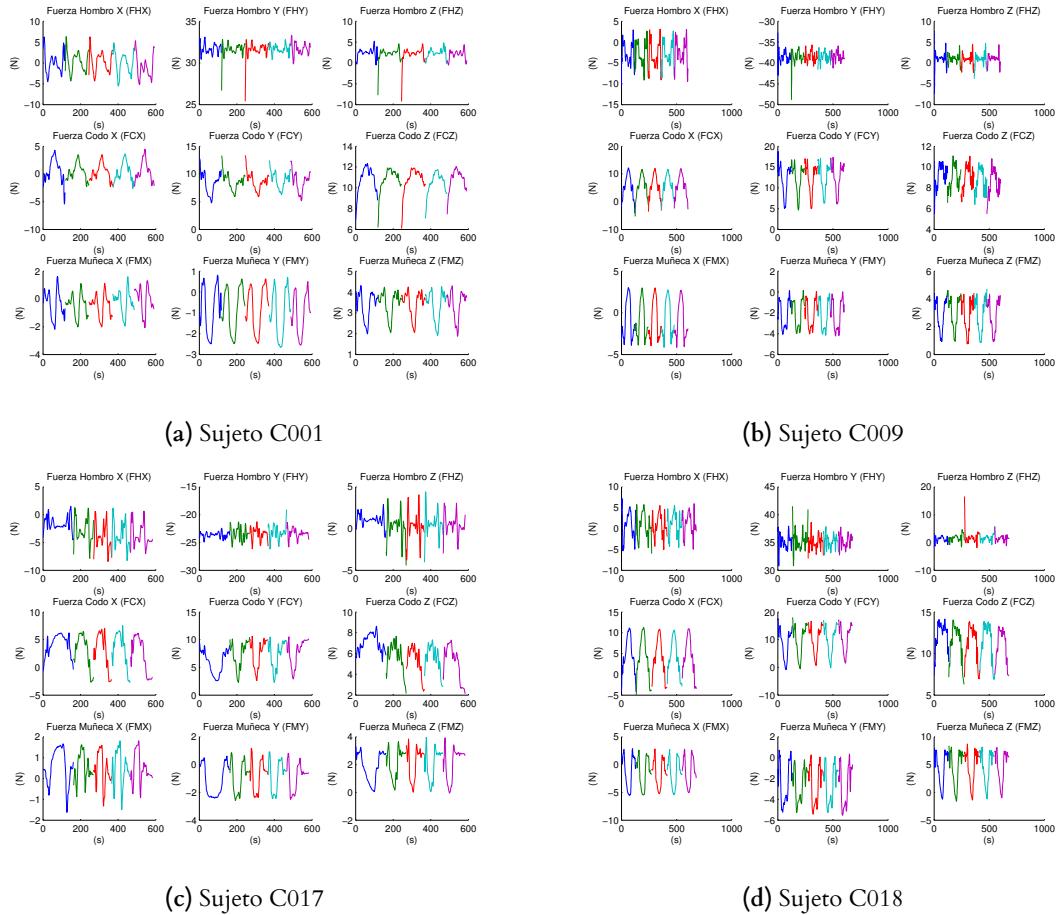


Figura B.5: Concatenación de las 5 iteraciones de las señales de Fuerza (Escenario de Sujeto Único – Controles, $F_m = 20$ Hz)

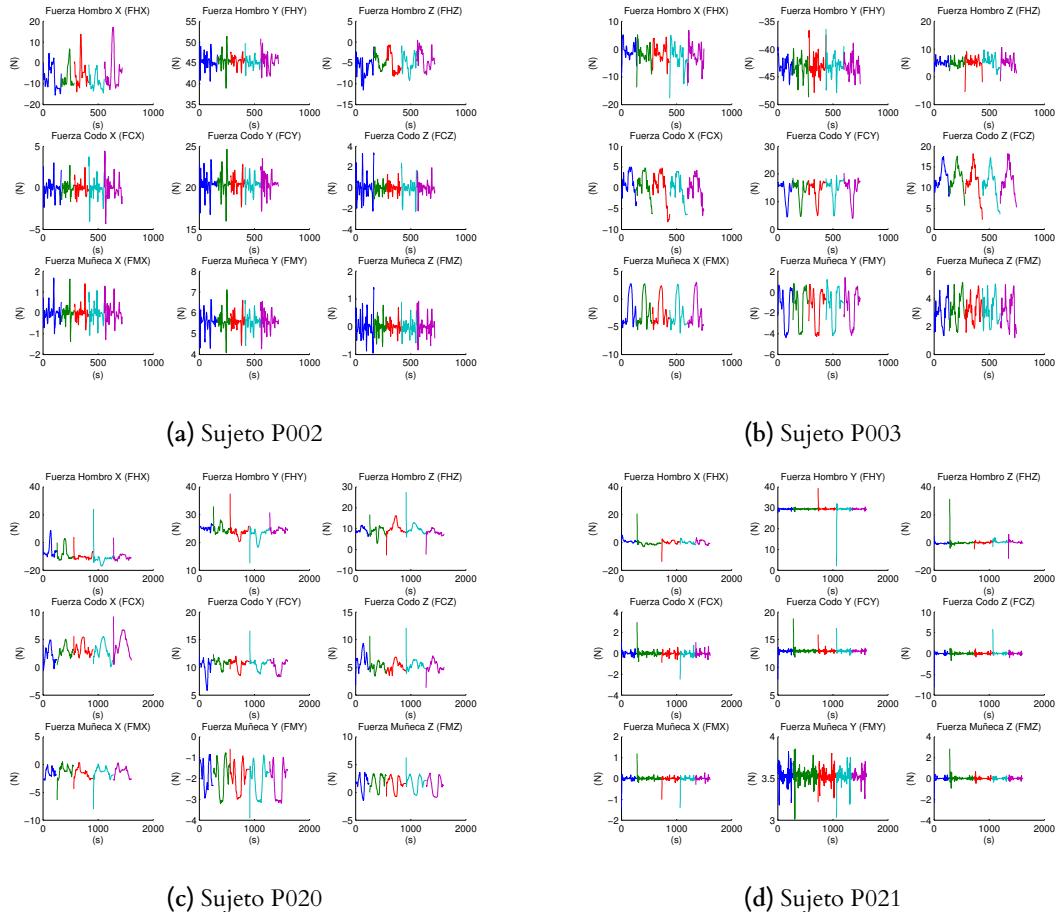


Figura B.6: Concatenación de las 5 iteraciones de las señales de Fuerza (Escenario de Sujeto Único – Pacientes, $F_m = 20$ Hz)

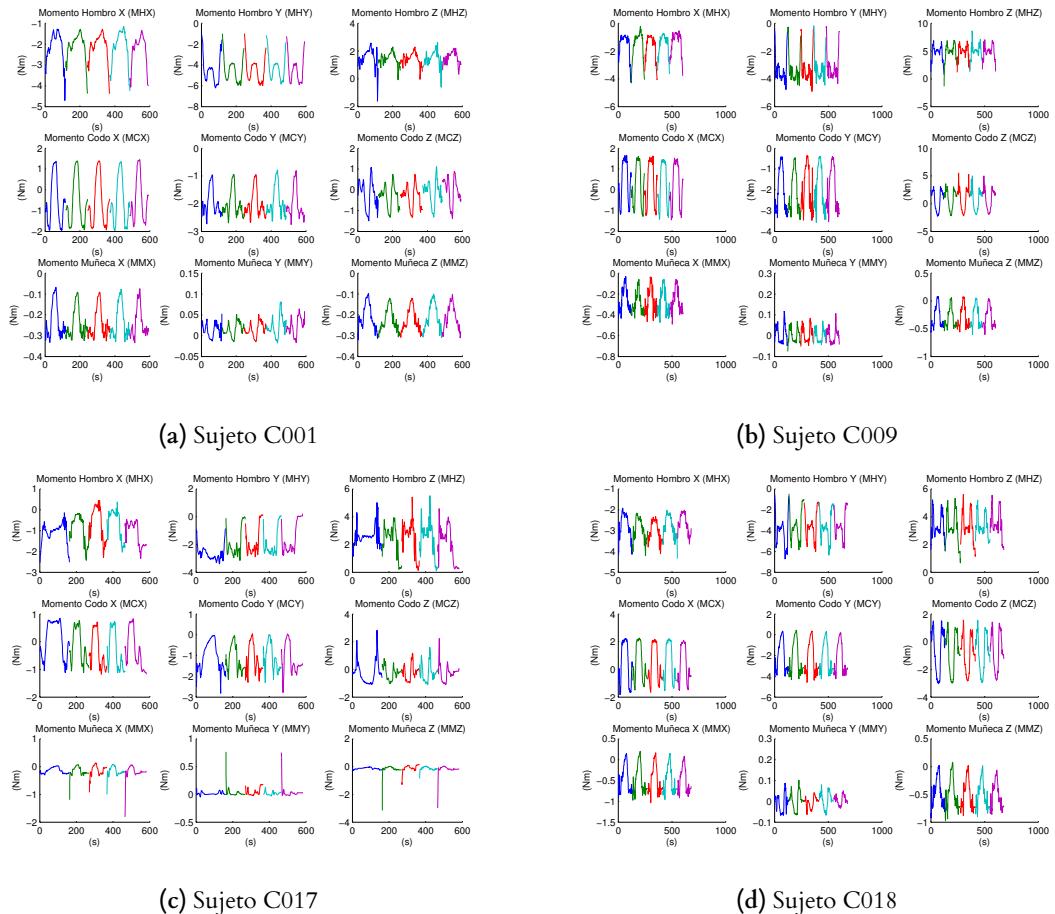


Figura B.7: Concatenación de las 5 iteraciones de las señales de Momento (Escenario de Sujeto Único – Controles, $F_m = 20$ Hz)

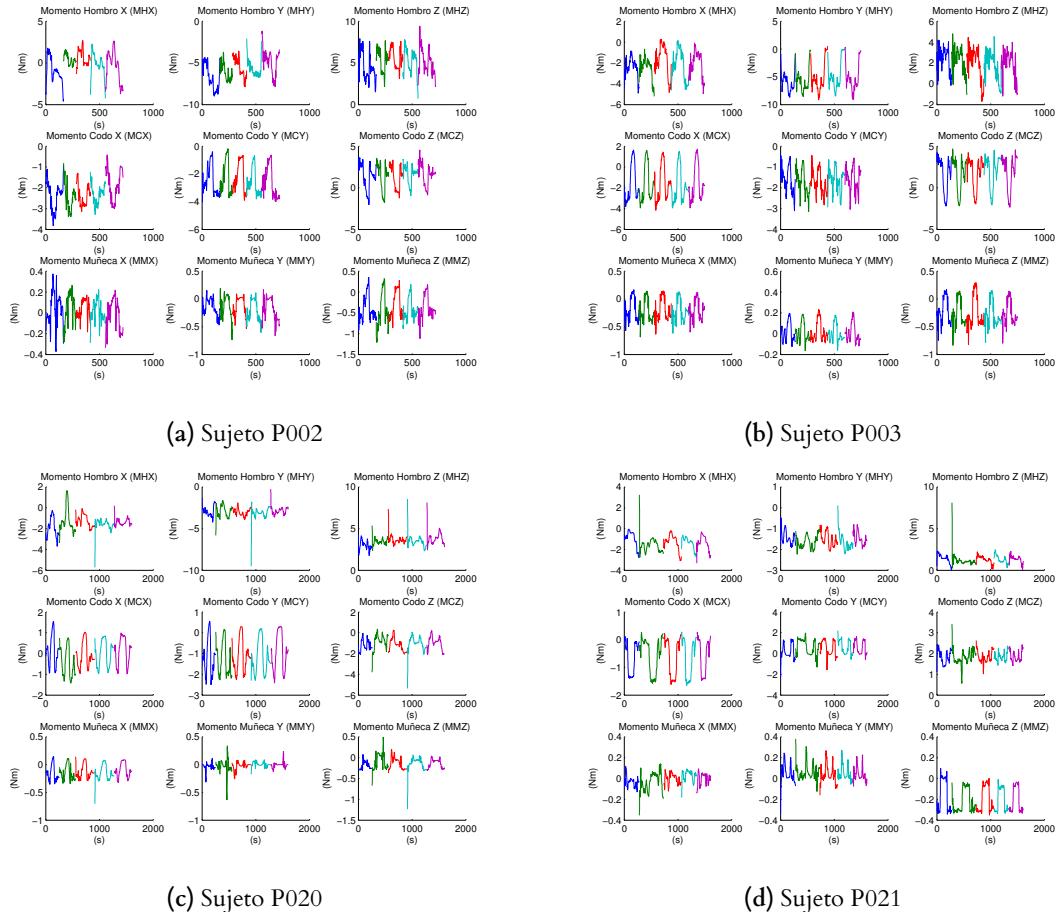
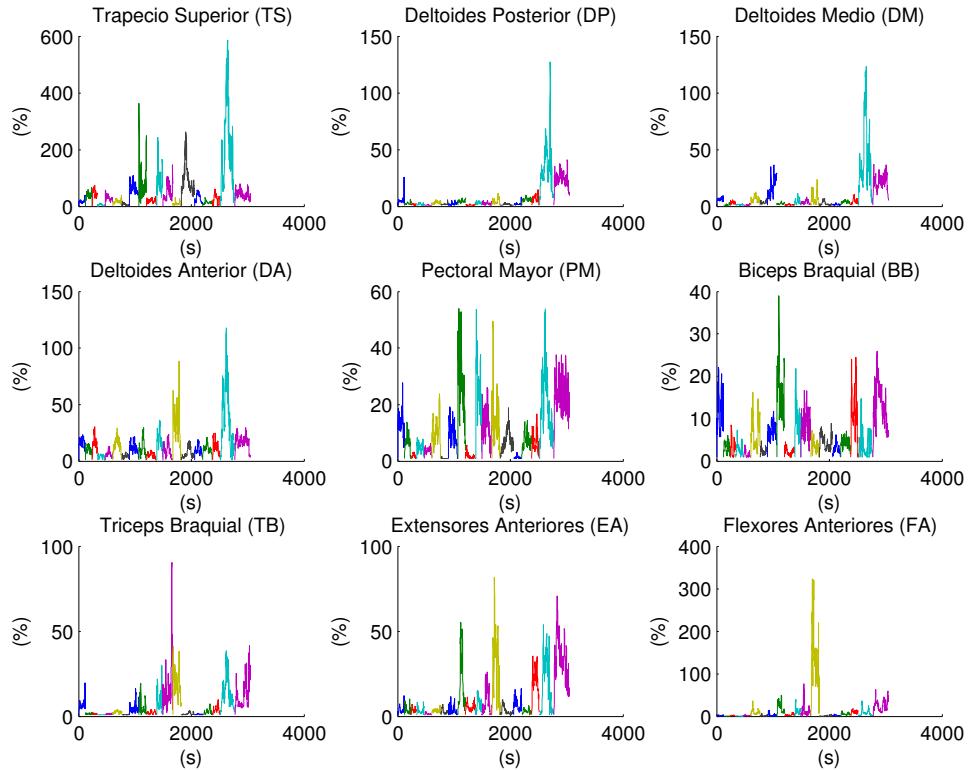
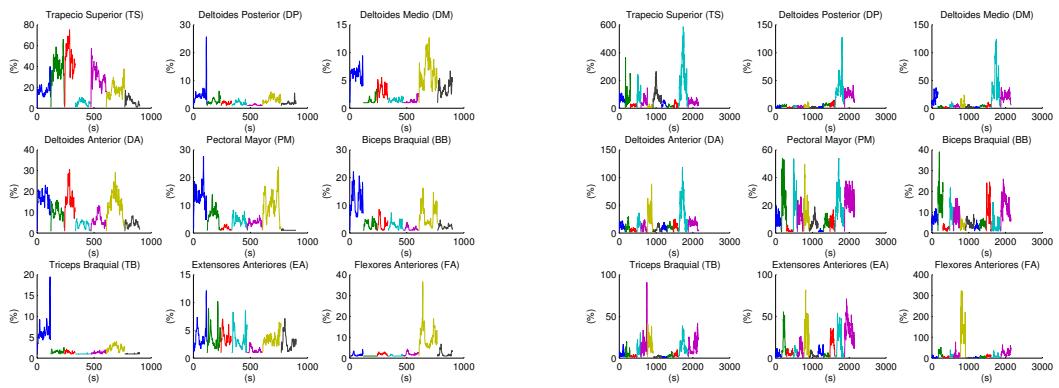


Figura B.8: Concatenación de las 5 iteraciones de las señales de Momento (Escenario de Sujeto Único – Pacientes, $F_m = 20$ Hz)



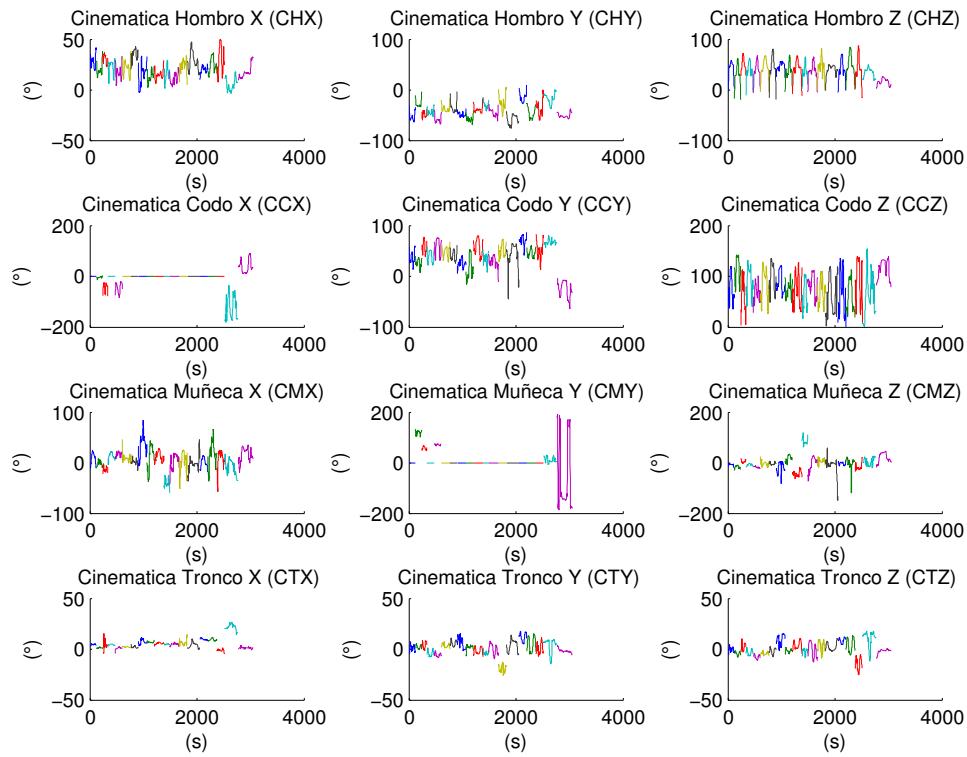
(a) Población completa (los 7 Controles y 12 Pacientes)



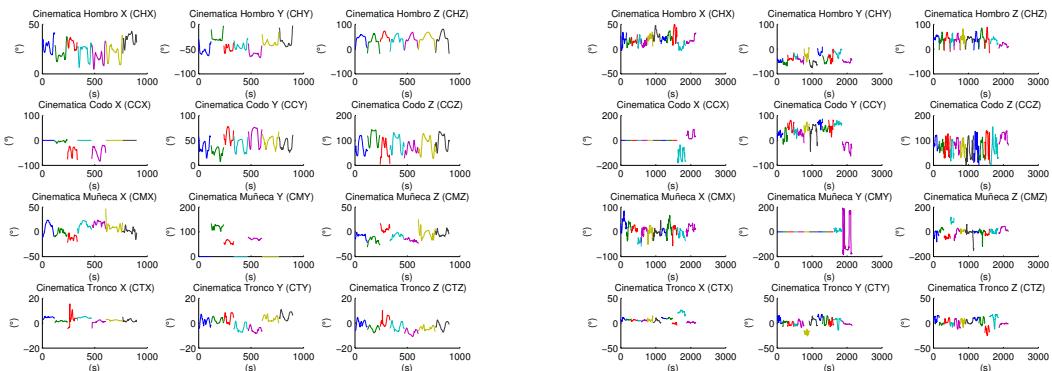
(b) Solo Controles

(c) Solo Pacientes

Figura B.9: Concatenación de las señales de Activación Normalizada (Escenario de Sujetos Múltiples, $F_m = 20$ Hz). El orden de los sujetos se ha dispuesto empezando por los 7 controles (C001, C009, C011, C013, C015, C017 y C018) y siguiendo con los 12 pacientes (P002, P003, P005, P006, P007, P008, P010, P012, P016, P019, P020 y P021)



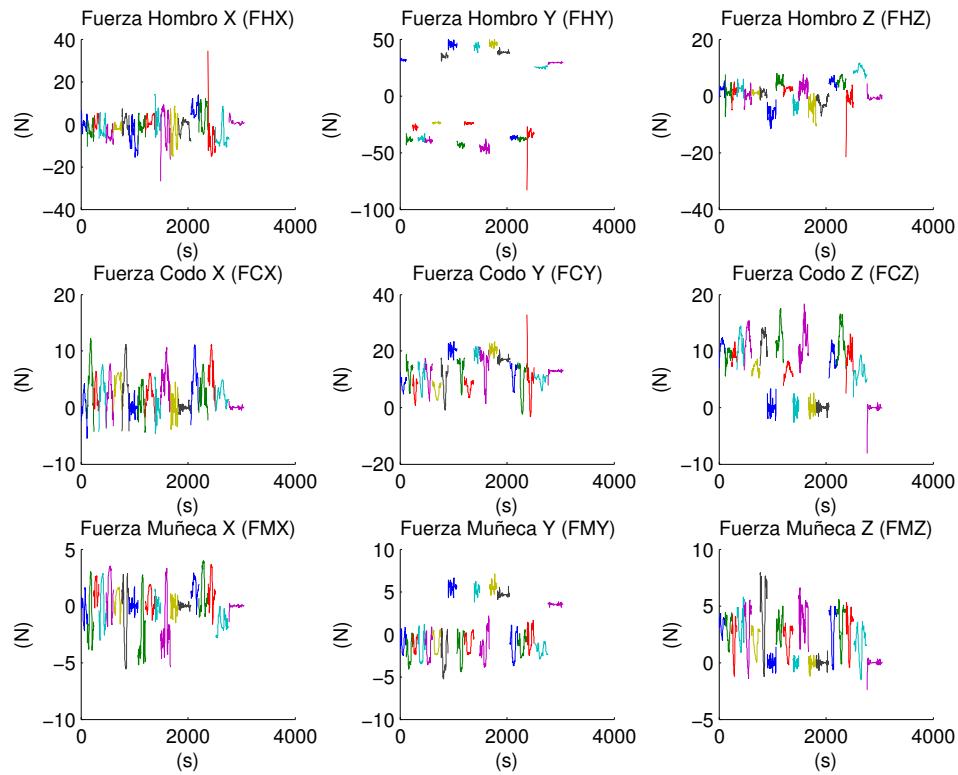
(a) Población completa (los 7 Controles y 12 Pacientes)



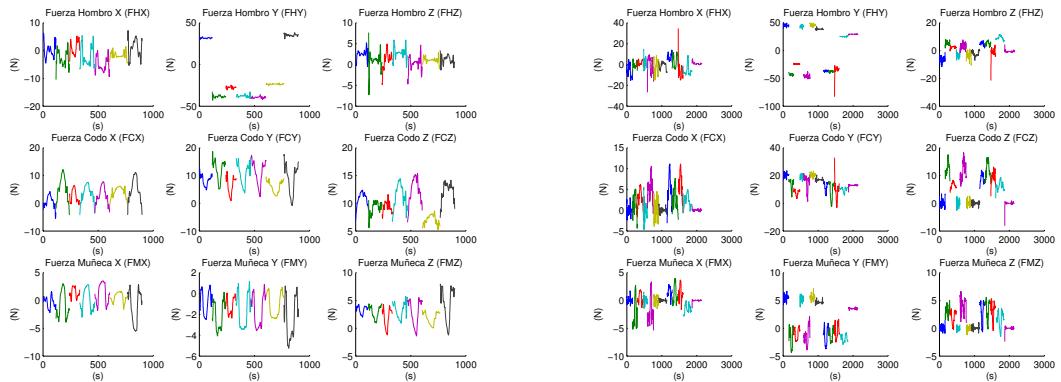
(b) Solo Controles

(c) Solo Pacientes

Figura B.10: Concatenación de las señales de Cinemática (Escenario de Sujetos Múltiples, $F_m = 20$ Hz). El orden de los sujetos se ha dispuesto empezando por los 7 controles (C001, C009, C011, C013, C015, C017 y C018) y siguiendo con los 12 pacientes (P002, P003, P005, P006, P007, P008, P010, P012, P016, P019, P020 y P021)



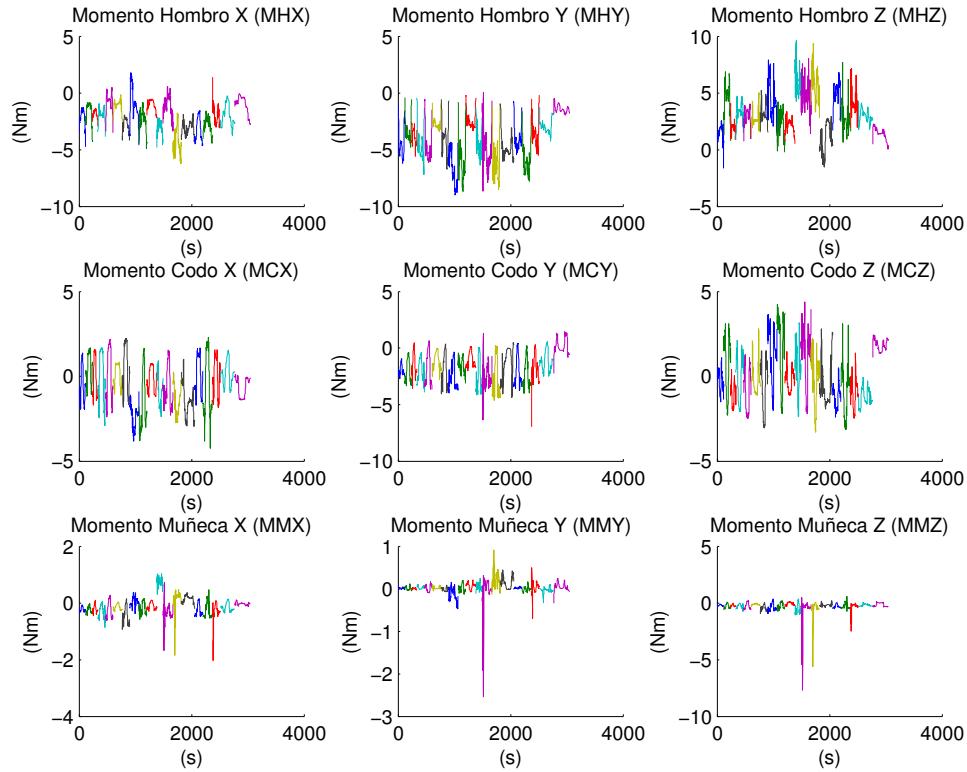
(a) Población completa (los 7 Controles y 12 Pacientes)



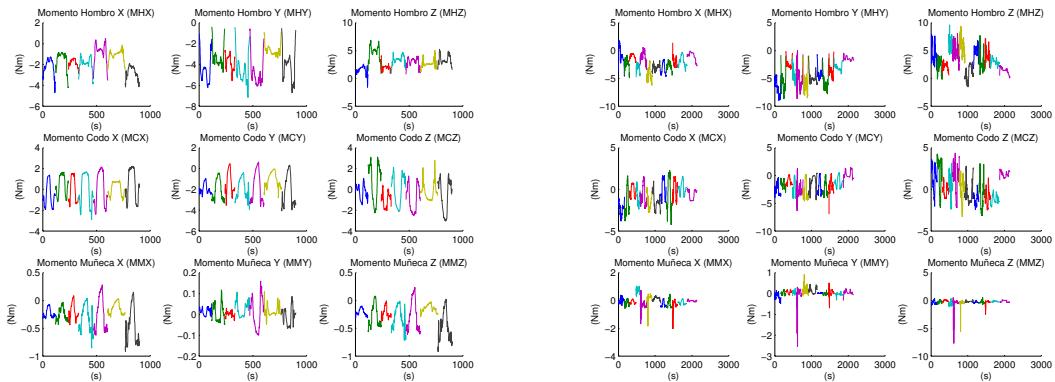
(b) Solo Controles

(c) Solo Pacientes

Figura B.11: Concatenación de las señales de Fuerza (Escenario de Sujetos Múltiples, $F_m = 20$ Hz). El orden de los sujetos se ha dispuesto empezando por los 7 controles (C001, C009, C011, C013, C015, C017 y C018) y siguiendo con los 12 pacientes (P002, P003, P005, P006, P007, P008, P010, P012, P016, P019, P020 y P021)



(a) Población completa (los 7 Controles y 12 Pacientes)



(b) Solo Controles

(c) Solo Pacientes

Figura B.12: Concatenación de las señales de Momento (Escenario de Sujetos Múltiples, $F_m = 20$ Hz). El orden de los sujetos se ha dispuesto empezando por los 7 controles (C001, C009, C011, C013, C015, C017 y C018) y siguiendo con los 12 pacientes (P002, P003, P005, P006, P007, P008, P010, P012, P016, P019, P020 y P021)

APÉNDICE C

Reducción de dimensionalidad en los datos de entrada: Self-organizing Map (SOM)

En lugar de encontrarnos ante un algoritmo de reducción de la dimensionalidad propiamente dicho, los [mapas auto-organizados](#) son [ANN](#) de aprendizaje no supervisado con aspecto competitivo, es decir, premian a aquella neurona, y sus vecinas, con menor distancia a la muestra presente en la entrada de la red [24]. De esta forma las neuronas se reconfiguran automáticamente durante la fase de aprendizaje siguiendo las características de las muestras de entrada para obtener finalmente la U-Matrix [42], un mapa de las distancias existentes entre las diferentes neuronas y sus vecinas. Una vez ya en fase de producción, la red agrupará las nuevas muestras en diferentes clústeres según las características aprendidas.

En la figura C.1 se muestra un ejemplo de los resultados obtenidos por [SOM](#) para la señal de Activación Normalizada en el escenario ESM, aunque dichos resultados son similares a los obtenidos con el resto de señales de ambos escenarios y las conclusiones, por tanto, extrapolables. Concretando, la figura C.1a corresponde a la U-Matrix resultante del proceso de aprendizaje, mientras que el resto de figuras muestran mapas etiquetados con el identificador más frecuentemente detectado por cada neurona, siendo este el número del sujeto (figura C.1b), su sexo (figura C.1c) o el tipo, es decir, si es control o paciente (figura C.1d).

Desafortunadamente, las regiones que se pueden llegar a apreciar en la U-Matrix no están claramente definidas y sus distancias con sus vecinas tampoco son destacables. Si acaso, en la zona de esquina inferior derecha aparecen ciertas regiones que distinguirían al sujeto P008 de sus vecinos P019 y P007, pero también establece diferencias entre partes de la propia señal del sujeto P008. Consiguientemente, se puede establecer que no es factible utilizar una red [SOM](#) como clasificador para este tipo de entradas, siendo precisamente la naturaleza analógico-temporal de la señal la hipótesis para la falta de resultados.

Sin embargo, la verdadera razón por la que [SOM](#) ha sido incluido como un método de reducción de dimensionalidad en los datos de entrada es una consecuencia de las características de la U-Matrix producto del hecho de que se le pueden asignar a las distintas variables o componentes de la entrada sus contribuciones a la distancia final entre neuronas presente en el mapa. De esta manera se pueden detectar aquellas componentes que obtengan respuestas similares, pudiendo ser eliminadas directamente al ser redundante su contribución a la información presente en las entradas de la red.

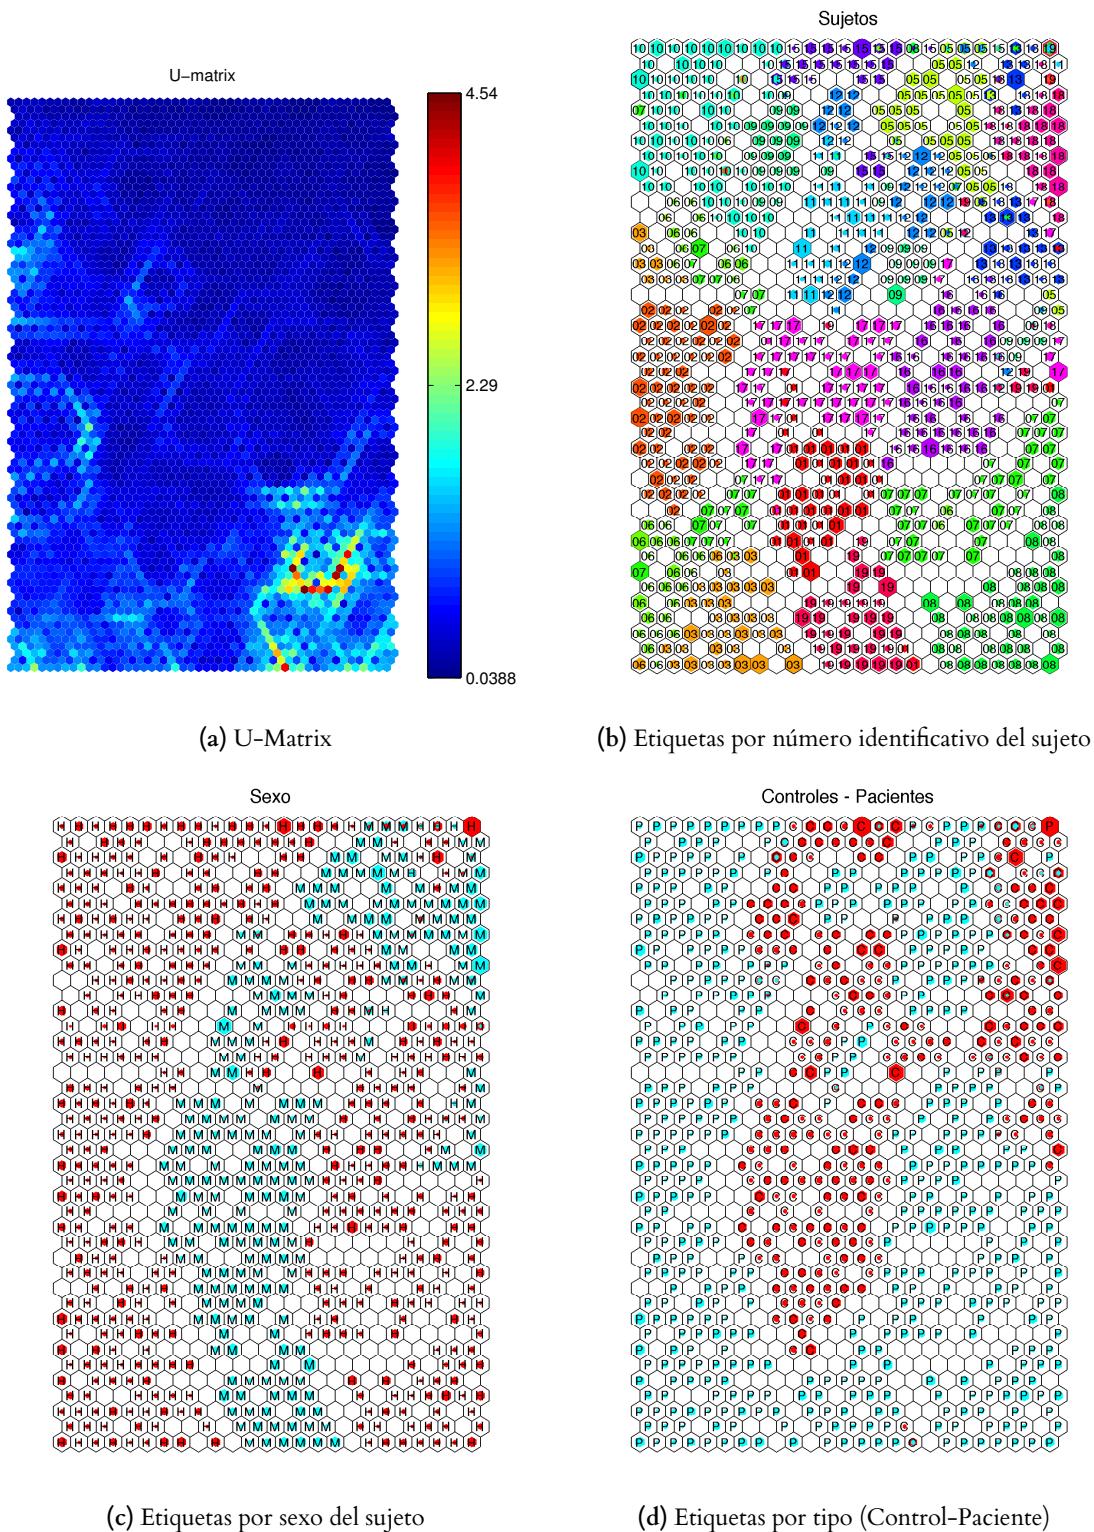


Figura C.1: U-Matrix de la señal de Activación Normalizada de toda la población del escenario ESM ($F_m = 20$ Hz) junto con mapas de clasificación en función del identificador más frecuente por neurona (número del sujeto, sexo y tipo de sujeto)

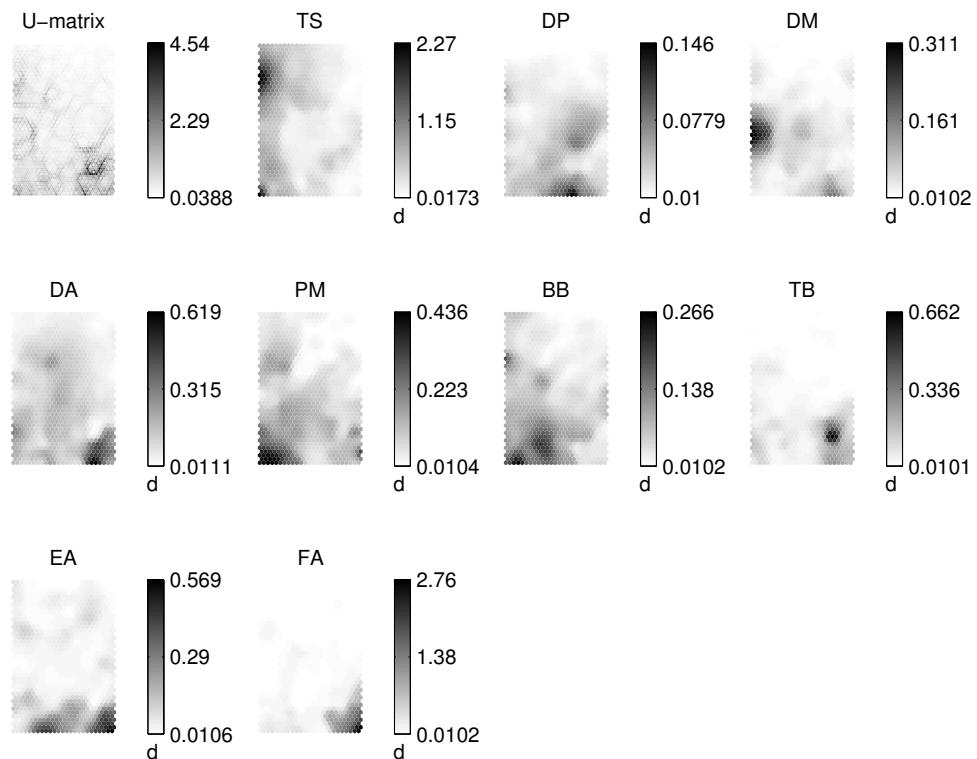


Figura C.2: Norma, por componentes, de la distancia entre neuronas de la señal de Activación Normalizada de toda la población del escenario ESM ($F_m = 20$ Hz)

La figura C.2 muestra la contribución de cada componente a la U-Matrix final para el ejemplo anterior con la Activación Normalizada. Desafortunadamente no se aprecian similitudes como para determinar la existencia de componentes redundantes o, en este caso, músculos con similares cargas de trabajo en la realización del movimiento, situación que se repite con el resto de escenarios y entradas. Definitivamente, aunque SOM no haya ayudado a reducir la dimensión de las variables de entrada, al menos nos confirma que su selección no estaba mal encaminada.

APÉNDICE D

Predicción del momento articular: Modelo de Hill

La relación entre la señal sEMG producida por un músculo y la fuerza realizada por este es no lineal y depende de gran cantidad de variables y condiciones. Entre los distintos factores tenemos el sistema de captura de la señal, la cantidad de fibras musculares, su velocidad de contracción y si esta es de tipo isométrica o isotónica, es decir, si el músculo mantiene constante su longitud al contraerse o si lo que se mantiene constante es la tensión en el músculo, siendo la longitud la que se modifica alargándose o acortándose.

Los primeros modelos musculares basados en sus propiedades viscoelásticas fueron propuestos por primera vez por Hill en 1938 [17]. Ya de una época más actual destaca la formulación mucho más refinada de Winters [45] pero, continuamente, surgen estudios que mejoran distintos aspectos del modelo [7, 8, 10]. En su forma más básica cada músculo es modelado por los tres elementos representados en la figura D.1. Por un lado la parte activa del músculo, la fibra muscular, se modela con un elemento contráctil (CE). Por el otro, su parte pasiva se modela añadiéndose dos elementos elásticos, uno en serie (SE) y otro en paralelo (PE), representando respectivamente el tendón y el tejido conjuntivo muscular (fascia, epimisio, perimisio y endomisio). Por la disposición de sus elementos sabemos que, para cualquier músculo,

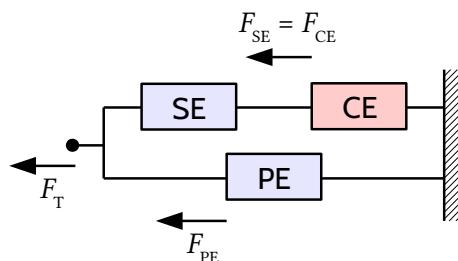


Figura D.1: Esquema del modelo de Hill de un músculo elástico mostrando el elemento contráctil (CE) y los elementos elásticos en serie (SE) y paralelo (PE) junto con sus respectivas fuerzas

la relación entre la fuerza ejercida por sus elementos y la total vendrá dada por:

$$F_{CE} = F_{SE} \quad (D.1a)$$

$$F_T = F_{CE} + F_{PE} \quad (D.1b)$$

Una explicación detallada del funcionamiento del modelo no entra dentro del contexto del presente TFM, pero un somero listado de alguno de sus resultados puede proporcionar una idea suficiente de su complejidad:

$$F_{CE} = F_{CE\max} f_l(L_{CE0}) f_v(V_{CE0}(u, L_{CE0}, \alpha)) u \quad (D.2)$$

$$F_{SE} = \left(\frac{F_{\max}(F_{CE\max})}{e^{S_{SE}} - 1} \right) \left(e^{\left(\frac{S_{SE}}{\Delta L_{\max}(L_{Ts})} \Delta L(L_{Ts}) \right)} - 1 \right) \quad (D.3)$$

$$F_{PE} = \left(\frac{F_{\max}(F_{CE\max})}{e^{S_{PE}} - 1} \right) \left(e^{\left(\frac{S_{PE}}{\Delta L_{\max}(L_{\max}, L_{CE0}, L_{Ts})} \Delta L(L_{CE0}, L_{Ts}) \right)} - 1 \right) \quad (D.4)$$

donde u es la activación muscular normalizada y F_{\max} , que es la fuerza máxima ejercida por el músculo, depende de la fuerza máxima de su elemento contráctil $F_{CE\max}$. También se ha tenido en cuenta la relación entre la fuerza ejercida por el elemento contráctil con la longitud activa de la fibra f_l , que depende adicionalmente de la longitud de la fibra óptima L_{CE0} , así como con la velocidad de contracción del músculo f_v . Esta última depende a su vez de la máxima velocidad del elemento contráctil con nivel de activación máximo V_{CE0} , la cual depende, a sí mismo, del porcentaje de fibras contráctiles rápidas α entre otros parámetros. Por otro lado, S_{SE} y S_{PE} son los factores de forma de los elementos correspondientes, L_{Ts} es la longitud de distensión del tendón en reposo, ΔL es la variación de longitud del elemento con respecto al reposo y ΔL_{\max} su variación máxima, siendo su longitud máxima L_{\max} .

Como se puede comprobar, la cantidad de parámetros es realmente elevada y ha de calibrarse para cada sujeto mediante un proceso de optimización con los datos de una iteración del movimiento de entrenamiento. Si se quiere conocer el momento neto en una articulación en cuyo movimiento intervengan M músculos, deberán modelarse todos ellos para conocer la fuerza total ejercida por cada uno F_{Tm} y las longitudes de los distintos huesos afectados. De esta manera, el momento neto de Hill para el k -ésimo grado de libertad (DoF), $\hat{\tau}_{Hk}$, vendrá dado por la fuerza que ejercen cada uno de los M músculos modelados F_{Tm} y el brazo de momento de cada uno ellos en relación con el k -ésimo DoF $r_{m,k}$:

$$\hat{\tau}_{Hk} = \sum_{m=1}^M F_{Tm} r_{m,k} \quad (D.5)$$

Como representación del rendimiento obtenido mediante el modelo de Hill optimizado propuesto por BUENO et ál. [8] se representa en la figura D.2 las predicciones del momento articular para hombro (componente MHX) y codo (componente MCZ) de 4 iteraciones del movimiento calculadas con el modelo calibrado por la 1.^a iteración. Del mismo modo se reproducen de forma más detallada en la figura D.3 las predicciones obtenidas para el paciente P002, pudiéndose comprobar el peor resultado obtenido en este caso con la predicción de la componente del hombro sobretodo.

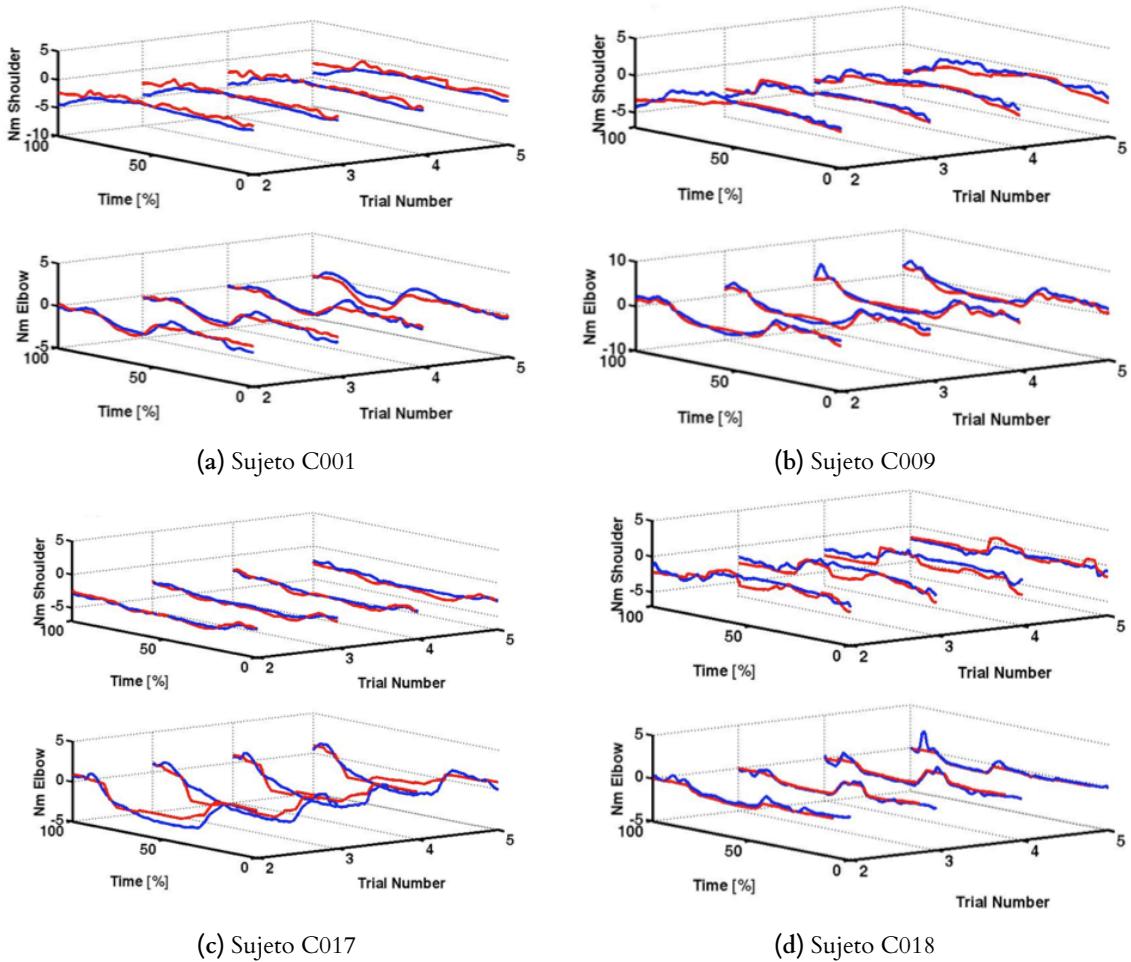


Figura D.2: Predicciones de validación por el modelo de Hill del momento articular en hombro (componente MHX) y codo (componente MCZ) producido en 4 iteraciones del movimiento realizadas por los sujetos de control. Se muestran, normalizadas en el tiempo, las distintas predicciones $\hat{\tau}_{Hk}$ en rojo con el correspondiente momento de referencia τ_{IDk} en azul

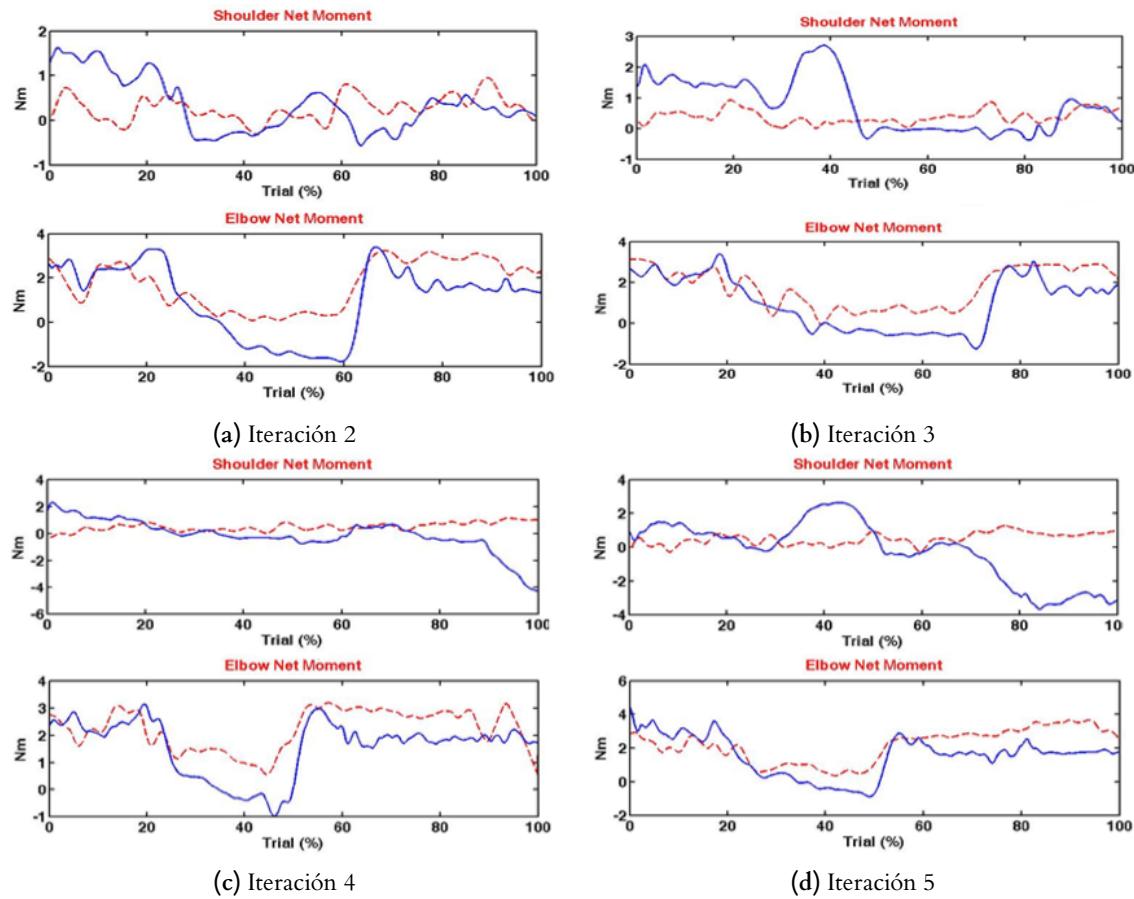


Figura D.3: Predicciones de validación por el modelo de Hill del momento articular en hombro (componente MHX) y codo (componente MCZ) producido en 4 iteraciones del movimiento realizadas por el paciente P002. Se muestran, normalizadas en el tiempo, las distintas predicciones $\hat{\tau}_{Hk}$ en rojo con el correspondiente momento de referencia τ_{IDk} en azul

APÉNDICE E

Predicciones de validación del escenario ESU

Una aproximación mediante parámetros estadísticos para la valoración de los resultados obtenidos por un estimador es indispensable por la objetividad proporcionada. Sin embargo, para alcanzar una comprensión más completa de su funcionamiento, también es interesante inspeccionar visualmente los resultados de dichas estimaciones. Es por ello que a continuación se muestran los resultados obtenidos durante la fase de validación de los diversos entrenamientos realizados en el escenario ESU para las predicciones del momento en las distintas articulaciones por los tres modelos seleccionados una vez en su configuración propuesta definitiva. Como entradas se han empleado las señales de Activación Normalizada y Cinemática muestreadas a $F_m = 20$ Hz. En todos los casos, al tratarse del escenario ESU, cada una de las iteraciones mostradas ha sido estimada por un modelo entrenado con los datos de las otras cuatro repeticiones del movimiento de la tarea de beber de un vaso realizadas por el sujeto.

E.1 Averaged Output MLP (aoMLP)

El estimador **aoMLP** se ha configurado mediante la utilización de un ensamblaje cuya salida es una simple media de los 30 **MLP** independientes que lo componen. Cada **MLP** individual cuenta con una capa oculta de 10 neuronas intermedias, emplea SCG como algoritmo de aprendizaje y Early-Stopping con un máximo de 10 fallos de validación consecutivos para detectar las condiciones de parada evitando caer en el sobreaprendizaje.

Sujeto C001 véase la figura [E.1](#)

Sujeto C009 véase la figura [E.2](#)

Sujeto C017 véase la figura [E.3](#)

Sujeto C018 véase la figura [E.4](#)

Sujeto P002 véase la figura [E.5](#)

Sujeto P003 véase la figura [E.6](#)

Sujeto P020 véase la figura [E.7](#)

Sujeto P021 véase la figura [E.8](#)

E.2 Radial Basis Network (RBN)

En este caso, la configuración del estimador **RBN** se ha elegido manualmente tomando $s = 2^7$ como spread de las neuronas gaussianas y configurando el goal, o objetivo del algoritmo de aprendizaje, como $g = 1/21$. Recordar que este valor no se ha seleccionado rigurosamente si no por heurística, correspondiendo el 21 a la dimensión de la entrada de la red, es decir, al total de las 9 variables de Activación Normalizada y las 12 de Cinemática.

Sujeto C001 véase la figura [E.9](#)

Sujeto C009 véase la figura [E.10](#)

Sujeto C017 véase la figura [E.11](#)

Sujeto C018 véase la figura [E.12](#)

Sujeto P002 véase la figura [E.13](#)

Sujeto P003 véase la figura [E.14](#)

Sujeto P020 véase la figura [E.15](#)

Sujeto P021 véase la figura [E.16](#)

E.3 Support Vector Machine (SVM)

Por último, para la configuración del estimador **SVM** se ha empleado la formulación ϵ -**SVR** con un kernel **RBF**. Además, se ha dejado el hiperparámetro ϵ en su valor por defecto (0,001) mientras que los otros dos hiperparámetros, C y γ , se han optimizado automáticamente mediante la búsqueda de dichos valores que maximizan la estimación del rendimiento del modelo calculada por validación cruzada.

Sujeto C001 véase la figura [E.17](#)

Sujeto C009 véase la figura [E.18](#)

Sujeto C017 véase la figura [E.19](#)

Sujeto C018 véase la figura [E.20](#)

Sujeto P002 véase la figura [E.21](#)

Sujeto P003 véase la figura [E.22](#)

Sujeto P020 véase la figura [E.23](#)

Sujeto P021 véase la figura [E.24](#)

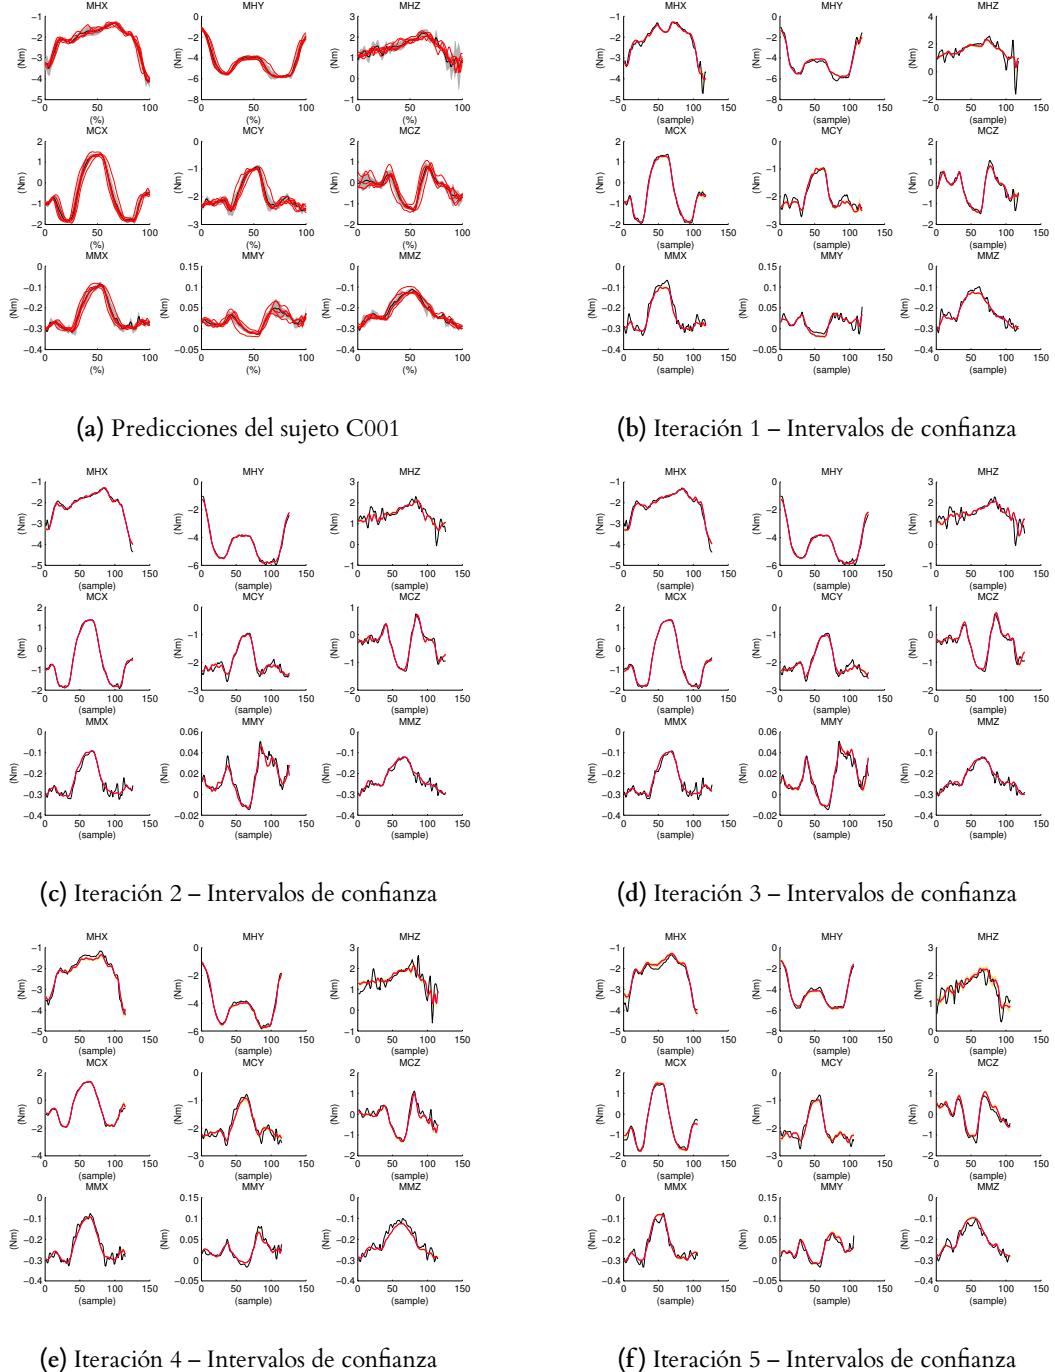


Figura E.1: Predicciones de validación por el modelo aoMLP del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto C001. El primer panel muestra en negro (sombreado gris) la media (desviación estándar) de las 5 iteraciones del momento de referencia τ_{IDk} junto con las 5 estimaciones $\hat{\tau}_{pk}$ realizadas por el modelo (en rojo). El resto de paneles comparan, separadamente para cada una de las 5 iteraciones, la predicción en rojo con la correspondiente función objetivo en negro, añadiéndose los intervalos de confianza de dicha estimación al 95 % (sombreado gris) y 99 % (sombreado amarillo) calculados punto a punto usando la distribución t de Student

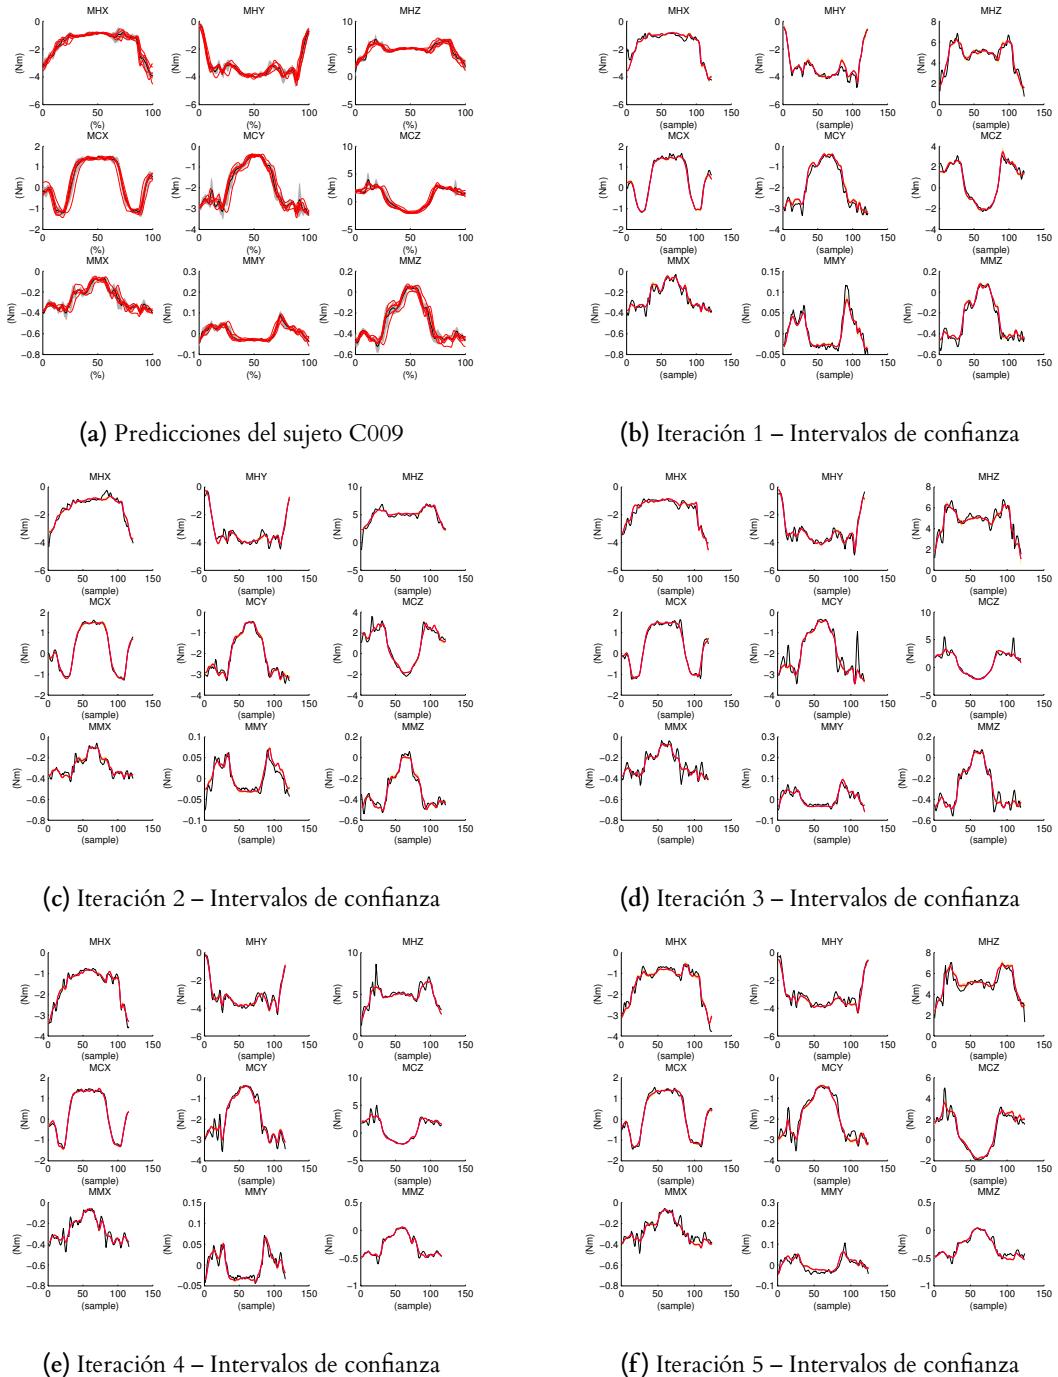


Figura E.2: Predicciones de validación por el modelo aoMLP del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto C009. El primer panel muestra en negro (sombreado gris) la media (desviación estándar) de las 5 iteraciones del momento de referencia τ_{IDk} junto con las 5 estimaciones $\hat{\tau}_{Pk}$ realizadas por el modelo (en rojo). El resto de paneles comparan, separadamente para cada una de las 5 iteraciones, la predicción en rojo con la correspondiente función objetivo en negro, añadiéndose los intervalos de confianza de dicha estimación al 95 % (sombreado gris) y 99 % (sombreado amarillo) calculados punto a punto usando la t distribución de Student

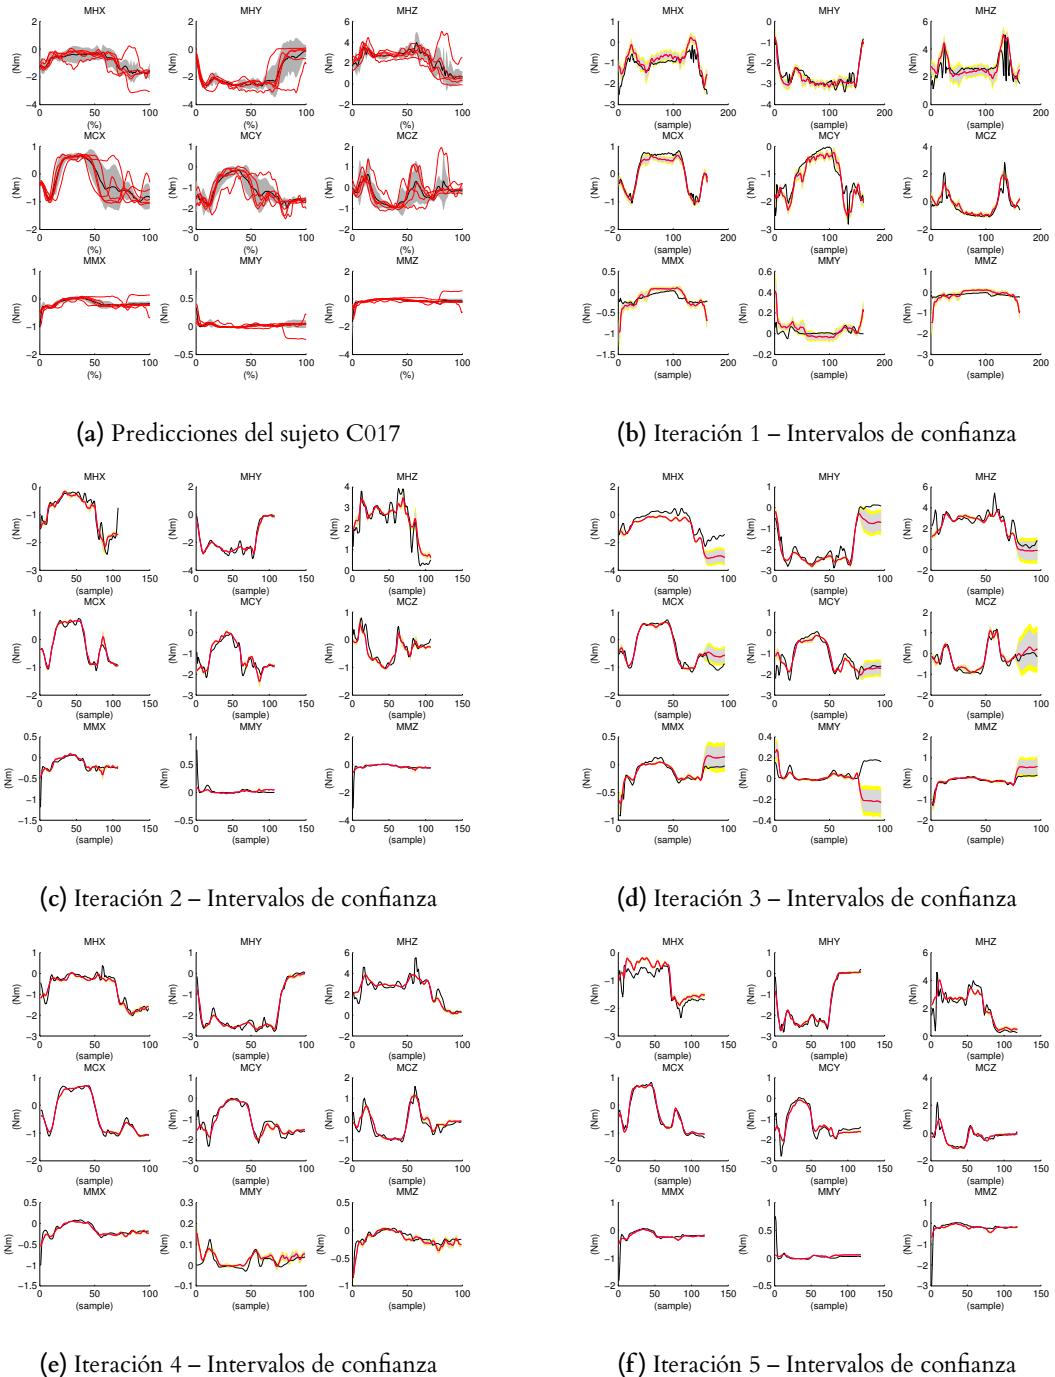


Figura E.3: Predicciones de validación por el modelo aoMLP del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto C017. El primer panel muestra en negro (sombreado gris) la media (desviación estándar) de las 5 iteraciones del momento de referencia τ_{IDk} junto con las 5 estimaciones $\hat{\tau}_{pk}$ realizadas por el modelo (en rojo). El resto de paneles comparan, separadamente para cada una de las 5 iteraciones, la predicción en rojo con la correspondiente función objetivo en negro, añadiéndose los intervalos de confianza de dicha estimación al 95 % (sombreado gris) y 99 % (sombreado amarillo) calculados punto a punto usando la t distribución de Student

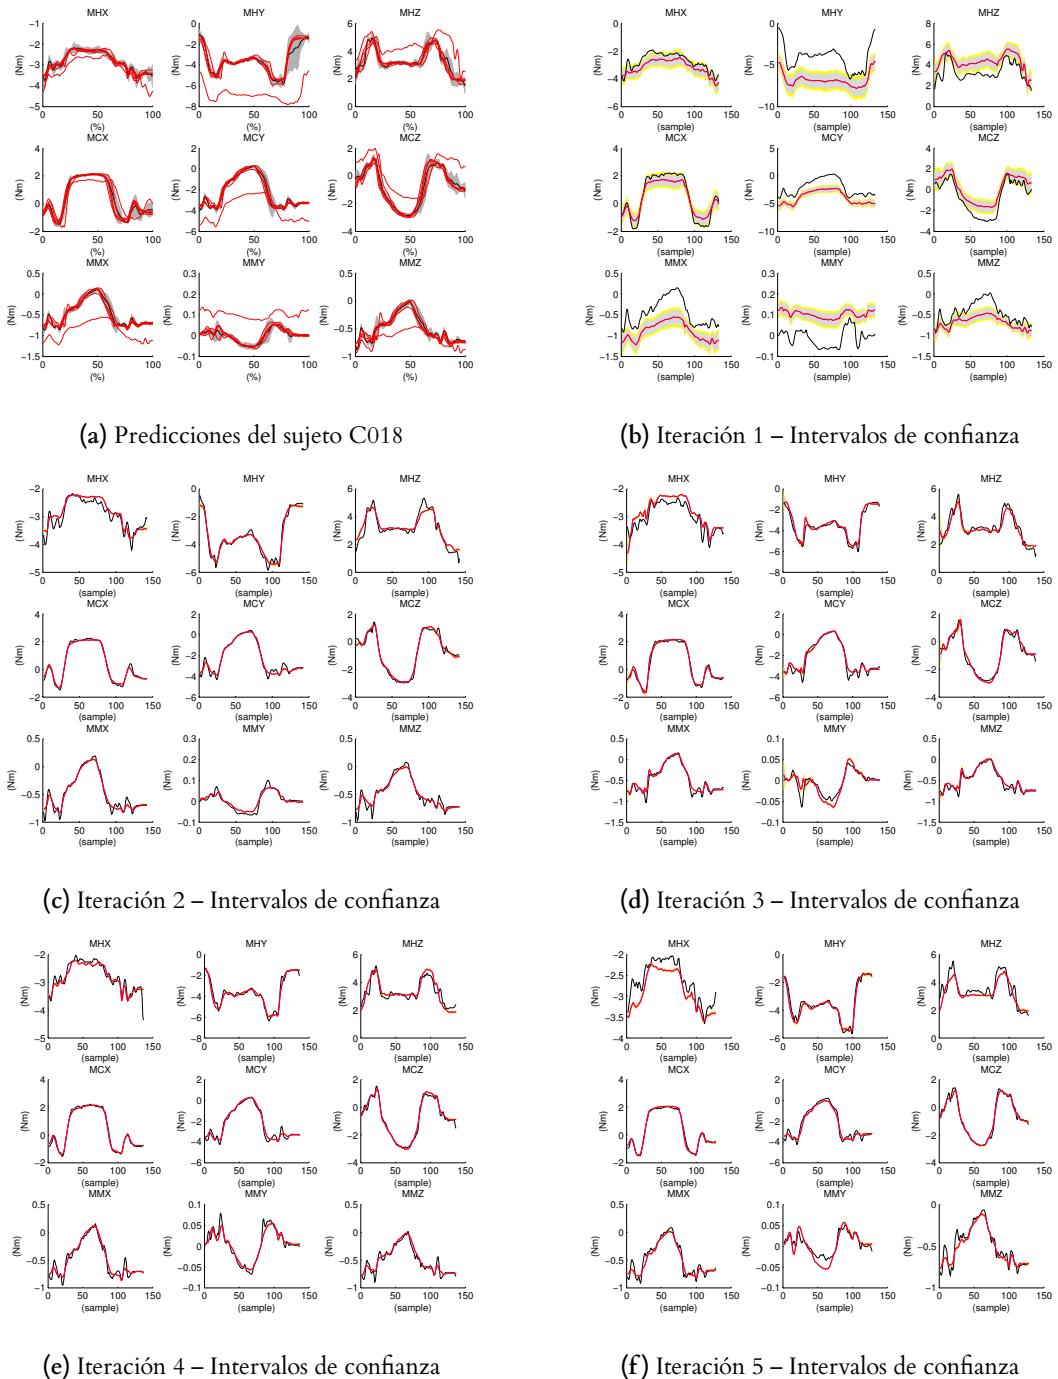


Figura E.4: Predicciones de validación por el modelo aoMLP del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto C018. El primer panel muestra en negro (sombreado gris) la media (desviación estándar) de las 5 iteraciones del momento de referencia τ_{IDk} junto con las 5 estimaciones $\hat{\tau}_{Pk}$ realizadas por el modelo (en rojo). El resto de paneles comparan, separadamente para cada una de las 5 iteraciones, la predicción en rojo con la correspondiente función objetivo en negro, añadiéndose los intervalos de confianza de dicha estimación al 95 % (sombreado gris) y 99 % (sombreado amarillo) calculados punto a punto usando la distribución t de Student

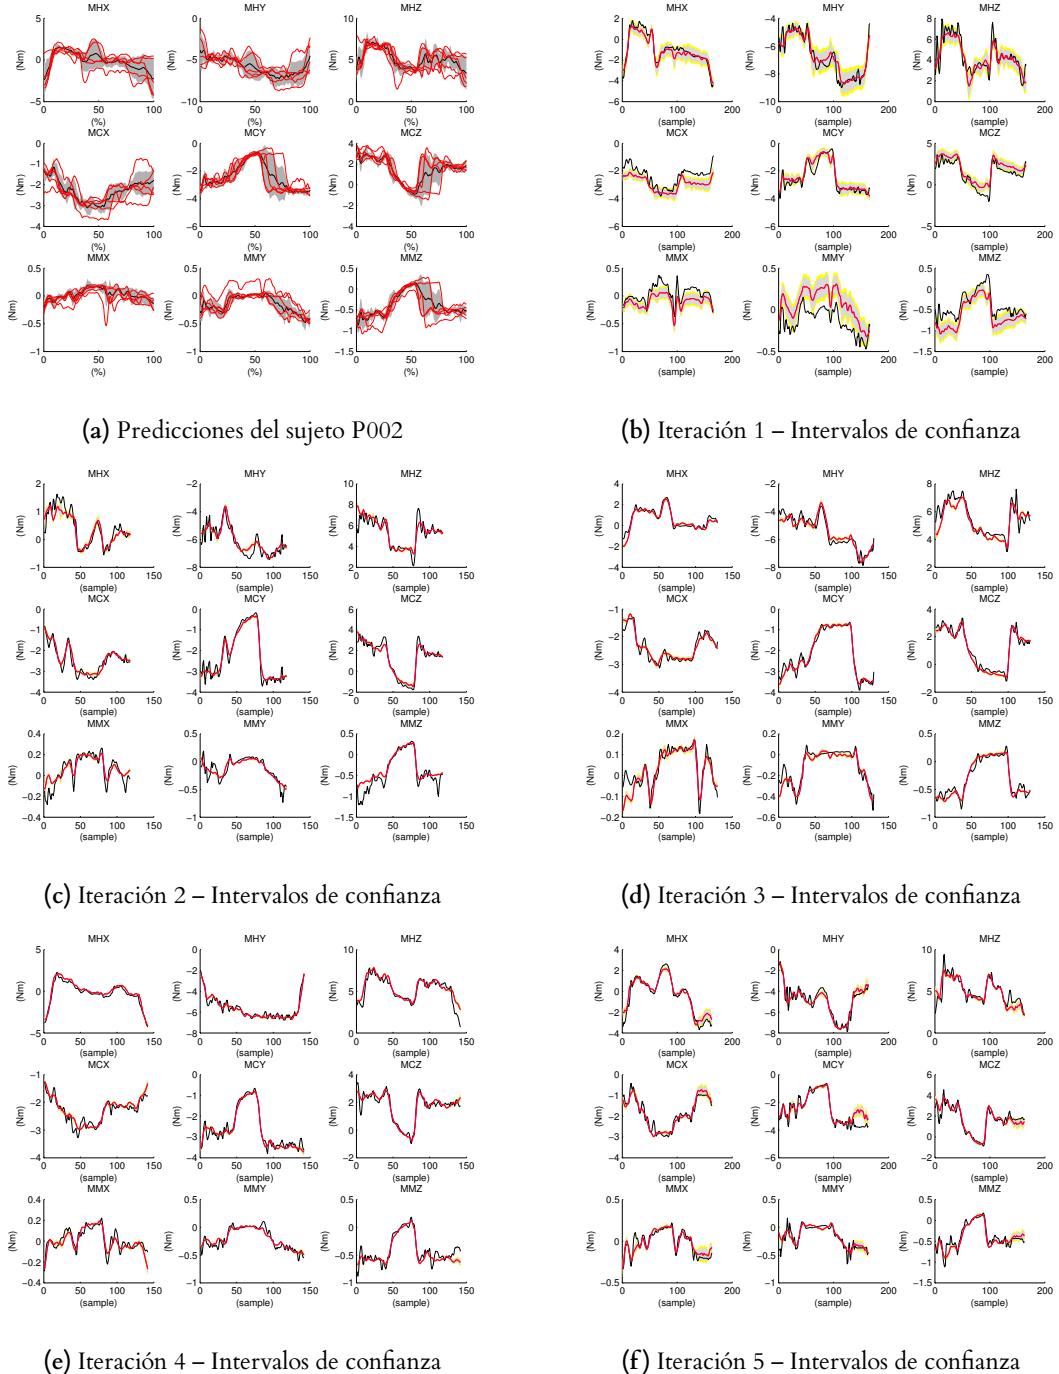


Figura E.5: Predicciones de validación por el modelo aoMLP del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto P002. El primer panel muestra en negro (sombreado gris) la media (desviación estándar) de las 5 iteraciones del momento de referencia τ_{IDk} junto con las 5 estimaciones $\hat{\tau}_{P_k}$ realizadas por el modelo (en rojo). El resto de paneles comparan, separadamente para cada una de las 5 iteraciones, la predicción en rojo con la correspondiente función objetivo en negro, añadiéndose los intervalos de confianza de dicha estimación al 95 % (sombreado gris) y 99 % (sombreado amarillo) calculados punto a punto usando la distribución t de Student

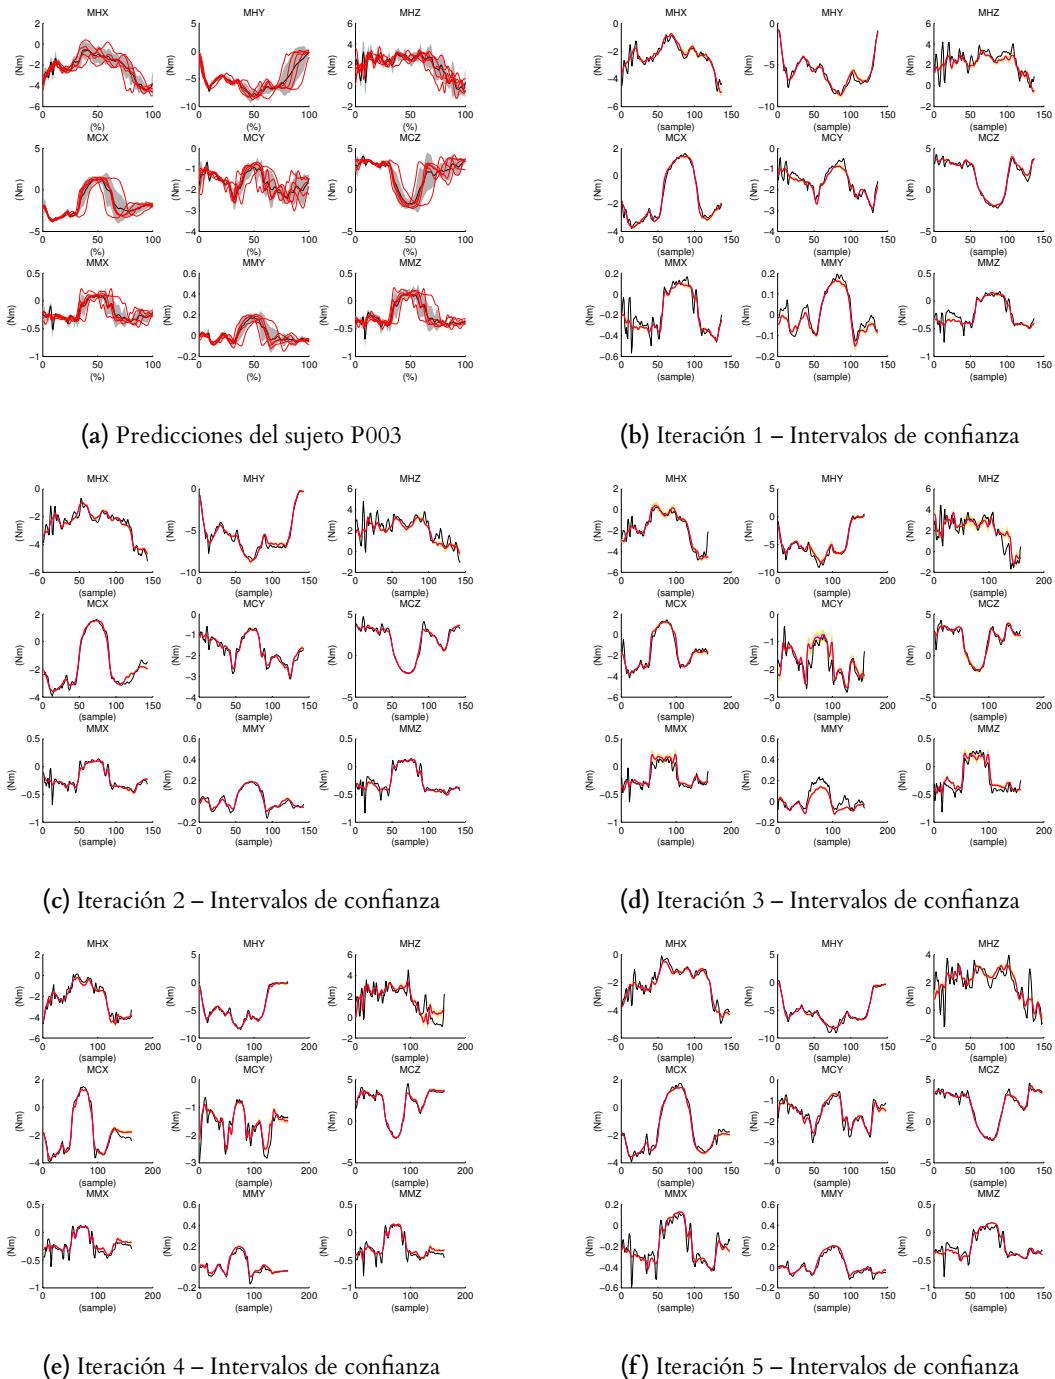


Figura E.6: Predicciones de validación por el modelo aoMLP del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto P003. El primer panel muestra en negro (sombreado gris) la media (desviación estándar) de las 5 iteraciones del momento de referencia τ_{IDk} junto con las 5 estimaciones $\hat{\tau}_{Pk}$ realizadas por el modelo (en rojo). El resto de paneles comparan, separadamente para cada una de las 5 iteraciones, la predicción en rojo con la correspondiente función objetivo en negro, añadiéndose los intervalos de confianza de dicha estimación al 95 % (sombreado gris) y 99 % (sombreado amarillo) calculados punto a punto usando la distribución t de Student

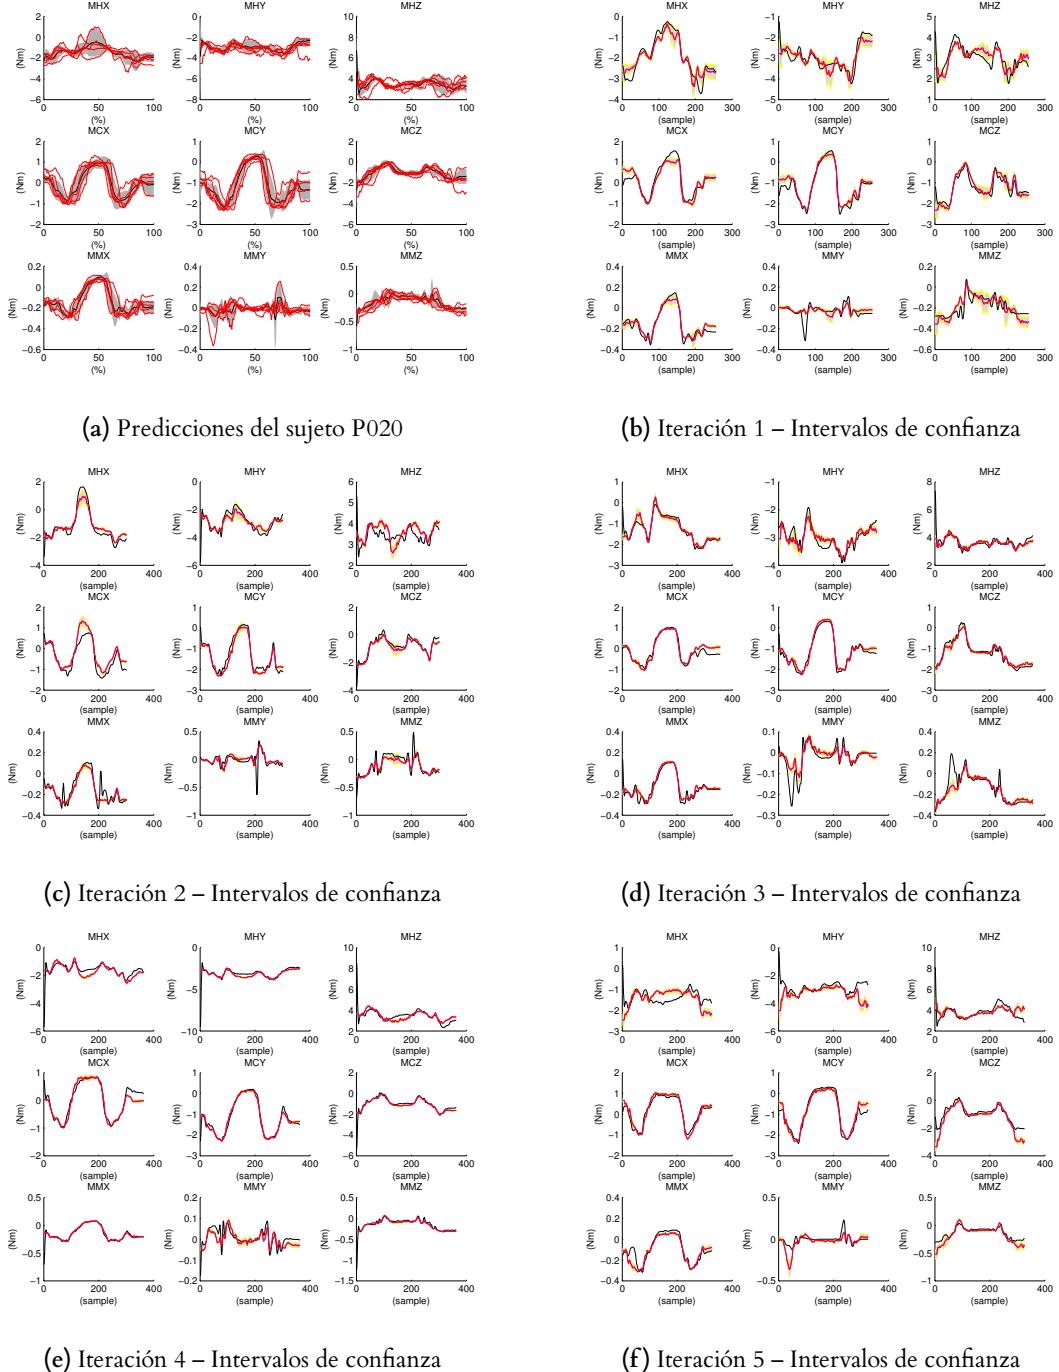


Figura E.7: Predicciones de validación por el modelo aoMLP del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto P020. El primer panel muestra en negro (sombreado gris) la media (desviación estándar) de las 5 iteraciones del momento de referencia τ_{IDk} junto con las 5 estimaciones $\hat{\tau}_{pk}$ realizadas por el modelo (en rojo). El resto de paneles comparan, separadamente para cada una de las 5 iteraciones, la predicción en rojo con la correspondiente función objetivo en negro, añadiéndose los intervalos de confianza de dicha estimación al 95 % (sombreado gris) y 99 % (sombreado amarillo) calculados punto a punto usando la distribución t de Student

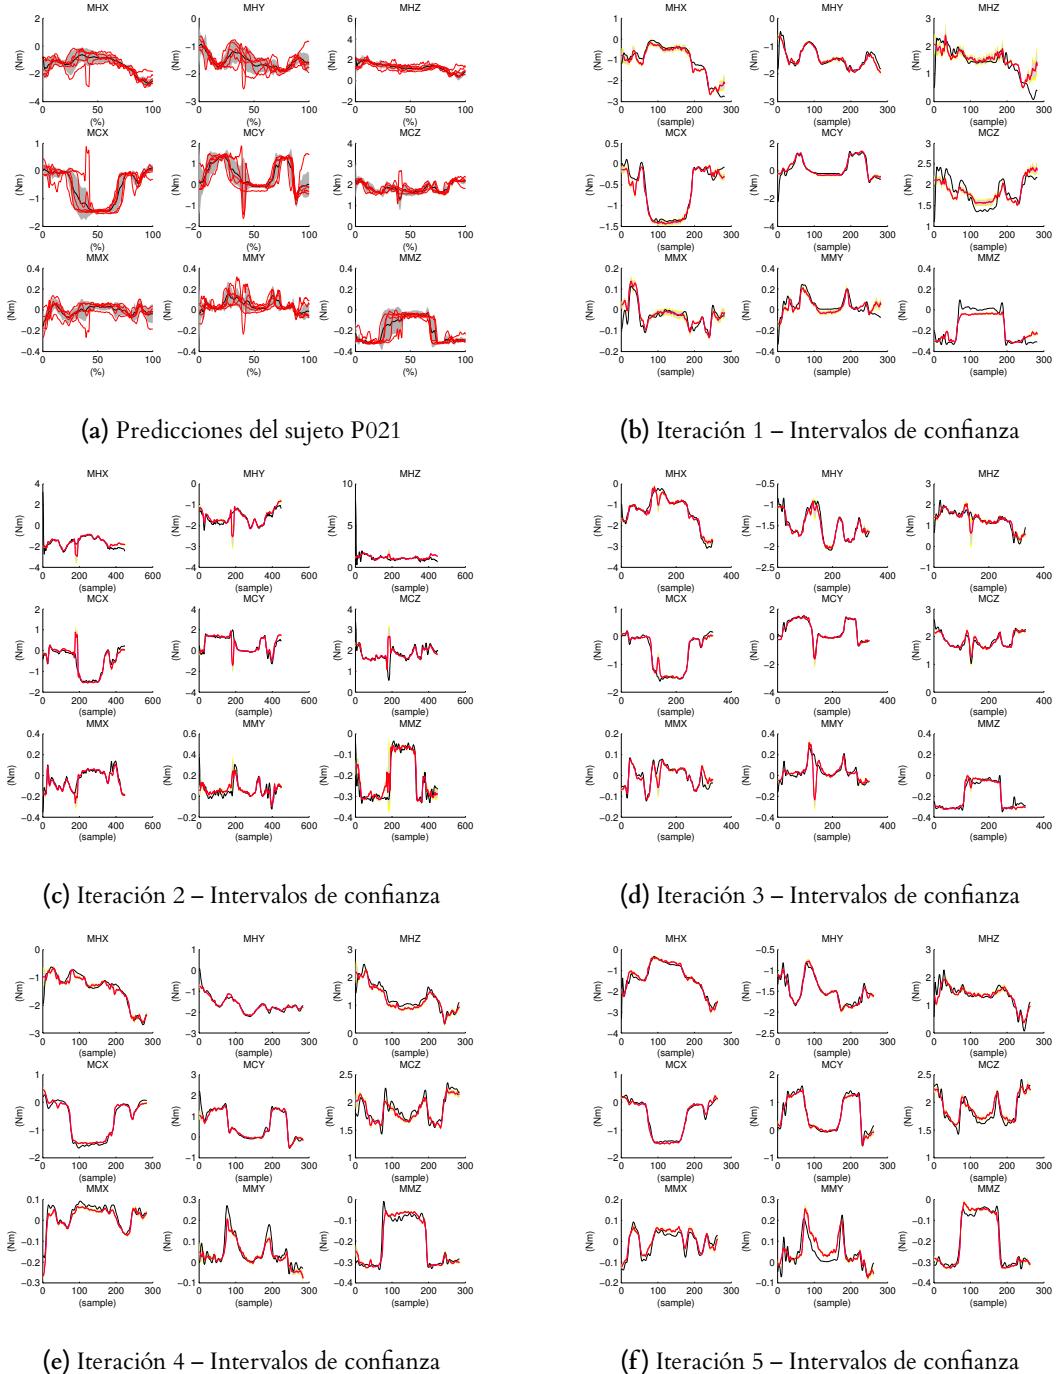


Figura E.8: Predicciones de validación por el modelo aoMLP del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto P021. El primer panel muestra en negro (sombreado gris) la media (desviación estándar) de las 5 iteraciones del momento de referencia τ_{IDk} junto con las 5 estimaciones $\hat{\tau}_{pk}$ realizadas por el modelo (en rojo). El resto de paneles comparan, separadamente para cada una de las 5 iteraciones, la predicción en rojo con la correspondiente función objetivo en negro, añadiéndose los intervalos de confianza de dicha estimación al 95 % (sombreado gris) y 99 % (sombreado amarillo) calculados punto a punto usando la distribución t de Student

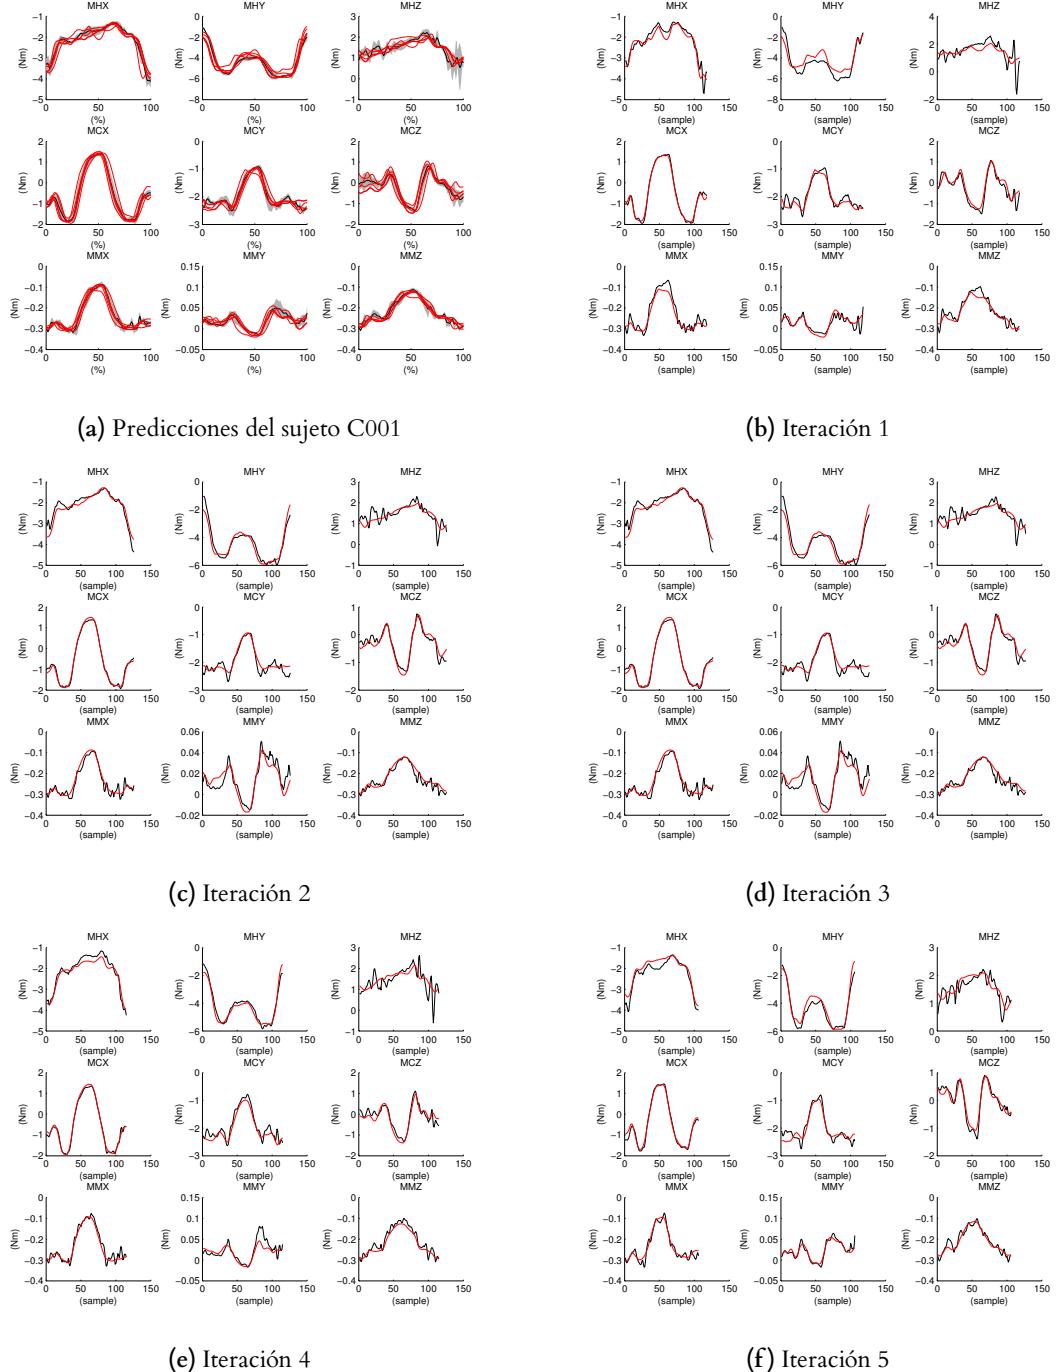


Figura E.9: Predicciones de validación por el modelo RBN del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto C001. El primer panel muestra en negro (sombreado gris) la media (desviación estándar) de las 5 iteraciones del momento de referencia τ_{IDk} junto con las 5 estimaciones $\hat{\tau}_{Rk}$ realizadas por el modelo (en rojo). El resto de paneles comparan, separadamente para cada una de las 5 iteraciones, la predicción en rojo con la correspondiente función objetivo en negro

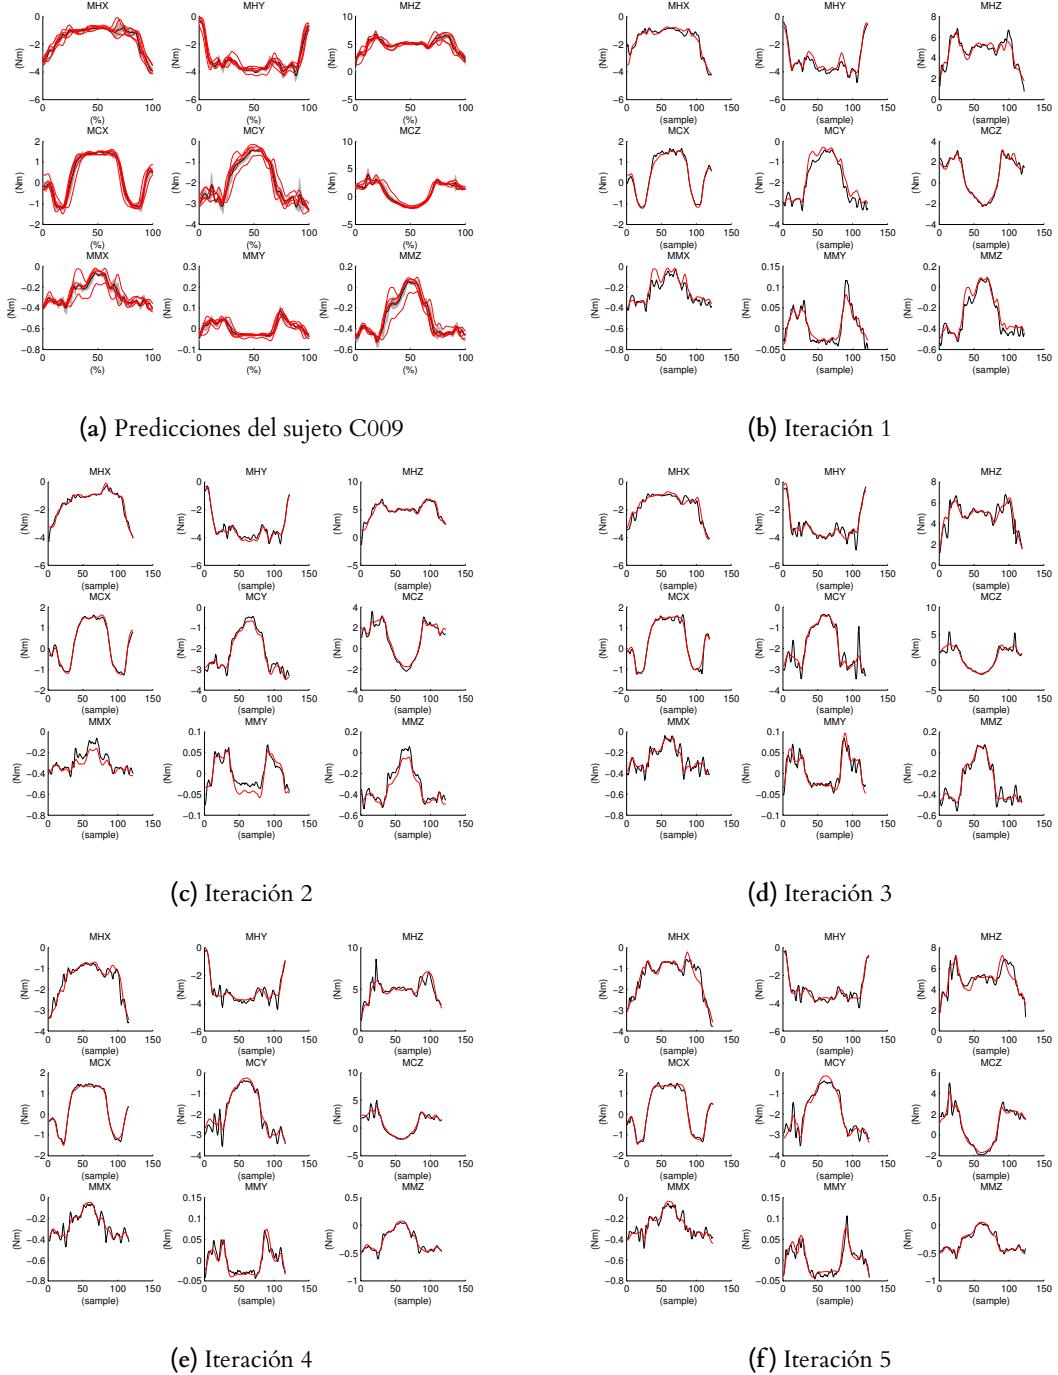


Figura E.10: Predicciones de validación por el modelo RBN del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto C009. El primer panel muestra en negro (sombreado gris) la media (desviación estándar) de las 5 iteraciones del momento de referencia τ_{IDk} junto con las 5 estimaciones $\hat{\tau}_{Rk}$ realizadas por el modelo (en rojo). El resto de paneles comparan, separadamente para cada una de las 5 iteraciones, la predicción en rojo con la correspondiente función objetivo en negro

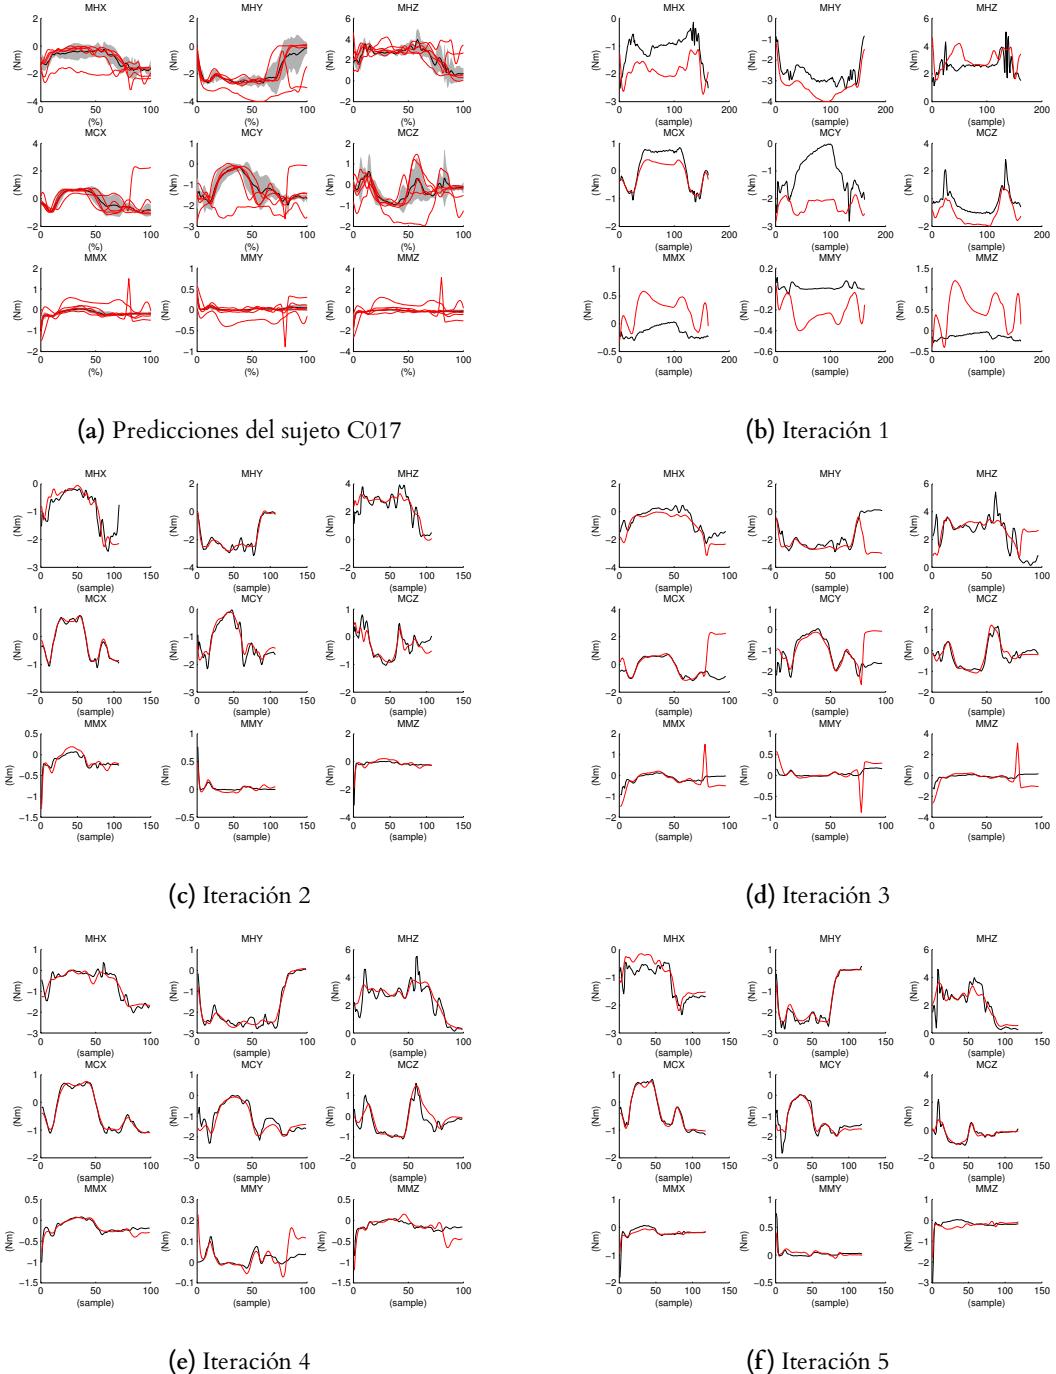


Figura E.11: Predicciones de validación por el modelo RBN del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto C017. El primer panel muestra en negro (sombreado gris) la media (desviación estándar) de las 5 iteraciones del momento de referencia τ_{IDk} junto con las 5 estimaciones $\hat{\tau}_{Rk}$ realizadas por el modelo (en rojo). El resto de paneles comparan, separadamente para cada una de las 5 iteraciones, la predicción en rojo con la correspondiente función objetivo en negro

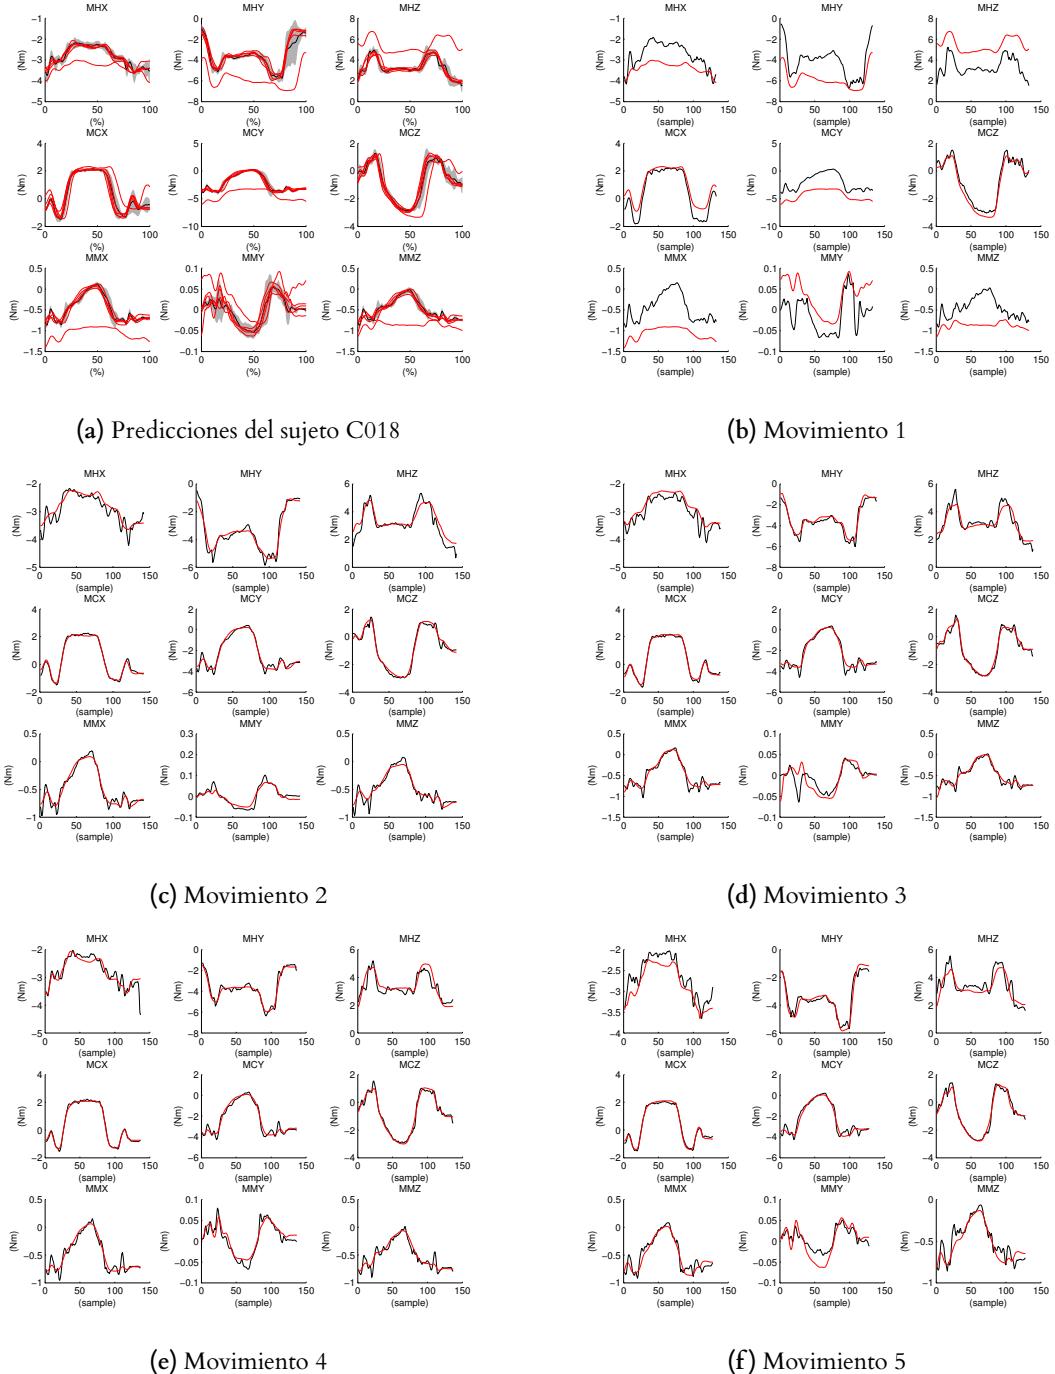


Figura E.12: Predicciones de validación por el modelo RBN del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto C018. El primer panel muestra en negro (sombreado gris) la media (desviación estándar) de las 5 iteraciones del momento de referencia τ_{IDk} junto con las 5 estimaciones $\hat{\tau}_{Rk}$ realizadas por el modelo (en rojo). El resto de paneles comparan, separadamente para cada una de las 5 iteraciones, la predicción en rojo con la correspondiente función objetivo en negro

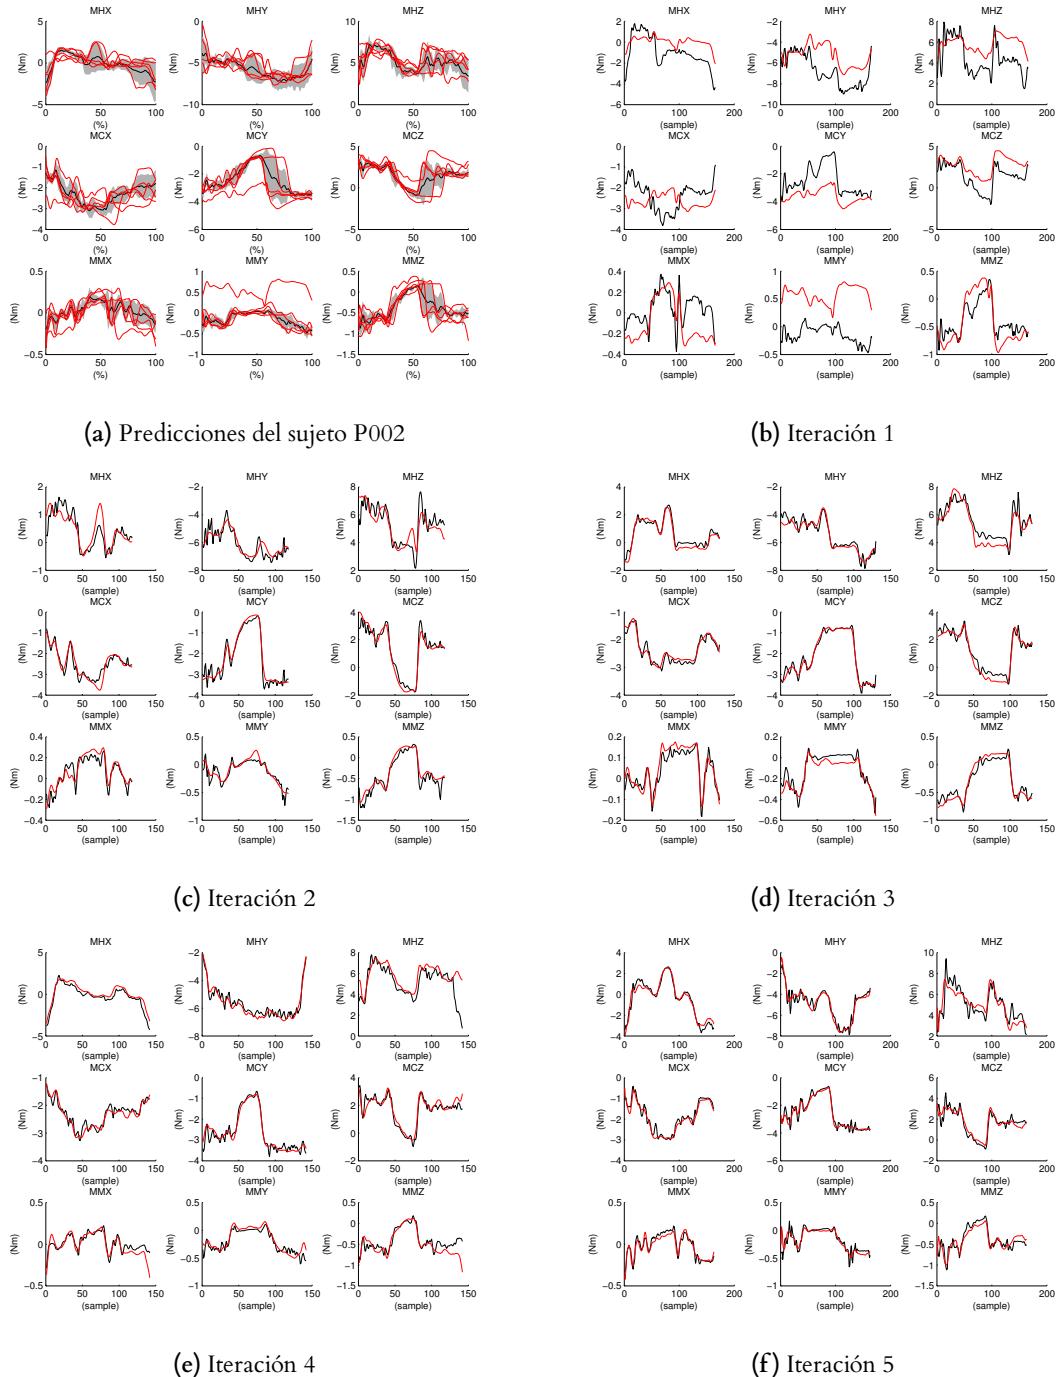


Figura E.13: Predicciones de validación por el modelo RBN del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto P002. El primer panel muestra en negro (sombreado gris) la media (desviación estándar) de las 5 iteraciones del momento de referencia τ_{IDk} junto con las 5 estimaciones $\hat{\tau}_{Rk}$ realizadas por el modelo (en rojo). El resto de paneles comparan, separadamente para cada una de las 5 iteraciones, la predicción en rojo con la correspondiente función objetivo en negro

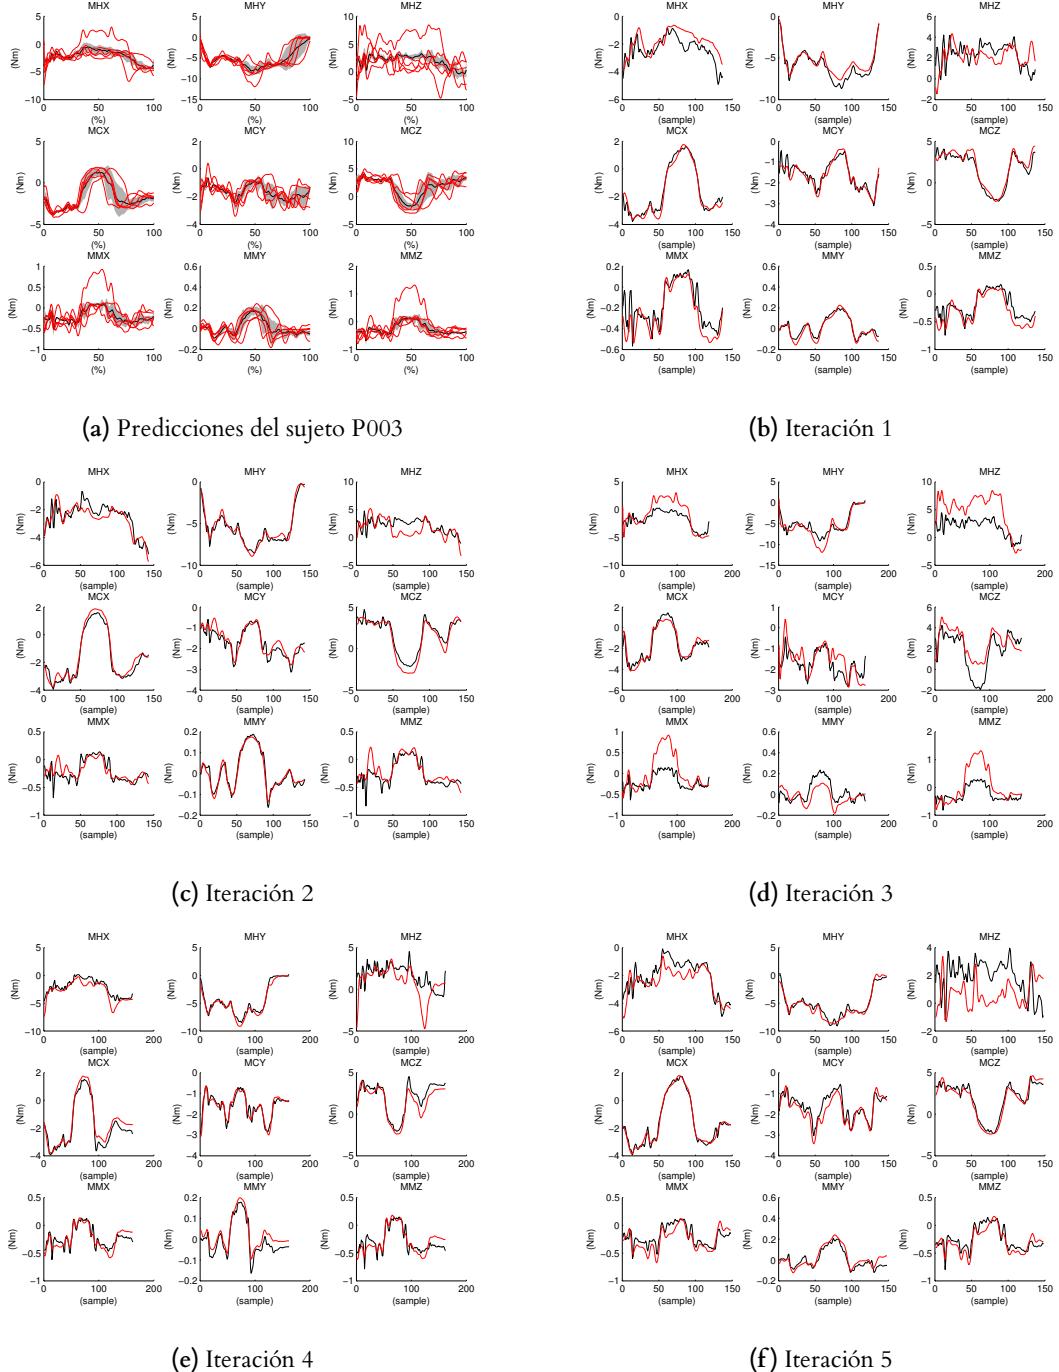


Figura E.14: Predicciones de validación por el modelo RBN del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto P003. El primer panel muestra en negro (sombreado gris) la media (desviación estándar) de las 5 iteraciones del momento de referencia τ_{IDk} junto con las 5 estimaciones $\hat{\tau}_{Rk}$ realizadas por el modelo (en rojo). El resto de paneles comparan, separadamente para cada una de las 5 iteraciones, la predicción en rojo con la correspondiente función objetivo en negro

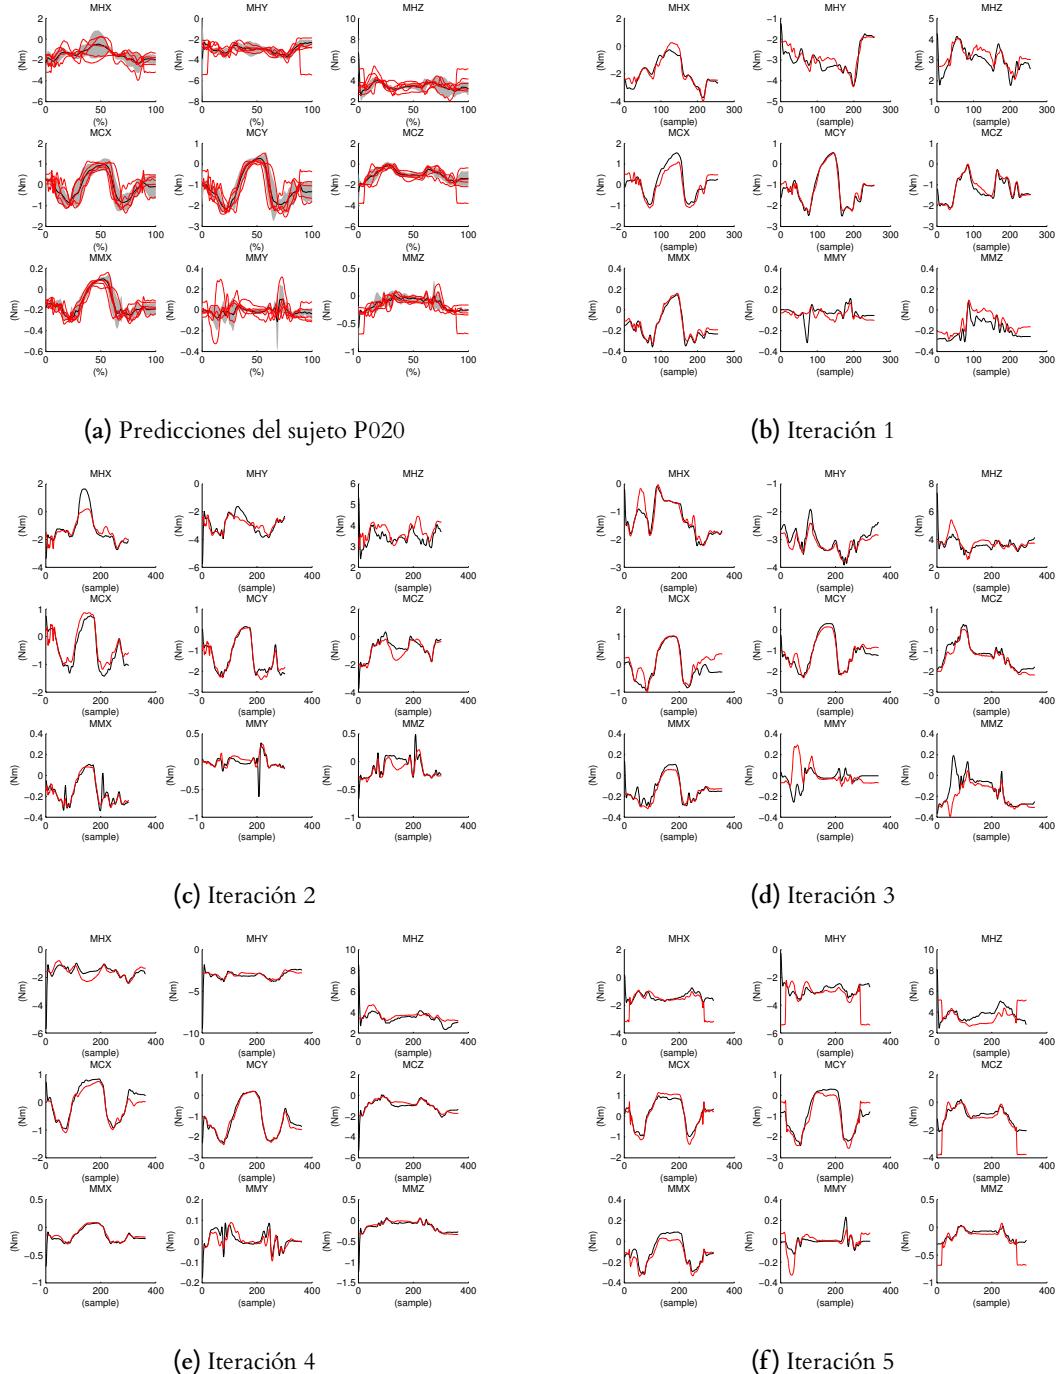


Figura E.15: Predicciones de validación por el modelo RBN del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto P020. El primer panel muestra en negro (sombreado gris) la media (desviación estándar) de las 5 iteraciones del momento de referencia τ_{IDk} junto con las 5 estimaciones $\hat{\tau}_{Rk}$ realizadas por el modelo (en rojo). El resto de paneles comparan, separadamente para cada una de las 5 iteraciones, la predicción en rojo con la correspondiente función objetivo en negro

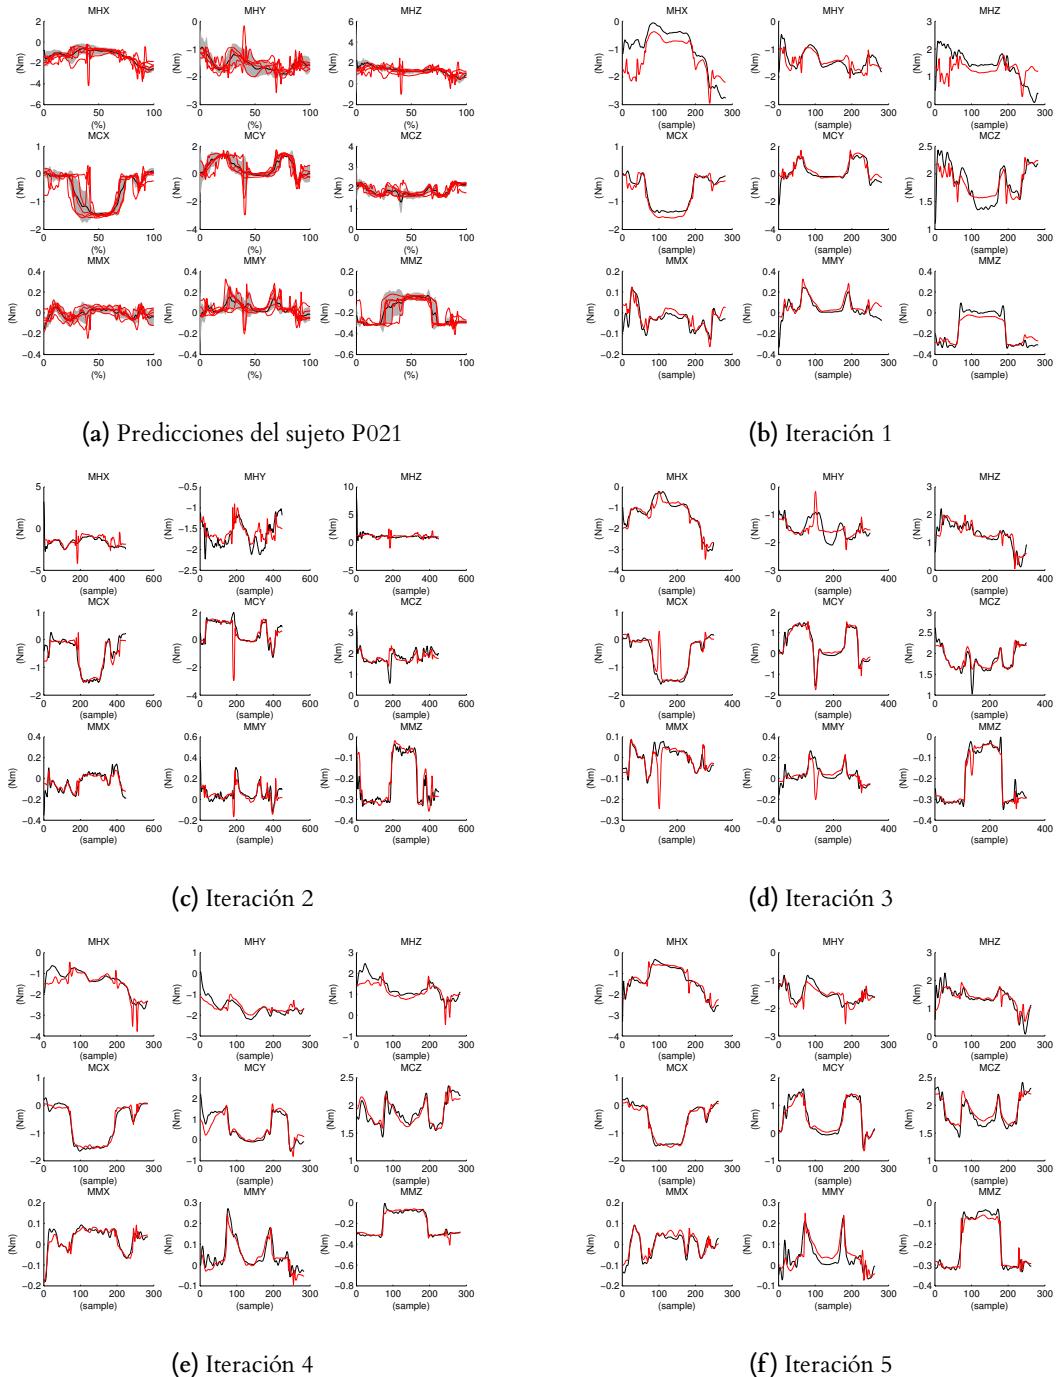


Figura E.16: Predicciones de validación por el modelo RBN del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto P021. El primer panel muestra en negro (sombreado gris) la media (desviación estándar) de las 5 iteraciones del momento de referencia τ_{IDk} junto con las 5 estimaciones $\hat{\tau}_{Rk}$ realizadas por el modelo (en rojo). El resto de paneles comparan, separadamente para cada una de las 5 iteraciones, la predicción en rojo con la correspondiente función objetivo en negro

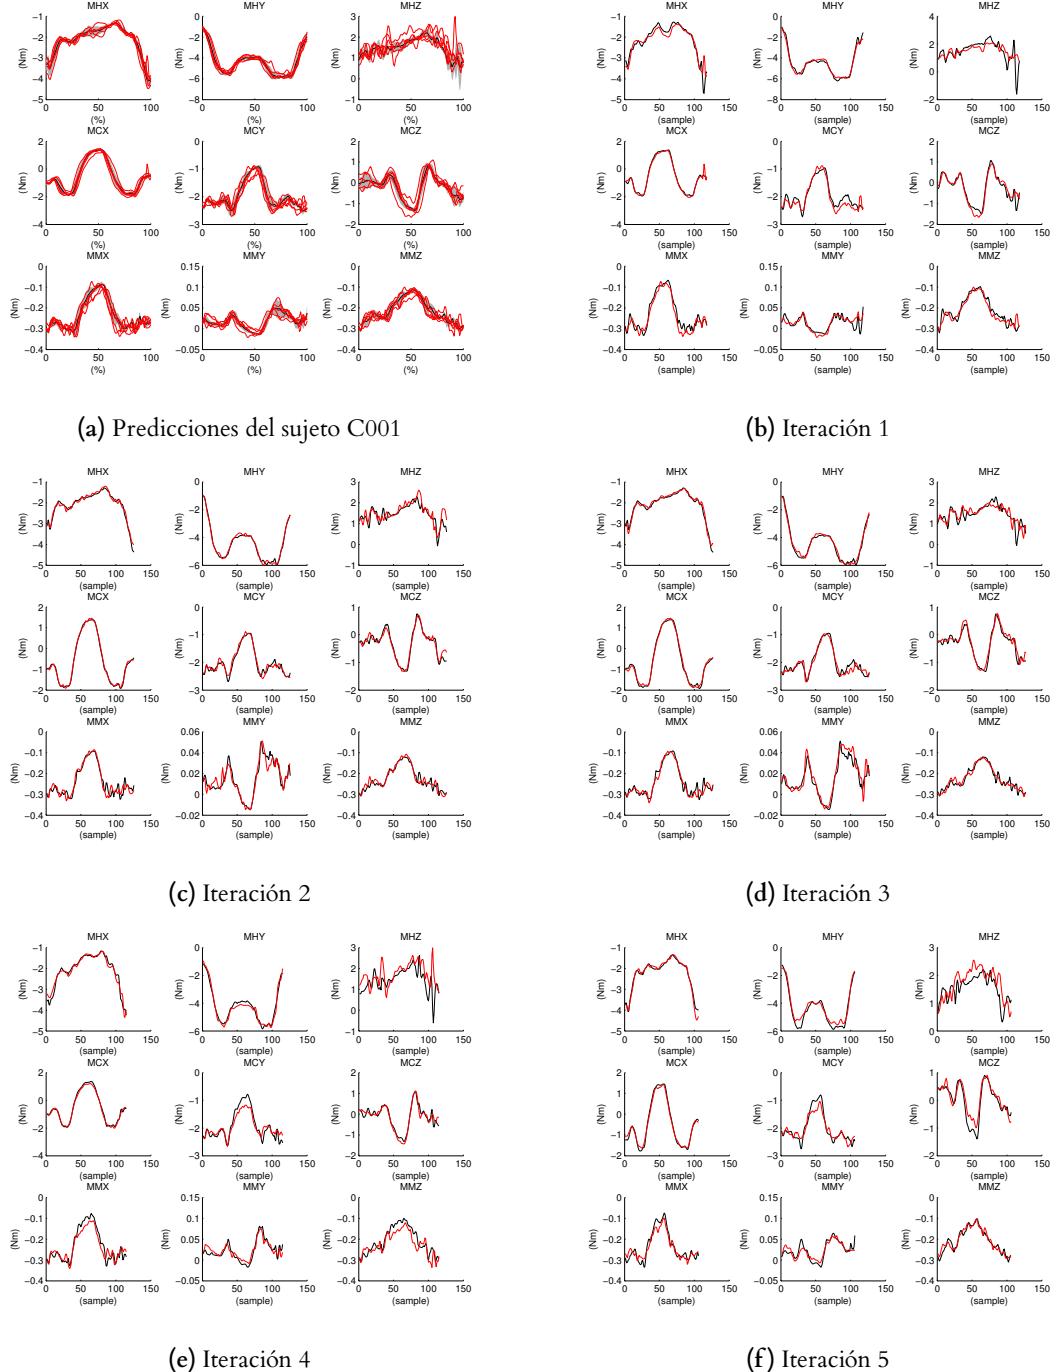


Figura E.17: Predicciones de validación por el modelo SVM del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto C001. El primer panel muestra en negro (sombreado gris) la media (desviación estándar) de las 5 iteraciones del momento de referencia τ_{IDk} junto con las 5 estimaciones $\hat{\tau}_{V_k}$ realizadas por el modelo (en rojo). El resto de paneles comparan, separadamente para cada una de las 5 iteraciones, la predicción en rojo con la correspondiente función objetivo en negro

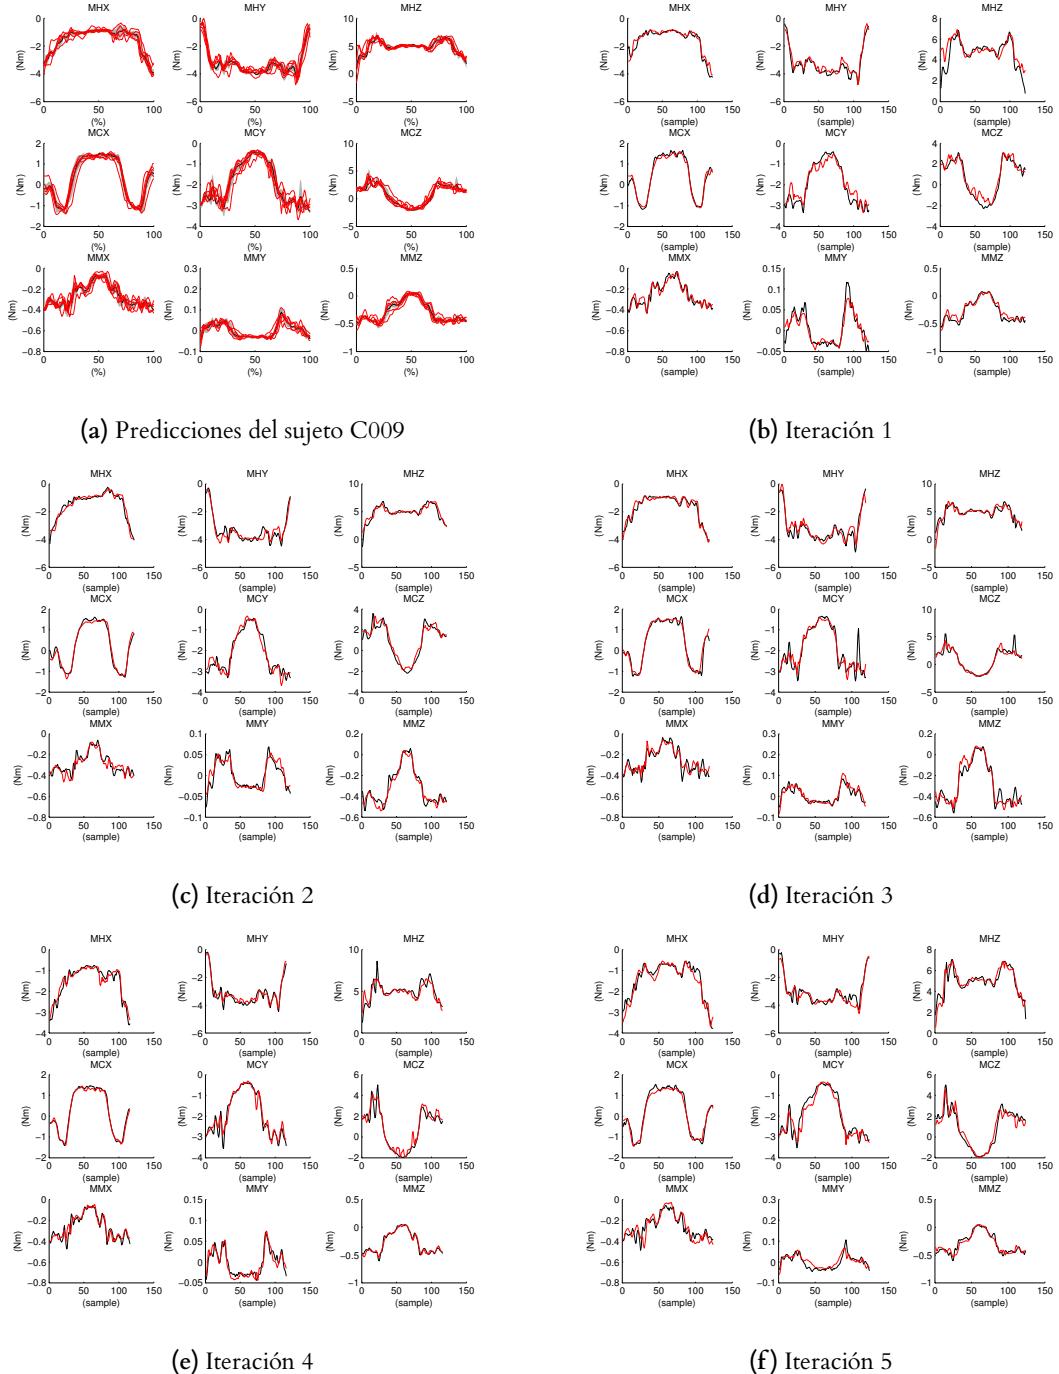


Figura E.18: Predicciones de validación por el modelo SVM del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto C009. El primer panel muestra en negro (sombreado gris) la media (desviación estándar) de las 5 iteraciones del momento de referencia τ_{IDk} junto con las 5 estimaciones $\hat{\tau}_{V_k}$ realizadas por el modelo (en rojo). El resto de paneles comparan, separadamente para cada una de las 5 iteraciones, la predicción en rojo con la correspondiente función objetivo en negro

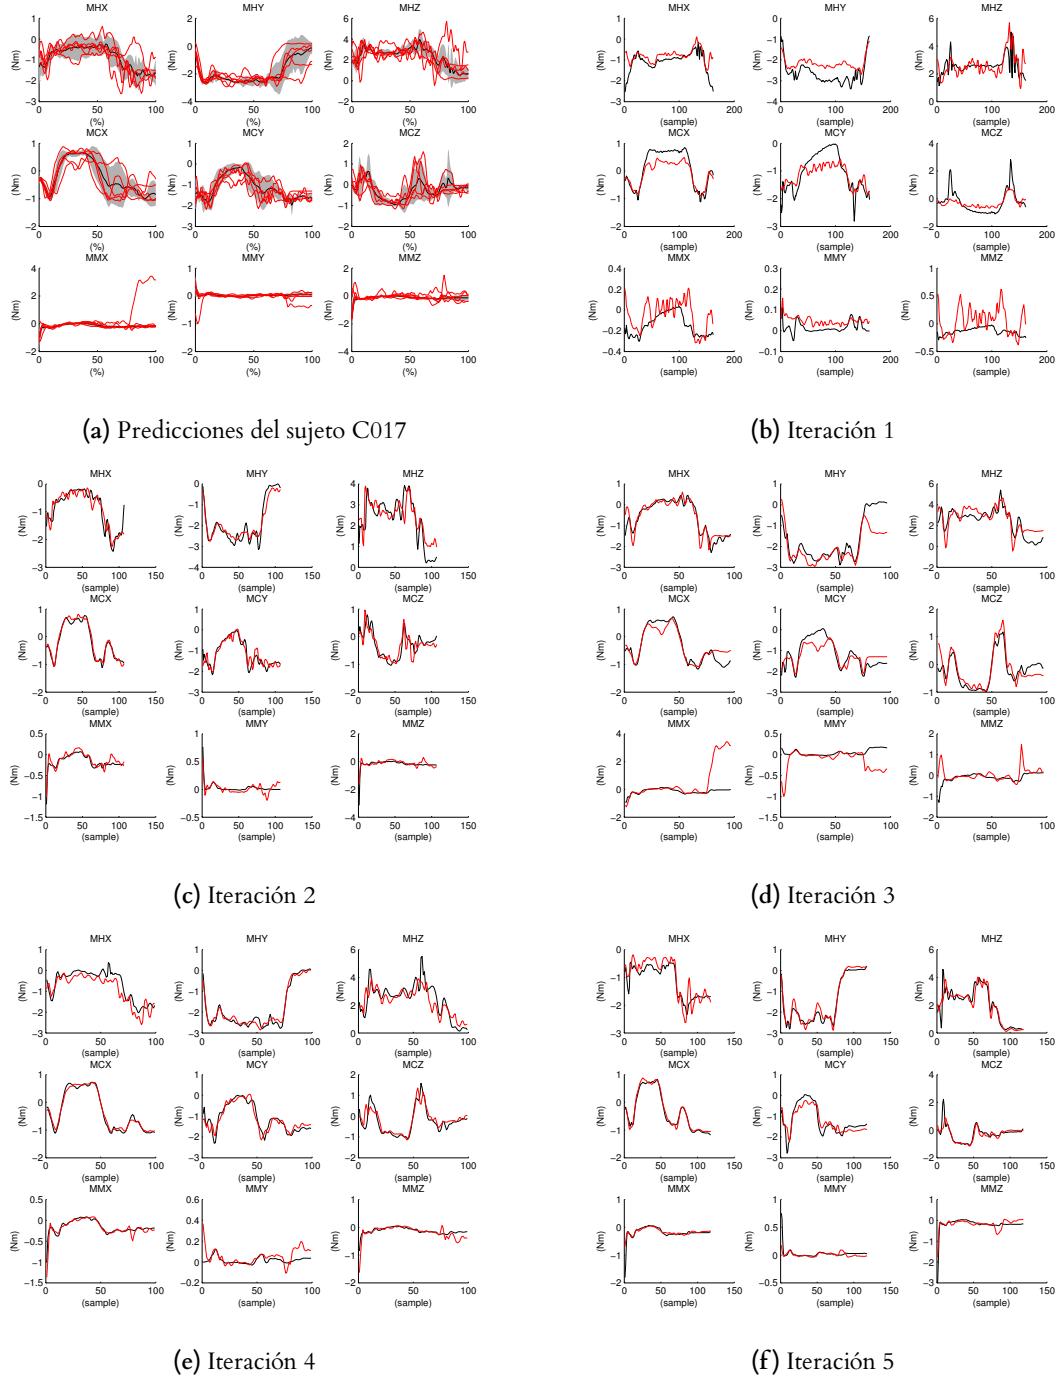


Figura E.19: Predicciones de validación por el modelo SVM del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto C017. El primer panel muestra en negro (sombreado gris) la media (desviación estándar) de las 5 iteraciones del momento de referencia τ_{IDk} junto con las 5 estimaciones $\hat{\tau}_{V_k}$ realizadas por el modelo (en rojo). El resto de paneles comparan, separadamente para cada una de las 5 iteraciones, la predicción en rojo con la correspondiente función objetivo en negro

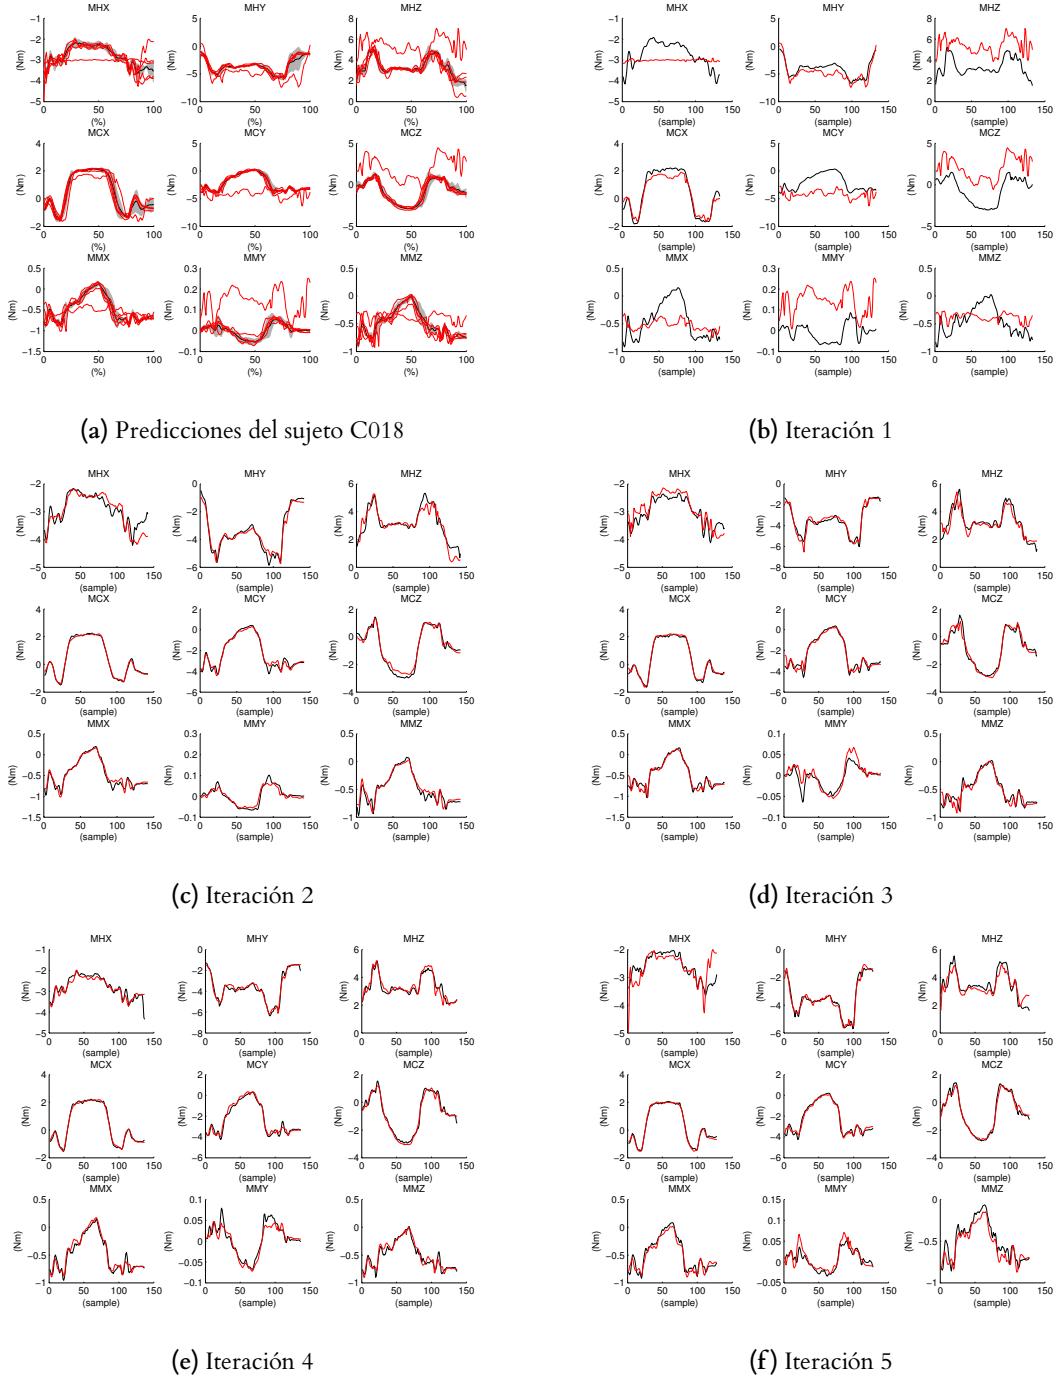


Figura E.20: Predicciones de validación por el modelo SVM del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto C018. El primer panel muestra en negro (sombreado gris) la media (desviación estándar) de las 5 iteraciones del momento de referencia τ_{IDk} junto con las 5 estimaciones $\hat{\tau}_{V_k}$ realizadas por el modelo (en rojo). El resto de paneles comparan, separadamente para cada una de las 5 iteraciones, la predicción en rojo con la correspondiente función objetivo en negro

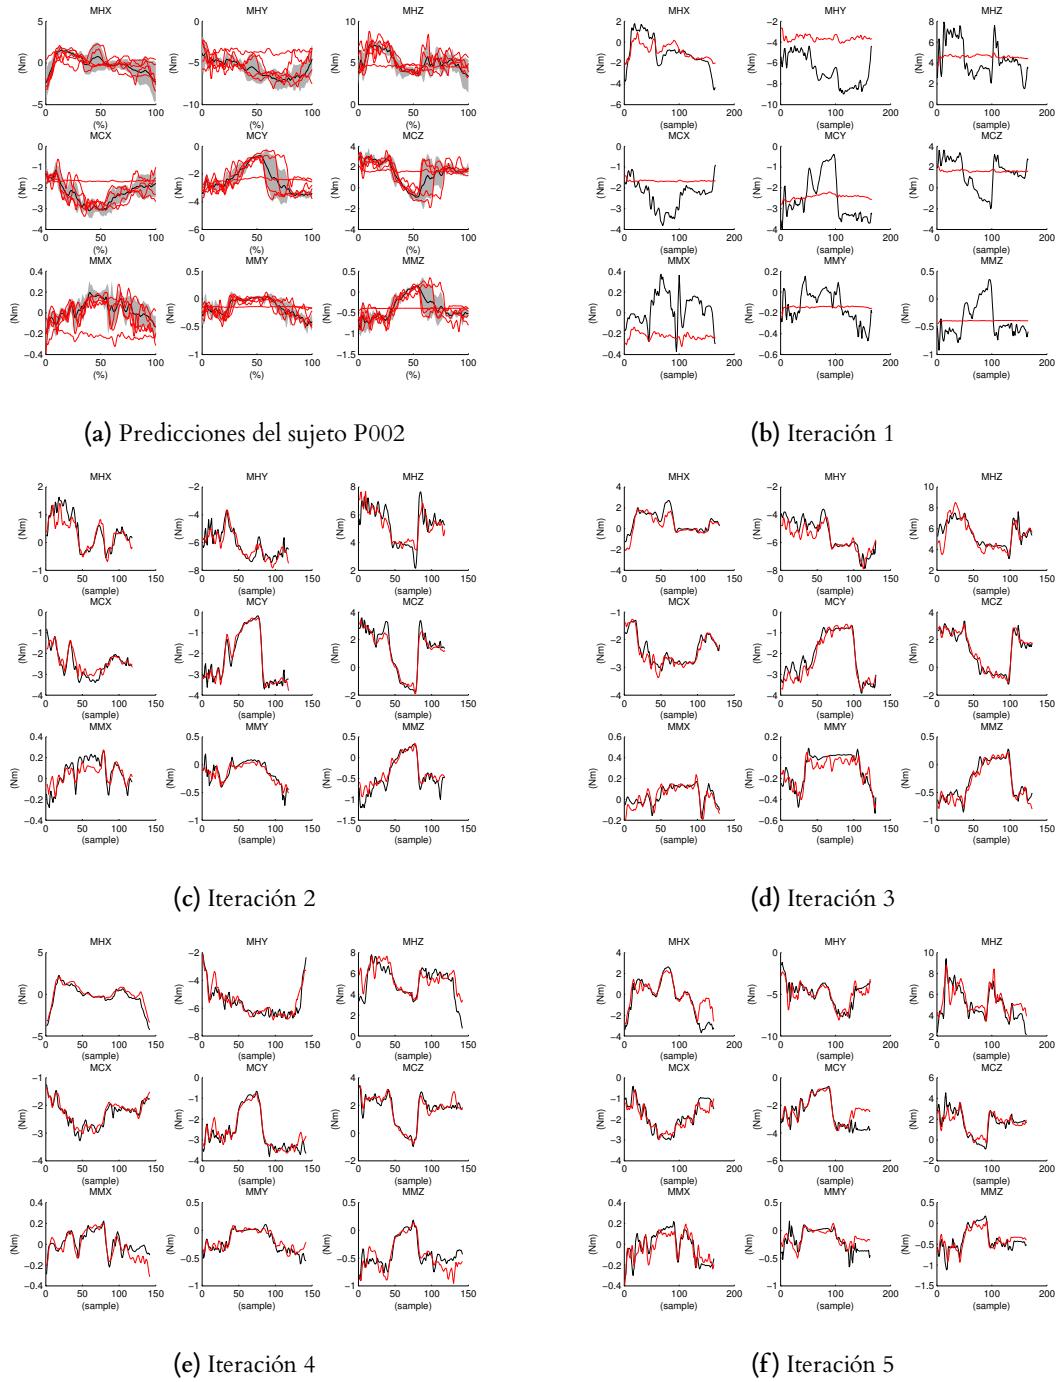


Figura E.21: Predicciones de validación por el modelo SVM del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto P002. El primer panel muestra en negro (sombreado gris) la media (desviación estándar) de las 5 iteraciones del momento de referencia τ_{IDk} junto con las 5 estimaciones $\hat{\tau}_{V_k}$ realizadas por el modelo (en rojo). El resto de paneles comparan, separadamente para cada una de las 5 iteraciones, la predicción en rojo con la correspondiente función objetivo en negro

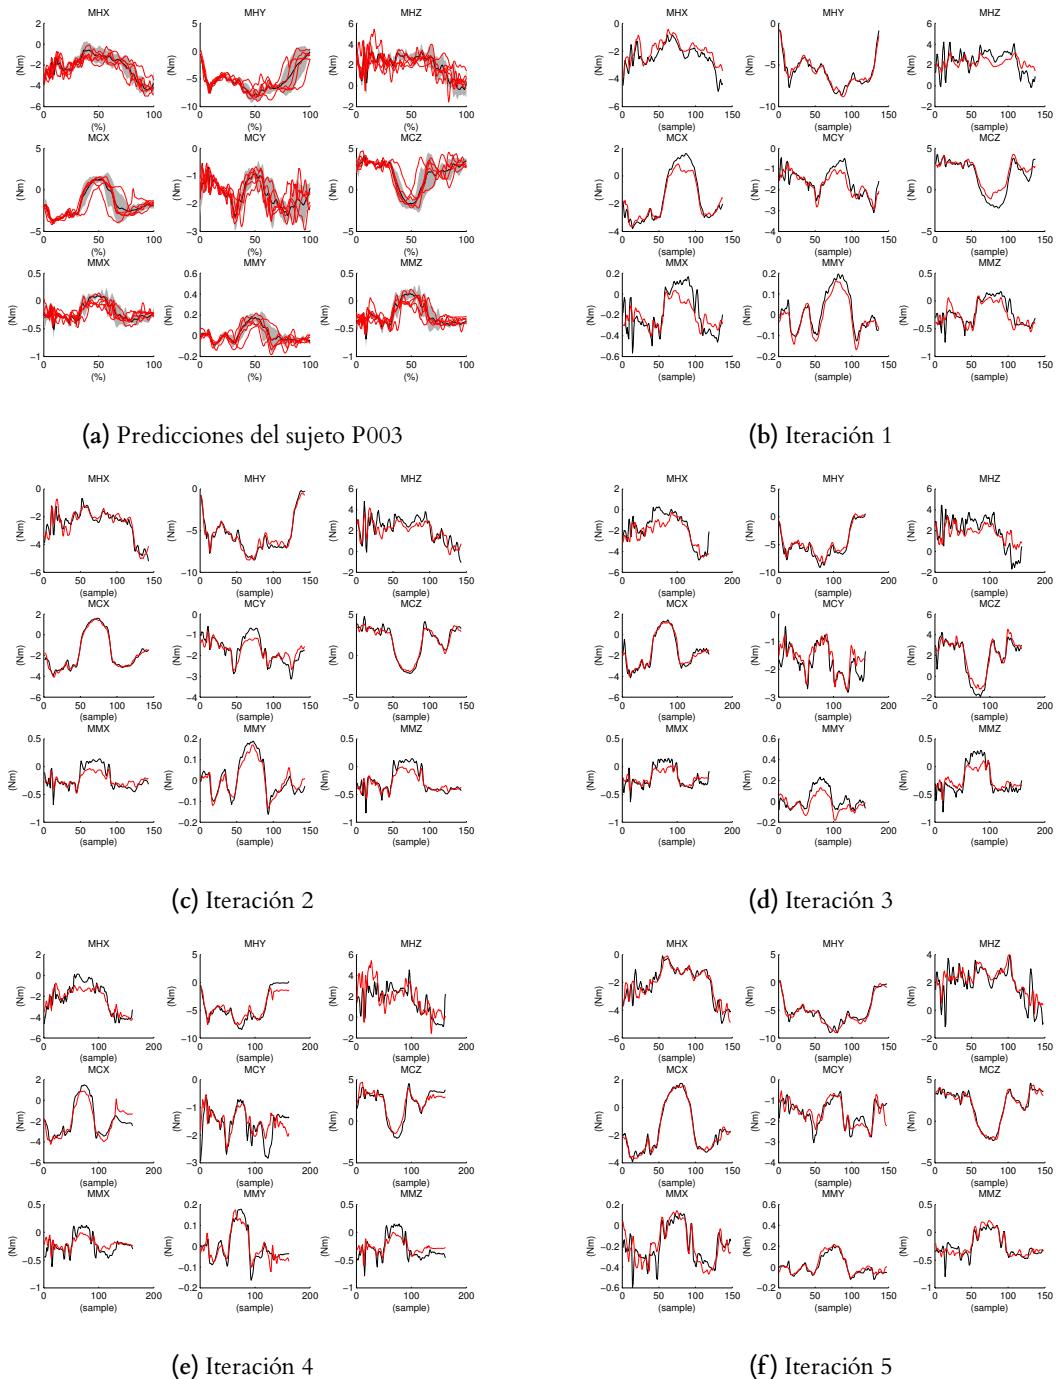


Figura E.22: Predicciones de validación por el modelo SVM del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto P003. El primer panel muestra en negro (sombreado gris) la media (desviación estándar) de las 5 iteraciones del momento de referencia τ_{IDk} junto con las 5 estimaciones $\hat{\tau}_{V_k}$ realizadas por el modelo (en rojo). El resto de paneles comparan, separadamente para cada una de las 5 iteraciones, la predicción en rojo con la correspondiente función objetivo en negro

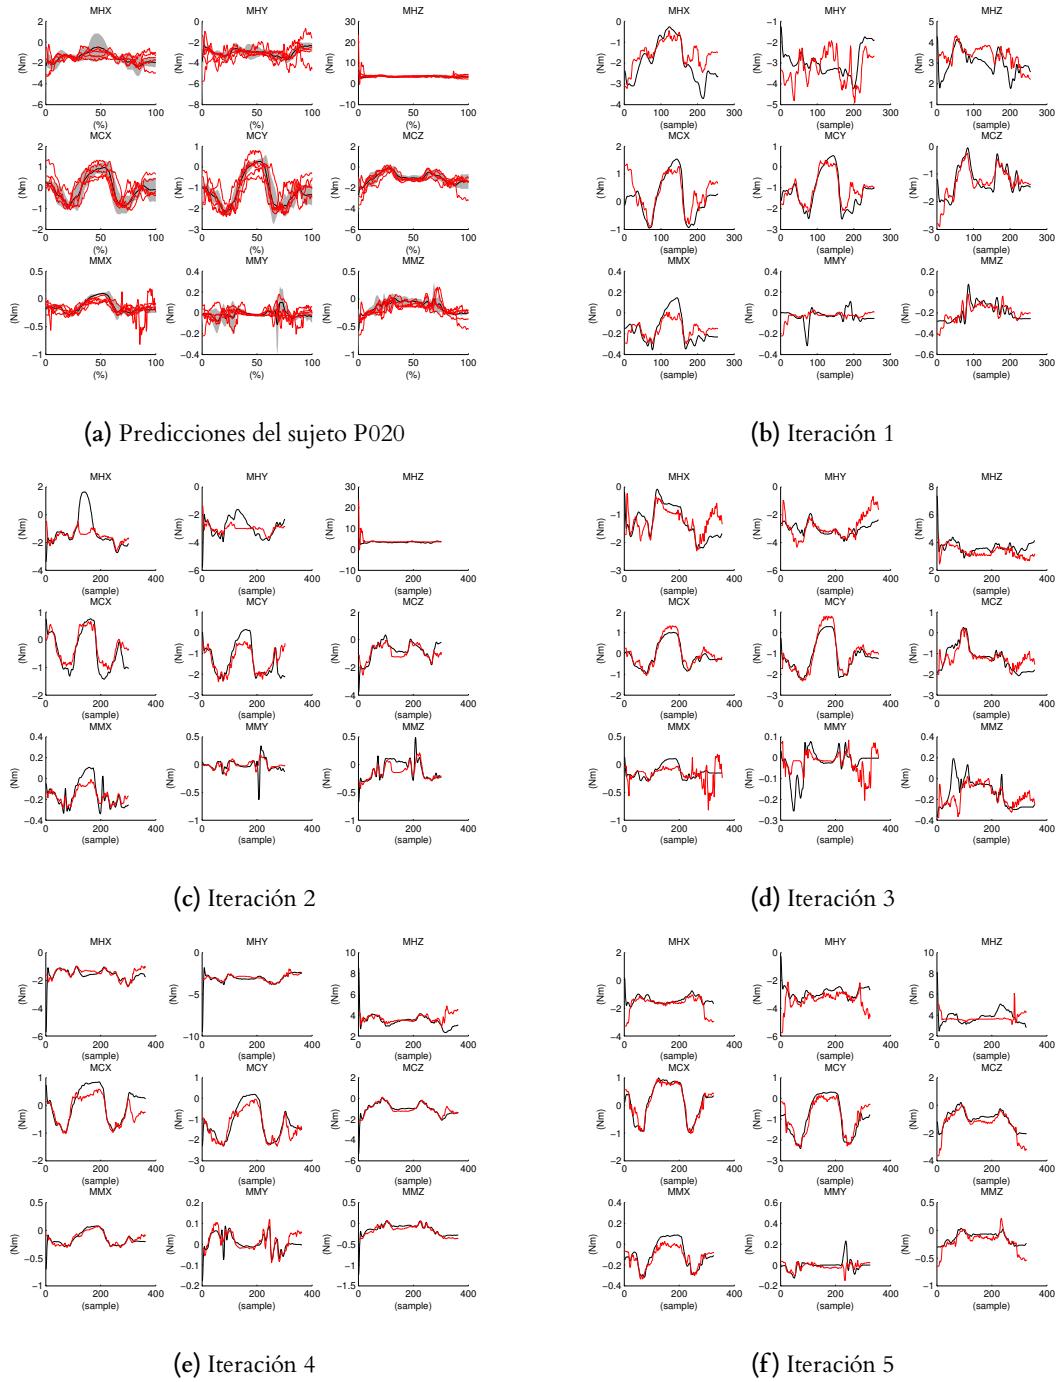


Figura E.23: Predicciones de validación por el modelo SVM del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto P020. El primer panel muestra en negro (sombreado gris) la media (desviación estándar) de las 5 iteraciones del momento de referencia τ_{IDk} junto con las 5 estimaciones $\hat{\tau}_{V_k}$ realizadas por el modelo (en rojo). El resto de paneles comparan, separadamente para cada una de las 5 iteraciones, la predicción en rojo con la correspondiente función objetivo en negro

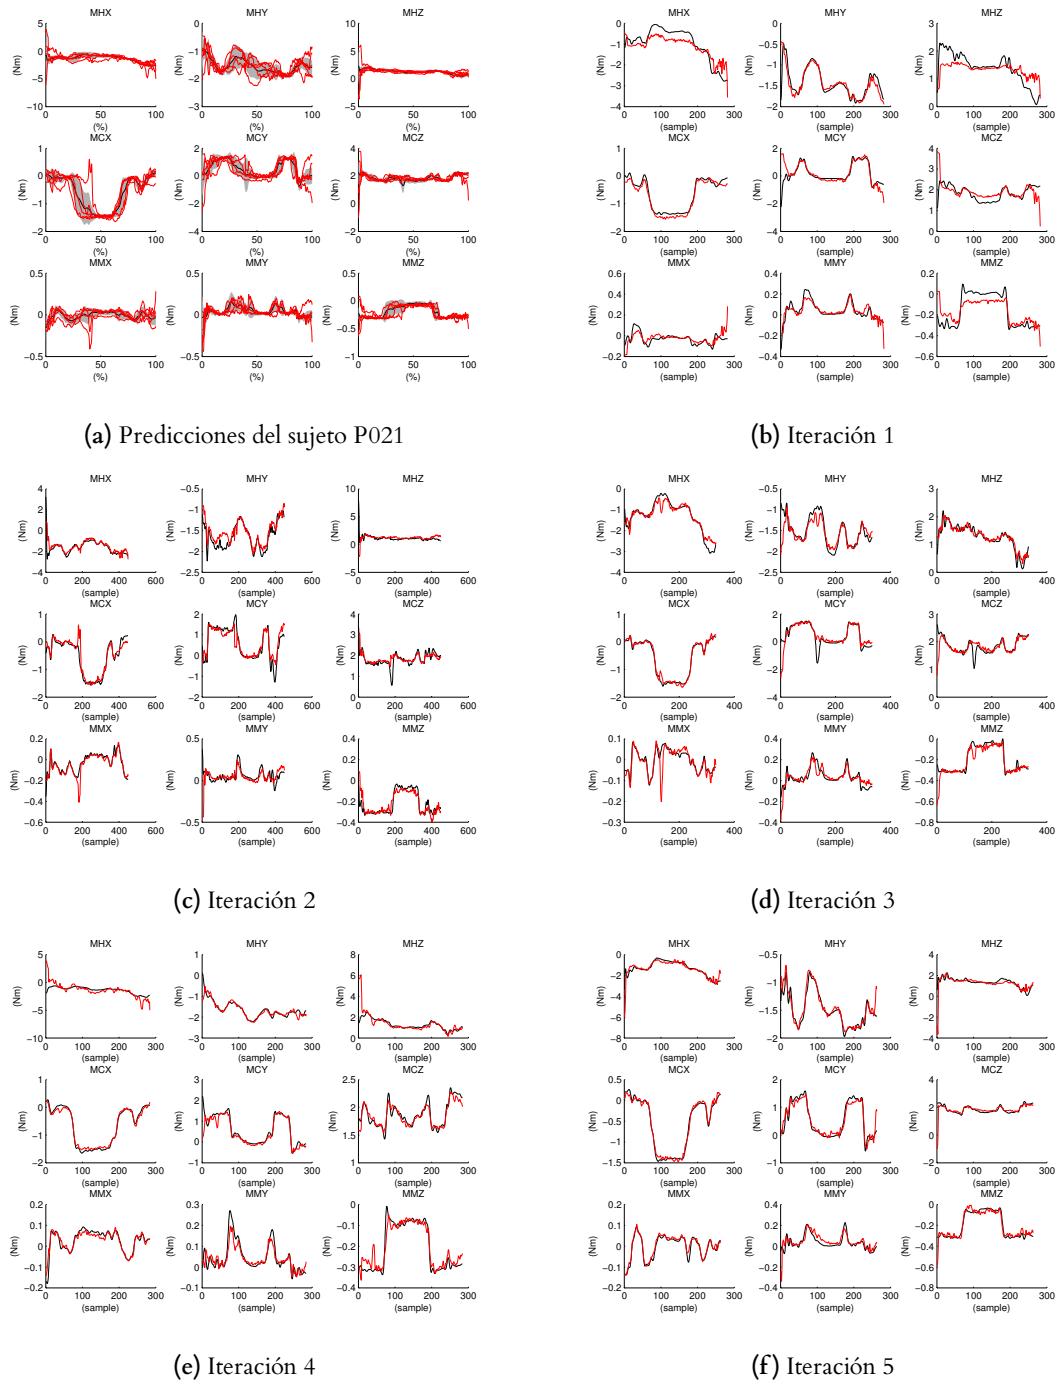


Figura E.24: Predicciones de validación por el modelo SVM del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto P021. El primer panel muestra en negro (sombreado gris) la media (desviación estándar) de las 5 iteraciones del momento de referencia τ_{IDk} junto con las 5 estimaciones $\hat{\tau}_{V_k}$ realizadas por el modelo (en rojo). El resto de paneles comparan, separadamente para cada una de las 5 iteraciones, la predicción en rojo con la correspondiente función objetivo en negro

APÉNDICE F

Predicciones de validación del escenario ESM

Para poder valorar los rendimientos obtenido en el escenario ESM se han incluido algunos de los resultados más representativos obtenidos durante la fase de validación de los diversos entrenamientos realizados en el escenario para las predicciones de los pares en las distintas articulaciones por los tres modelos seleccionados una vez en su configuración propuesta definitiva. Como entradas se han empleado las señales de Activación Normalizada y Cinemática muestreadas a $F_m = 20$ Hz. Al tratarse del escenario ESM, se han realizado tres pruebas diferentes: una empleando solo controles, otra con solo pacientes y una última mezclando ambos tipos de sujetos. En cada una de ellas se ha aplicado LOOCV, de forma que cada iteración mostrada ha sido estimada por un modelo entrenado con los datos del resto de repeticiones del movimiento de la tarea de beber de un vaso realizadas por los sujetos disponibles en la prueba.

F.1 Averaged Output MLP (aoMLP)

El estimador aoMLP se ha configurado mediante la utilización de un ensamblaje cuya salida es una simple media de los 30 MLP independientes que lo componen. Todos los MLP individuales comparten el mismo número de neuronas en la capa oculta y que ha sido optimizado automáticamente para cada sesión. Además se emplea SCG como algoritmo de aprendizaje y Early-Stopping con un máximo de 10 fallos de validación consecutivos para detectar las condiciones de parada evitando caer en el sobreaprendizaje.

solo Controles véase la figura F.1

solo Pacientes véase la figura F.2

Población (Controles) véase la figura F.3

Población (Pacientes) véase la figura F.4

F.2 Radial Basis Network (RBN)

En este caso, la configuración del estimador RBN se ha elegido manualmente tomando $s = 2^7$ como spread de las neuronas gaussianas y configurando el goal, o objetivo del algoritmo de aprendizaje, como $g = 1/21$. Recordar que este valor no se ha seleccionado rigurosamente si

no por heurística, correspondiendo el 21 a la dimensión de la entrada de la red, es decir, al total de las 9 variables de Activación Normalizada y las 12 de Cinemática.

solo Controles véase la figura [F.5](#)

solo Pacientes véase la figura [F.6](#)

Población (Controles) véase la figura [F.7](#)

Población (Pacientes) véase la figura [F.8](#)

F.3 Support Vector Machine (SVM)

Por último, para la configuración del estimador **SVM** se ha empleado la formulación ϵ -**SVR** con un kernel **RBF**. Además, se ha dejado el hiperparámetro ϵ en su valor por defecto (0,001) mientras que los otros dos hiperparámetros, C y γ , se han optimizado automáticamente mediante la búsqueda de dichos valores que maximizan la estimación del rendimiento del modelo calculada por validación cruzada.

solo Controles véase la figura [F.9](#)

solo Pacientes véase la figura [F.10](#)

Población (Controles) véase la figura [F.11](#)

Población (Pacientes) véase la figura [F.12](#)

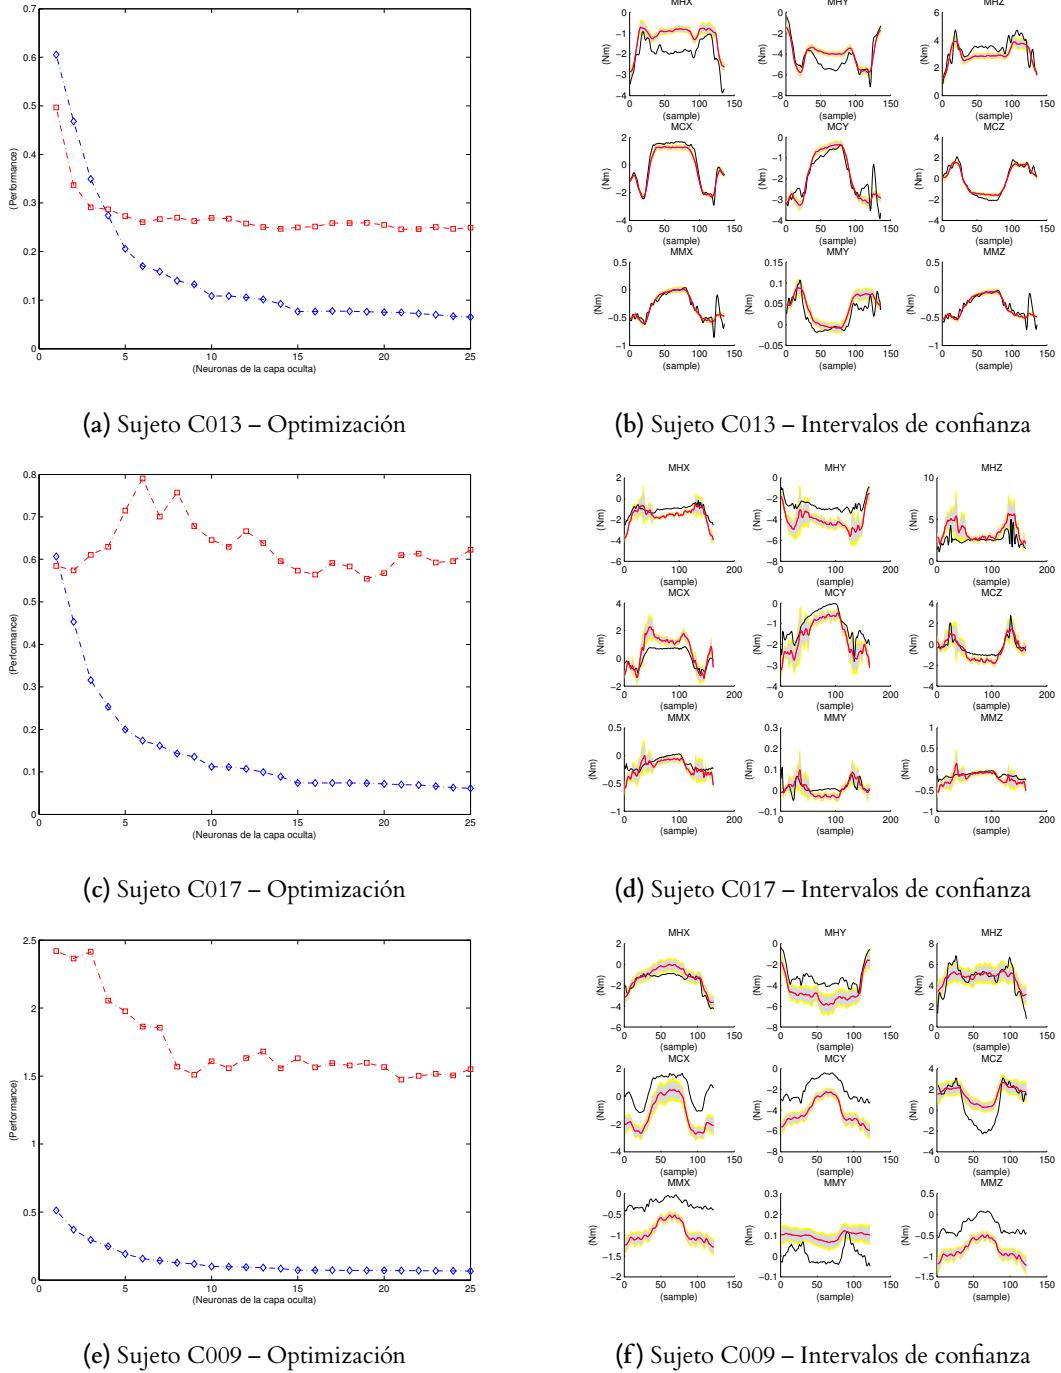


Figura F.1: Optimización automática del número de neuronas ocultas y predicción de validación por el modelo aoMLP del momento articular para el escenario ESM – solo Controles. Los paneles de optimización muestran el rendimiento MSE del entrenamiento (en azul) frente al de validación (en rojo). Los paneles de predicción muestran la predicción $\hat{\tau}_{p_k}$ en rojo con la correspondiente función objetivo τ_{ID_k} en negro, añadiéndose los intervalos de confianza de dicha estimación al 95 % (sombreado gris) y 99 % (sombreado amarillo) calculados punto a punto usando la distribución t de Student

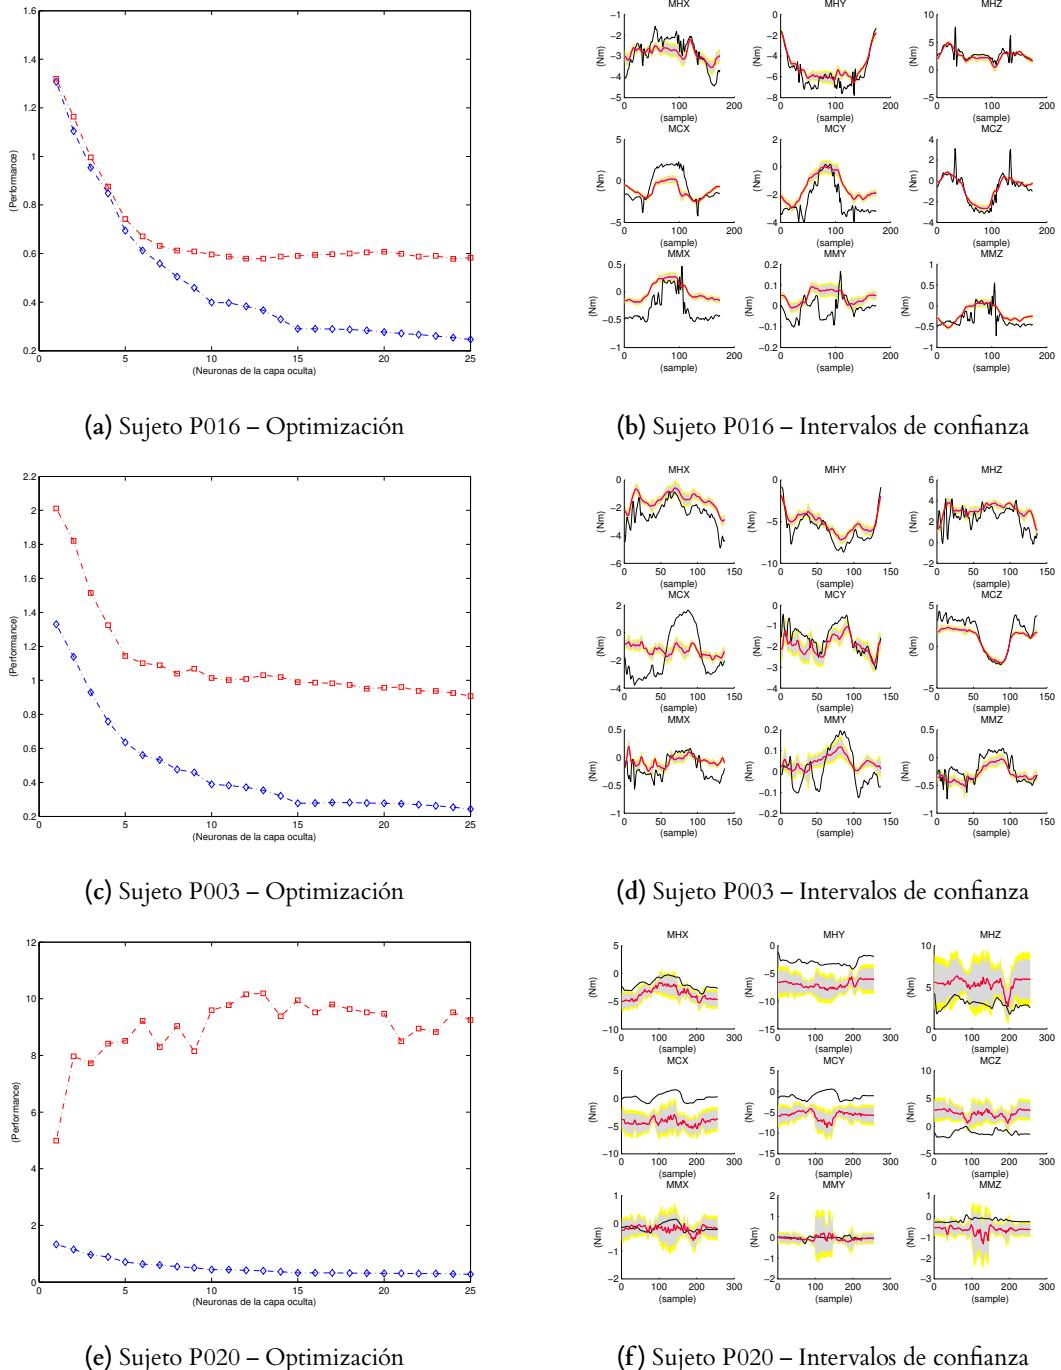


Figura F.2: Optimización automática del número de neuronas ocultas y predicción de validación por el modelo aoMLP del momento articular para el escenario ESM – solo Pacientes. Los paneles de optimización muestran el rendimiento MSE del entrenamiento (en azul) frente al de validación (en rojo). Los paneles de predicción muestran la predicción $\hat{\tau}_{pk}$ en rojo con la correspondiente función objetivo τ_{IDk} en negro, añadiéndose los intervalos de confianza de dicha estimación al 95 % (sombreado gris) y 99 % (sombreado amarillo) calculados punto a punto usando la distribución t de Student

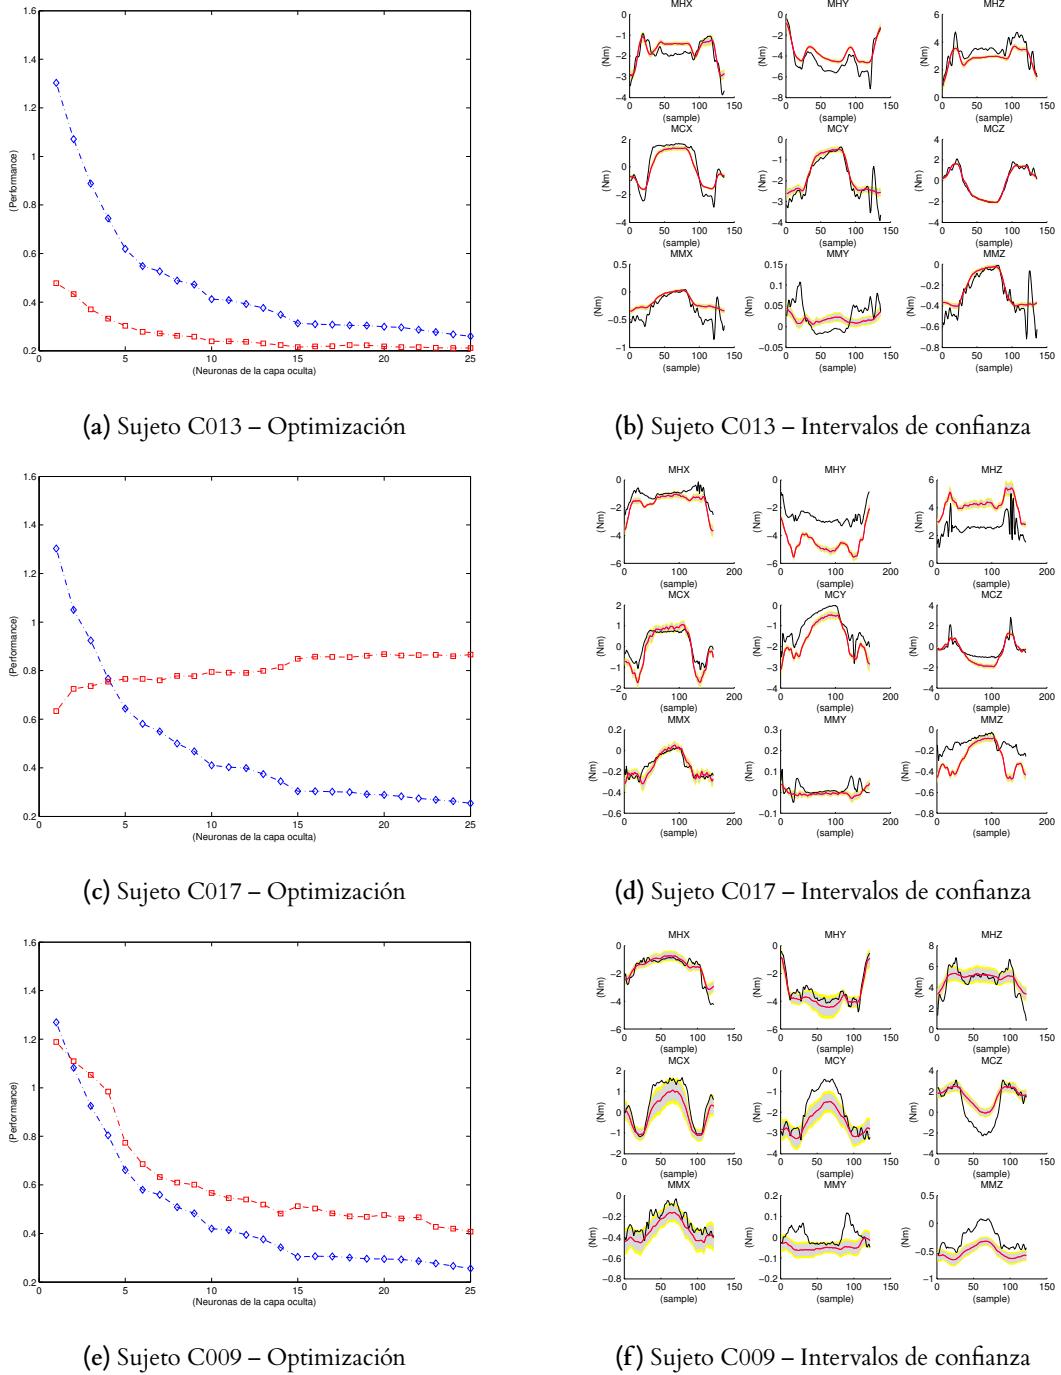


Figura F.3: Optimización automática del número de neuronas ocultas y predicción de validación por el modelo aoMLP del momento articular para el escenario ESM – Población (Controles). Los paneles de optimización muestran el rendimiento MSE del entrenamiento (en azul) frente al de validación (en rojo). Los paneles de predicción muestran la predicción $\hat{\tau}_{pk}$ en rojo con la correspondiente función objetivo τ_{IDk} en negro, añadiéndose los intervalos de confianza de dicha estimación al 95 % (sombreado gris) y 99 % (sombreado amarillo) calculados punto a punto usando la distribución t de Student

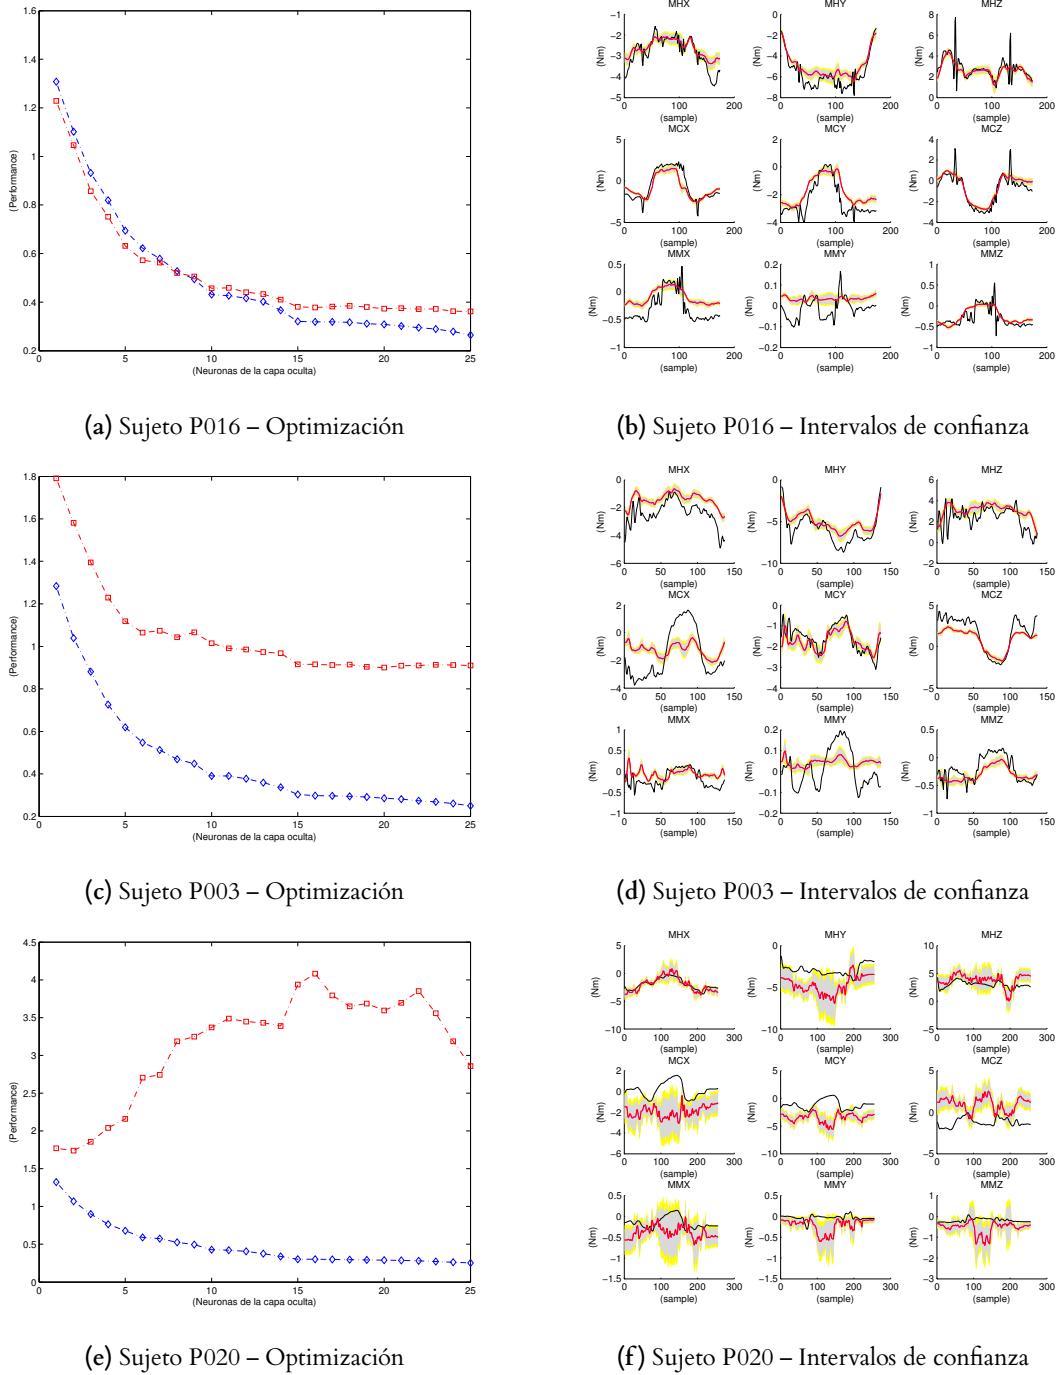


Figura F.4: Optimización automática del número de neuronas ocultas y predicción de validación por el modelo aoMLP del momento articular para el escenario ESM – Población (Pacientes). Los paneles de optimización muestran el rendimiento MSE del entrenamiento (en azul) frente al de validación (en rojo). Los paneles de predicción muestran la predicción $\hat{\tau}_{pk}$ en rojo con la correspondiente función objetivo τ_{IDk} en negro, añadiéndose los intervalos de confianza de dicha estimación al 95 % (sombreado gris) y 99 % (sombreado amarillo) calculados punto a punto usando la distribución t de Student

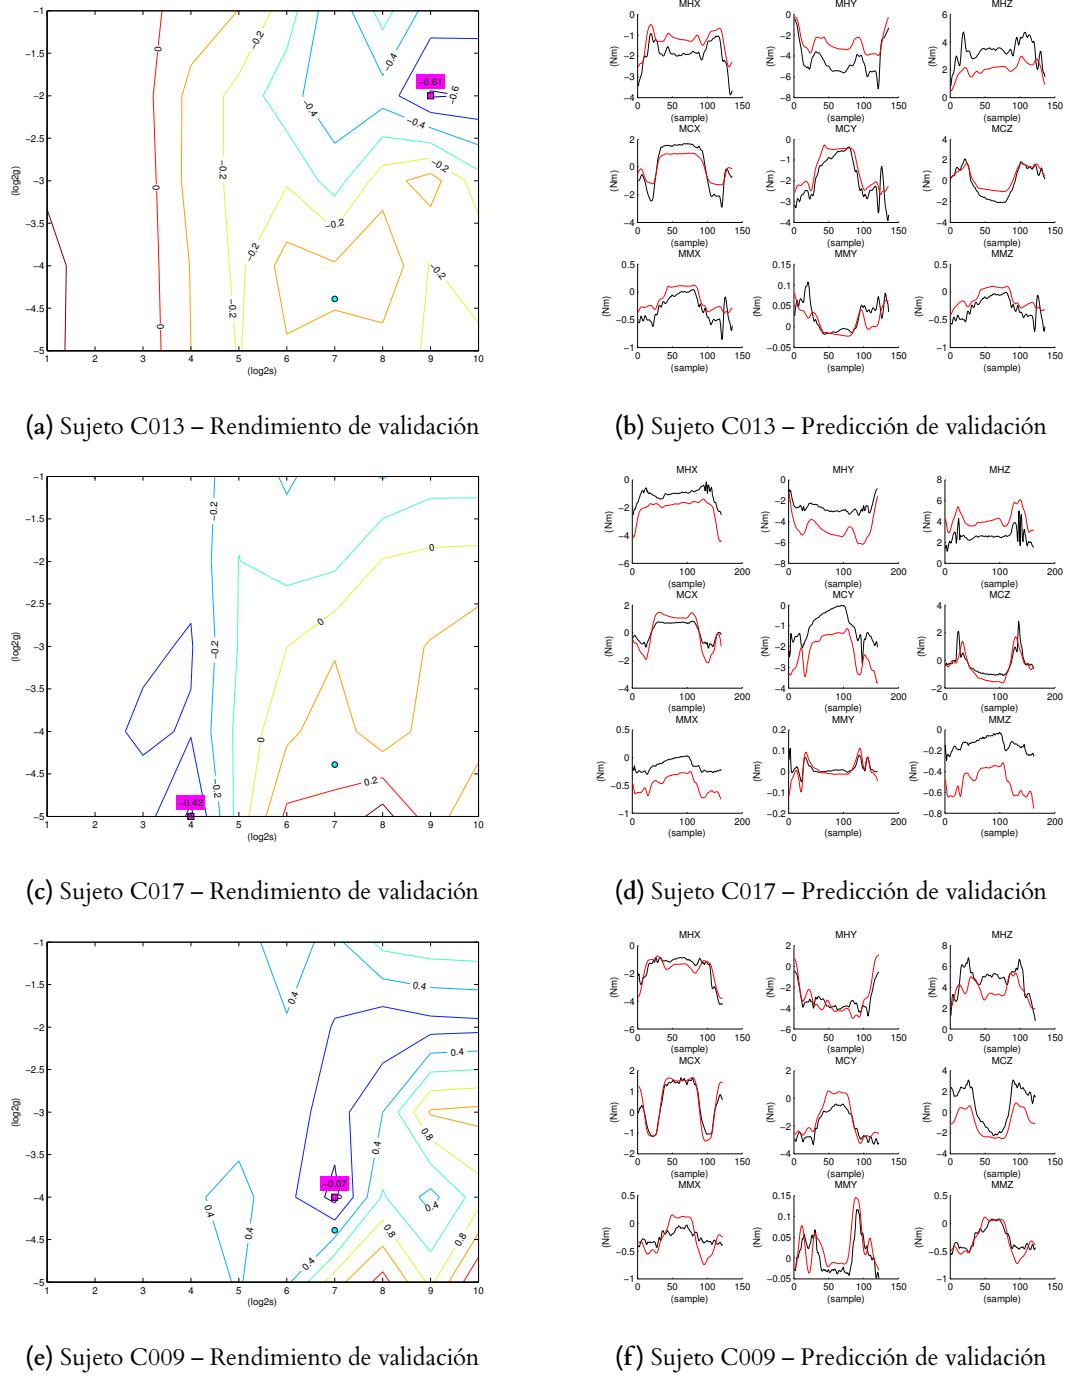


Figura F.5: Mapa de rendimiento de validación y predicción de validación por el modelo RBN del momento articular para el escenario ESM – solo Controles. Los paneles de optimización muestran con un marcador magenta la localización del mínimo del MSE de validación y en cian los hiperparámetros finalmente empleados. Los paneles de predicción muestran la predicción $\hat{\tau}_{Rk}$ en rojo con la correspondiente función objetivo τ_{IDk} en negro

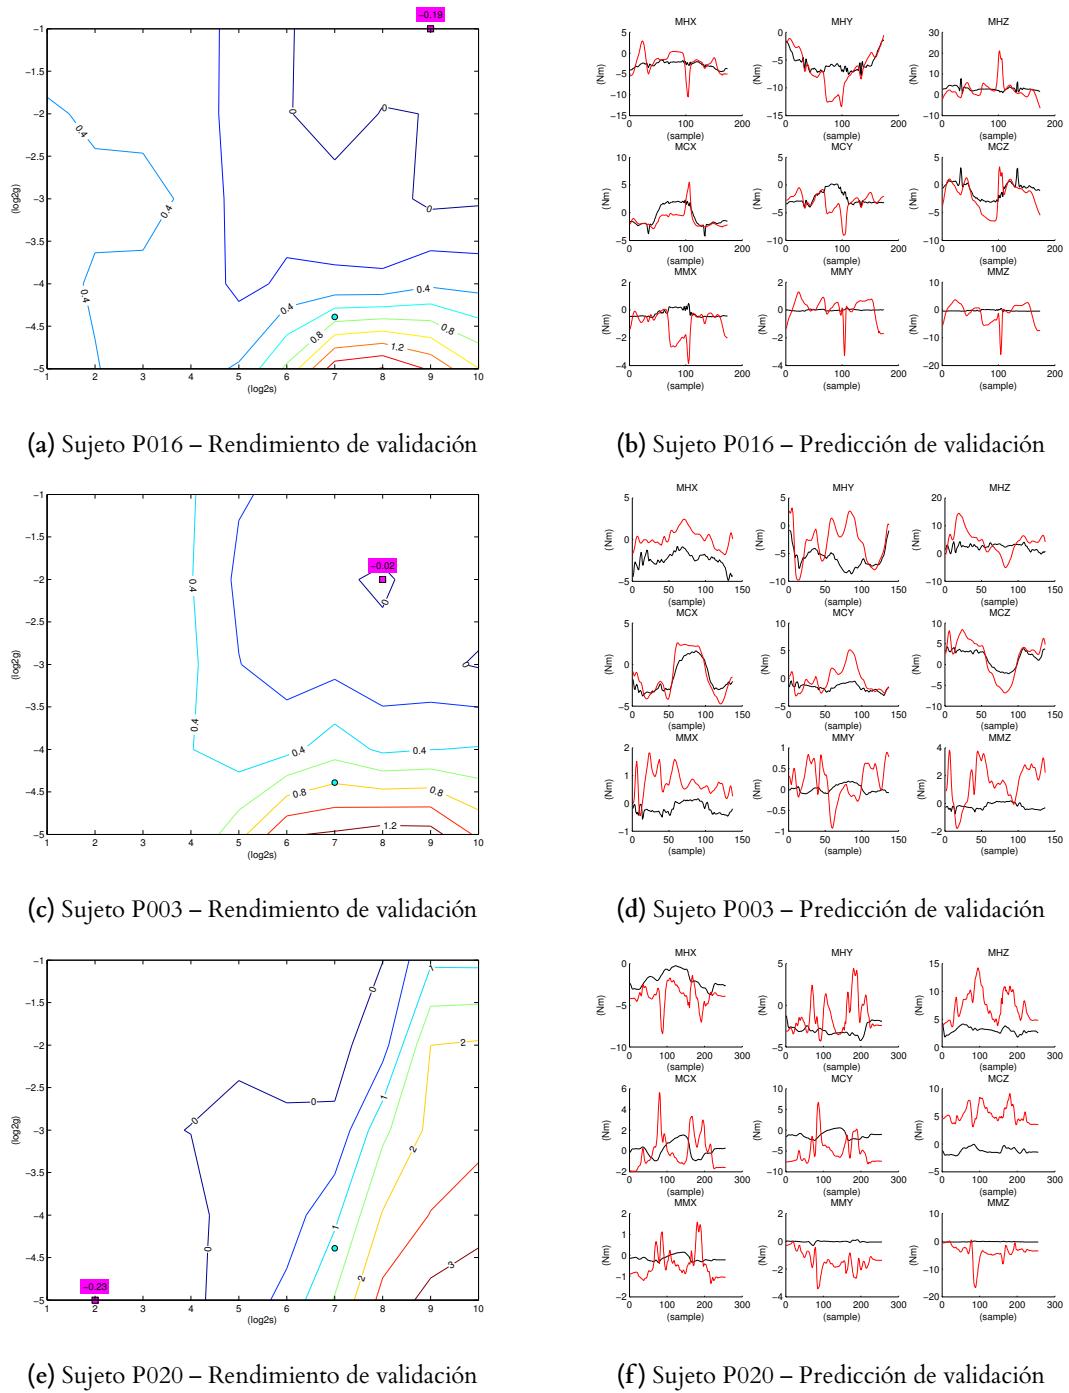


Figura F.6: Mapa de rendimiento de validación y predicción de validación por el modelo RBN del momento articular para el escenario ESM – solo Pacientes. Los paneles de optimización muestran con un marcador magenta la localización del mínimo del MSE de validación y en cian los hiperparámetros finalmente empleados. Los paneles de predicción muestran la predicción $\hat{\tau}_{Rk}$ en rojo con la correspondiente función objetivo τ_{IDk} en negro

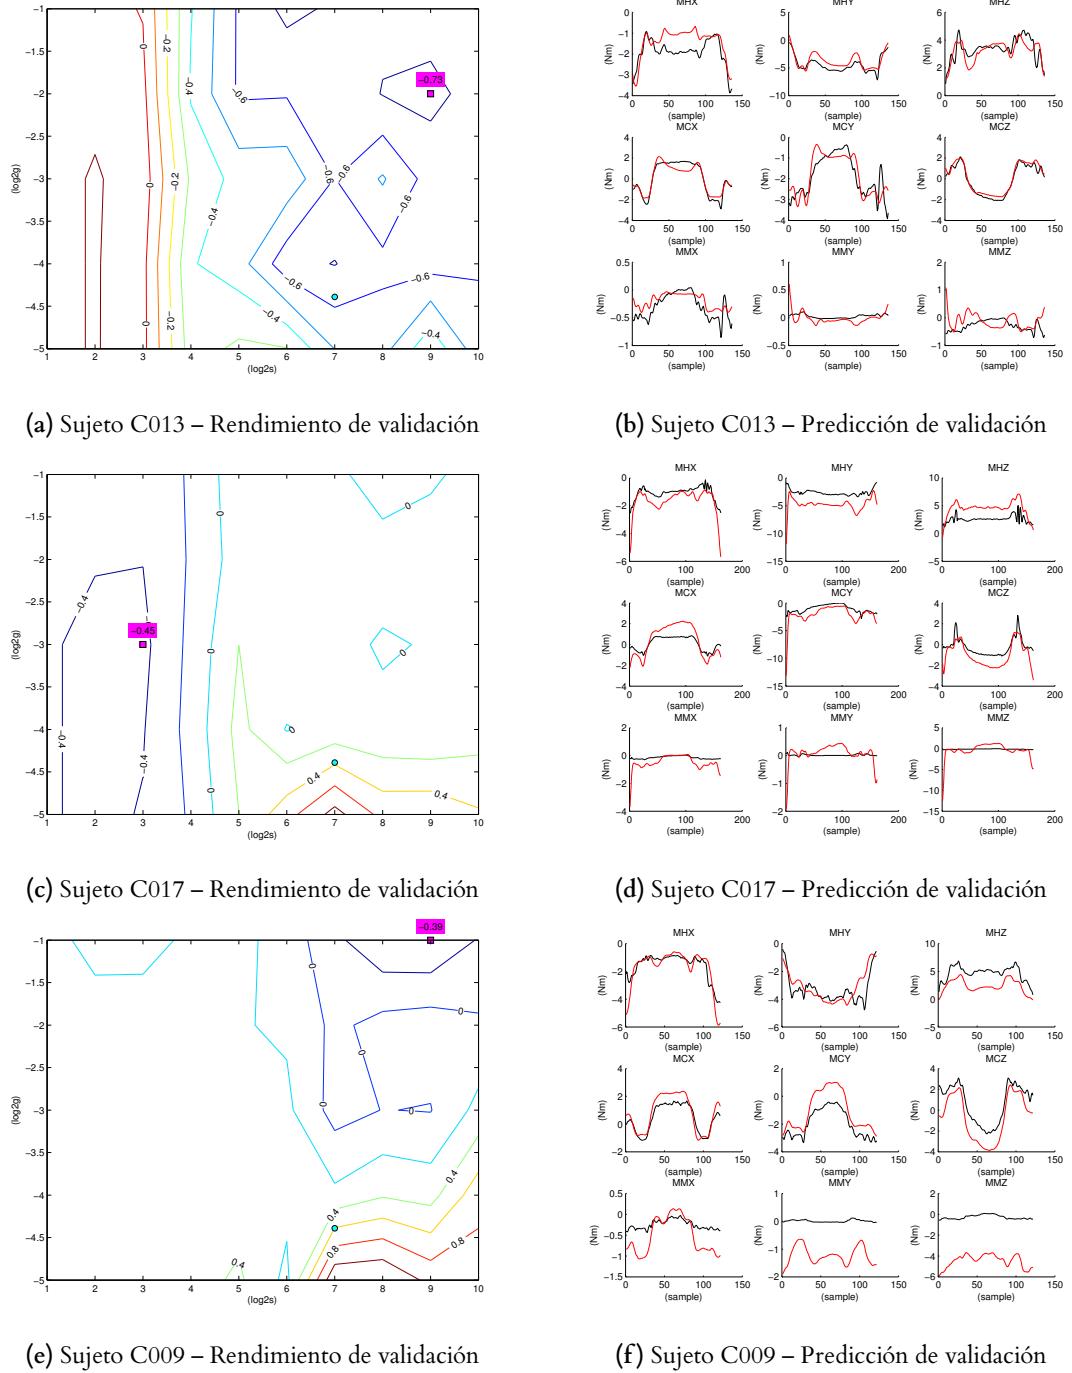


Figura F.7: Mapa de rendimiento de validación y predicción de validación por el modelo RBN del momento articular para el escenario ESM – Población (Controles). Los paneles de optimización muestran con un marcador magenta la localización del mínimo del MSE de validación y en cian los hiperparámetros finalmente empleados. Los paneles de predicción muestran la predicción $\hat{\tau}_{Rk}$ en rojo con la correspondiente función objetivo τ_{IDk} en negro

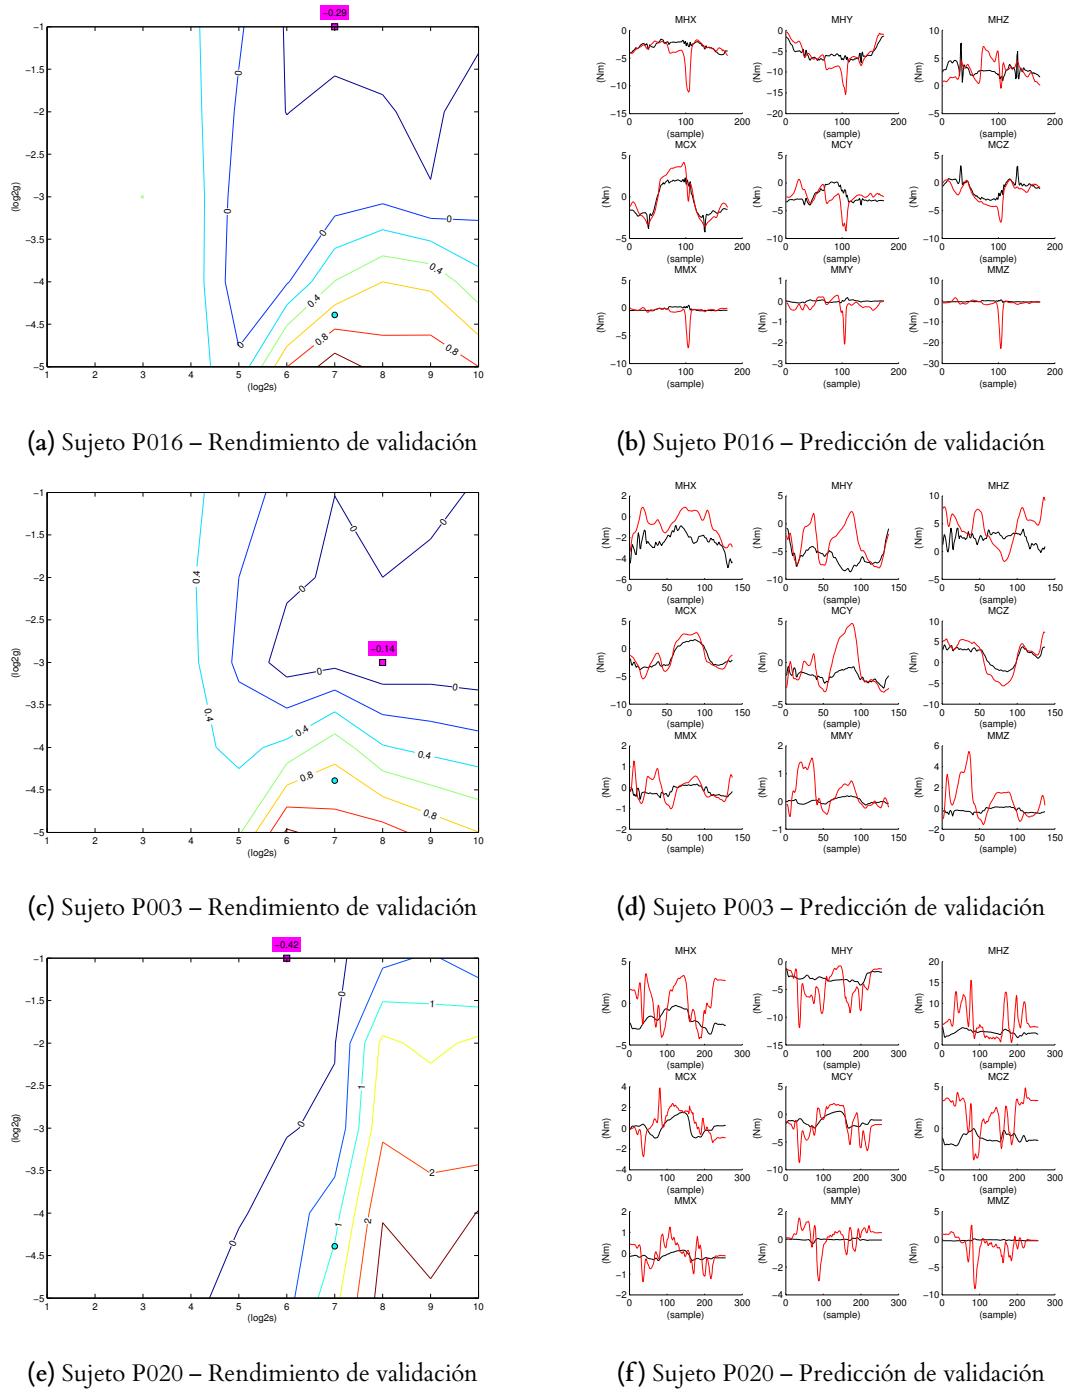


Figura F.8: Mapa de rendimiento de validación y predicción de validación por el modelo RBN del momento articular para el escenario ESM – Población (Pacientes). Los paneles de optimización muestran con un marcador magenta la localización del mínimo del MSE de validación y en cian los hiperparámetros finalmente empleados. Los paneles de predicción muestran la predicción $\hat{\tau}_{Rk}$ en rojo con la correspondiente función objetivo τ_{IDk} en negro

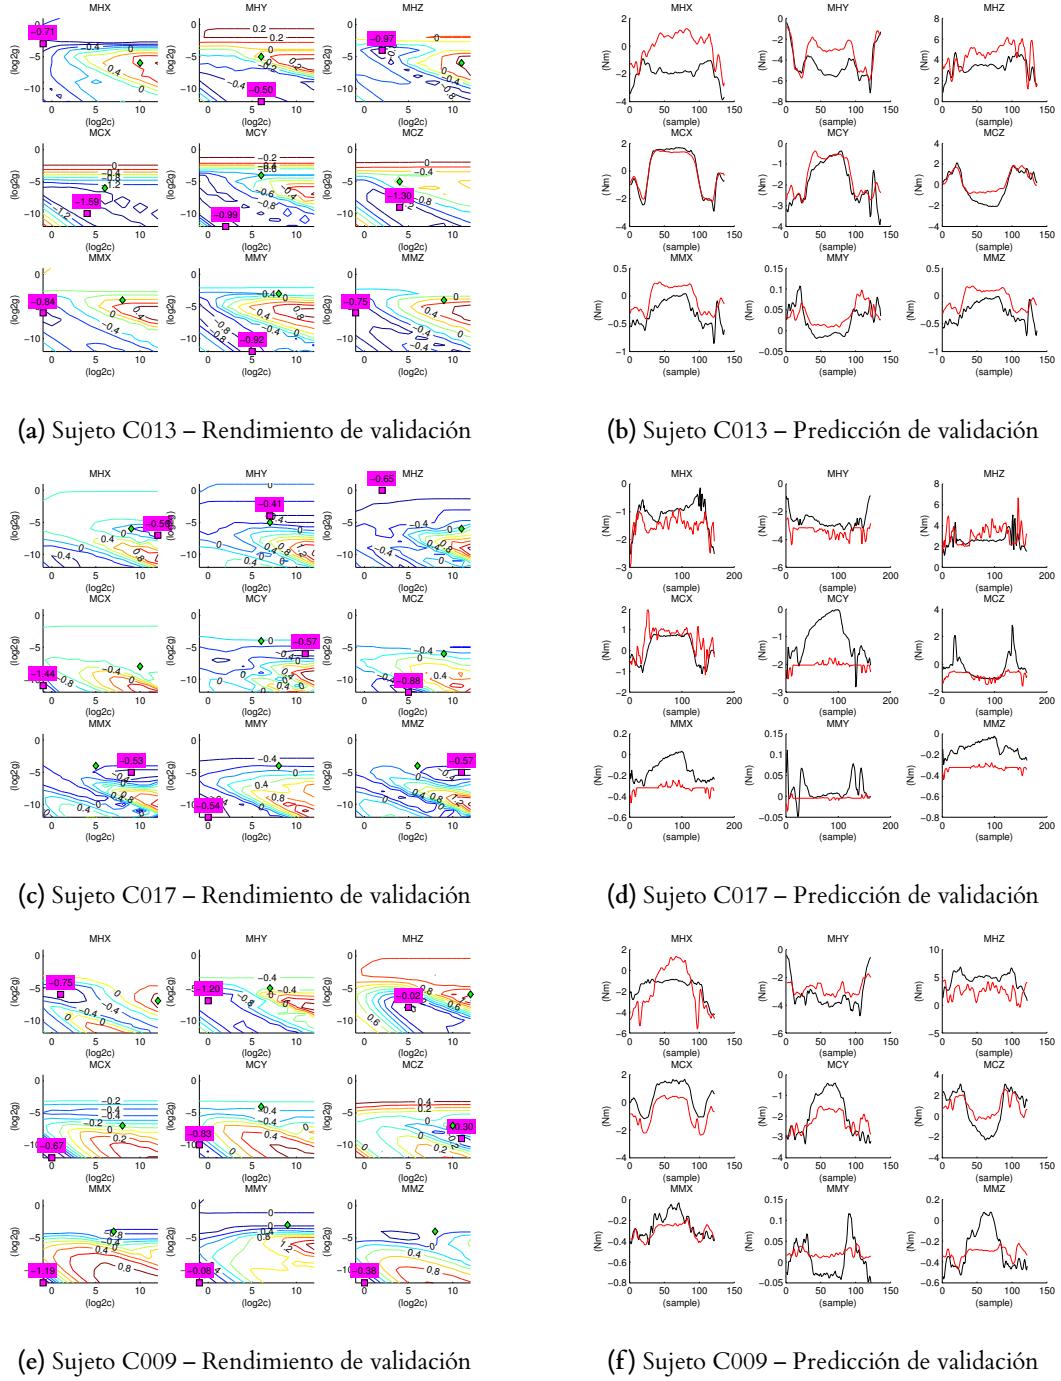
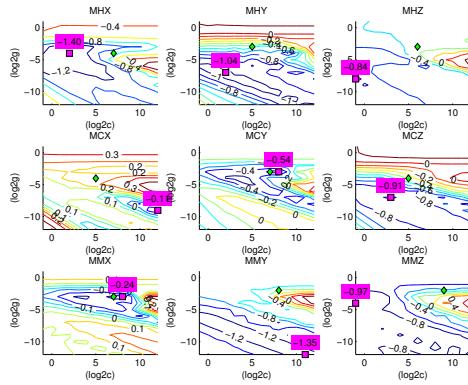
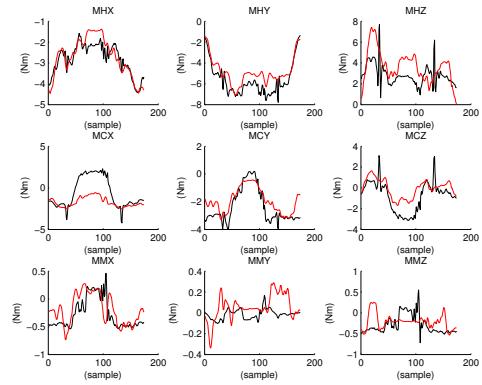


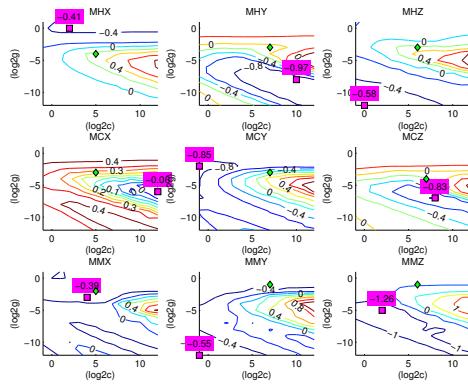
Figura F.9: Mapa de rendimiento de validación y predicción de validación por el modelo SVM del momento articular para el escenario ESM – solo Controles. Los paneles de optimización muestran con un marcador magenta la localización del mínimo del MSE de validación y en verde los hiperparámetros encontrados por el proceso de búsqueda con el entrenamiento generalizado por validación cruzada. Los paneles de predicción muestran la predicción $\hat{\tau}_{V_k}$ en rojo con la correspondiente función objetivo τ_{ID_k} en negro



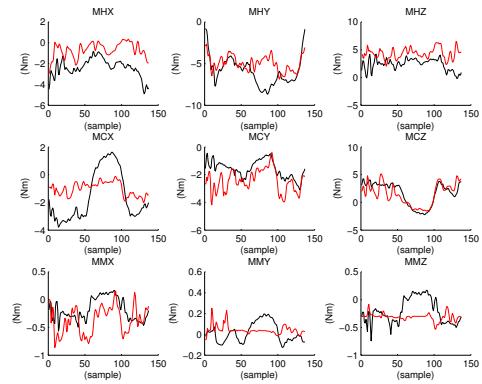
(a) Sujeto P016 – Rendimiento de validación



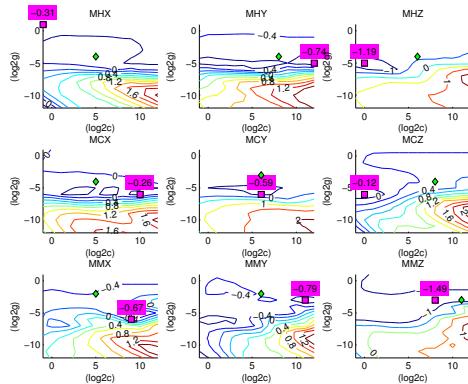
(b) Sujeto P016 – Predicción de validación



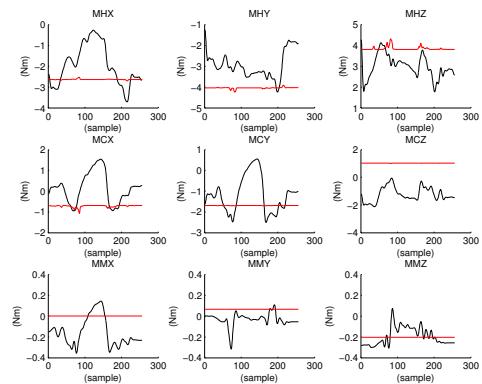
(c) Sujeto P003 – Rendimiento de validación



(d) Sujeto P003 – Predicción de validación



(e) Sujeto P020 – Rendimiento de validación



(f) Sujeto P020 – Predicción de validación

Figura F.10: Mapa de rendimiento de validación y predicción de validación por el modelo SVM del momento articular para el escenario ESM – solo Pacientes. Los paneles de optimización muestran con un marcador magenta la localización del mínimo del MSE de validación y en verde los hiperparámetros encontrados por el proceso de búsqueda con el entrenamiento generalizado por validación cruzada. Los paneles de predicción muestran la predicción $\hat{\tau}_{V_k}$ en rojo con la correspondiente función objetivo τ_{ID_k} en negro

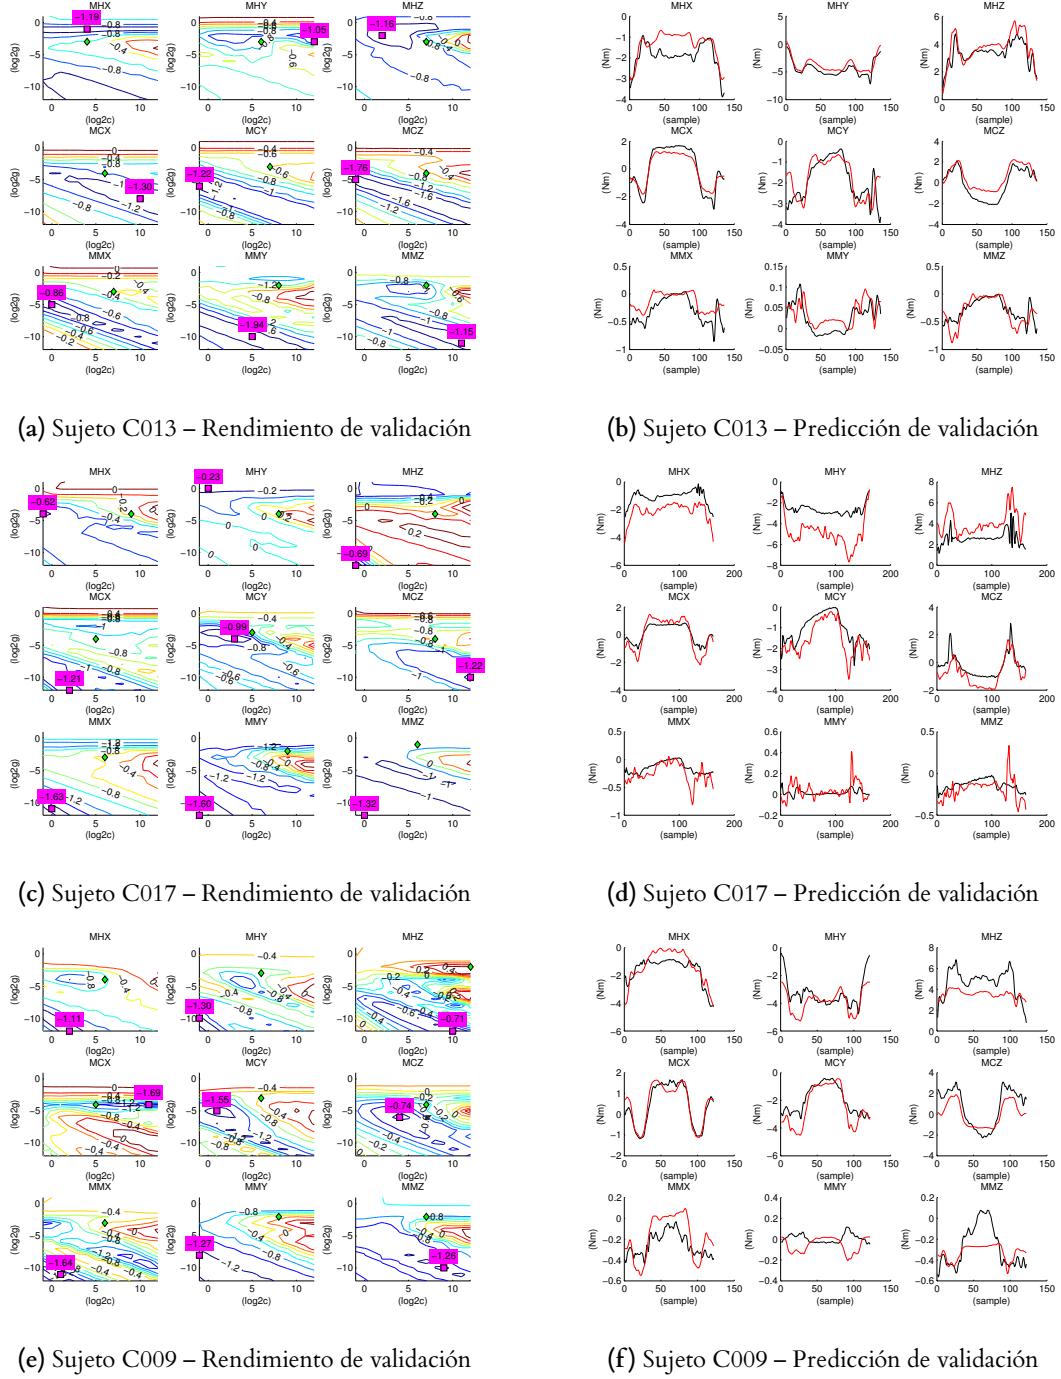


Figura F.11: Mapa de rendimiento de validación y predicción de validación por el modelo SVM del momento articular para el escenario ESM – Población (Controles). Los paneles de optimización muestran con un marcador magenta la localización del mínimo del MSE de validación y en verde los hiperparámetros encontrados por el proceso de búsqueda con el entrenamiento generalizado por validación cruzada. Los paneles de predicción muestran la predicción $\hat{\tau}_{V_k}$ en rojo con la correspondiente función objetivo τ_{ID_k} en negro

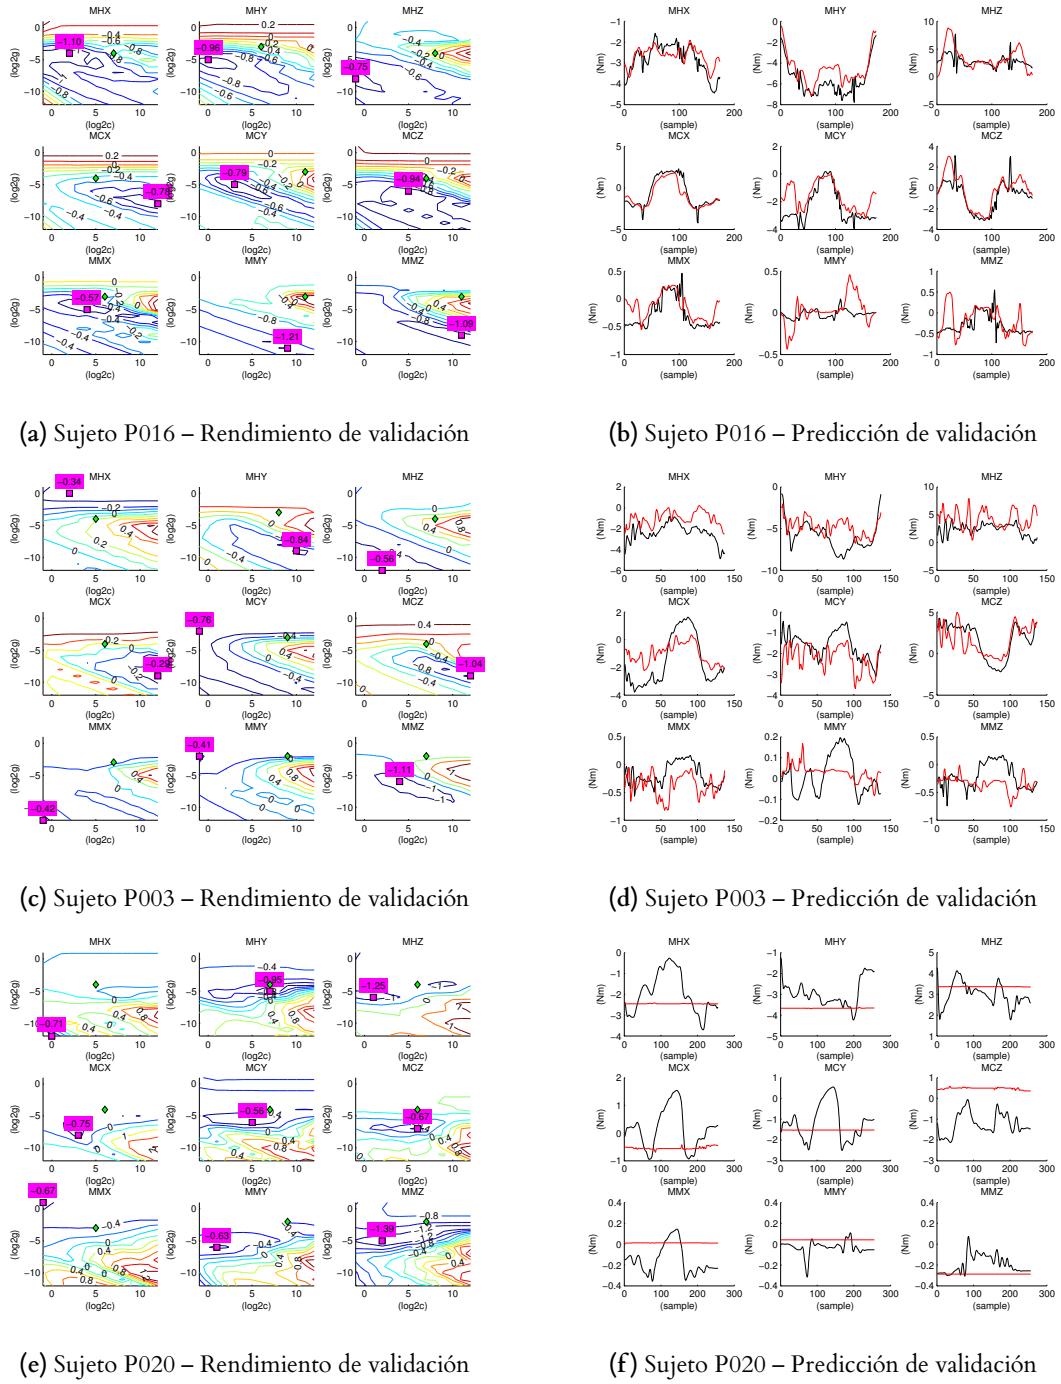


Figura F.12: Mapa de rendimiento de validación y predicción de validación por el modelo SVM del momento articular para el escenario ESM – Población (Pacientes). Los paneles de optimización muestran con un marcador magenta la localización del mínimo del MSE de validación y en verde los hiperparámetros encontrados por el proceso de búsqueda con el entrenamiento generalizado por validación cruzada. Los paneles de predicción muestran la predicción $\hat{\tau}_{V_k}$ en rojo con la correspondiente función objetivo τ_{ID_k} en negro

APÉNDICE G

Tablas complementarias de resultados obtenidos

Para complementar los datos proporcionados en el capítulo 6 se anexan los resultados, detallados a nivel de articulación (hombro, codo o muñeca), para los distintos modelos propuestos junto con las variaciones del modelo aoMLP del escenario ESU.

G.1 Modelos propuestos para el escenario ESU

aoMLP véanse la figura G.1 y la tabla G.1

RBN véanse la figura G.2 y la tabla G.2

SVM véanse la figura G.3 y la tabla G.3

G.2 Modelos propuestos para el escenario ESM

aoMLP véanse la figura G.4 y la tabla G.4

RBN véanse la figura G.5 y la tabla G.5

SVM véanse la figura G.6 y la tabla G.6

G.3 Variaciones de las configuraciones propuestas

Sin ensamble véanse la figura G.7 y la tabla G.7

Ensamble de 10 MLP véanse la figura G.8 y la tabla G.8

F_m de 200 Hz véanse la figura G.9 y la tabla G.9

Entrenamiento LM véanse la figura G.10 y la tabla G.10

Sin Cinemática véanse la figura G.11 y la tabla G.11

3 Sinergias véanse la figura G.14 y la tabla G.14

5 Sinergias véanse la figura G.15 y la tabla G.15

80 % PCA véanse la figura G.12 y la tabla G.12

90 % PCA véanse la figura G.13 y la tabla G.13

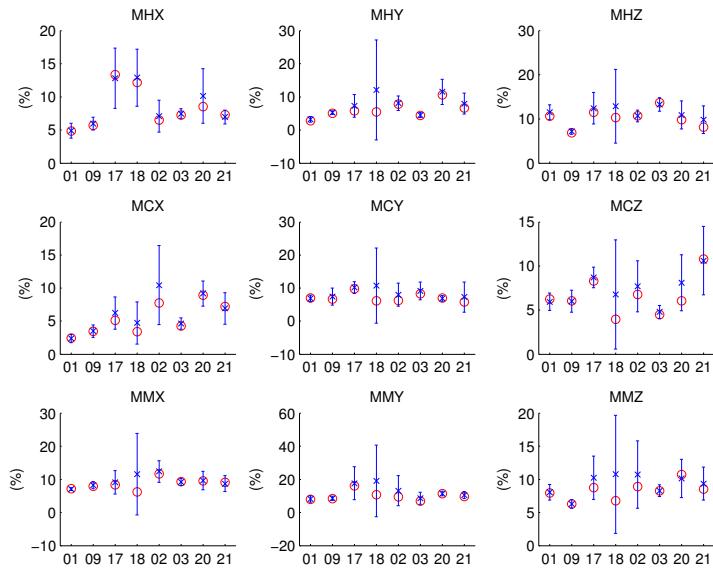


Figura G.1: NRMSD esperado para el modelo aoMLP propuesto en el escenario ESU. Está representado tanto por la media y desviación estándar (en azul) como por la mediana (en rojo) de las predicciones de validación realizadas al aplicar LOOCV

Tabla G.1: Resultados del modelo aoMLP para el escenario ESU

	Controles				Pacientes				
	C001	C009	C017	C018	P002	P003	P020	P021	
R²	Homb	0,86 ± 0,03	0,92 ± 0,01	0,85 ± 0,12	0,89 ± 0,05	0,88 ± 0,03	0,85 ± 0,02	0,49 ± 0,27	0,77 ± 0,24
	Codo	0,96 ± 0,01	0,96 ± 0,02	0,90 ± 0,02	0,98 ± 0,01	0,92 ± 0,03	0,94 ± 0,03	0,92 ± 0,03	0,83 ± 0,18
	Muñe	0,93 ± 0,02	0,92 ± 0,03	0,51 ± 0,14	0,91 ± 0,05	0,85 ± 0,04	0,90 ± 0,01	0,69 ± 0,08	0,81 ± 0,08
	Total	0,92 ± 0,01	0,93 ± 0,02	0,76 ± 0,08	0,93 ± 0,04	0,88 ± 0,02	0,90 ± 0,01	0,70 ± 0,09	0,80 ± 0,15
NRMSD	Homb	0,07 ± 0,01	0,06 ± 0,00	0,11 ± 0,03	0,13 ± 0,09	0,09 ± 0,02	0,08 ± 0,01	0,11 ± 0,03	0,08 ± 0,02
	Codo	0,05 ± 0,01	0,06 ± 0,01	0,08 ± 0,01	0,07 ± 0,07	0,09 ± 0,04	0,06 ± 0,01	0,08 ± 0,01	0,08 ± 0,03
	Muñe	0,08 ± 0,01	0,08 ± 0,01	0,12 ± 0,04	0,14 ± 0,14	0,12 ± 0,06	0,09 ± 0,02	0,10 ± 0,02	0,10 ± 0,01
	Total	0,06 ± 0,01	0,06 ± 0,01	0,11 ± 0,03	0,11 ± 0,10	0,10 ± 0,03	0,08 ± 0,01	0,10 ± 0,02	0,09 ± 0,02
E_{rms} (N m)	Homb	0,21 ± 0,04	0,30 ± 0,02	0,38 ± 0,13	0,52 ± 0,52	0,46 ± 0,07	0,49 ± 0,06	0,42 ± 0,14	0,22 ± 0,12
	Codo	0,11 ± 0,02	0,25 ± 0,08	0,21 ± 0,05	0,36 ± 0,39	0,31 ± 0,15	0,27 ± 0,05	0,23 ± 0,05	0,18 ± 0,11
	Muñe	0,01 ± 0,00	0,03 ± 0,00	0,14 ± 0,05	0,09 ± 0,10	0,11 ± 0,07	0,06 ± 0,01	0,06 ± 0,01	0,04 ± 0,01
	Total	0,11 ± 0,02	0,19 ± 0,03	0,24 ± 0,06	0,33 ± 0,34	0,29 ± 0,09	0,27 ± 0,04	0,24 ± 0,06	0,15 ± 0,08
E_{max} (N m)	Homb	0,70 ± 0,24	1,20 ± 0,35	1,32 ± 0,32	1,23 ± 0,75	1,52 ± 0,27	1,71 ± 0,33	2,88 ± 1,55	1,58 ± 1,61
	Codo	0,33 ± 0,09	0,96 ± 0,49	0,72 ± 0,14	0,80 ± 0,49	0,91 ± 0,31	0,91 ± 0,35	1,09 ± 0,47	0,99 ± 0,83
	Muñe	0,04 ± 0,00	0,09 ± 0,01	0,85 ± 0,52	0,22 ± 0,13	0,29 ± 0,13	0,25 ± 0,03	0,34 ± 0,17	0,16 ± 0,06
	Total	0,36 ± 0,10	0,75 ± 0,16	0,96 ± 0,22	0,75 ± 0,46	0,91 ± 0,21	0,96 ± 0,21	1,44 ± 0,70	0,91 ± 0,82

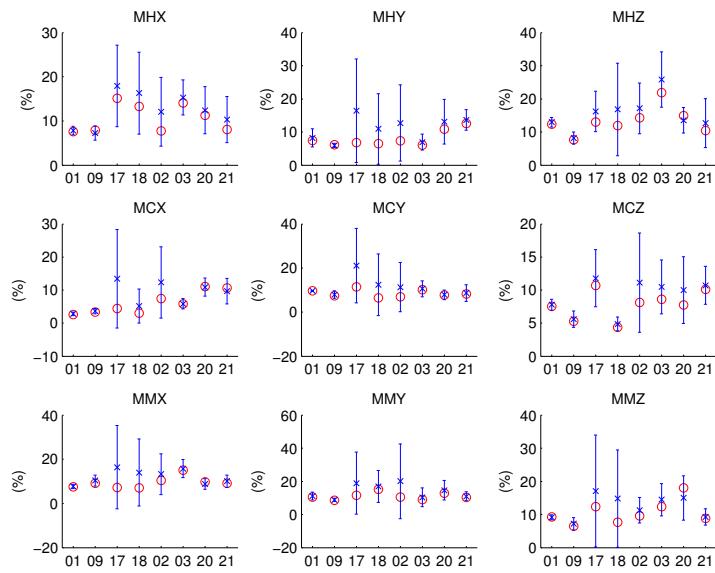


Figura G.2: NRMSD esperado para el modelo RBN propuesto en el escenario ESU. Está representado tanto por la media y desviación estándar (en azul) como por la mediana (en rojo) de las predicciones de validación realizadas al aplicar LOOCV

Tabla G.2: Resultados del modelo RBN para el escenario ESU

	Controles				Pacientes				
	C001	C009	C017	C018	P002	P003	P020	P021	
R²	Homb	0,79 ± 0,03	0,89 ± 0,03	0,67 ± 0,27	0,85 ± 0,08	0,73 ± 0,21	0,64 ± 0,11	0,45 ± 0,29	0,55 ± 0,23
	Codo	0,93 ± 0,01	0,97 ± 0,02	0,74 ± 0,23	0,98 ± 0,01	0,86 ± 0,15	0,89 ± 0,09	0,89 ± 0,02	0,79 ± 0,17
	Muñé	0,89 ± 0,02	0,92 ± 0,01	0,47 ± 0,24	0,81 ± 0,17	0,76 ± 0,20	0,81 ± 0,06	0,63 ± 0,07	0,76 ± 0,13
	Total	0,87 ± 0,02	0,92 ± 0,02	0,62 ± 0,24	0,88 ± 0,08	0,79 ± 0,19	0,78 ± 0,03	0,66 ± 0,09	0,70 ± 0,14
NRMSD	Homb	0,10 ± 0,01	0,07 ± 0,01	0,17 ± 0,09	0,15 ± 0,11	0,14 ± 0,09	0,16 ± 0,04	0,13 ± 0,05	0,12 ± 0,04
	Codo	0,07 ± 0,00	0,06 ± 0,01	0,15 ± 0,10	0,07 ± 0,07	0,12 ± 0,10	0,09 ± 0,03	0,10 ± 0,02	0,10 ± 0,02
	Muñé	0,09 ± 0,01	0,09 ± 0,02	0,17 ± 0,18	0,15 ± 0,13	0,15 ± 0,12	0,13 ± 0,05	0,13 ± 0,04	0,10 ± 0,02
	Total	0,09 ± 0,01	0,07 ± 0,01	0,17 ± 0,11	0,12 ± 0,10	0,13 ± 0,10	0,13 ± 0,04	0,12 ± 0,03	0,11 ± 0,02
E_{rms} (N m)	Homb	0,34 ± 0,08	0,35 ± 0,04	0,57 ± 0,32	0,58 ± 0,57	0,78 ± 0,56	1,23 ± 0,56	0,55 ± 0,28	0,34 ± 0,13
	Codo	0,15 ± 0,01	0,24 ± 0,06	0,44 ± 0,34	0,38 ± 0,40	0,46 ± 0,45	0,46 ± 0,15	0,28 ± 0,08	0,22 ± 0,11
	Muñé	0,02 ± 0,00	0,03 ± 0,01	0,25 ± 0,18	0,12 ± 0,15	0,15 ± 0,14	0,13 ± 0,10	0,08 ± 0,02	0,04 ± 0,01
	Total	0,17 ± 0,03	0,21 ± 0,03	0,42 ± 0,28	0,36 ± 0,37	0,47 ± 0,38	0,60 ± 0,27	0,30 ± 0,12	0,20 ± 0,08
E_{max} (N m)	Homb	1,04 ± 0,28	1,29 ± 0,25	1,60 ± 0,61	1,34 ± 0,82	2,06 ± 0,94	3,08 ± 1,10	2,89 ± 1,69	1,66 ± 1,38
	Codo	0,43 ± 0,09	0,84 ± 0,34	1,12 ± 0,55	0,81 ± 0,53	1,14 ± 0,75	1,20 ± 0,39	1,11 ± 0,47	1,18 ± 0,85
	Muñé	0,05 ± 0,00	0,10 ± 0,02	0,90 ± 0,59	0,29 ± 0,22	0,39 ± 0,20	0,32 ± 0,20	0,37 ± 0,16	0,18 ± 0,08
	Total	0,51 ± 0,12	0,74 ± 0,16	1,21 ± 0,57	0,81 ± 0,52	1,19 ± 0,62	1,54 ± 0,54	1,46 ± 0,75	1,00 ± 0,75

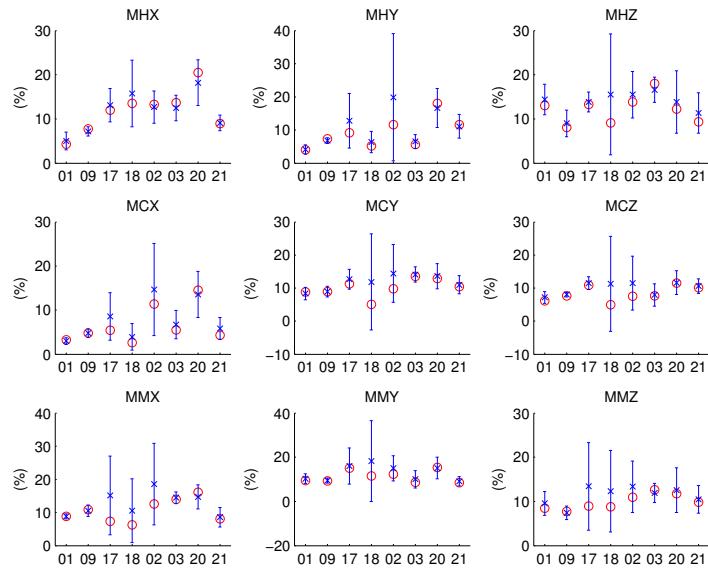


Figura G.3: NRMSD esperado para el modelo SVM propuesto en el escenario ESU. Está representado tanto por la media y desviación estándar (en azul) como por la mediana (en rojo) de las predicciones de validación realizadas al aplicar LOOCV

Tabla G.3: Resultados del modelo SVM para el escenario ESU

		Controles				Pacientes			
		C001	C009	C017	C018	P002	P003	P020	P021
R²	Homb	0,80 ± 0,07	0,87 ± 0,03	0,74 ± 0,20	0,76 ± 0,21	0,66 ± 0,23	0,76 ± 0,05	0,20 ± 0,12	0,65 ± 0,12
	Codo	0,95 ± 0,01	0,95 ± 0,02	0,83 ± 0,04	0,92 ± 0,14	0,73 ± 0,33	0,86 ± 0,08	0,78 ± 0,07	0,68 ± 0,15
	Muñé	0,88 ± 0,04	0,87 ± 0,05	0,42 ± 0,24	0,76 ± 0,34	0,61 ± 0,33	0,79 ± 0,05	0,46 ± 0,19	0,70 ± 0,15
	Total	0,88 ± 0,04	0,89 ± 0,01	0,67 ± 0,14	0,81 ± 0,23	0,67 ± 0,30	0,80 ± 0,06	0,48 ± 0,04	0,68 ± 0,08
NRMSD	Homb	0,08 ± 0,02	0,08 ± 0,01	0,13 ± 0,04	0,13 ± 0,08	0,16 ± 0,09	0,12 ± 0,02	0,16 ± 0,05	0,11 ± 0,02
	Codo	0,06 ± 0,01	0,07 ± 0,01	0,11 ± 0,03	0,09 ± 0,11	0,14 ± 0,09	0,10 ± 0,02	0,13 ± 0,02	0,09 ± 0,02
	Muñé	0,10 ± 0,01	0,09 ± 0,01	0,15 ± 0,09	0,14 ± 0,12	0,16 ± 0,08	0,12 ± 0,02	0,14 ± 0,04	0,09 ± 0,02
	Total	0,08 ± 0,01	0,08 ± 0,01	0,13 ± 0,05	0,12 ± 0,10	0,15 ± 0,08	0,11 ± 0,02	0,14 ± 0,03	0,10 ± 0,02
E_{rms} (N m)	Homb	0,27 ± 0,08	0,40 ± 0,05	0,46 ± 0,12	0,50 ± 0,43	0,93 ± 0,62	0,71 ± 0,18	0,77 ± 0,24	0,40 ± 0,16
	Codo	0,14 ± 0,03	0,32 ± 0,05	0,27 ± 0,10	0,53 ± 0,76	0,50 ± 0,37	0,42 ± 0,13	0,36 ± 0,05	0,25 ± 0,09
	Muñé	0,02 ± 0,02	0,04 ± 0,01	0,25 ± 0,26	0,09 ± 0,08	0,13 ± 0,07	0,09 ± 0,01	0,09 ± 0,02	0,05 ± 0,02
	Total	0,14 ± 0,04	0,25 ± 0,03	0,33 ± 0,13	0,37 ± 0,42	0,52 ± 0,35	0,40 ± 0,09	0,40 ± 0,09	0,23 ± 0,04
E_{max} (N m)	Homb	1,01 ± 0,51	1,46 ± 0,23	1,46 ± 0,39	1,33 ± 0,65	2,35 ± 0,89	2,10 ± 0,50	4,31 ± 2,70	2,75 ± 1,59
	Codo	0,43 ± 0,16	1,13 ± 0,51	0,91 ± 0,32	1,11 ± 1,11	1,37 ± 0,73	1,20 ± 0,33	1,45 ± 0,34	1,52 ± 0,52
	Muñé	0,05 ± 0,01	0,11 ± 0,02	0,94 ± 0,67	0,23 ± 0,16	0,37 ± 0,12	0,27 ± 0,04	0,38 ± 0,14	0,28 ± 0,13
	Total	0,49 ± 0,22	0,90 ± 0,20	1,10 ± 0,28	0,89 ± 0,64	1,36 ± 0,57	1,19 ± 0,24	2,05 ± 0,99	1,52 ± 0,44

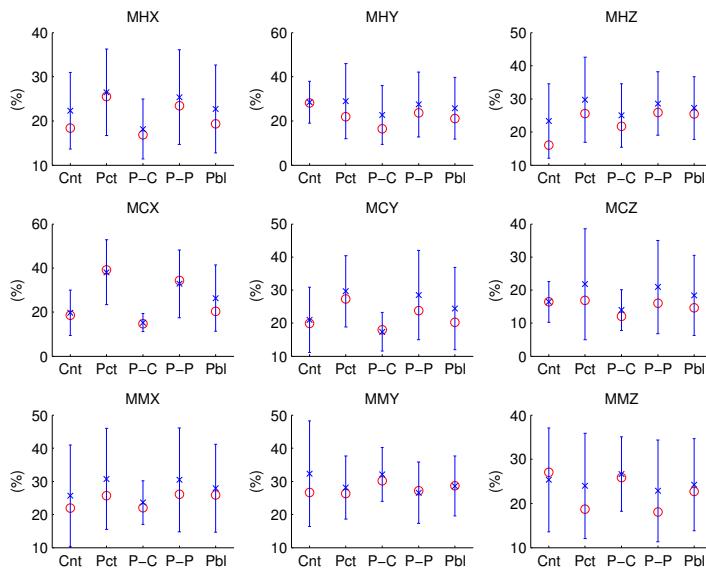


Figura G.4: NRMSE esperado para el modelo aoMLP propuesto en el escenario ESM. Están representados tanto por la media y desviación estándar (en azul) como por la mediana (en rojo) de las predicciones de validación realizadas al aplicar LOOCV

Tabla G.4: Resultados del modelo aoMLP para el escenario ESM

		solo		Población completa		
		Controles	Pacientes	Controles	Pacientes	Todos
R²	Homb	0,63 ± 0,14	0,50 ± 0,17	0,67 ± 0,18	0,52 ± 0,14	0,58 ± 0,17
	Codo	0,89 ± 0,07	0,59 ± 0,15	0,91 ± 0,04	0,63 ± 0,22	0,74 ± 0,22
	Muñé	0,66 ± 0,15	0,29 ± 0,22	0,60 ± 0,12	0,24 ± 0,19	0,37 ± 0,24
	Total	0,72 ± 0,08	0,46 ± 0,16	0,73 ± 0,07	0,47 ± 0,15	0,56 ± 0,18
NRMSE	Homb	0,25 ± 0,08	0,28 ± 0,12	0,22 ± 0,09	0,27 ± 0,09	0,25 ± 0,09
	Codo	0,19 ± 0,08	0,30 ± 0,12	0,16 ± 0,04	0,27 ± 0,12	0,23 ± 0,11
	Muñé	0,28 ± 0,13	0,27 ± 0,09	0,27 ± 0,04	0,27 ± 0,09	0,27 ± 0,07
	Total	0,24 ± 0,07	0,28 ± 0,09	0,22 ± 0,03	0,27 ± 0,08	0,25 ± 0,07
E_{rms} (N m)	Homb	1,04 ± 0,20	1,51 ± 0,71	0,87 ± 0,29	1,41 ± 0,51	1,21 ± 0,51
	Codo	0,80 ± 0,47	1,58 ± 1,05	0,58 ± 0,18	1,26 ± 0,60	1,01 ± 0,59
	Muñé	0,18 ± 0,14	0,31 ± 0,16	0,13 ± 0,06	0,29 ± 0,16	0,23 ± 0,15
	Total	0,67 ± 0,21	1,14 ± 0,58	0,53 ± 0,11	0,99 ± 0,34	0,82 ± 0,36
E_{max} (N m)	Homb	2,12 ± 0,42	3,30 ± 0,87	1,88 ± 0,37	3,06 ± 0,63	2,63 ± 0,79
	Codo	1,62 ± 0,56	3,20 ± 1,56	1,30 ± 0,19	2,74 ± 0,97	2,21 ± 1,05
	Muñé	0,36 ± 0,13	1,11 ± 1,12	0,25 ± 0,09	1,05 ± 1,12	0,76 ± 0,96
	Total	1,37 ± 0,26	2,54 ± 0,96	1,14 ± 0,14	2,29 ± 0,72	1,87 ± 0,80

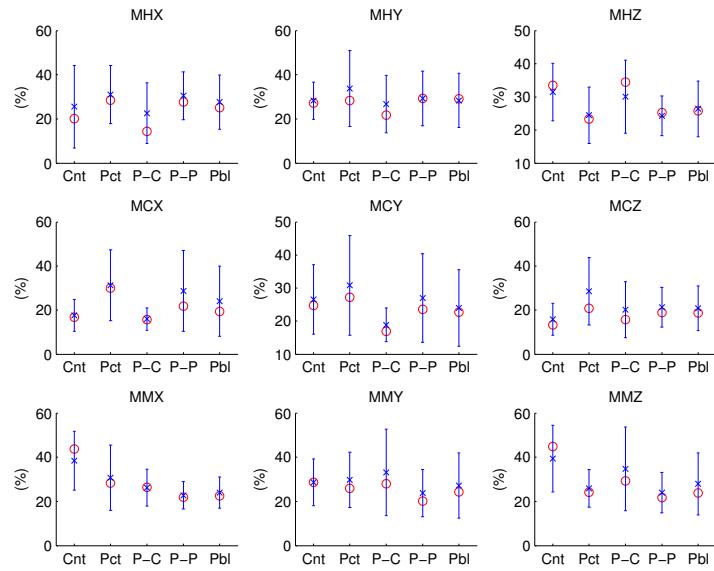


Figura G.5: NRMSD esperado para el modelo RBN propuesto en el escenario ESM. Está representado tanto por la media y desviación estándar (en azul) como por la mediana (en rojo) de las predicciones de validación realizadas al aplicar LOOCV

Tabla G.5: Resultados del modelo RBN para el escenario ESM

		solo Controles		Población completa		
			Pacientes	Controles	Pacientes	Todos
R²	Homb	0,57 ± 0,21	0,15 ± 0,10	0,45 ± 0,22	0,16 ± 0,08	0,27 ± 0,21
	Codo	0,85 ± 0,08	0,34 ± 0,22	0,80 ± 0,11	0,38 ± 0,21	0,53 ± 0,27
	Muñé	0,50 ± 0,20	0,15 ± 0,09	0,37 ± 0,15	0,15 ± 0,13	0,23 ± 0,18
	Total	0,64 ± 0,14	0,21 ± 0,09	0,54 ± 0,09	0,23 ± 0,09	0,34 ± 0,18
NRMSD	Homb	0,28 ± 0,10	0,30 ± 0,10	0,26 ± 0,11	0,28 ± 0,08	0,27 ± 0,09
	Codo	0,20 ± 0,05	0,30 ± 0,14	0,18 ± 0,06	0,26 ± 0,10	0,23 ± 0,09
	Muñé	0,35 ± 0,12	0,29 ± 0,10	0,31 ± 0,14	0,23 ± 0,07	0,26 ± 0,11
	Total	0,28 ± 0,07	0,30 ± 0,10	0,25 ± 0,09	0,26 ± 0,08	0,26 ± 0,08
E_{rms} (N m)	Homb	1,61 ± 0,73	6,05 ± 4,51	1,51 ± 0,64	4,66 ± 4,18	3,50 ± 3,64
	Codo	0,95 ± 0,44	4,74 ± 4,00	0,98 ± 0,46	3,41 ± 2,49	2,52 ± 2,30
	Muñé	0,34 ± 0,23	3,65 ± 3,55	0,80 ± 0,58	2,46 ± 2,42	1,85 ± 2,09
	Total	0,97 ± 0,45	4,81 ± 3,52	1,10 ± 0,46	3,51 ± 2,78	2,62 ± 2,49
E_{max} (N m)	Homb	3,21 ± 1,59	16,25 ± 12,79	3,58 ± 1,66	11,96 ± 7,75	8,87 ± 7,41
	Codo	2,03 ± 1,01	11,97 ± 11,40	2,50 ± 1,45	9,61 ± 8,21	6,99 ± 7,37
	Muñé	0,65 ± 0,50	12,27 ± 17,51	2,11 ± 1,81	9,02 ± 10,81	6,47 ± 9,18
	Total	1,96 ± 1,01	13,50 ± 13,36	2,73 ± 1,57	10,19 ± 8,24	7,44 ± 7,48

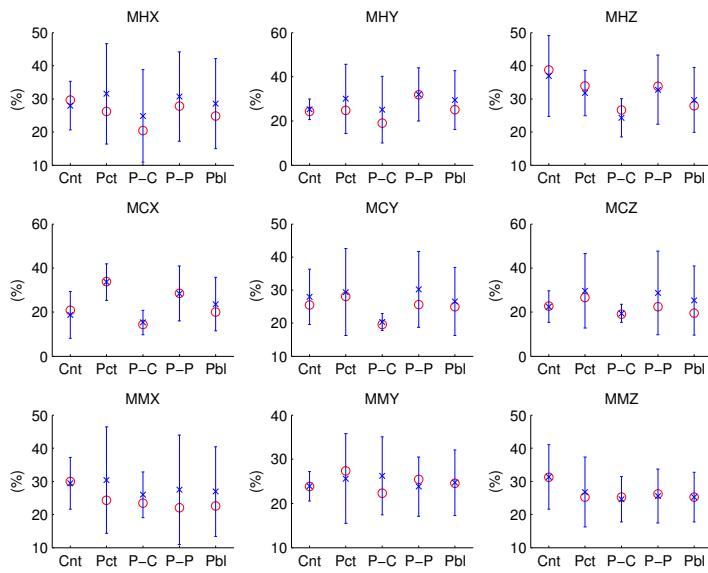


Figura G.6: NRMSD esperado para el modelo SVM propuesto en el escenario ESM. Está representado tanto por la media y desviación estándar (en azul) como por la mediana (en rojo) de las predicciones de validación realizadas al aplicar LOOCV

Tabla G.6: Resultados del modelo SVM para el escenario ESM

		solo		Población completa		
		Controles	Pacientes	Controles	Pacientes	Todos
R²	Homb	0,32 ± 0,12	0,22 ± 0,17	0,50 ± 0,22	0,24 ± 0,18	0,34 ± 0,23
	Codo	0,67 ± 0,27	0,37 ± 0,23	0,78 ± 0,13	0,39 ± 0,28	0,54 ± 0,30
	Muñé	0,36 ± 0,16	0,08 ± 0,10	0,33 ± 0,22	0,11 ± 0,15	0,19 ± 0,20
	Total	0,45 ± 0,16	0,23 ± 0,15	0,54 ± 0,15	0,25 ± 0,18	0,35 ± 0,20
NRMSD	Homb	0,30 ± 0,05	0,31 ± 0,11	0,25 ± 0,10	0,32 ± 0,10	0,29 ± 0,10
	Codo	0,23 ± 0,06	0,31 ± 0,10	0,18 ± 0,02	0,29 ± 0,11	0,25 ± 0,10
	Muñé	0,28 ± 0,05	0,28 ± 0,09	0,26 ± 0,06	0,26 ± 0,08	0,26 ± 0,07
	Total	0,27 ± 0,03	0,30 ± 0,08	0,23 ± 0,04	0,29 ± 0,07	0,27 ± 0,07
E_{rms} (N m)	Homb	1,58 ± 0,48	1,68 ± 0,57	1,17 ± 0,43	1,70 ± 0,50	1,51 ± 0,54
	Codo	0,85 ± 0,18	1,41 ± 0,33	0,75 ± 0,10	1,25 ± 0,32	1,07 ± 0,36
	Muñé	0,16 ± 0,07	0,43 ± 0,38	0,15 ± 0,05	0,31 ± 0,16	0,25 ± 0,15
	Total	0,86 ± 0,20	1,17 ± 0,35	0,69 ± 0,13	1,09 ± 0,26	0,94 ± 0,29
E_{max} (N m)	Homb	3,21 ± 0,59	3,79 ± 0,97	2,61 ± 0,85	3,73 ± 0,92	3,32 ± 1,04
	Codo	1,82 ± 0,33	2,92 ± 0,61	1,69 ± 0,13	2,67 ± 0,59	2,31 ± 0,67
	Muñé	0,30 ± 0,11	1,42 ± 1,33	0,36 ± 0,09	1,12 ± 1,06	0,84 ± 0,91
	Total	1,78 ± 0,20	2,71 ± 0,87	1,55 ± 0,31	2,51 ± 0,72	2,15 ± 0,76

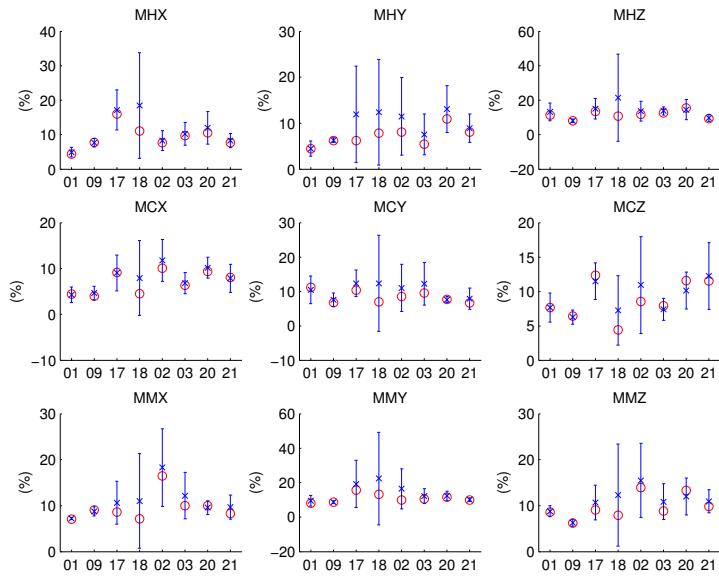


Figura G.7: NRMSD esperado para el modelo aoMLP propuesto en el escenario ESU sin usar aprendizaje por ensamble. Está representado tanto por la media y desviación estándar (en azul) como por la mediana (en rojo) de las predicciones de validación realizadas al aplicar LOOCV

Tabla G.7: Resultados del modelo aoMLP para el escenario ESU – Sin ensamble

	Controles				Pacientes				
	C001	C009	C017	C018	P002	P003	P020	P021	
R²	Homb	0,84 ± 0,05	0,89 ± 0,03	0,76 ± 0,17	0,73 ± 0,30	0,81 ± 0,11	0,78 ± 0,07	0,39 ± 0,26	0,75 ± 0,21
	Codo	0,93 ± 0,04	0,96 ± 0,02	0,84 ± 0,06	0,94 ± 0,08	0,83 ± 0,12	0,90 ± 0,05	0,89 ± 0,03	0,80 ± 0,16
	Muñé	0,91 ± 0,03	0,91 ± 0,03	0,41 ± 0,12	0,83 ± 0,17	0,71 ± 0,12	0,85 ± 0,04	0,64 ± 0,06	0,79 ± 0,05
	Total	0,89 ± 0,02	0,92 ± 0,02	0,67 ± 0,10	0,84 ± 0,18	0,79 ± 0,11	0,84 ± 0,04	0,64 ± 0,08	0,78 ± 0,13
NRMSD	Homb	0,08 ± 0,02	0,07 ± 0,01	0,15 ± 0,06	0,17 ± 0,17	0,11 ± 0,05	0,11 ± 0,02	0,13 ± 0,05	0,09 ± 0,02
	Codo	0,07 ± 0,02	0,06 ± 0,01	0,11 ± 0,03	0,09 ± 0,09	0,11 ± 0,05	0,09 ± 0,03	0,09 ± 0,01	0,09 ± 0,03
	Muñé	0,08 ± 0,01	0,08 ± 0,01	0,14 ± 0,07	0,15 ± 0,16	0,17 ± 0,09	0,12 ± 0,04	0,11 ± 0,02	0,10 ± 0,01
	Total	0,08 ± 0,02	0,07 ± 0,01	0,13 ± 0,05	0,14 ± 0,14	0,13 ± 0,06	0,10 ± 0,03	0,11 ± 0,02	0,10 ± 0,02
E_{rms} (N m)	Homb	0,25 ± 0,05	0,36 ± 0,03	0,60 ± 0,34	0,93 ± 1,28	0,62 ± 0,33	0,78 ± 0,33	0,53 ± 0,22	0,25 ± 0,10
	Codo	0,17 ± 0,06	0,26 ± 0,05	0,28 ± 0,09	0,47 ± 0,54	0,46 ± 0,30	0,40 ± 0,11	0,27 ± 0,04	0,20 ± 0,11
	Muñé	0,01 ± 0,00	0,03 ± 0,00	0,19 ± 0,11	0,10 ± 0,11	0,18 ± 0,16	0,10 ± 0,07	0,07 ± 0,01	0,04 ± 0,01
	Total	0,15 ± 0,04	0,22 ± 0,02	0,35 ± 0,16	0,50 ± 0,64	0,42 ± 0,26	0,43 ± 0,16	0,29 ± 0,08	0,16 ± 0,07
E_{max} (N m)	Homb	0,79 ± 0,22	1,51 ± 0,34	1,79 ± 0,98	1,87 ± 1,62	1,86 ± 0,66	2,61 ± 0,95	2,95 ± 1,57	1,66 ± 1,39
	Codo	0,55 ± 0,23	1,01 ± 0,35	0,99 ± 0,35	1,15 ± 0,91	1,30 ± 0,61	1,27 ± 0,36	1,19 ± 0,39	1,04 ± 0,81
	Muñé	0,04 ± 0,01	0,09 ± 0,01	1,11 ± 0,70	0,24 ± 0,16	0,48 ± 0,29	0,30 ± 0,12	0,34 ± 0,16	0,19 ± 0,08
	Total	0,46 ± 0,14	0,87 ± 0,12	1,30 ± 0,60	1,09 ± 0,89	1,21 ± 0,51	1,40 ± 0,44	1,50 ± 0,68	0,96 ± 0,75

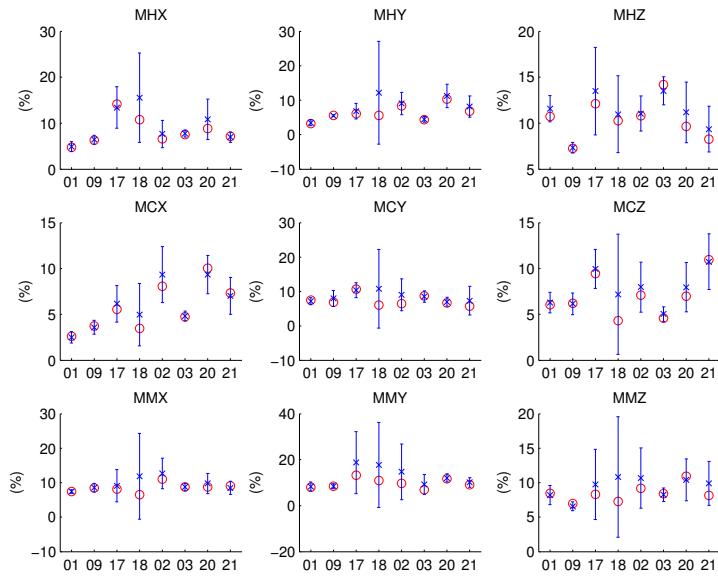


Figura G.8: NRMSD esperado para el modelo aoMLP propuesto en el escenario ESU con un ensamble menor, de únicamente 10 MLP, y aplicando la mediana. Están representados tanto por la media y desviación estándar (en azul) como por la mediana (en rojo) de las predicciones de validación realizadas al aplicar LOOCV

Tabla G.8: Resultados del modelo aoMLP para el escenario ESU – Ensamble de 10 MLP

	Controles				Pacientes				
	C001	C009	C017	C018	P002	P003	P020	P021	
R²	Homb	0,86 ± 0,03	0,92 ± 0,01	0,86 ± 0,10	0,86 ± 0,09	0,86 ± 0,04	0,85 ± 0,02	0,47 ± 0,26	0,78 ± 0,25
	Codo	0,96 ± 0,01	0,96 ± 0,02	0,90 ± 0,02	0,97 ± 0,03	0,92 ± 0,03	0,94 ± 0,02	0,91 ± 0,03	0,83 ± 0,16
	Muñé	0,93 ± 0,02	0,91 ± 0,03	0,53 ± 0,14	0,88 ± 0,11	0,83 ± 0,05	0,89 ± 0,02	0,67 ± 0,08	0,83 ± 0,06
	Total	0,92 ± 0,01	0,93 ± 0,02	0,76 ± 0,06	0,90 ± 0,08	0,87 ± 0,03	0,90 ± 0,01	0,68 ± 0,09	0,81 ± 0,14
NRMSD	Homb	0,07 ± 0,01	0,06 ± 0,00	0,11 ± 0,04	0,13 ± 0,09	0,09 ± 0,02	0,09 ± 0,01	0,11 ± 0,03	0,08 ± 0,02
	Codo	0,05 ± 0,01	0,06 ± 0,01	0,09 ± 0,02	0,08 ± 0,07	0,09 ± 0,03	0,06 ± 0,01	0,08 ± 0,01	0,08 ± 0,02
	Muñé	0,08 ± 0,01	0,08 ± 0,01	0,13 ± 0,05	0,13 ± 0,13	0,13 ± 0,07	0,09 ± 0,02	0,11 ± 0,02	0,10 ± 0,01
	Total	0,07 ± 0,01	0,07 ± 0,01	0,11 ± 0,03	0,11 ± 0,10	0,10 ± 0,04	0,08 ± 0,01	0,10 ± 0,02	0,09 ± 0,01
E_{rms} (N m)	Homb	0,21 ± 0,04	0,32 ± 0,02	0,40 ± 0,15	0,51 ± 0,49	0,49 ± 0,12	0,50 ± 0,07	0,43 ± 0,13	0,22 ± 0,13
	Codo	0,12 ± 0,03	0,25 ± 0,07	0,22 ± 0,06	0,39 ± 0,44	0,32 ± 0,15	0,27 ± 0,03	0,23 ± 0,05	0,18 ± 0,11
	Muñé	0,01 ± 0,00	0,03 ± 0,00	0,12 ± 0,04	0,10 ± 0,11	0,12 ± 0,08	0,06 ± 0,01	0,06 ± 0,01	0,03 ± 0,01
	Total	0,12 ± 0,02	0,20 ± 0,02	0,25 ± 0,07	0,33 ± 0,35	0,31 ± 0,12	0,28 ± 0,04	0,24 ± 0,06	0,14 ± 0,08
E_{max} (N m)	Homb	0,75 ± 0,27	1,25 ± 0,39	1,33 ± 0,36	1,31 ± 0,70	1,60 ± 0,34	1,79 ± 0,43	2,90 ± 1,52	1,58 ± 1,65
	Codo	0,36 ± 0,09	0,95 ± 0,47	0,73 ± 0,19	0,89 ± 0,62	0,93 ± 0,33	0,94 ± 0,30	1,11 ± 0,47	1,01 ± 0,83
	Muñé	0,04 ± 0,00	0,10 ± 0,02	0,78 ± 0,57	0,23 ± 0,15	0,32 ± 0,14	0,26 ± 0,02	0,35 ± 0,16	0,16 ± 0,06
	Total	0,38 ± 0,11	0,77 ± 0,15	0,95 ± 0,23	0,81 ± 0,49	0,95 ± 0,25	0,99 ± 0,23	1,45 ± 0,69	0,91 ± 0,83

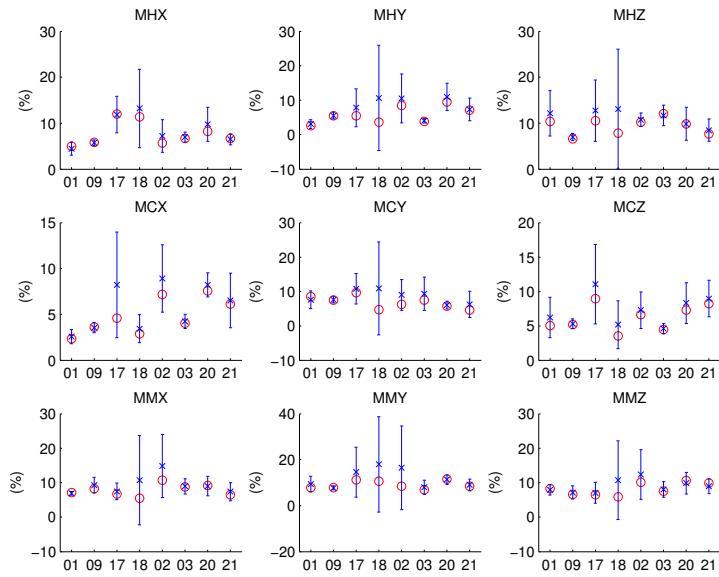


Figura G.9: NRMSD esperado para el modelo aoMLP propuesto en el escenario ESU usando una F_m de 200 Hz. Está representado tanto por la media y desviación estándar (en azul) como por la mediana (en rojo) de las predicciones de validación realizadas al aplicar LOOCV

Tabla G.9: Resultados del modelo aoMLP para el escenario ESU – F_m de 200 Hz

	Controles				Pacientes				
	C001	C009	C017	C018	P002	P003	P020	P021	
R²	Homb	0,87 ± 0,03	0,92 ± 0,01	0,85 ± 0,15	0,88 ± 0,12	0,88 ± 0,04	0,88 ± 0,03	0,53 ± 0,28	0,80 ± 0,23
	Codo	0,96 ± 0,02	0,97 ± 0,00	0,87 ± 0,09	0,97 ± 0,04	0,92 ± 0,04	0,93 ± 0,05	0,93 ± 0,02	0,87 ± 0,15
	Muñé	0,92 ± 0,03	0,92 ± 0,02	0,59 ± 0,20	0,85 ± 0,20	0,83 ± 0,08	0,90 ± 0,04	0,70 ± 0,08	0,84 ± 0,08
	Total	0,92 ± 0,02	0,94 ± 0,01	0,77 ± 0,11	0,90 ± 0,12	0,88 ± 0,04	0,90 ± 0,03	0,72 ± 0,09	0,84 ± 0,13
NRMSD	Homb	0,07 ± 0,02	0,06 ± 0,00	0,11 ± 0,05	0,12 ± 0,12	0,09 ± 0,03	0,08 ± 0,01	0,10 ± 0,03	0,07 ± 0,01
	Codo	0,05 ± 0,02	0,05 ± 0,00	0,10 ± 0,05	0,06 ± 0,06	0,08 ± 0,04	0,06 ± 0,02	0,08 ± 0,01	0,07 ± 0,02
	Muñé	0,08 ± 0,02	0,08 ± 0,01	0,10 ± 0,04	0,13 ± 0,15	0,15 ± 0,11	0,08 ± 0,02	0,10 ± 0,02	0,08 ± 0,02
	Total	0,07 ± 0,02	0,07 ± 0,01	0,10 ± 0,04	0,11 ± 0,11	0,11 ± 0,06	0,07 ± 0,02	0,09 ± 0,02	0,08 ± 0,01
E_{rms} (N m)	Homb	0,21 ± 0,07	0,30 ± 0,02	0,40 ± 0,20	0,60 ± 0,84	0,51 ± 0,19	0,45 ± 0,09	0,40 ± 0,15	0,20 ± 0,11
	Codo	0,13 ± 0,05	0,23 ± 0,02	0,26 ± 0,14	0,36 ± 0,44	0,31 ± 0,17	0,26 ± 0,06	0,21 ± 0,05	0,16 ± 0,10
	Muñé	0,01 ± 0,00	0,03 ± 0,01	0,10 ± 0,05	0,11 ± 0,15	0,15 ± 0,16	0,06 ± 0,02	0,06 ± 0,02	0,03 ± 0,01
	Total	0,12 ± 0,04	0,19 ± 0,01	0,25 ± 0,12	0,36 ± 0,48	0,32 ± 0,17	0,26 ± 0,05	0,22 ± 0,07	0,13 ± 0,07
E_{max} (N m)	Homb	0,69 ± 0,21	1,21 ± 0,24	1,33 ± 0,29	1,34 ± 1,23	1,67 ± 0,37	1,65 ± 0,37	2,80 ± 1,57	1,57 ± 1,60
	Codo	0,34 ± 0,11	0,87 ± 0,19	0,91 ± 0,32	0,80 ± 0,57	0,89 ± 0,25	0,92 ± 0,31	1,11 ± 0,42	0,91 ± 0,75
	Muñé	0,04 ± 0,01	0,10 ± 0,01	0,77 ± 0,50	0,23 ± 0,20	0,35 ± 0,22	0,24 ± 0,05	0,35 ± 0,15	0,16 ± 0,07
	Total	0,36 ± 0,10	0,73 ± 0,10	1,00 ± 0,30	0,79 ± 0,66	0,97 ± 0,26	0,94 ± 0,24	1,42 ± 0,69	0,88 ± 0,79

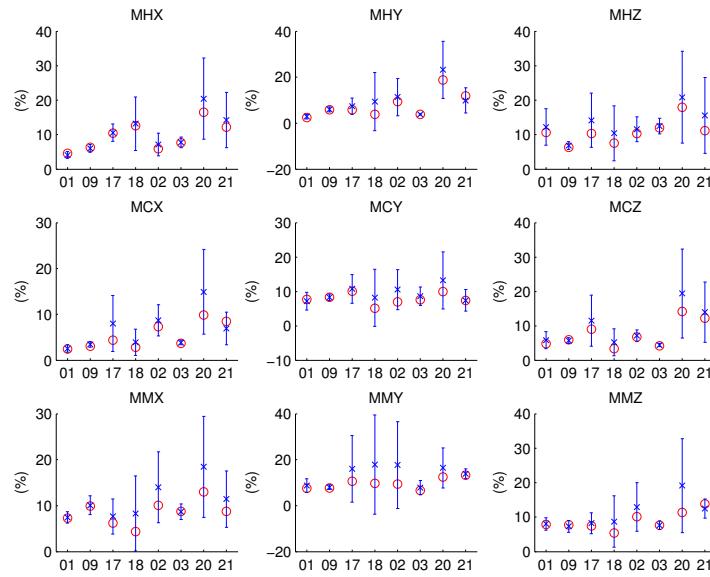


Figura G.10: NRMSD esperado para el modelo aoMLP propuesto en el escenario ESU entrenando con el algoritmo Levenberg–Marquardt (LM). Está representado tanto por la media y desviación estándar (en azul) como por la mediana (en rojo) de las predicciones de validación realizadas al aplicar LOOCV

Tabla G.10: Resultados del modelo aoMLP para el escenario ESU – Entrenamiento LM

		Controles				Pacientes			
		C001	C009	C017	C018	P002	P003	P020	P021
R²	Homb	0,87 ± 0,03	0,89 ± 0,05	0,84 ± 0,14	0,89 ± 0,10	0,87 ± 0,06	0,86 ± 0,03	0,27 ± 0,13	0,45 ± 0,09
	Codo	0,96 ± 0,02	0,96 ± 0,01	0,86 ± 0,10	0,98 ± 0,02	0,91 ± 0,05	0,94 ± 0,03	0,66 ± 0,31	0,74 ± 0,16
	Muñé	0,92 ± 0,04	0,90 ± 0,03	0,63 ± 0,21	0,86 ± 0,20	0,81 ± 0,11	0,90 ± 0,03	0,44 ± 0,29	0,64 ± 0,13
	Total	0,92 ± 0,02	0,92 ± 0,02	0,78 ± 0,13	0,91 ± 0,11	0,86 ± 0,06	0,90 ± 0,03	0,46 ± 0,21	0,61 ± 0,10
NRMSD	Homb	0,06 ± 0,02	0,07 ± 0,02	0,11 ± 0,04	0,11 ± 0,09	0,10 ± 0,04	0,08 ± 0,01	0,22 ± 0,12	0,13 ± 0,07
	Codo	0,05 ± 0,02	0,06 ± 0,01	0,10 ± 0,06	0,06 ± 0,05	0,09 ± 0,03	0,06 ± 0,01	0,16 ± 0,10	0,09 ± 0,04
	Muñé	0,08 ± 0,02	0,09 ± 0,01	0,11 ± 0,06	0,12 ± 0,12	0,15 ± 0,11	0,08 ± 0,02	0,18 ± 0,11	0,13 ± 0,03
	Total	0,07 ± 0,02	0,07 ± 0,01	0,10 ± 0,05	0,09 ± 0,09	0,11 ± 0,06	0,07 ± 0,01	0,18 ± 0,11	0,12 ± 0,04
E_{rms} (N m)	Homb	0,20 ± 0,06	0,31 ± 0,04	0,39 ± 0,19	0,45 ± 0,52	0,54 ± 0,25	0,46 ± 0,08	3,17 ± 3,63	0,79 ± 0,47
	Codo	0,12 ± 0,04	0,24 ± 0,04	0,25 ± 0,14	0,28 ± 0,29	0,32 ± 0,16	0,24 ± 0,03	1,04 ± 1,08	0,24 ± 0,11
	Muñé	0,01 ± 0,00	0,03 ± 0,01	0,11 ± 0,03	0,08 ± 0,10	0,14 ± 0,13	0,06 ± 0,01	0,30 ± 0,32	0,06 ± 0,02
	Total	0,11 ± 0,04	0,19 ± 0,02	0,25 ± 0,11	0,27 ± 0,30	0,34 ± 0,18	0,25 ± 0,04	1,50 ± 1,68	0,36 ± 0,18
E_{max} (N m)	Homb	0,66 ± 0,18	1,17 ± 0,39	1,20 ± 0,15	1,09 ± 0,83	1,64 ± 0,39	1,56 ± 0,34	9,97 ± 8,29	4,43 ± 0,96
	Codo	0,34 ± 0,11	0,77 ± 0,26	0,87 ± 0,33	0,69 ± 0,47	0,90 ± 0,22	0,91 ± 0,28	3,29 ± 2,52	1,26 ± 0,75
	Muñé	0,04 ± 0,01	0,09 ± 0,03	0,66 ± 0,27	0,19 ± 0,16	0,34 ± 0,18	0,19 ± 0,03	0,97 ± 0,73	0,29 ± 0,08
	Total	0,34 ± 0,09	0,68 ± 0,20	0,91 ± 0,16	0,66 ± 0,49	0,96 ± 0,25	0,89 ± 0,21	4,74 ± 3,85	1,99 ± 0,46

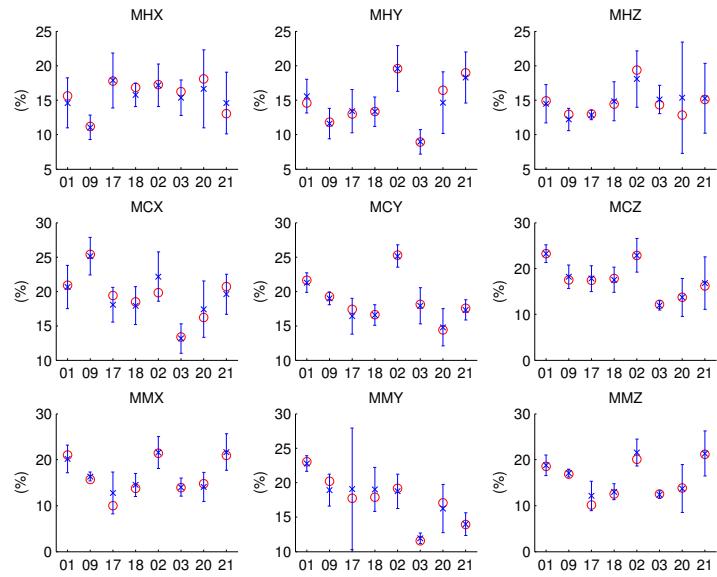


Figura G.11: NRMSD esperado para el modelo aoMLP propuesto en el escenario ESU sin usar la señal de Cinemática. Está representado tanto por la media y desviación estándar (en azul) como por la mediana (en rojo) de las predicciones de validación realizadas al aplicar LOOCV

Tabla G.11: Resultados del modelo aoMLP para el escenario ESU – Sin Cinemática

	Controles				Pacientes				
	C001	C009	C017	C018	P002	P003	P020	P021	
R²	Homb	0,57 ± 0,12	0,73 ± 0,06	0,73 ± 0,15	0,72 ± 0,07	0,44 ± 0,11	0,74 ± 0,08	0,24 ± 0,13	0,46 ± 0,15
	Codo	0,44 ± 0,07	0,57 ± 0,05	0,61 ± 0,02	0,72 ± 0,05	0,31 ± 0,09	0,70 ± 0,06	0,68 ± 0,07	0,51 ± 0,11
	Muñé	0,46 ± 0,07	0,57 ± 0,02	0,33 ± 0,11	0,67 ± 0,11	0,30 ± 0,08	0,74 ± 0,06	0,43 ± 0,04	0,45 ± 0,12
	Total	0,49 ± 0,07	0,62 ± 0,02	0,56 ± 0,03	0,70 ± 0,07	0,35 ± 0,05	0,72 ± 0,04	0,45 ± 0,05	0,47 ± 0,12
NRMSD	Homb	0,15 ± 0,02	0,12 ± 0,01	0,15 ± 0,02	0,15 ± 0,02	0,18 ± 0,02	0,13 ± 0,02	0,16 ± 0,04	0,16 ± 0,03
	Codo	0,22 ± 0,01	0,21 ± 0,02	0,17 ± 0,02	0,17 ± 0,02	0,23 ± 0,02	0,14 ± 0,01	0,15 ± 0,02	0,18 ± 0,02
	Muñé	0,21 ± 0,01	0,17 ± 0,01	0,15 ± 0,05	0,16 ± 0,02	0,21 ± 0,01	0,13 ± 0,01	0,15 ± 0,02	0,19 ± 0,02
	Total	0,19 ± 0,01	0,17 ± 0,01	0,16 ± 0,02	0,16 ± 0,02	0,21 ± 0,02	0,13 ± 0,01	0,15 ± 0,02	0,18 ± 0,02
E_{rms} (N m)	Homb	0,54 ± 0,06	0,57 ± 0,03	0,49 ± 0,06	0,54 ± 0,08	1,02 ± 0,18	0,79 ± 0,05	0,61 ± 0,11	0,40 ± 0,12
	Codo	0,53 ± 0,03	0,85 ± 0,03	0,42 ± 0,05	0,78 ± 0,10	0,84 ± 0,08	0,66 ± 0,07	0,41 ± 0,07	0,38 ± 0,05
	Muñé	0,04 ± 0,00	0,07 ± 0,00	0,13 ± 0,06	0,10 ± 0,02	0,17 ± 0,02	0,09 ± 0,00	0,08 ± 0,02	0,06 ± 0,01
	Total	0,37 ± 0,03	0,49 ± 0,01	0,35 ± 0,03	0,47 ± 0,06	0,68 ± 0,07	0,51 ± 0,02	0,37 ± 0,05	0,28 ± 0,06
E_{max} (N m)	Homb	1,67 ± 0,31	1,82 ± 0,31	1,58 ± 0,13	1,61 ± 0,17	2,83 ± 0,50	2,31 ± 0,45	3,06 ± 1,36	1,78 ± 1,26
	Codo	1,42 ± 0,19	2,24 ± 0,19	1,29 ± 0,27	2,22 ± 0,13	2,10 ± 0,24	2,30 ± 0,53	1,43 ± 0,40	1,42 ± 0,28
	Muñé	0,10 ± 0,01	0,18 ± 0,02	0,85 ± 0,66	0,29 ± 0,02	0,46 ± 0,06	0,31 ± 0,05	0,36 ± 0,15	0,23 ± 0,07
	Total	1,06 ± 0,15	1,41 ± 0,07	1,24 ± 0,22	1,37 ± 0,10	1,80 ± 0,25	1,64 ± 0,28	1,62 ± 0,59	1,14 ± 0,47

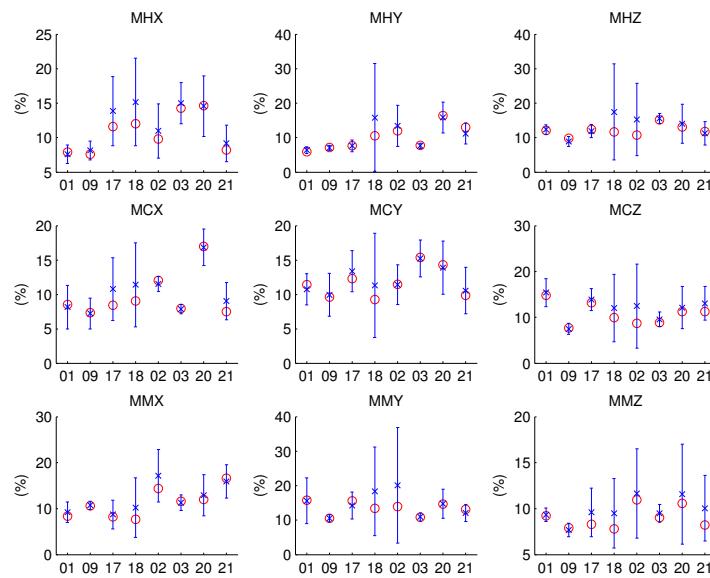


Figura G.12: NRMSD esperado para el modelo aoMLP propuesto en el escenario ESU aplicando PCA para dejar únicamente las componentes que explican el 80 % de la varianza de la entrada. Están representados tanto por la media y desviación estándar (en azul) como por la mediana (en rojo) de las predicciones de validación realizadas al aplicar LOOCV

Tabla G.12: Resultados del modelo aoMLP para el escenario ESU – 80 % PCA

	Controles				Pacientes				
	C001	C009	C017	C018	P002	P003	P020	P021	
R²	Homb	0,81 ± 0,02	0,88 ± 0,02	0,84 ± 0,10	0,80 ± 0,15	0,80 ± 0,06	0,75 ± 0,07	0,30 ± 0,17	0,72 ± 0,20
	Codo	0,86 ± 0,06	0,93 ± 0,03	0,78 ± 0,04	0,93 ± 0,03	0,85 ± 0,05	0,83 ± 0,05	0,76 ± 0,06	0,76 ± 0,15
	Muñé	0,85 ± 0,09	0,87 ± 0,04	0,54 ± 0,08	0,85 ± 0,10	0,70 ± 0,13	0,82 ± 0,04	0,55 ± 0,06	0,67 ± 0,09
	Total	0,84 ± 0,05	0,90 ± 0,02	0,72 ± 0,04	0,86 ± 0,09	0,79 ± 0,07	0,80 ± 0,03	0,54 ± 0,05	0,72 ± 0,14
NRMSD	Homb	0,09 ± 0,01	0,08 ± 0,01	0,11 ± 0,02	0,16 ± 0,12	0,13 ± 0,05	0,13 ± 0,01	0,15 ± 0,04	0,11 ± 0,03
	Codo	0,11 ± 0,03	0,08 ± 0,02	0,13 ± 0,02	0,12 ± 0,07	0,12 ± 0,04	0,11 ± 0,01	0,14 ± 0,03	0,11 ± 0,03
	Muñé	0,11 ± 0,03	0,10 ± 0,01	0,11 ± 0,03	0,13 ± 0,08	0,16 ± 0,09	0,11 ± 0,01	0,13 ± 0,02	0,13 ± 0,01
	Total	0,11 ± 0,02	0,09 ± 0,01	0,12 ± 0,02	0,13 ± 0,09	0,14 ± 0,06	0,11 ± 0,01	0,14 ± 0,03	0,11 ± 0,02
E_{rms} (N m)	Homb	0,29 ± 0,03	0,39 ± 0,01	0,37 ± 0,07	0,69 ± 0,68	0,76 ± 0,45	0,75 ± 0,04	0,54 ± 0,09	0,27 ± 0,10
	Codo	0,28 ± 0,08	0,34 ± 0,09	0,31 ± 0,07	0,54 ± 0,39	0,48 ± 0,31	0,48 ± 0,05	0,37 ± 0,07	0,23 ± 0,09
	Muñé	0,02 ± 0,00	0,04 ± 0,00	0,12 ± 0,07	0,08 ± 0,04	0,15 ± 0,12	0,07 ± 0,00	0,07 ± 0,02	0,04 ± 0,01
	Total	0,20 ± 0,04	0,26 ± 0,03	0,27 ± 0,05	0,44 ± 0,37	0,47 ± 0,29	0,43 ± 0,03	0,33 ± 0,06	0,18 ± 0,07
E_{max} (N m)	Homb	0,90 ± 0,18	1,42 ± 0,29	1,17 ± 0,22	1,59 ± 1,13	2,03 ± 0,82	2,16 ± 0,22	2,94 ± 1,47	1,53 ± 1,58
	Codo	0,84 ± 0,30	1,18 ± 0,46	1,09 ± 0,37	1,27 ± 0,46	1,19 ± 0,51	1,44 ± 0,18	1,24 ± 0,36	1,12 ± 0,62
	Muñé	0,05 ± 0,01	0,11 ± 0,02	0,83 ± 0,56	0,20 ± 0,08	0,36 ± 0,18	0,29 ± 0,03	0,34 ± 0,16	0,17 ± 0,08
	Total	0,60 ± 0,15	0,91 ± 0,13	1,03 ± 0,24	1,02 ± 0,54	1,19 ± 0,49	1,30 ± 0,10	1,51 ± 0,63	0,94 ± 0,73

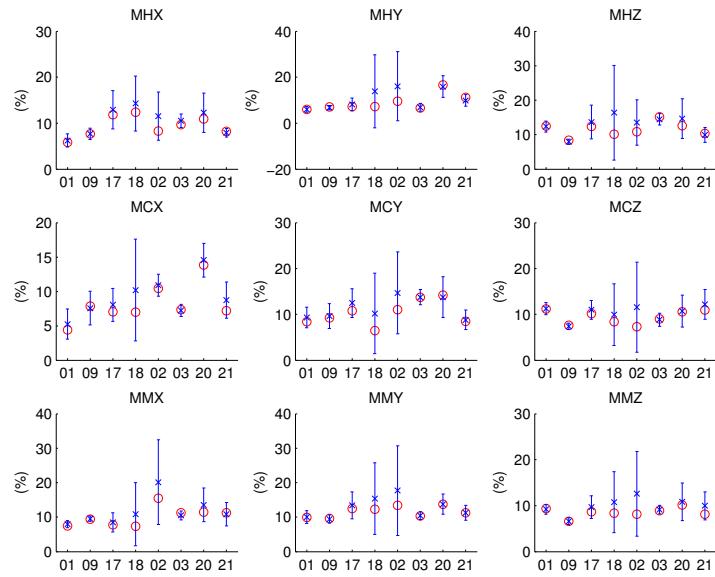


Figura G.13: NRMSD esperado para el modelo aoMLP propuesto en el escenario ESU aplicando PCA para dejar únicamente las componentes que explican el 90 % de la varianza de la entrada. Está representado tanto por la media y desviación estándar (en azul) como por la mediana (en rojo) de las predicciones de validación realizadas al aplicar LOOCV

Tabla G.13: Resultados del modelo aoMLP para el escenario ESU – 90 % PCA

	Controles				Pacientes				
	C001	C009	C017	C018	P002	P003	P020	P021	
R²	Homb	0,83 ± 0,03	0,90 ± 0,01	0,83 ± 0,12	0,82 ± 0,17	0,82 ± 0,06	0,80 ± 0,04	0,33 ± 0,17	0,75 ± 0,22
	Codo	0,91 ± 0,02	0,94 ± 0,03	0,83 ± 0,03	0,95 ± 0,03	0,86 ± 0,06	0,86 ± 0,03	0,80 ± 0,06	0,80 ± 0,13
	Muñé	0,91 ± 0,02	0,90 ± 0,03	0,51 ± 0,10	0,86 ± 0,11	0,72 ± 0,11	0,85 ± 0,03	0,60 ± 0,05	0,78 ± 0,05
	Total	0,88 ± 0,01	0,91 ± 0,02	0,73 ± 0,08	0,87 ± 0,10	0,80 ± 0,06	0,84 ± 0,02	0,58 ± 0,06	0,78 ± 0,13
NRMSD	Homb	0,08 ± 0,01	0,07 ± 0,00	0,12 ± 0,04	0,15 ± 0,12	0,14 ± 0,09	0,11 ± 0,01	0,14 ± 0,04	0,09 ± 0,02
	Codo	0,09 ± 0,01	0,08 ± 0,02	0,11 ± 0,02	0,10 ± 0,08	0,12 ± 0,07	0,10 ± 0,01	0,13 ± 0,03	0,10 ± 0,02
	Muñé	0,09 ± 0,01	0,09 ± 0,01	0,11 ± 0,03	0,12 ± 0,09	0,17 ± 0,11	0,10 ± 0,01	0,13 ± 0,02	0,11 ± 0,01
	Total	0,09 ± 0,01	0,08 ± 0,01	0,11 ± 0,02	0,12 ± 0,09	0,14 ± 0,09	0,10 ± 0,01	0,13 ± 0,03	0,10 ± 0,01
E_{rms} (N m)	Homb	0,27 ± 0,04	0,36 ± 0,02	0,39 ± 0,12	0,62 ± 0,66	0,77 ± 0,59	0,64 ± 0,04	0,54 ± 0,12	0,25 ± 0,12
	Codo	0,20 ± 0,04	0,34 ± 0,08	0,25 ± 0,05	0,47 ± 0,39	0,49 ± 0,37	0,44 ± 0,04	0,34 ± 0,07	0,21 ± 0,07
	Muñé	0,02 ± 0,00	0,03 ± 0,00	0,14 ± 0,06	0,08 ± 0,06	0,15 ± 0,13	0,07 ± 0,00	0,07 ± 0,02	0,04 ± 0,01
	Total	0,16 ± 0,02	0,24 ± 0,03	0,26 ± 0,06	0,39 ± 0,37	0,47 ± 0,36	0,38 ± 0,03	0,32 ± 0,06	0,16 ± 0,06
E_{max} (N m)	Homb	0,84 ± 0,13	1,31 ± 0,37	1,28 ± 0,40	1,45 ± 1,20	1,96 ± 0,82	2,03 ± 0,14	2,92 ± 1,52	1,57 ± 1,59
	Codo	0,54 ± 0,08	1,17 ± 0,45	0,86 ± 0,25	1,11 ± 0,57	1,30 ± 0,65	1,44 ± 0,23	1,25 ± 0,37	1,06 ± 0,61
	Muñé	0,05 ± 0,00	0,10 ± 0,02	0,97 ± 0,38	0,23 ± 0,09	0,36 ± 0,18	0,28 ± 0,02	0,33 ± 0,17	0,16 ± 0,07
	Total	0,48 ± 0,05	0,86 ± 0,13	1,03 ± 0,24	0,93 ± 0,61	1,21 ± 0,54	1,25 ± 0,07	1,50 ± 0,65	0,93 ± 0,74

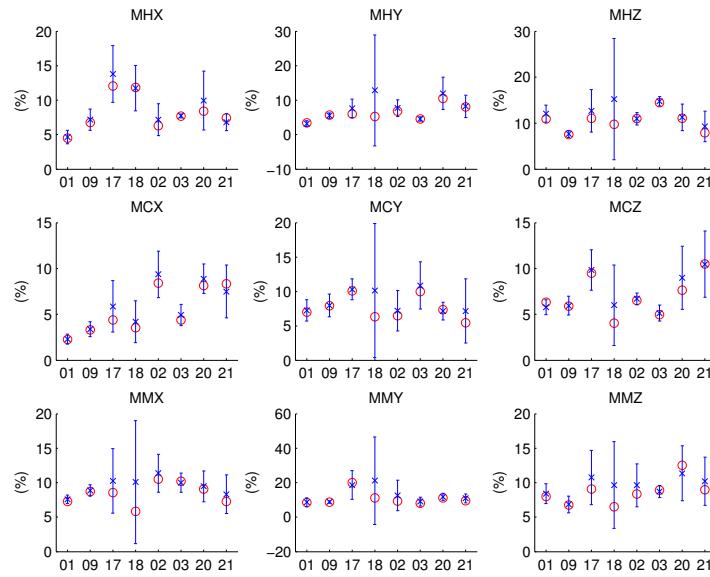


Figura G.14: NRMSD esperado para el modelo aoMLP propuesto en el escenario ESU codificando la actividad muscular con solo 3 Sinergias. Está representado tanto por la media y desviación estándar (en azul) como por la mediana (en rojo) de las predicciones de validación realizadas al aplicar LOOCV

Tabla G.14: Resultados del modelo aoMLP para el escenario ESU – 3 Sinergias

	Controles				Pacientes				
	C001	C009	C017	C018	P002	P003	P020	P021	
R²	Homb	0,85 ± 0,02	0,91 ± 0,01	0,84 ± 0,13	0,87 ± 0,07	0,88 ± 0,04	0,84 ± 0,03	0,47 ± 0,28	0,78 ± 0,24
	Codo	0,96 ± 0,01	0,96 ± 0,02	0,89 ± 0,03	0,98 ± 0,01	0,93 ± 0,02	0,92 ± 0,04	0,92 ± 0,03	0,83 ± 0,18
	Muñé	0,92 ± 0,03	0,91 ± 0,02	0,49 ± 0,13	0,89 ± 0,09	0,85 ± 0,05	0,88 ± 0,02	0,69 ± 0,07	0,80 ± 0,09
	Total	0,91 ± 0,01	0,93 ± 0,01	0,74 ± 0,06	0,92 ± 0,05	0,89 ± 0,03	0,88 ± 0,01	0,69 ± 0,09	0,81 ± 0,14
NRMSD	Homb	0,07 ± 0,01	0,07 ± 0,01	0,11 ± 0,03	0,13 ± 0,10	0,09 ± 0,02	0,09 ± 0,00	0,11 ± 0,03	0,08 ± 0,02
	Codo	0,05 ± 0,01	0,06 ± 0,01	0,09 ± 0,02	0,07 ± 0,05	0,08 ± 0,02	0,07 ± 0,02	0,08 ± 0,01	0,08 ± 0,03
	Muñé	0,08 ± 0,01	0,08 ± 0,01	0,13 ± 0,04	0,14 ± 0,14	0,11 ± 0,05	0,09 ± 0,01	0,11 ± 0,02	0,10 ± 0,02
	Total	0,07 ± 0,01	0,07 ± 0,01	0,11 ± 0,03	0,11 ± 0,10	0,09 ± 0,02	0,08 ± 0,01	0,10 ± 0,02	0,09 ± 0,02
E_{rms} (N m)	Homb	0,21 ± 0,05	0,33 ± 0,01	0,39 ± 0,13	0,59 ± 0,66	0,46 ± 0,07	0,52 ± 0,04	0,44 ± 0,17	0,22 ± 0,12
	Codo	0,11 ± 0,03	0,25 ± 0,06	0,21 ± 0,05	0,31 ± 0,28	0,27 ± 0,08	0,29 ± 0,06	0,23 ± 0,05	0,18 ± 0,12
	Muñé	0,01 ± 0,00	0,03 ± 0,00	0,14 ± 0,04	0,08 ± 0,08	0,10 ± 0,06	0,06 ± 0,01	0,06 ± 0,01	0,04 ± 0,01
	Total	0,11 ± 0,02	0,20 ± 0,02	0,25 ± 0,07	0,33 ± 0,34	0,28 ± 0,07	0,29 ± 0,03	0,25 ± 0,07	0,14 ± 0,08
E_{max} (N m)	Homb	0,73 ± 0,28	1,36 ± 0,33	1,29 ± 0,37	1,30 ± 0,82	1,56 ± 0,29	1,75 ± 0,29	2,91 ± 1,57	1,56 ± 1,61
	Codo	0,34 ± 0,08	0,92 ± 0,40	0,72 ± 0,16	0,72 ± 0,35	0,87 ± 0,22	0,94 ± 0,25	1,07 ± 0,46	1,00 ± 0,86
	Muñé	0,04 ± 0,00	0,10 ± 0,01	0,86 ± 0,53	0,21 ± 0,09	0,28 ± 0,13	0,28 ± 0,02	0,35 ± 0,16	0,16 ± 0,07
	Total	0,37 ± 0,12	0,80 ± 0,14	0,96 ± 0,21	0,74 ± 0,42	0,90 ± 0,18	0,99 ± 0,14	1,45 ± 0,71	0,91 ± 0,83

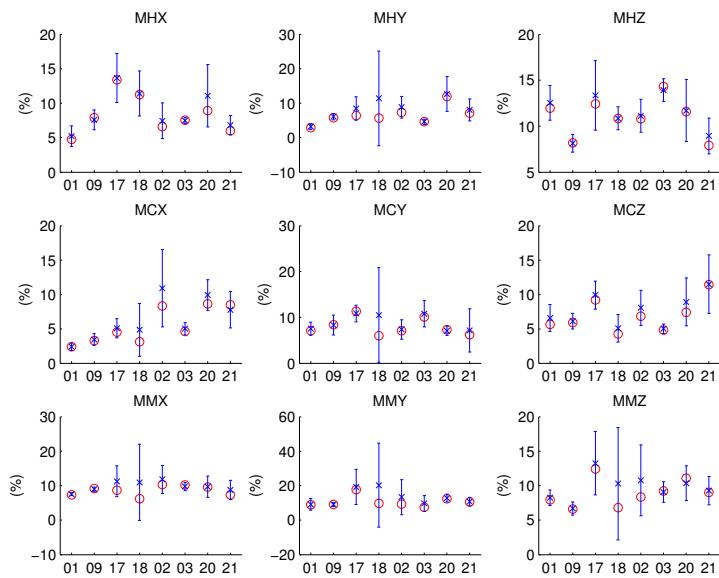


Figura G.15: NRMSD esperado para el modelo aoMLP propuesto en el escenario ESU codificando la actividad muscular con solo 5 Sinergias. Está representado tanto por la media y desviación estándar (en azul) como por la mediana (en rojo) de las predicciones de validación realizadas al aplicar LOOCV

Tabla G.15: Resultados del modelo aoMLP para el escenario ESU – 5 Sinergias

	Controles				Pacientes				
	C001	C009	C017	C018	P002	P003	P020	P021	
R²	Homb	0,84 ± 0,01	0,89 ± 0,02	0,81 ± 0,14	0,88 ± 0,05	0,87 ± 0,03	0,84 ± 0,03	0,45 ± 0,27	0,79 ± 0,25
	Codo	0,96 ± 0,01	0,96 ± 0,02	0,89 ± 0,02	0,98 ± 0,01	0,92 ± 0,02	0,92 ± 0,04	0,91 ± 0,03	0,81 ± 0,20
	Muñé	0,92 ± 0,03	0,91 ± 0,02	0,44 ± 0,12	0,89 ± 0,09	0,85 ± 0,05	0,88 ± 0,03	0,65 ± 0,05	0,80 ± 0,08
	Total	0,90 ± 0,02	0,92 ± 0,01	0,71 ± 0,07	0,92 ± 0,05	0,88 ± 0,03	0,88 ± 0,01	0,67 ± 0,08	0,80 ± 0,15
NRMSD	Homb	0,07 ± 0,01	0,07 ± 0,01	0,12 ± 0,03	0,11 ± 0,05	0,09 ± 0,02	0,09 ± 0,00	0,12 ± 0,04	0,08 ± 0,02
	Codo	0,05 ± 0,01	0,06 ± 0,01	0,09 ± 0,01	0,07 ± 0,05	0,09 ± 0,03	0,07 ± 0,01	0,09 ± 0,02	0,09 ± 0,03
	Muñé	0,08 ± 0,01	0,08 ± 0,00	0,15 ± 0,06	0,14 ± 0,15	0,12 ± 0,06	0,10 ± 0,02	0,11 ± 0,02	0,10 ± 0,01
	Total	0,07 ± 0,01	0,07 ± 0,01	0,12 ± 0,03	0,11 ± 0,08	0,10 ± 0,04	0,08 ± 0,01	0,10 ± 0,02	0,09 ± 0,02
E_{rms} (N m)	Homb	0,23 ± 0,05	0,35 ± 0,01	0,40 ± 0,11	0,47 ± 0,38	0,48 ± 0,09	0,51 ± 0,03	0,47 ± 0,17	0,21 ± 0,13
	Codo	0,12 ± 0,03	0,26 ± 0,07	0,21 ± 0,04	0,33 ± 0,30	0,32 ± 0,15	0,29 ± 0,04	0,24 ± 0,06	0,19 ± 0,13
	Muñé	0,01 ± 0,00	0,03 ± 0,00	0,17 ± 0,08	0,10 ± 0,11	0,11 ± 0,08	0,07 ± 0,01	0,06 ± 0,01	0,04 ± 0,01
	Total	0,12 ± 0,03	0,21 ± 0,02	0,26 ± 0,07	0,30 ± 0,26	0,30 ± 0,10	0,29 ± 0,03	0,26 ± 0,07	0,15 ± 0,09
E_{max} (N m)	Homb	0,83 ± 0,33	1,41 ± 0,32	1,34 ± 0,34	1,20 ± 0,48	1,60 ± 0,41	1,80 ± 0,34	2,92 ± 1,56	1,57 ± 1,61
	Codo	0,36 ± 0,10	0,95 ± 0,44	0,74 ± 0,17	0,74 ± 0,35	0,97 ± 0,41	0,98 ± 0,33	1,06 ± 0,48	1,04 ± 0,91
	Muñé	0,04 ± 0,01	0,10 ± 0,01	0,89 ± 0,52	0,22 ± 0,13	0,30 ± 0,16	0,28 ± 0,04	0,35 ± 0,17	0,16 ± 0,06
	Total	0,41 ± 0,14	0,82 ± 0,12	0,99 ± 0,21	0,72 ± 0,31	0,96 ± 0,30	1,02 ± 0,20	1,44 ± 0,70	0,92 ± 0,84

Bibliografía

- [1] POUYA AHMADIAN, STEFANO CAGNONI y LUCA ASCARI. «How capable is non-invasive EEG data of predicting the next movement? A mini review». *Frontiers in Human Neuroscience* 7 (abr. de 2013). ISSN: 1662-5161. doi: [10.3389/fnhum.2013.00124](https://doi.org/10.3389/fnhum.2013.00124). URL: <http://www.ncbi.nlm.nih.gov/pmc/articles/PMC3619112/> (vid. pág. 5).
- [2] ETHEM ALPAYDIN. *Introduction to Machine Learning*. 2a ed. Adaptive Computation and Machine Learning. Cambridge, Mass: MIT Press, 2010. ISBN: 978-0-262-01243-0. URL: <https://mitpress.mit.edu/books/introduction-machine-learning> (vid. pág. 23).
- [3] A.T.C. AU y R.F. KIRSCH. «EMG-based prediction of shoulder and elbow kinematics in able-bodied and spinal cord injured individuals». *IEEE Transactions on Rehabilitation Engineering* 8.4 (dic. de 2000), págs. 471-480. ISSN: 1063-6528. doi: [10.1109/86.895950](https://doi.org/10.1109/86.895950) (vid. pág. 2).
- [4] MICHAEL W. BERRY, MURRAY BROWNE et ál. «Algorithms and applications for approximate nonnegative matrix factorization». *Computational Statistics & Data Analysis* 52.1 (sep. de 2007), págs. 155-173. ISSN: 0167-9473. doi: [10.1016/j.csda.2006.11.006](https://doi.org/10.1016/j.csda.2006.11.006). URL: <http://www.sciencedirect.com/science/article/pii/S0167947306004191> (vid. pág. 14).
- [5] D. S. BROOMHEAD y DAVID LOWE. «Multivariable Functional Interpolation and Adaptive Networks». *Complex Systems* 2.3 (1988), págs. 321-355. URL: http://www.complex-systems.com/abstracts/v02_i03_a05.html (vid. pág. 20).
- [6] THOMAS S. BUCHANAN, DAVID G. LLOYD et ál. «Estimation of muscle forces and joint moments using a forward-inverse dynamics model». *Medicine & Science in Sports & Exercise* 37.11 (nov. de 2005), págs. 1911-1916. ISSN: 0195-9131. doi: [10.1249/01.mss.0000176684.24008.6f](https://doi.org/10.1249/01.mss.0000176684.24008.6f). URL: <http://content.wkhealth.com/linkback/openurl?sid=WKPTLP:landingpage&an=00005768-200511000-00013> (vid. pág. 3).
- [7] THOMAS S. BUCHANAN, DAVID G. LLOYD et ál. «Neuromusculoskeletal Modeling: Estimation of Muscle Forces and Joint Moments and Movements From Measurements of Neural Command». *Journal of applied biomechanics* 20.4 (nov. de 2004), págs. 367-395. ISSN: 1065-8483. URL: <http://www.ncbi.nlm.nih.gov/pmc/articles/PMC1357215/> (vid. págs. 2, 7, 77).

- [8] D.R. BUENO y L. MONTANO. «An optimized model for estimation of muscle contribution and human joint torques from sEMG information». *2012 Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. Ago. de 2012, págs. 3364-3367. doi: [10.1109/EMBC.2012.6346686](https://doi.org/10.1109/EMBC.2012.6346686) (vid. págs. 2, 77, 78).
- [9] CLAUDIO CASTELLINI y PATRICK VAN DER SMAGT. «Surface EMG in advanced hand prosthetics». *Biological Cybernetics* 100.1 (nov. de 2008), págs. 35-47. ISSN: 0340-1200, 1432-0770. doi: [10.1007/s00422-008-0278-1](https://doi.org/10.1007/s00422-008-0278-1). URL: <http://link.springer.com/article/10.1007/s00422-008-0278-1> (vid. págs. 2, 5, 17, 20, 47).
- [10] E.E. CAVALLARO, J. ROSEN et ál. «Real-Time Myoprocessors for a Neural Controlled Powered Exoskeleton Arm». *IEEE Transactions on Biomedical Engineering* 53.11 (nov. de 2006), págs. 2387-2396. ISSN: 0018-9294. doi: [10.1109/TBME.2006.880883](https://doi.org/10.1109/TBME.2006.880883) (vid. pág. 77).
- [11] GAVIN C. CAWLEY y NICOLA L. C. TALBOT. «On Over-fitting in Model Selection and Subsequent Selection Bias in Performance Evaluation». *Journal of Machine Learning Research* 11 (jul. de 2010), 2079-2107. URL: <http://www.jmlr.org/papers/v11/cawley10a.html> (vid. págs. 19, 25).
- [12] CHIH-CHUNG CHANG y CHIH-JEN LIN. «LIBSVM: A Library for Support Vector Machines». *ACM Transactions on Intelligent Systems and Technology* 2.3 (mayo de 2011). Software available at <http://www.csie.ntu.edu.tw/~cjlin/libsvm>, 27:1-27:27. ISSN: 2157-6904. doi: [10.1145/1961189.1961199](https://doi.org/10.1145/1961189.1961199). URL: <http://doi.acm.org/10.1145/1961189.1961199> (vid. págs. 22, 24).
- [13] S.L. DELP, F.C. ANDERSON et ál. «OpenSim: Open-Source Software to Create and Analyze Dynamic Simulations of Movement». *IEEE Transactions on Biomedical Engineering* 54.11 (nov. de 2007), págs. 1940-1950. ISSN: 0018-9294. doi: [10.1109/TBME.2007.901024](https://doi.org/10.1109/TBME.2007.901024) (vid. pág. 6).
- [14] JANEZ DEMŠAR. «Statistical Comparisons of Classifiers over Multiple Data Sets». *Journal of Machine Learning Research* 7 (ene. de 2006), 1-30. URL: <http://www.jmlr.org/papers/v7/demsar06a.html> (vid. pág. 45).
- [15] JAIME DÍAZ-GUZMÁN, JOSE A. EGIDO et ál. «Stroke and Transient Ischemic Attack Incidence Rate in Spain: The IBERICTUS Study». *Cerebrovascular Diseases* 34.4 (2012), págs. 272-281. ISSN: 1421-9786. doi: [10.1159/000342652](https://doi.org/10.1159/000342652). URL: <http://www.karger.com/Article/Abstract/342652> (vid. pág. 2).
- [16] TREVOR HASTIE, SAHARON ROSSET et ál. «The Entire Regularization Path for the Support Vector Machine». *Journal of Machine Learning Research* 5 (oct. de 2004), 1392-1415. URL: <http://www.jmlr.org/papers/v5/hastie04a.html> (vid. pág. 22).
- [17] A. V. HILL. «The Heat of Shortening and the Dynamic Constants of Muscle». *Proceedings of the Royal Society of London B: Biological Sciences* 126.843 (oct. de 1938), págs. 136-195. ISSN: 0962-8452, 1471-2954. doi: [10.1098/rspb.1938.0050](https://doi.org/10.1098/rspb.1938.0050). URL: <http://rsbroyalsocietypublishing.org/content/126/843/136> (vid. págs. 2, 77).
- [18] J.G. HINCAPIE y R.F. KIRSCH. «Feasibility of EMG-Based Neural Network Controller for an Upper Extremity Neuroprosthesis». *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 17.1 (feb. de 2009), págs. 80-90. ISSN: 1534-4320. doi: [10.1109/TNSRE.2008.2010480](https://doi.org/10.1109/TNSRE.2008.2010480) (vid. pág. 2).

- [19] MYLES HOLLANDER, DOUGLAS A. WOLFE y ERIC CHICKEN. *Nonparametric statistical methods*. 3a ed. Hoboken, New Jersey: John Wiley & Sons, Inc, 2014. ISBN: 978-0-470-38737-5. URL: <http://eu.wiley.com/WileyCDA/WileyTitle/productCd-0470387378.html> (vid. pág. 45).
- [20] CHIH-WEI HSU, CHIH-CHUNG CHANG y CHIH-JEN LIN. *A Practical Guide to Support Vector Classification*. Inf. téc. Taiwan: Department of Computer Science, National Taiwan University, abr. de 2010. URL: <http://www.csie.ntu.edu.tw/~cjlin/papers/guide/guide.pdf> (vid. págs. 22, 40).
- [21] HYPER Project, "Hybrid Neuroprosthetic and Neurorobotic Devices for Functional Compensation and Rehabilitation of Motor Disorders". CSD2009-00067. 2010. URL: <http://www.car.upm-csic.es/bioingenieria/hyper/index.htm> (visitado 15-06-2015) (vid. pág. 1).
- [22] I.T. JOLLIFFE. *Principal Component Analysis*. 2a ed. Springer Series in Statistics. New York: Springer-Verlag, 2002. ISBN: 978-0-387-95442-4. URL: <http://link.springer.com/10.1007/b98835> (vid. pág. 12).
- [23] KAZUO KIGUCHI, T. TANAKA y T. FUKUDA. «Neuro-fuzzy control of a robotic exoskeleton with EMG signals». *IEEE Transactions on Fuzzy Systems* 12.4 (ago. de 2004), págs. 481-490. ISSN: 1063-6706. DOI: [10.1109/TFUZZ.2004.832525](https://doi.org/10.1109/TFUZZ.2004.832525) (vid. pág. 5).
- [24] TEUVO KOHONEN. «Self-organized formation of topologically correct feature maps». *Biological Cybernetics* 43.1 (ene. de 1982), págs. 59-69. ISSN: 0340-1200, 1432-0770. DOI: [10.1007/BF00337288](https://doi.org/10.1007/BF00337288). URL: <http://link.springer.com/article/10.1007/BF00337288> (vid. pág. 73).
- [25] JEFFREY C. LAGARIAS, JAMES A. REEDS et ál. «Convergence Properties of the Nelder-Mead Simplex Method in Low Dimensions». *SIAM Journal of Optimization* 9 (1998), págs. 112-147. DOI: [10.1.1.120.6062](https://doi.org/10.1.1.120.6062). URL: <http://citeserex.ist.psu.edu/viewdoc/summary?doi=10.1.1.120.6062> (vid. pág. 40).
- [26] T. LENZI, S.M.M. DE ROSSI et ál. «Proportional EMG control for upper-limb powered exoskeletons». *2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBC*. Ago. de 2011, págs. 628-631. DOI: [10.1109/IEMBS.2011.6090139](https://doi.org/10.1109/IEMBS.2011.6090139) (vid. págs. 5, 7).
- [27] DAVID G LLOYD y THOR F BESIER. «An EMG-driven musculoskeletal model to estimate muscle forces and knee joint moments in vivo». *Journal of Biomechanics* 36.6 (jun. de 2003), págs. 765-776. ISSN: 0021-9290. DOI: [10.1016/S0021-9290\(03\)00010-1](https://doi.org/10.1016/S0021-9290(03)00010-1). URL: <http://www.sciencedirect.com/science/article/pii/S0021929003000101> (vid. pág. 7).
- [28] C. LOCONSOLE, S. DETTORI et ál. «An EMG-based approach for on-line predicted torque control in robotic-assisted rehabilitation». *2014 IEEE Haptics Symposium (HAPTICS)*. Feb. de 2014, págs. 181-186. DOI: [10.1109/HAPTICS.2014.6775452](https://doi.org/10.1109/HAPTICS.2014.6775452) (vid. pág. 2).
- [29] VINCENT Y. MA, LEIGHTON CHAN y KADIR J. CARRUTHERS. «Incidence, Prevalence, Costs, and Impact on Disability of Common Conditions Requiring Rehabilitation in the United States: Stroke, Spinal Cord Injury, Traumatic Brain Injury, Multiple Sclerosis, Osteoarthritis, Rheumatoid Arthritis, Limb Loss, and Back Pain». *Archives of Physical Medicine and Rehabilitation* 95.5 (mayo de 2014), 986-995.e1. ISSN: 0003-9993. DOI:

- 10.1016/j.apmr.2013.10.032. URL: <http://www.sciencedirect.com/science/article/pii/S0003999314000318> (vid. pág. 1).
- [30] MARTIN FODSLETTE MØLLER. «A scaled conjugate gradient algorithm for fast supervised learning». *Neural Networks* 6.4 (1993), págs. 525–533. ISSN: 0893-6080. DOI: 10.1016/S0893-6080(05)80056-5. URL: <http://www.sciencedirect.com/science/article/pii/S0893608005800565> (vid. pág. 19).
- [31] ANA DE LOS REYES-GUZMÁN, ÁNGEL GIL-AGUDO et ál. «Kinematic analysis of the daily activity of drinking from a glass in a population with cervical spinal cord injury». *Journal of NeuroEngineering and Rehabilitation* 7.1 (ago. de 2010), pág. 41. ISSN: 1743-0003. DOI: 10.1186/1743-0003-7-41. URL: <http://www.jneuroengrehab.com/content/7/1/41/abstract> (vid. pág. 5).
- [32] JACOB ROSEN, MOSHE B. FUCHS y MIRCEA ARCAN. «Performances of Hill-Type and Neural Network Muscle Models—Toward a Myosignal-Based Exoskeleton». *Computers and Biomedical Research* 32.5 (oct. de 1999), págs. 415–439. ISSN: 0010-4809. DOI: 10.1006/cbmr.1999.1524. URL: <http://www.sciencedirect.com/science/article/pii/S001048099915240> (vid. págs. 2, 5, 7, 17).
- [33] D. E. RUMELHART, G. E. HINTON y R. J. WILLIAMS. «Learning internal representations by error propagation». *Parallel Distributed Processing: Explorations in the Microstructure of Cognition, Vol. 1*. Ed. por DAVID E. RUMELHART, JAMES L. McCLELLAND y CORPORATE PDP RESEARCH GROUP. Cambridge, MA, USA: MIT Press, 1986, págs. 318–362. ISBN: 0-262-68053-X. URL: <http://dl.acm.org/citation.cfm?id=104279.104293> (vid. págs. 18, 20).
- [34] SEYED SAFAVYNIA, GELSY TORRES-OVIEDO y LENA TING. «Muscle Synergies: Implications for Clinical Evaluation and Rehabilitation of Movement». *Topics in Spinal Cord Injury Rehabilitation* 17.1 (jul. de 2011), págs. 16–24. ISSN: 1082-0744. DOI: 10.1310/sci1701-16. URL: <http://archive.scijournal.com/doi/abs/10.1310/sci1701-16> (vid. pág. 13).
- [35] MASSIMO SARTORI, LEONARDO GIZZI et ál. «A musculoskeletal model of human locomotion driven by a low dimensional set of impulsive excitation primitives». *Frontiers in Computational Neuroscience* 7 (2013), pág. 79. DOI: 10.3389/fncom.2013.00079. URL: <http://journal.frontiersin.org/article/10.3389/fncom.2013.00079/full> (vid. pág. 45).
- [36] A. J. SHARKEY. «Multi-Net Systems». *Combining Artificial Neural Nets: Ensemble and Modular Multi-Net Systems*. Perspectives in Neural Computing. London: Springer London, 1999, págs. 1–30. ISBN: 978-1-85233-004-0 978-1-4471-0793-4. URL: <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.28.2383> (vid. pág. 20).
- [37] ANOUSHKA SINGH, LINDSAY TETREAULT et ál. «Global prevalence and incidence of traumatic spinal cord injury». *Clinical Epidemiology* 6 (sep. de 2014), págs. 309–331. ISSN: 1179-1349. DOI: 10.2147/CLEP.S68889. URL: <http://www.dovepress.com/global-prevalence-and-incidence-of-traumatic-spinal-cord-injury-peer-reviewed-article-CLEP> (vid. pág. 2).

- [38] R. SONG y DR K. Y. TONG. «Using recurrent artificial neural network model to estimate voluntary elbow torque in dynamic situations». *Medical and Biological Engineering and Computing* 43.4 (ago. de 2005), págs. 473-480. ISSN: 0140-0118, 1741-0444. DOI: 10.1007/BF02344728. URL: <http://link.springer.com/article/10.1007/BF02344728> (vid. págs. 2, 3, 5, 7, 47).
- [39] DIDIER STAUDENMANN, KARIN ROELEVLD et ál. «Methodological aspects of SEMG recordings for force estimation – A tutorial and review». *Journal of Electromyography and Kinesiology* 20.3 (jun. de 2010), págs. 375-387. ISSN: 1050-6411. DOI: 10.1016/j.jelekin.2009.08.005. URL: <http://www.sciencedirect.com/science/article/pii/S1050641109001229> (vid. pág. 7).
- [40] THE MATHWORKS, INC. *Choose a Multilayer Neural Network Training Function - MATLAB & Simulink - MathWorks*. 2013. URL: <http://mathworks.com/help/nnet/ug/choose-a-multilayer-neural-network-training-function.html> (visitado 16-06-2015) (vid. pág. 19).
- [41] MATTHEW C. TRESCH, VINCENT C. K. CHEUNG y ANDREA D'AVELLA. «Matrix Factorization Algorithms for the Identification of Muscle Synergies: Evaluation on Simulated and Experimental Data Sets». *Journal of Neurophysiology* 95.4 (abr. de 2006), págs. 2199-2212. ISSN: 0022-3077, 1522-1598. DOI: 10.1152/jn.00222.2005. URL: <http://jn.physiology.org/content/95/4/2199> (vid. pág. 13).
- [42] A. ULTSCH. *U^{*}-Matrix: a Tool to visualize Clusters in high dimensional Data*. In Research report Dept. of Mathematics and Computer Science 36. Germany: University of Marburg, 2003. URL: <http://www.mathematik.uni-marburg.de/~databionics/papers/ultsch03ustar.pdf> (vid. pág. 73).
- [43] VLADIMIR NAUMOVICH VAPNIK. *Statistical learning theory*. Adaptive and learning systems for signal processing, communications, and control. New York: Wiley, 1998. ISBN: 978-0-471-03003-4. URL: <http://eu.wiley.com/WileyCDA/WileyTitle/productCd-0471030031.html> (vid. pág. 22).
- [44] VLADIMIR VAPNIK, STEVEN E. GOLOWICH y ALEX J. SMOLA. «Support Vector Method for Function Approximation, Regression Estimation and Signal Processing». *Advances in Neural Information Processing Systems* 9. Ed. por M. C. MOZER, M. I. JORDAN y T. PETSCHE. MIT Press, 1997, págs. 281-287. URL: <http://papers.nips.cc/paper/1187-support-vector-method-for-function-approximation-regression-estimation-and-signal-processing.pdf> (vid. pág. 24).
- [45] JACK M. WINTERS. «Hill-Based Muscle Models: A Systems Engineering Perspective». *Multiple Muscle Systems*. Ed. por JACK M. WINTERS y SAVIO L.-Y. Woo. Springer New York, 1990, págs. 69-93. ISBN: 978-1-4613-9032-9 978-1-4613-9030-5. URL: http://link.springer.com/chapter/10.1007/978-1-4613-9030-5_5 (vid. pág. 77).
- [46] DAPENG YANG, JINGDONG ZHAO et ál. «EMG pattern recognition and grasping force estimation: Improvement to the myocontrol of multi-DOF prosthetic hands». *IEEE/RSJ International Conference on Intelligent Robots and Systems, 2009. IROS 2009*. Oct. de 2009, págs. 516-521. DOI: 10.1109/IROS.2009.5354544 (vid. págs. 2, 5, 17).

Siglas

ANN	Artificial Neural Network
aoMLP	Averaged Output MLP
MLP	Multilayer Perceptron
NMF	Nonnegative Matrix Factorization
PCA	Principal Component Analysis
RBF	Radial Basis Function
RBN	Radial Basis Network
SOM	Self-organizing Map
SVM	Support Vector Machine
SVR	Support Vector Regression

Glosario

Análisis de componentes principales

véase [Principal Component Analysis](#)

Artificial Neural Network (ANN)

Las redes neuronales artificiales son un conjunto de algoritmos de aprendizaje automático inspiradas en las redes neuronales biológicas. En concreto son dos los elementos claves en los que se basan, la interconexión existente entre las salidas de unas neuronas a las entradas de otras, y la no linealidad en la función de respuesta de las neuronas que realizan el aprendizaje [2, 18, 143, 145, 146](#)

Averaged Output MLP (aoMLP)

Ensamble de múltiples [MLP](#) configurado para que su salida sea un simple promediado de las salidas de los [MLP](#) individuales [20, 26, 27, 29, 36, 40, 45–49, 51, 81, 107, 121, 143](#)

Factorización no-negativa de matrices

véase [Nonnegative Matrix Factorization](#)

Función de base radial

véase [Radial Basis Function](#)

Mapa auto-organizado

véase [Self-organizing Map](#)

Multilayer Perceptron (MLP)

El perceptrón multicapa es un tipo de [ANN](#) caracterizada por la utilización de neuronas con respuesta sigmoidea dispuestas una estructura feedforward y cuyo aprendizaje de tipo supervisado está basado en algoritmos de retropropagación o, en inglés, back-propagation [2, 17–20, 36, 49, 81, 143, 145](#)

Máquina de vectores soporte

véase Support Vector Machine

Nonnegative Matrix Factorization (NMF)

La factorización no-negativa de matrices es un conjunto de técnicas de análisis multivariable que permite la descomposición de matrices a la vez que asegura conservar el carácter no negativo de los elementos de la matriz original. De esta forma se puede aplicar una transformación de bases a un conjunto de datos cuando es importante que mantenga su carácter no negativo original 13, 143

Perceptrón multicapa

véase Multilayer Perceptron

Principal Component Analysis (PCA)

El análisis de componentes principales es una técnica estadística que permite reducir la dimensionalidad de un conjunto de datos mediante una transformación de bases. La elección de las bases del nuevo sistema de coordenadas dependerá de la variabilidad presente en el conjunto de datos y con el único requisito de que sean ortonormales 11–13, 15, 50, 143

Radial Basis Function (RBF)

Las funciones de base radial son un tipo de funciones cuya respuesta depende únicamente de la distancia al origen o a algún otro punto conocido como centroide. Aunque existen varias funciones de esta clase, la gaussiana es su representante más habitualmente empleado 20, 22, 36, 82, 108, 143, 146

Radial Basis Network (RBN)

Las redes de base radial son un tipo de ANN que usa neuronas cuya función de respuesta es de tipo RBF, aunque mayoritariamente suele ser la gaussiana. Su sencilla estructura y algoritmo de aprendizaje las hace muy fáciles de manejar, a costa de requerir una mayor potencia computacional 17, 36, 40, 45, 47, 48, 51, 82, 107, 143

Red de base radial

véase Radial Basis Network

Red neuronal artificial

véase Artificial Neural Network

Self-organizing Map (SOM)

Los mapas auto-organizados de Kohonen son un tipo de ANN basadas en un algoritmo de aprendizaje competitivo no supervisado. Sus características propician una efectiva aplicación a problemas de clustering 3, 73, 75, 143

Support Vector Machine (SVM)

Las máquinas de vectores soporte son un conjunto de modelos de aprendizaje supervisado mediante algoritmos estadísticos. Estas técnicas son empleadas en el reconocimiento de patrones, tanto en tareas de clasificación como de ajuste funcional 2, 22, 40, 45, 47, 48, 51, 53, 82, 108, 143, 147

Support Vector Regression (SVR)

Conjunto de las SVM destinadas al análisis de regresión o ajuste funcional 2, 17, 22–24, 82, 108, 143

Índice de algoritmos

3.1 Algoritmo de actualización multiplicativa para NMF	14
3.2 Algoritmo Alternating Least-Squares (ALS) para NMF	14
4.1 Algoritmo de entrenamiento de RBN	21

Índice de tablas

6.1	Comparativa cuantitativa de los modelos propuestos para el escenario ESU	46
6.2	Comparativa cuantitativa de los modelos propuestos para el escenario ESM	48
6.3	Resumen de los rendimientos obtenidos para el escenario ESU	49
7.1	Comparativa cualitativa de los modelos propuestos para el escenario ESU	52
B.1	Características de los sujetos	57
B.2	Codificación de las variables biomecánicas	58
B.3	Listado de las variables biomecánicas de cinemática	58
B.4	Listado de las variables biomecánicas de fuerza	59
B.5	Listado de las variables biomecánicas de momento	59
B.6	Listado de las variables electromiográficas	60
G.1	Resultados del modelo aoMLP para el escenario ESU	122
G.2	Resultados del modelo RBN para el escenario ESU	123
G.3	Resultados del modelo SVM para el escenario ESU	124
G.4	Resultados del modelo aoMLP para el escenario ESM	125
G.5	Resultados del modelo RBN para el escenario ESM	126
G.6	Resultados del modelo SVM para el escenario ESM	127
G.7	Resultados del modelo aoMLP para el escenario ESU – Sin ensamble	128
G.8	Resultados del modelo aoMLP para el escenario ESU – Ensamble de 10 MLP	129
G.9	Resultados del modelo aoMLP para el escenario ESU – F_m de 200 Hz	130
G.10	Resultados del modelo aoMLP para el escenario ESU – Entrenamiento LM	131
G.11	Resultados del modelo aoMLP para el escenario ESU – Sin Cinemática	132
G.12	Resultados del modelo aoMLP para el escenario ESU – 80 % PCA	133
G.13	Resultados del modelo aoMLP para el escenario ESU – 90 % PCA	134
G.14	Resultados del modelo aoMLP para el escenario ESU – 3 Sinergias	135
G.15	Resultados del modelo aoMLP para el escenario ESU – 5 Sinergias	136

Índice de figuras

1.1	Diagrama de bloques del proceso de predicción	3
2.1	Vista esquemática cenital de la actividad de beber de un vaso	6
2.2	Diagrama de bloques del proceso de cálculo de Dinámica Inversa realizado por OpenSim	7
2.3	Representación temporal de las señales disponibles de una iteración del movimiento realizado por el sujeto C009 ($F_m = 20 \text{ Hz}$)	8
2.4	Representación temporal de las señales disponibles de una iteración del movimiento realizado por el sujeto P002 ($F_m = 20 \text{ Hz}$)	9
3.1	Promedio y desviación por componente del porcentaje de varianza explicada de la señal de Activación Normalizada ($F_m = 20 \text{ Hz}$)	12
3.2	Promedio y desviación por componente del porcentaje de varianza explicada de las señales de Activación Normalizada y Cinemática ($F_m = 20 \text{ Hz}$)	13
3.3	Promedio y desviación por número de Sinergias del porcentaje de varianza explicada de la señal de Activación Normalizada ($F_m = 20 \text{ Hz}$)	14
4.1	Descripción de un perceptrón multicapa (MLP)	18
4.2	Rendimiento y estado de un MLP durante la fase de entrenamiento	19
4.3	Descripción de una red de base radial (RBN)	21
4.4	Rendimiento de una RBN durante la fase de entrenamiento	22
4.5	Interpretación geométrica de la regresión por vectores soporte (SVR)	23
5.1	Casos de la variación del rendimiento en función del número de neuronas ocultas durante el proceso de optimización para el modelo aoMLP	27
5.2	Percentiles e intervalos de confianza de las predicciones por el modelo aoMLP del momento articular para iteraciones del escenario ESU	28
5.3	Predicciones por el modelo aoMLP del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto C009	30

5.4	Predicciones por el modelo aoMLP del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto P002	31
5.5	Optimización del número de neuronas ocultas y predicción por el modelo aoMLP del momento articular para el escenario ESM – solo Controles	32
5.6	Optimización del número de neuronas ocultas y predicción por el modelo aoMLP del momento articular para el escenario ESM – solo Pacientes	33
5.7	Optimización del número de neuronas ocultas y predicción por el modelo aoMLP del momento articular para el escenario ESM – Población (Controles)	34
5.8	Optimización del número de neuronas ocultas y predicción por el modelo aoMLP del momento articular para el escenario ESM – Población (Pacientes)	35
5.9	Casos de la variación de los rendimientos de entrenamiento y validación durante el proceso de optimización para el modelo RBN	37
5.10	Predicciones por el modelo RBN del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto C009	38
5.11	Predicciones por el modelo RBN del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto P002	39
5.12	Casos de la variación de los rendimientos de entrenamiento, con y sin validación cruzada, durante la optimización del modelo SVM	41
5.13	Casos de la variación de los rendimientos de validación y entrenamiento por validación cruzada durante la optimización del modelo SVM	42
5.14	Predicciones por el modelo SVM del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto C009	43
5.15	Predicciones por el modelo SVM del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto P002	44
B.1	Concatenación de las 5 iteraciones de las señales de Activación Normalizada (Escenario de Sujeto Único – Controles, $F_m = 20$ Hz)	61
B.2	Concatenación de las 5 iteraciones de las señales de Activación Normalizada (Escenario de Sujeto Único – Pacientes, $F_m = 20$ Hz)	62
B.3	Concatenación de las 5 iteraciones de las señales de Cinemática (Escenario de Sujeto Único – Controles, $F_m = 20$ Hz)	63
B.4	Concatenación de las 5 iteraciones de las señales de Cinemática (Escenario de Sujeto Único – Pacientes, $F_m = 20$ Hz)	64
B.5	Concatenación de las 5 iteraciones de las señales de Fuerza (Escenario de Sujeto Único – Controles, $F_m = 20$ Hz)	65
B.6	Concatenación de las 5 iteraciones de las señales de Fuerza (Escenario de Sujeto Único – Pacientes, $F_m = 20$ Hz)	66
B.7	Concatenación de las 5 iteraciones de las señales de Momento (Escenario de Sujeto Único – Controles, $F_m = 20$ Hz)	67
B.8	Concatenación de las 5 iteraciones de las señales de Momento (Escenario de Sujeto Único – Pacientes, $F_m = 20$ Hz)	68
B.9	Concatenación de las señales de Activación Normalizada (Escenario de Sujetos Múltiples, $F_m = 20$ Hz)	69
B.10	Concatenación de las señales de Cinemática (Escenario de Sujetos Múltiples, $F_m = 20$ Hz)	70

B.11	Concatenación de las señales de Fuerza (Escenario de Sujetos Múltiples, $F_m = 20 \text{ Hz}$)	71
B.12	Concatenación de las señales de Momento (Escenario de Sujetos Múltiples, $F_m = 20 \text{ Hz}$)	72
C.1	U-Matix de la señal de Activación Normalizada de toda la población del escenario ESM ($F_m = 20 \text{ Hz}$) junto con mapas de clasificación	74
C.2	Norma, por componentes, de la distancia entre neuronas de la señal de Activación Normalizada de toda la población del escenario ESM ($F_m = 20 \text{ Hz}$)	75
D.1	Esquema del modelo de Hill de un músculo elástico	77
D.2	Predicciones por el modelo de Hill del momento articular producido en 4 iteraciones del movimiento realizadas por los sujetos de control	79
D.3	Predicciones por el modelo de Hill del momento articular producido en 4 iteraciones del movimiento realizadas por el paciente P002	80
E.1	Predicciones por el modelo aoMLP del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto C001	83
E.2	Predicciones por el modelo aoMLP del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto C009	84
E.3	Predicciones por el modelo aoMLP del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto C017	85
E.4	Predicciones por el modelo aoMLP del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto C018	86
E.5	Predicciones por el modelo aoMLP del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto P002	87
E.6	Predicciones por el modelo aoMLP del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto P003	88
E.7	Predicciones por el modelo aoMLP del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto P020	89
E.8	Predicciones por el modelo aoMLP del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto P021	90
E.9	Predicciones por el modelo RBN del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto C001	91
E.10	Predicciones por el modelo RBN del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto C009	92
E.11	Predicciones por el modelo RBN del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto C017	93
E.12	Predicciones por el modelo RBN del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto C018	94
E.13	Predicciones por el modelo RBN del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto P002	95
E.14	Predicciones por el modelo RBN del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto P003	96

E.15	Predicciones por el modelo RBN del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto P020	97
E.16	Predicciones por el modelo RBN del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto P021	98
E.17	Predicciones por el modelo SVM del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto C001	99
E.18	Predicciones por el modelo SVM del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto C009	100
E.19	Predicciones por el modelo SVM del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto C017	101
E.20	Predicciones por el modelo SVM del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto C018	102
E.21	Predicciones por el modelo SVM del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto P002	103
E.22	Predicciones por el modelo SVM del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto P003	104
E.23	Predicciones por el modelo SVM del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto P020	105
E.24	Predicciones por el modelo SVM del momento articular producido en las 5 iteraciones del movimiento realizadas por el sujeto P021	106
F.1	Optimización del número de neuronas ocultas y predicción por el modelo aoMLP del momento articular para el escenario ESM – solo Controles . . .	109
F.2	Optimización del número de neuronas ocultas y predicción por el modelo aoMLP del momento articular para el escenario ESM – solo Pacientes . . .	110
F.3	Optimización del número de neuronas ocultas y predicción por el modelo aoMLP del momento articular para el escenario ESM – Población (Controles)	111
F.4	Optimización del número de neuronas ocultas y predicción por el modelo aoMLP del momento articular para el escenario ESM – Población (Pacientes)	112
F.5	Mapa de rendimiento de validación y predicción por el modelo RBN del momento articular para el escenario ESM – solo Controles	113
F.6	Mapa de rendimiento de validación y predicción por el modelo RBN del momento articular para el escenario ESM – solo Pacientes	114
F.7	Mapa de rendimiento de validación y predicción por el modelo RBN del momento articular para el escenario ESM – Población (Controles)	115
F.8	Mapa de rendimiento de validación y predicción por el modelo RBN del momento articular para el escenario ESM – Población (Pacientes)	116
F.9	Mapa de rendimiento de validación y predicción por el modelo SVM del momento articular para el escenario ESM – solo Controles	117
F.10	Mapa de rendimiento de validación y predicción por el modelo SVM del momento articular para el escenario ESM – solo Pacientes	118
F.11	Mapa de rendimiento de validación y predicción por el modelo SVM del momento articular para el escenario ESM – Población (Controles)	119

F.12	Mapa de rendimiento de validación y predicción por el modelo SVM del momento articular para el escenario ESM – Población (Pacientes)	120
G.1	NRMSD esperado para el modelo aoMLP propuesto en el escenario ESU	122
G.2	NRMSD esperado para el modelo RBN propuesto en el escenario ESU	123
G.3	NRMSD esperado para el modelo SVM propuesto en el escenario ESU	124
G.4	NRMSD esperado para el modelo aoMLP propuesto en el escenario ESM	125
G.5	NRMSD esperado para el modelo RBN propuesto en el escenario ESM	126
G.6	NRMSD esperado para el modelo SVM propuesto en el escenario ESM	127
G.7	NRMSD esperado para el modelo aoMLP propuesto en el escenario ESU – Sin ensamble	128
G.8	NRMSD esperado para el modelo aoMLP propuesto en el escenario ESU – Ensamble de 10 MLP	129
G.9	NRMSD esperado para el modelo aoMLP propuesto en el escenario ESU – F_m de 200 Hz	130
G.10	NRMSD esperado para el modelo aoMLP propuesto en el escenario ESU – Entrenamiento LM	131
G.11	NRMSD esperado para el modelo aoMLP propuesto en el escenario ESU – Sin Cinemática	132
G.12	NRMSD esperado para el modelo aoMLP propuesto en el escenario ESU – 80 % PCA	133
G.13	NRMSD esperado para el modelo aoMLP propuesto en el escenario ESU – 90 % PCA	134
G.14	NRMSD esperado para el modelo aoMLP propuesto en el escenario ESU – 3 Sinergias	135
G.15	NRMSD esperado para el modelo aoMLP propuesto en el escenario ESU – 5 Sinergias	136

