



ESCUELA DE DOCTORADO Y ESTUDIOS DE POSGRADO

*Programa de Doctorado en
Ingeniería Industrial, Informática y Medioambiental*

TESIS DOCTORAL

Modelado de sistemas complejos mediante métodos de agrupamiento e hibridación de técnicas inteligentes

Autor: José Luis Casteleiro Roca

Directores: José Luis Calvo Rolle
Juan Albino Méndez Pérez

La Laguna, Septiembre de 2019

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46



Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46




Dr. José Luis Calvo Rolle, profesor del Departamento de Ingeniería Industrial de la Universidade da Coruña, y Dr. Juan Albino Méndez Pérez, profesor del Departamento de Ingeniería Informática y de Sistemas de la Universidad de La Laguna.

AUTORIZAN

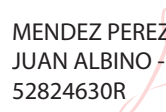
A la defensa de la Tesis Doctoral titulada “*Modelado de sistemas complejos mediante métodos de agrupamiento e hibridación de técnicas inteligentes*”, realizada por D. José Luis Casteleiro Roca, bajo nuestra dirección y supervisión, y que presenta para la obtención del grado de Doctor por la Universidad de La Laguna.

En La Laguna, a 16 de septiembre de 2019



Firmado digitalmente por CALVO ROLLE
JOSE LUIS - 32672840Y
Nombre de reconocimiento (DN): c=ES,
serialNumber=IDCES-32672840Y,
givenName=JOSE LUIS, sn=CALVO ROLLE,
cn=CALVO ROLLE JOSE LUIS - 32672840Y
Fecha: 2019.09.13 13:13:15 +02'00'

Dr. José Luis Calvo Rolle



Firmado digitalmente
por MENDEZ PEREZ
JUAN ALBINO -
52824630R
Fecha: 2019.09.13
12:50:03 +01'00'

Dr. Juan Albino Méndez Pérez

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46



Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

A todos los que nunca dejasteis de insistir y terquear para que sacara este proyecto adelante. De no haber sido por vuestra inestimable persistencia, nunca habría podido llegar hasta aquí.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46



Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Agradecimientos

Quiero agradecer a toda la gente que me ha apoyado durante el tiempo que me ha llevado conseguir hacer un trabajo que pueda ser llamado Tesis Doctoral; que, a decir verdad, no ha sido un trabajo a corto plazo.

Además, tampoco me quiero olvidar de los que me sufrieron; que, curiosamente, son los mismos que me apoyaron hasta ver terminado este trabajo.

Por último, simplemente me gustaría remarcar que deseo, y espero, que este trabajo sirva de inicio para hacer algo más grande en un futuro.

José Luis Casteleiro
La Laguna, Septiembre de 2019

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

II

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Resumen

El presente trabajo de investigación aborda el estudio y desarrollo de un sistema de modelado híbrido que combina métodos de agrupamiento estándar, o *clustering*, con algoritmos de regresión. Con esta propuesta, se pretende dividir el problema de modelado de un sistema en un conjunto de modelos locales. De esta forma se pueden definir zonas con un comportamiento similar de un modo más preciso. Durante la etapa de regresión, se aplican varias técnicas sobre cada uno de los grupos, con el fin de lograr la mejor aproximación en los modelos locales obtenidos. Por tanto, el modelo híbrido estará formado por el conjunto de todos estos modelos. Esta novedosa propuesta permite obtener resultados altamente satisfactorios en todos los procesos reales en los que se ha aplicado.

El sistema desarrollado ha sido validado sobre tres supuestos reales diferentes. En el primero de ellos, el modelo híbrido se emplea para obtener o predecir el valor que debiera medir un sensor para poder realizar detección de fallos. La aplicación real utiliza la señal BIS, que se emplea para determinar el grado de hipnosis de un paciente sedado. En el segundo, el modelo propuesto se utiliza para crear un sensor virtual, obteniendo el valor de una variable a partir de otras. La aplicación real, en este caso, se desarrolla sobre un sensor para monitorizar el estado de carga de una batería. En el último caso, el modelo híbrido se usa para predecir valores de variables en un tiempo futuro, en instantes posteriores al de la ejecución del modelo. Como aplicación real para este caso, se trata de predecir el valor de la señal ANI empleada en operaciones quirúrgicas, que es un indicador del dolor que sufren los pacientes durante una intervención.

Palabras clave: *Sistemas inteligentes, Sistemas no lineales, Sistemas híbridos, Soft Computing, Inteligencia Artificial*

III

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

IV

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Abstract

The following proposal presents a hybrid system that combines standard grouping methods, or clustering, with regression algorithms. The problem of building a hybrid system is divided into a set of local models. The system groups zones into local models on the basis of their behavior. In this way, it is possible to define, with greater precision, zones whose behavior is similar. During the regression stage, several techniques are applied to each group, in order to establish a close relationship between all the local models within the system. This novel proposal has obtained highly satisfactory results in real-life scenarios.

Three case studies have been conducted in a real environment, with the aim of testing the developed system. In the first one, the hybrid model was employed in the detection of erroneous sensors. This was done by predicting the value that a sensor should obtain and comparing it with the real value. The detections of faulty sensors can be applied in the BIS signal, which is used to determine the depth of anaesthesia in a sedated patient. In the second experiment, the proposed model has been used to create a virtual sensor, obtaining the value of one variable on the basis of the values of other signals. This functionality can be applied to sensor that monitor the state of charge of a battery. In the last case study, the hybrid model has been used to predict the values of variables at a future time. This is an important feature in real applications, such as the ANI signal where future values are predicted during surgical operations, an indicator of the pain suffered by patients during an intervention.

Keywords: *Intelligent systems, Non-linear systems, Hybrid systems, Soft Computing, Artificial Intelligence*

v

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

VI

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Índice general

1. Introducción	1
1.1. Antecedentes	1
1.2. Motivación	6
1.3. Objetivos	8
1.4. Metodología	10
1.5. Estructura	10
2. Métodos	15
2.1. Técnicas de agrupamiento	15
2.2. Regresión mediante Redes Neuronales Artificiales	17
2.3. Regresión mediante Máquinas de Soporte Vectorial	18
2.3.1. Máquina de Soporte Vectorial con Mínimos Cuadrados	19
2.4. Regresión polinomial	20
2.5. Técnicas de validación	20
2.5.1. Método <i>Hold out</i>	21
2.5.2. <i>Cross Validation</i> (Validación cruzada)	21
2.5.3. Evaluación de los métodos de regresión	22
3. Propuesta de modelado	27
3.1. Técnicas inteligentes de modelado	27
3.2. Modelado híbrido con técnicas inteligentes	29
3.2.1. Agrupamiento de los datos - <i>Clustering</i>	29
3.2.2. Modelos locales de regresión	29
3.2.3. Selección de la mejor configuración híbrida	30
4. Hybrid intelligent system to perform fault detection on BIS sensor during surgeries	33
4.1. Introduction	35
4.2. The Anesthesia Issue	39
4.2.1. Sensor technology for hypnosis assessment	39
4.2.2. Clinical study and protocol	41
4.3. Hybrid model proposal	41

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA
UNIVERSIDAD DE LA LAGUNA

Fecha: 20/09/2019 13:27:50

JOSÉ LUIS CALVO ROLLE
UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:29:29

Juan Albino Méndez Pérez
UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:30:46

4.3.1. The Dataset	45
4.3.2. Modelling Techniques	45
4.3.2.1. Data Clustering: the K-Means Algorithm	45
4.3.2.2. Multi Layer Perceptron (MLP)	46
4.3.2.3. Support Vector Regression (SVR), Least Square Support Vector Regression (LS-SVR)	47
4.3.2.4. Polynomial regression	47
4.4. Results	48
4.4.1. Clustering and modeling results	48
4.4.2. Fault Detection System Results	50
4.5. Conclusions	55
5. Power cell SOC modelling for intelligent virtual sensor implementation	63
5.1. Introduction	65
5.2. Case study	67
5.2.1. The battery	67
5.2.2. Capacity confirmation test	68
5.3. Model approach	71
5.3.1. Techniques used	72
5.3.1.1. Clustering	72
5.3.1.2. Regression Techniques	74
5.3.2. Preprocessing the dataset	76
5.4. Results	78
5.4.1. Statistical Analysis	80
5.5. Conclusions and future works	81
6. Hybrid model for the ANI index prediction using Remifentanil drug and EMG signal	89
6.1. Introduction	91
6.2. Case of Study	93
6.3. Model approach	93
6.3.1. Dataset Obtaining and Description	95
6.3.2. Used Techniques	97
6.3.2.1. Data Clustering - The K-means algorithm	97
6.3.2.2. Artificial Neural Networks (ANN). Multi-Layer Perceptron (MLP)	98

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

6.3.2.3. Support Vector Regression (SVR), Least Square Support Vector Regression (LS-SVR)	98
6.4. Results	99
6.5. Conclusions	102
6.6. Future works	103
6.7. Acknowledgements	104
7. Conclusiones	109
8. Trabajos futuros	111
Justificantes de los artículos	115
Publicaciones del doctorando	123
Referencias	137

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

X

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Índice de figuras

2.1. Ejemplo de evolución del K-Means en varias iteraciones	16
2.2. Estructura de una red neuronal multicapa	17
2.3. Espacio de entradas y espacio de características	19
2.4. Validación cruzada (<i>K-Fold Cross Validation</i>)	22
3.1. Esquema básico de un modelo de regresión	27
3.2. Modelo de regresión con estados anteriores de entradas y salidas	28
3.3. Selección del mejor algoritmo de regresión	28
3.4. Esquema de la división de los datos en grupos	30
3.5. Diagrama interno genérico de un modelo híbrido	31
3.6. Diagrama de flujo para la creación de un modelo híbrido	31
4.1. BIS Vista monitor	40
4.2. The anesthesia issue. Input and Output definition	42
4.3. Hybrid model proposal	42
4.4. BIS case	43
4.5. Modeling process	44
4.6. Real (top) and predicted (bottom) BIS signal for one complete surgery	53
4.7. Real (top), predicted (middle), and error (bottom) BIS signal for 100 samples during surgery	53
4.8. Complete surgery with fault detection Range of 10	54
4.9. Complete surgery with fault detection Range of 15	54
5.1. Capacity confirmation test diagram	68
5.2. Current and voltage measured during one cycle	70
5.3. Energy and temperatures measured in one cycle	70
5.4. Model approach	72
5.5. Modeling process	72
5.6. PCA Analysis	77
5.7. MLHL Analysis	78
5.8. Boxplot of MSE by cluster	80
6.1. Case of study. Input/Output representation	94

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA
UNIVERSIDAD DE LA LAGUNA

Fecha: 20/09/2019 13:27:50

JOSÉ LUIS CALVO ROLLE
UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:29:29

Juan Albino Méndez Pérez
UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:30:46

6.2. Model approach	94
6.3. Model approach with the timed variables indicated	95
6.4. Hybrid intelligent model	95
6.5. Modeling process	96
6.6. K-Fold Training process	96
6.7. All the surgery ANI signal for the first testing patient. Real (blue continuous) and predicted (red dashed) ANI signals	102
6.8. All the surgery ANI signal for the second testing patient. Real (blue continuous) and predicted (red dashed) ANI signals	102

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Índice de tablas

4.1. Number of samples in each cluster in percentage	49
4.2. Clusters MSE	51
4.3. Best regression technique for each cluster	52
4.4. Results of the chosen configuration	52
5.1. Samples assigned to clusters	78
5.2. Best MSE achieved for each technique	79
5.3. MSE for the best methods	79
5.4. p-value for each model in each cluster	81
6.1. Best MAE for each cluster	100
6.2. Best algorithm for each cluster	101
6.3. Hybrid MSE for each combination	101
6.4. Validation performance measures	102

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

XIV

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

CAPÍTULO 1



Introducción

En este capítulo se exponen, en primer lugar, los antecedentes que dan lugar a la elaboración de este trabajo. Posteriormente, se aborda la motivación que se persigue con esta tesis doctoral, centrándose en los problemas más usuales encontrados, y en la posibilidad de mejorarlos. Los últimos puntos describen tanto los objetivos específicos del trabajo, la metodología utilizada para su consecución, así como la exposición de la estructura principal del documento.

1.1. Antecedentes

El desarrollo de soluciones eficientes dentro del ámbito de la ingeniería, pasa por disponer de modelos fiables que permitan representar el sistema sobre el que se está trabajando de una manera exacta y sencilla. La disponibilidad de estos modelos permite, por un lado, analizar con mayor facilidad las propiedades y comportamiento del sistema y, por otro, facilitar el diseño, ya que se permite la validación de soluciones en simulación, previas a la implantación de la solución en el sistema real.

Como es bien sabido, existen dos enfoques cuando se aborda la síntesis del modelo de un sistema. Una posibilidad es recurrir a modelos basados en los principios fundamentales que definen el comportamiento del sistema (modelo teórico), y la otra es obtener un modelo a partir de datos obtenidos del propio sistema (modelo empírico). La aplicación de modelos teóricos en la industria ha sido ampliamente utilizada con éxito para describir procesos de complejidad limitada, y en su rango de comportamiento lineal. Sin embargo, para el desarrollo de modelos de procesos no lineales o procesos en los que la complejidad es elevada, el uso de modelos empíricos aparece como una solución más adecuada y con mejores prestaciones. En estos modelos se trata de realizar un análisis de los datos recogidos de entradas y salidas del proceso con el objetivo de encontrar una representación matemática que reproduzca el comportamiento observado.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 1. Introducción

De forma general, la metodología usada comúnmente en el diseño de modelos empíricos involucra tres etapas. Una primera etapa es la de análisis de los datos obtenidos, donde se trata de extraer información de cómo se comporta el sistema; por ejemplo, de cómo una o más variables dependientes se comportan frente a una o más variables explicativas. En la siguiente etapa se propone una estructura matemática que englobe a una clase de modelos entre los que se encuentra el que se corresponde con los datos disponibles. Y en una última etapa se identifica, de entre todos los modelos existentes en esa clase, cuál es el que más se acerca al comportamiento observado.

Los métodos empíricos más comunes son los basados en regresión lineal, en los que la variable dependiente se expresa como una función lineal de una variable explicativa. Para el cálculo de los parámetros que definen el modelo (coeficientes de regresión) se emplean técnicas de ajuste como la de mínimos cuadrados. En la práctica muchos procesos no pueden ser descritos por una función tan sencilla como la lineal, siendo necesario el uso de modelos de regresión no lineales para poder representar fidedignamente al sistema. Por otro lado, lo más común es que la variable de interés dependa de más de una variable explicativa. Esto da lugar a los métodos de regresión múltiple. Estos métodos, conocidos como MRA (*Multiple Regression Analysis*) son de mayor ámbito e incluyen tanto regresión lineal como no lineal con múltiples variables explicativas.

Los métodos de modelado tradicional basados en MRA [10] se han usado en múltiples y diferentes aplicaciones durante mucho tiempo [14, 16, 22]. Por ejemplo, en [16, 20] se presentan modelos mejorados para estimar el coste de las fases iniciales de proyectos; estos modelos logran una mejora de casi un 20% con respecto a otros al utilizar técnicas basadas en MRA. En [12] se muestran modelos basados en MRA para pruebas en pacientes dependientes que permiten una mejora en los tratamientos. El modelo, que se validó sobre una población de 274 pacientes con dependencia del alcohol pudo demostrar el impacto positivo de la farmacoterapia durante los 6 primeros meses, y una mejora en los índices de recaída durante el primer año del tratamiento. Otro ejemplo de aplicación de MRA a la industria puede encontrarse en [14]. En este caso se aborda el desarrollo de una metodología para la medida de la calidad de prestaciones de un suministrador (*Supplier Quality Performance Assessment, SQPA*) para la industria de fabricación de computadoras. Los resultados obtenidos en este caso permitieron introducir nuevas estrategias para la mejora de la cadena de suministro en la industria.

Los métodos MRA tienen dos ventajas destacables:

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

1.1 Antecedentes

- La primera es la capacidad para determinar, de forma relativamente sencilla, la influencia de las variables explicativas en la variable dependiente.
- La segunda es la facilidad para detectar *outliers*, o anomalías, en el funcionamiento de un proceso. Esto surge por lo intuitivo que resulta analizar si la influencia de una variable explicativa en la dependiente no se corresponde con lo esperado.

Sin duda, este tipo de técnicas son las que mayor despliegue tuvieron en el pasado debido a su sencillez y rendimiento. A pesar de los ejemplos de éxito señalados, los métodos basados en MRA tienen limitaciones para la descripción de algunos procesos, como por ejemplo en [8, 10]. En estos trabajos, uno de ellos enfocado al modelado del efecto de las fuentes de calor en habitaciones ventiladas y otro al análisis de datos de radiación en diferentes condiciones atmosféricas, se usaron métodos tradicionales basados en MRA y se obtuvieron resultados que evidenciaron la necesidad de recurrir a otras herramientas de modelado más avanzadas.

En general, las limitaciones de los métodos basados en MRA se ponen de manifiesto cuando:

- El sistema presenta componentes fuertemente no lineales que no resultan fácilmente modelables con métodos MRA.
- La complejidad del sistema es muy elevada, lo que incrementaría la complejidad del modelo MRA o conduciría a una sobreparametrización del mismo.
- El conjunto de datos empíricos para el modelado no está completo. Los métodos MRA son especialmente sensibles a la escasez de datos del conjunto, y pueden conducir fácilmente a la propuesta de resultados incorrectos que podrían ser minimizados con otras estrategias.

Para estas situaciones, la alternativa con mejores prestaciones es el uso de métodos basados en inteligencia artificial. Estas técnicas de *Soft Computing* suelen ofrecer resultados satisfactorios incluso en presencia de no linealidades importantes. En [21, 23] se utilizan meta clasificadores en un sistema de control predictivo basado en aprendizaje automático. La aplicación de esta estrategia se realizó sobre un proceso productivo en el sector de la metalurgia mostrando las mejoras en el proceso de predicción del controlador predictivo con estos algoritmos inteligentes de modelado.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 1. Introducción

En [23], se utilizan métodos basados en máquinas de soporte vectorial para la predicción de la siniestralidad laboral en función de las condiciones de trabajo. El modelo desarrollado fue capaz de clasificar a los trabajadores que sufrieron algún accidente laboral durante los últimos 12 meses, y a los que no lo habían tenido, en función de sus condiciones laborales.

En [15, 17] se utilizan redes neuronales artificiales combinadas con técnicas de MRA para mejorar el modelo calculado. En el primer caso se aplicó a la predicción de derrumbes en excavaciones subterráneas y en el segundo a predicciones en el mercado bursátil. En otra aplicación presentada en [2] se muestra la detección y predicción de fallos en un aerogenerador, empleando *Soft Computing* para crear los modelos finales, con resultados prometedores.

Estos ejemplos ilustran de manera evidente las ventajas del uso de modelos inteligentes en diferentes campos de la ingeniería. Los casos mencionados ofrecen un único modelo global basado en inteligencia artificial para la predicción de variables. Sin embargo, para un proceso que opere en regiones del espacio de estados muy diferenciadas, un único modelo global puede, en ocasiones, disminuir su exactitud en función de la zona de operación en la que se encuentra el sistema. Así, una tendencia en los últimos años es el desarrollo de modelos que permitan recoger de forma más exacta el comportamiento del proceso en todo el espacio de estados.

En esta línea, parece razonable considerar que un margen de mejora en los modelos inteligentes sería abordar el desarrollo de modelos locales válidos en cualquier región de operación en la que se encuentre el sistema. De este modo el modelo global del sistema estaría conformado por un conjunto de modelos locales que se irían activando en función de la zona de operación en la que se encuentre el sistema.

En el campo de la ingeniería de control, por ejemplo, podemos encontrar muchos trabajos de control predictivo híbrido que se basan en esta idea y que han ido aplicándose en diferentes ámbitos [3, 4].

Para la hibridación de modelos a partir de datos de funcionamiento del sistema, las técnicas de agrupamiento (*clustering*) resultan especialmente interesantes [1]. Estas técnicas consisten en dividir el conjunto de datos en diferentes grupos y etiquetar cada dato en función del agrupamiento al que pertenece. Para la formación de los *clusters* se medirá la distancia entre elementos del conjunto de datos y de los agrupamientos entre sí. La asignación de cada dato a un *cluster* se realizará para minimizar la distancia

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

1.2 Motivación

entre los datos pertenecientes a un mismo agrupamiento.

En cuanto a las técnicas de *clustering*, uno de los métodos más utilizados a la hora de dividir conjuntos de datos es el algoritmo K-Means de aprendizaje no supervisado [6, 7, 13]. Este algoritmo permite dividir el conjunto de datos completo en un número de grupos determinado. Cada muestra de datos pertenecerá a un grupo concreto en función de sus características. Una de las ventajas del algoritmo K-Means es que es un algoritmo muy rápido, lo que redundará en una disminución de la carga computacional asociada al mismo.

Otra estrategia para la formación de agrupamientos es el agrupamiento *Mean shift*, que se basa en un algoritmo de ventana deslizante que tiende a buscar áreas densas de puntos de datos. Una alternativa basada en este algoritmo, pero con mejoras interesantes, es el algoritmo de Agrupamiento Espacial Basado en Densidad de Aplicaciones con Ruido (*Density-Based Spatial Clustering of Applications with Noise*, DBSCAN).

Por último, existen dos algoritmos que merecen ser citados por sus buenas prestaciones para el agrupamiento. Uno es el Agrupamiento por maximización de expectativas mediante modelos gaussianos mixtos (*Expectation-Maximization*, EM *Clustering using Gaussian Mixture Models*, GMM) que permite resolver problemas de agrupamientos donde otros métodos no ofrecen buenos resultados; por ejemplo, *clusters* circulares con diferente radio y mismo centro o *clusters* no circulares. Y el otro método es el agrupamiento jerárquico acumulativo (*Agglomerative Hierarchical Clustering*, AHC). Este método consigue los agrupamientos mediante la agrupación de forma jerárquica de *sub-clusters*, y ofrece ventajas interesantes como la no necesidad de definir el número de agrupamientos a priori.

Un agrupamiento obtenido de este modo facilitaría la síntesis de modelos de mayor precisión en la zona de operación correspondiente. Así, en la literatura se pueden encontrar diferentes trabajos dirigidos en esta línea [19, 24].

Las propuestas de modelado avanzado se dirigen entonces al desarrollo de modelos locales en cada uno de estos agrupamientos que posteriormente puedan ser combinados para generar un modelo híbrido basado en estos modelos locales. En trabajos previos como en [5, 9, 11, 18] se ha utilizado este tipo de metodología con resultados altamente satisfactorios.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

1.2. Motivación

El uso de modelos de regresión para el modelado de sistemas ofrece, en general, buenos resultados para describir el comportamiento del sistema y predecir la evolución de sus variables. No obstante, cuando la complejidad del sistema es elevada, los modelos de regresión disminuyen sus prestaciones. Esta complejidad suele estar relacionada con fuertes componentes no lineales, con alta variabilidad en la dinámica o con alto número de variables que definen el estado del sistema. El uso de modelos de regresión no lineal se presenta como una alternativa para describir el comportamiento de estos sistemas. El enfoque comúnmente empleado es el de encontrar una representación global que permita predecir el comportamiento de las variables del sistema a lo largo del tiempo. En los casos en que la complejidad del sistema sea muy elevada incluso los modelos de regresión no lineales ofrecen prestaciones inadecuadas para algunas aplicaciones.

Por tanto, cuando se trabaja en aplicaciones con sistemas complejos, o en las que es necesario disponer de un alto grado de exactitud, surge la necesidad de buscar alternativas de modelado de altas prestaciones para abordar el diseño de las soluciones. La propuesta de este trabajo se dirige a la mejora de las prestaciones en el modelado de sistemas complejos mediante la agregación de modelos locales. La idea es desarrollar un modelo basado en múltiples modelos locales con gran exactitud en las diferentes regiones del espacio de estados en las que trabaja el sistema.

En cuanto a metodologías, cuando se desea alcanzar un nivel alto en la bondad de las predicciones del modelo, la incorporación de técnicas de inteligencia artificial es una alternativa de gran interés en cuanto a versatilidad y prestaciones. El uso de estas metodologías exige la disponibilidad de datos de funcionamiento del proceso bajo estudio para realizar el entrenamiento de los sistemas inteligentes. En el contexto industrial en el que se aborda esta tesis, no existen limitaciones en este sentido, por lo que estas técnicas inteligentes han sido las elegidas para la implementación de los modelos desarrollados.

El resultado de esta propuesta de modelado es un modelo híbrido inteligente. La hibridación surge por la combinación de diferentes modelos locales para generar un modelo global. Esto implica un proceso previo de análisis de datos para realizar agrupamientos relacionados con las distintas zonas de trabajo del proceso. Como la dinámica del proceso bajo análisis es compleja, parece razonable que en cada uno de estos agrupamientos no se fije una misma técnica de modelado, común para todos, sino que la

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

1.2 Motivación

síntesis de cada modelo local se realice eligiendo la técnica que mejores prestaciones ofrezca en cada agrupamiento. Como resultado, cada modelo global usará distintas técnicas inteligentes combinadas, ya que los resultados obtenidos en cada agrupamiento de datos dependerán de su naturaleza y de la distribución de las características no lineales que puedan tener los mismos.

La motivación subyacente en este trabajo se encuentra en el interés en resolver problemas de modelado que con métodos tradicionales no se han podido abordar de forma eficiente. Para validar la propuesta se presentan tres aplicaciones de gran interés en la industria. En concreto se han considerado tres aspectos que juegan un papel decisivo en el contexto de la industria 4.0 en donde la mayoría de los dispositivos disponen de gran cantidad de información, capacidad de procesamiento y toma de decisiones:

- **Detección de fallos.** La disponibilidad de mecanismos eficientes para la detección y aislamiento de fallos (*Fault Detection Isolation*, FDI) juega un papel crítico para la garantizar la seguridad y eficiencia de los procesos. Existen dos aproximaciones básicas para el diseño de estas técnicas: FDI basado en modelos y FDI basado en señales. En ambos casos la incorporación de técnicas de inteligencia artificial ha mostrado un gran potencial para mejorar los mecanismos de detección. Por ello, este trabajo se enfoca hacia la propuesta de una solución para la detección de fallos basado en modelos inteligentes. En concreto, se ha considerado una aplicación en el ámbito de la instrumentación en medicina donde la importancia en la fiabilidad de las señales es fundamental para la seguridad del paciente. Se propone el diseño de un sistema que permite detectar situaciones anómalas en la operación de un monitor de profundidad hipnótica durante un proceso anestésico. Esto resulta fundamental para evitar que el anestesista infunda dosis de fármacos que puedan comprometer la seguridad del paciente.
- **Síntesis de sensores virtuales.** El interés de disponer de sensores virtuales es doble. Por un lado, existen situaciones en las que no es posible la medida de una variable; en este caso, se recurre a un sistema que hace la función de observador con el fin de estimar el valor de esa señal no medible. Otra situación ocurre cuando la variable es medible pero no existe sensor o bien el sensor está en modo fallo. En esta situación, resulta fundamental suplir esa medida con una estimación aportada por un sensor virtual. Esta es otra de las soluciones que se contempla en este trabajo con una aplicación en el ámbito de los sistemas de energía. La propuesta se centra en la predicción del estado de carga de baterías, que actualmente resulta

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 1. Introducción

fundamental para la gestión del flujo de energía en sistemas eléctricos y, más concretamente, en el marco de redes eléctricas inteligentes (*Smart Grids*).

- Predicción de variables. Tradicionalmente la gestión y control de sistemas avanzados se puede realizar mediante señales o mediante modelos. La ventaja del uso de modelos es que el sistema de control puede disponer de predicciones de las variables, lo que le permite anticiparse a la evolución del sistema en la definición de las políticas de control. El elemento fundamental en estos sistemas es el sistema de predicción, ya que el rendimiento del sistema dependerá de lo fiable que sean estas predicciones. De nuevo, el uso de sistemas inteligentes que aprendan de la experiencia pasada del proceso, surgen como una alternativa muy interesante para el desarrollo de predictores. Con este objetivo, el presente trabajo expone una aplicación en el ámbito de la medicina, proponiendo un sistema para predecir el comportamiento del paciente durante el proceso anestésico. Estas predicciones permitirán al experto clínico tomar mejores decisiones y anticiparse a posibles situaciones de riesgo para el paciente.

Como se observa, la motivación de este trabajo de investigación tiene dos vertientes claras. Por un lado, se propone una nueva metodología para el modelado de sistemas complejos usando técnicas de inteligencia artificial. Y por otra parte, el trabajo tiene el propio interés de la aplicación de esta metodología en tres problemas actuales en el contexto de la industria conectada y que se han implementado en dos áreas de gran importancia en la actualidad: los sistemas de gestión de energía y la ingeniería biomédica.

1.3. Objetivos

El objetivo que se plantea en esta tesis es el diseño de una estrategia de modelado híbrido basada en técnicas de inteligencia artificial para la aplicación a sistemas complejos. La propuesta de modelo debe basarse en el uso de la información de funcionamiento del sistema y debe incorporar características que permitan adaptarse a los distintos puntos de operación. Para la validación de la estrategia se considerará su aplicación para dar respuesta a tres problemas en la industria: detección de fallos en procesos, diseño de sensores virtuales y predicción del comportamiento de variables. En particular, se considerarán tres aplicaciones relacionadas con la detección de fallos en la monitorización de la profundidad anestésica en pacientes, la predicción de variables

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

1.4 Metodología

para evaluar el nivel analgésico en pacientes y el diseño de un sensor virtual para el estado de carga de un sistema de almacenamiento de energía.

De forma detallada los objetivos específicos planteados son los siguientes:

- Propuesta de una metodología de modelado mediante la combinación de técnicas de regresión basada en técnicas de inteligencia artificial. Por el interés y prestaciones que ofrecen los métodos de regresión que se explorarán serán la regresión polinomial, métodos basados en redes neuronales y máquinas de soporte vectorial.
- Propuesta de un modelo híbrido mediante una estrategia de agregación de modelos locales obtenidos mediante técnicas de agrupamiento. La evaluación del modelo obtenido se hará mediante *Cross Validation* (validación cruzada) y *Hold Out*.
- Aplicación del modelo para la resolución de los siguientes problemas:
 - Desarrollo de un sistema de detección de fallos en la monitorización de la profundidad anestésica en pacientes sometidos a anestesia general. En particular, se considerará el problema de detección de fallos en el monitor de índice biespectral (*Bispectral Index*, BIS) usado para determinar el nivel de hipnosis en el paciente. El sistema debe ser capaz de detectar episodios en los que la señal capturada sea una señal no válida como medida de la hipnosis.
 - Propuesta de un modelo de predicción para evaluar el nivel de dolor que sufrirán los pacientes durante una intervención quirúrgica con anestesia general. Se considerará al paciente bajo anestesia con una infusión de analgésico (Remifentanil) continua para mantener el nivel de dolor en el umbral adecuado. La monitorización del estado analgésico del paciente se realizará con el monitor ANI (*AntiNociception Index*) que es uno de los monitores de mayor interés para la medida del estado analgésico.
 - Diseño de un sensor virtual para estimar el estado de carga en una batería. Las baterías sobre las que se realizará el estudio son del tipo LFP (*Lithium Iron Phosphate*, concretamente la LiFePo4) cuyos datos de funcionamiento serán recogidos de un sistema real. El sensor virtual desarrollado debe permitir su funcionamiento en tiempo real para evidenciar así su potencial en aplicaciones reales de sistemas de gestión de energía.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 1. Introducción

1.4. Metodología

La metodología que se ha seguido a lo largo de este trabajo para alcanzar los objetivos propuestos se puede resumir en los siguientes puntos:

- Selección y estudio de las técnicas que se utilizan en este trabajo.
- Asimilación, comprensión y uso de los algoritmos.
- Desarrollar formalmente el procedimiento del modelado híbrido para su aplicación sobre diversos sistemas.
- Comprobar la validez del modelado híbrido en sistemas reales.
- Verificar el correcto funcionamiento del modelo en aplicaciones concretas.
- Comprobar la viabilidad del procedimiento creado para la predicción de variables en un tiempo futuro.

1.5. Estructura

Debido a que este trabajo se presenta en la modalidad de compendio de publicaciones, la estructura de este documento no guarda relación directa con la metodología mencionada. Después del presente capítulo de Introducción, se presentan los métodos utilizados para la creación del modelado híbrido. En el capítulo 3, se desarrolla la propuesta de modelado, incluyendo el procedimiento para crear un modelo híbrido sobre sistemas diversos.

A continuación, en los capítulos 4, 5 y 6, se presentan tres artículos con distintos casos de estudios donde se aplicó el modelo híbrido obteniendo buenos resultados. Los estudios de las técnicas de regresión y clasificación, junto con las pruebas mencionadas en los objetivos, están incluidas en estos tres artículos. Debido a que estos objetivos se recogen a lo largo de cada uno de los trabajos, no están incluidos explícitamente en ningún capítulo de este documento.

En el primer caso de estudio, capítulo 4, se desarrolló un modelo para calcular la señal de salida de un sensor de la señal BIS, indicadora del nivel de sedación de

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

1.5 Estructura

un paciente durante una intervención quirúrgica. Este modelo se utiliza para realizar detección de fallos en el sensor mencionado, a través de la comparación del valor real y el predicho por el modelo.

En el segundo caso, capítulo 5, el modelo se utiliza para crear un sensor virtual; un sensor que indica el valor de una variable que no dispone de sensor real en la planta. En concreto se trata de un sensor para medir el nivel de carga de una batería, teniendo como datos reales la tensión, la corriente y la temperatura de la batería. Este tipo de sensores tienen una gran proyección ya que, a través de un modelo semejante al desarrollado, se pueden medir variables que no son accesibles en muchos sistemas.

En el capítulo 6, se crea un modelo híbrido para obtener la medida de una variable en un horizonte futuro. Concretamente, se predice la evolución de la señal ANI, indicadora del dolor que sufren los pacientes durante la anestesia en operaciones quirúrgicas. En este caso, el error obtenido es mayor que en los casos anteriores, pero la predicción es suficiente como para poder anticipar la reacción de los pacientes. Con este modelo se valida la utilización de la propuesta para calcular variables con un horizonte de tiempo mayor.

Para finalizar esta tesis, en los capítulos 7 y 8, se exponen las conclusiones y trabajos futuros tanto de manera general como específicos para los casos de estudio mostrados. En la última parte del documento, se incluyen tanto las portadas de los artículos, como un listado de los trabajos de investigación del autor. En el último apartado de este documento se recogen todas las referencias bibliográficas utilizadas a lo largo de la tesis.

Bibliografía

- [1] C. C. Aggarwal. *Data classification: algorithms and applications*. CRC press, 2014.
- [2] A. Alvarez-Huerta, R. Gonzalez-Miguel, D. Garcia-Metola, and A. Noriega-Gonzalez. Failure detection and prediction in wind turbines by using scada data. *Dyna*, 86(4):467–473, 2011. ISSN 0012-7361. doi: 10.6036/4025.
- [3] A. Bemporad and M. Morari. Control of systems integrating logic, dynamics, and constraints. *Automatica*, 35(3):407–427, 1999. ISSN 0005-1098. doi: 10.1016/S0005-1098(98)00178-2.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 1. Introducción

- [4] A. Bemporad, G. Ferrari-Trecate, D. Mignone, M. Morari, and F. D. Torrisi. Model predictive control — ideas for the next generation. In *1999 European Control Conference (ECC)*, pages 3880–3885, 1999. doi: 10.23919/ECC.1999.7099937.
- [5] J. L. Calvo-Rolle, J. L. Casteleiro-Roca, H. Quintián, and M. C. Meizoso-Lopez. A hybrid intelligent system for PID controller using in a steel rolling process. *Expert Systems with Applications*, 40(13):5188–5196, 2013. ISSN 0957-4174. doi: 10.1016/j.eswa.2013.03.013.
- [6] J.-L. Casteleiro-Roca, J. Calvo-Rolle, J. Méndez Pérez, N. Roqueñí Gutiérrez, and F. de Cos Juez. Hybrid intelligent system to perform fault detection on BIS sensor during surgeries. *Sensors*, 17(1):179, 1 2017. ISSN 1424-8220. doi: 10.3390/s17010179.
- [7] A. Cherif, H. Cardot, and R. Boné. SOM time series clustering and prediction with recurrent neural networks. *Neurocomput.*, 74(11):1936–1944, 5 2011. ISSN 0925-2312. doi: 10.1016/j.neucom.2010.11.026.
- [8] Y. Cho and H. B. Awbi. A study of the effect of heat source location in a ventilated room using multiple regression analysis. *Building and Environment*, 42(5):2072–2082, 2007. ISSN 0360-1323. doi: 10.1016/j.buildenv.2006.03.008.
- [9] M. J. Crespo-Ramos, I. Machón-González, H. López-García, and J. L. Calvo-Rolle. Detection of locally relevant variables using SOM-NG algorithm. *Engineering Applications of Artificial Intelligence*, 26(8):1992–2000, 2013. ISSN 0952-1976. doi: 10.1016/j.engappai.2013.04.012.
- [10] C. Crespo-Turrado, M. d. C. Meizoso-Lopez, F. Sanchez-Lasheras, B. A. Rodriguez-Gomez, J. L. Calvo-Rolle, and F. J. de Cos Juez. Missing data imputation of solar radiation data under different atmospheric conditions. *Sensors*, 14(11):20382, 2014. ISSN 1424-8220. doi: 10.3390/s141120382.
- [11] J. A. Fernández, C. D. Muñiz, P. G. Nieto, F. de Cos Juez, F. S. Lasheras, and M. Roqueñí. Forecasting the cyanotoxins presence in fresh waters: A new model based on genetic algorithms combined with the MARS technique. *Ecological engineering*, 53:68–78, 2013. doi: 10.1016/j.ecoleng.2012.12.015.
- [12] G. Flórez, P. A. Saiz, P. García-Portilla, F. J. De Cos, S. Dapia, S. Álvarez, L. Nogueiras, and J. Bobes. Predictors of posttreatment drinking outcomes in patients with alcohol dependence. *European addiction research*, 21(1):19–30, 2014. doi: 10.1159/000358194.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

1.5 Estructura

- [13] M. H. Ghaseminezhad and A. Karami. A novel self-organizing map (SOM) neural network for discrete groups of data clustering. *Appl. Soft Comput.*, 11(4):3771–3778, 6 2011. ISSN 1568-4946. doi: 10.1016/j.asoc.2011.02.009.
- [14] L.-H. Ho, S.-Y. Feng, Y.-C. Lee, and T.-M. Yen. Using modified IPA to evaluate supplier’s performance: Multiple regression analysis and DEMATEL approach. *Expert Systems with Applications*, 39(8):7102–7109, 2012. ISSN 0957-4174. doi: 10.1016/j.eswa.2012.01.034.
- [15] H. Jang and E. Topal. Optimizing overbreak prediction based on geological parameters comparing multiple regression analysis and artificial neural network. *Tunnelling and Underground Space Technology*, 38(0):161–169, 2013. ISSN 0886-7798. doi: 10.1016/j.tust.2013.06.003.
- [16] R. Jin, K. Cho, C. Hyun, and M. Son. MRA-based revised CBR model for cost prediction in the early stage of construction projects. *Expert Systems with Applications*, 39(5):5214–5222, 2012. ISSN 0957-4174. doi: 10.1016/j.eswa.2011.11.018.
- [17] F. S. Lasheras, F. J. de Cos Juez, A. S. Sánchez, A. Krzemień, and P. R. Fernández. Forecasting the COMEX copper spot price by means of neural networks and ARIMA models. *Resources Policy*, 45:37–43, 2015. ISSN 0301-4207. doi: 10.1016/j.resourpol.2015.03.004.
- [18] I. Machón-González, H. López-García, and J. L. Calvo-Rolle. Neuro-robust controller for non-linear systems. *Dyna*, 86(3):308–317, 2011. doi: 10.6036/3949.
- [19] D. Martínez-Rego, O. Fontenla-Romero, and A. Alonso-Betanzos. Efficiency of local models ensembles for time series prediction. *Expert Syst. Appl.*, 38(6):6884–6894, 6 2011. ISSN 0957-4174. doi: 10.1016/j.eswa.2010.12.036.
- [20] P. G. Nieto, J. A. Fernández, F. S. Lasheras, F. de Cos Juez, and C. D. M. niz. A new improved study of cyanotoxins presence from experimental cyanobacteria concentrations in the trasona reservoir (northern spain) using the MARS technique. *Science of The Total Environment*, 430:88–92, 2012. ISSN 0048-9697. doi: 10.1016/j.scitotenv.2012.04.068.
- [21] J. Nieves-Acedo, I. Santos-Grueiro, and P. Garcia-Bringas. Enhancing the prediction stage of a model predictive control systems through meta-classifiers. *Dyna*, 88(3):290–298, 2013. ISSN 0012-7361. doi: 10.6036/5426.
- [22] J. Osborn, D. Guzman, F. J. de Cos Juez, A. G. Basden, T. J. Morris, E. Gendron, T. Butterley, R. M. Myers, A. Guesalaga, F. Sanchez Lasheras, M. Gomez Victoria,

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 1. Introducción

- M. L. Sánchez Rodríguez, D. Gratadour, and G. Rousset. Open-loop tomography with artificial neural networks on CANARY: on-sky results. *Monthly Notices of the Royal Astronomical Society*, 441(3):2508–2514, 2014. doi: 10.1093/mnras/stu758.
- [23] A. S. Sánchez, P. R. Fernández, F. S. Lasheras, F. J. de Cos Juez, and P. G. Nieto. Prediction of work-related accidents according to working conditions using support vector machines. *Applied Mathematics and Computation*, 218(7):3539–3552, 2011. doi: 10.1016/j.amc.2011.08.100.
- [24] A. S. Sánchez, F. J. Iglesias-Rodríguez, P. R. Fernández, and F. de Cos Juez. Applying the k-nearest neighbor technique to the classification of workers according to their risk of suffering musculoskeletal disorders. *International Journal of Industrial Ergonomics*, 52:92–99, 2016. doi: 10.1016/j.ergon.2015.09.012.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

CAPÍTULO 2



Métodos

Las técnicas que se utilizarán en este trabajo, ya han sido mencionadas en la introducción. En este capítulo se describirá cada una de ellas de una forma un poco más detallada, exponiendo su función principal y los parámetros de ajuste correspondientes. Como el objetivo de este trabajo es el empleo de las técnicas, no su análisis exhaustivo, no se definirán la totalidad de sus ajustes ni tampoco su funcionamiento en esos casos.

2.1. Técnicas de agrupamiento

El algoritmo K-Means es una técnica muy conocida de aprendizaje no supervisado para crear grupos (o *clusters*) de datos [7, 12]. Cada *cluster* está formado por muestras que comparten características similares entre ellas. El algoritmo se entrena con el objetivo de minimizar una función predefinida que, en la gran mayoría de los casos, será la distancia euclídea de los centroides (ecuación 2.1).

$$d_E(C, X) = \sqrt{(c_1 - x_1)^2 + (c_2 - x_2)^2 + \dots + (c_n - x_n)^2} = \sqrt{\sum_{i=1}^n (c_i - x_i)^2} \quad (2.1)$$

Donde:

$C \in \mathbb{R}^n$ es el centroide de un grupo

$X \in \mathbb{R}^n$ es la muestra de la que se quiere medir la distancia

El entrenamiento del algoritmo se inicia con la selección del número de grupos deseado, y se asignan aleatoriamente los centroides de cada grupo entre los datos disponibles. Durante el proceso de entrenamiento se repiten los siguientes pasos hasta que no haya cambios en los *clusters* entre una iteración y la anterior (figura 2.1).

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA
UNIVERSIDAD DE LA LAGUNA

Fecha: 20/09/2019 13:27:50

JOSÉ LUIS CALVO ROLLE
UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:29:29

Juan Albino Méndez Pérez
UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:30:46

Capítulo 2. Métodos

- Se determina el grupo al que pertenece cada muestra según la distancia a los diferentes centroides. El *cluster* asignado será el definido por el centroide más cercano.
- Se calculan los nuevos centroides como el centro de cada grupo creado teniendo en cuenta la nueva asignación de datos a los grupos.




Figura 2.1: Ejemplo de evolución del K-Means en varias iteraciones

El cálculo de los centroides finaliza cuando los datos asignados a cada *cluster* (así como los centroides) no varíen, y el algoritmo K-Means estará listo para usarse con nuevos datos. Al tener la ubicación final de los centroides, éstos se usarán para asignar los nuevos datos a su grupo específico. Este algoritmo obtiene mejores resultados cuando los datos están distribuidos uniformemente en el hiper-espacio, y los datos en los grupos tienen forma hiper-esférica [7].

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA
 UNIVERSIDAD DE LA LAGUNA

Fecha: 20/09/2019 13:27:50

JOSÉ LUIS CALVO ROLLE
 UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:29:29

Juan Albino Méndez Pérez
 UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:30:46

2.2. Regresión mediante Redes Neuronales Artificiales

Una de las configuraciones más utilizadas de las Redes Neuronales es la conocida como Perceptron Multicapa (*Multi Layer Perceptron*, MLP). Se trata de una Red Neuronal de tipo *feedforward* con una capa de entrada, una o más capas ocultas, y una capa de salida [11, 14, 17]. Se llama *feedforward* porque las conexiones siempre son hacia adelante, desde la capa de entrada a la de salida, y sin realimentación de las señales internas (figura 2.2). Cada capa tiene un número de neuronas que dependen de: el número de entradas (para el caso de la capa de entrada), la configuración elegida para el MLP (para las capas ocultas o intermedias), y el número de salidas (para la capa de salida).




Figura 2.2: Estructura de una red neuronal multicapa

Todas las neuronas de una misma capa comparten las mismas entradas, que son: las entradas de la red, en el caso de la primera capa; o las salidas de las capas anteriores, en el resto de los casos. Cada entrada a cada neurona tiene un peso específico asignado, y todas las entradas se suman internamente antes de calcular la salida de la neurona según la función de activación interna. Las funciones de activación típicas son la Tangente-Sigmoidal, la Logarítmica-Sigmoidal, la Lineal, el Escalón, etc., cada una de ellas con sus aplicaciones específicas. Cuando se usa la Red Neuronal para regresión, la configuración más extendida es usar la función Tangente-Sigmoidal en todas las neuronas excepto las de la capa de salida, en las que se suele usar la función Lineal. La función Tangente-Sigmoidal se puede ver en la ecuación 2.2.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA
 UNIVERSIDAD DE LA LAGUNA

Fecha: 20/09/2019 13:27:50

JOSÉ LUIS CALVO ROLLE
 UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:29:29

Juan Albino Méndez Pérez
 UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:30:46

Capítulo 2. Métodos

$$F(t) = \frac{e^t - e^{-t}}{e^t + e^{-t}} \quad (2.2)$$

Durante la fase de entrenamiento se ajustan los pesos asignados para cada variable en función de la salida deseada de la red [13]. Esta salida se puede calcular con la ecuación 2.3, en donde los pesos ajustados en el entrenamiento estarían en la variable θ .

$$f_{\theta}(x) = \beta + \sum_{i=1}^k a_i \phi(w_i^T x + b_i) \quad (2.3)$$

Donde:

$x = (x(1), \dots, x(d))^T \in \mathfrak{R}^d$ es el vector de entradas

k es el número de capas ocultas

ϕ es la función de activación

$\theta = (\beta, a_1, \dots, a_k, b_1, \dots, b_k, w_{11}, \dots, w_{kd})$ es el vector de los parámetros de la red

$w_i = (w_{i1}, \dots, w_{id})^T \in \mathfrak{R}^d$ es el vector de parámetros para cada unidad oculta i

2.3. Regresión mediante Máquinas de Soporte Vectorial

La Regresión con Soporte Vectorial (*Support Vector Regression*, SVR) es una modificación de las Máquinas de Soporte Vectorial (*Support Vector Machines*, SVM) usadas en clasificación [3]. La idea básica de las SVR es cambiar los datos de entrada a un espacio de características F , de alta dimensionalidad, a través de una transformación no lineal, y realizar una regresión lineal en este nuevo espacio. En la ecuación 2.4 se puede ver la relación entre las variables originales de entrada, y las nuevas en el espacio de características; la figura 2.3 muestra gráficamente este cambio para clasificación

$$\begin{array}{ccc} X & \Phi : X \rightarrow & F \\ X = (x_1, x_2) & & \Phi(X) = [\Phi_1(x), \Phi_2(x)] \end{array} \quad (2.4)$$

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46




Figura 2.3: Espacio de entradas y espacio de características

2.3.1. Máquina de Soporte Vectorial con Mínimos Cuadrados

La formulación de mínimos cuadrados para SVM se llama LS-SVM (*Least Square Support Vector Machine*). Con esta aproximación, la solución se obtiene resolviendo un sistema de ecuaciones lineales que, en términos generales, es comparable a las SVM [9]. La aplicación de las LS-SVM para regresión es conocida como LS-SVR (*Least Square Support Vector Regression*). En las LS-SVR, la función de olvido ϵ – *insensible* es reemplazada por una función cuadrática clásica de olvido, construida resolviendo un sistema lineal de Karush-Kuhn-Tucker (ecuación 2.5).

$$\begin{bmatrix} 0 & I_n^T \\ I_n & K + \gamma_{-1}I \end{bmatrix} \begin{bmatrix} b_0 \\ b \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix} \quad (2.5)$$

Donde:

- I_n es un vector de $[n \times 1]$ unos
- T indica la traspuesta de una matriz o vector
- γ es el vector de pesos
- b es el vector de regresión
- b_0 es el desplazamiento (*offset*) del modelo

En LS-SVR sólo es necesario ajustar 2 parámetros (γ , σ). Siendo σ el ancho del kernel utilizado [16].

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

2.4. Regresión polinomial

Un modelo de regresión polinomial se puede definir, de manera general, como una suma de funciones base [1, 2, 5, 15, 18]. El número de estas funciones depende del número de entradas al modelo junto con el grado del polinomio seleccionado.

La ecuación 2.6 muestra la formulación para un polinomio de primer grado y dos entradas. El modelo se vuelve más complejo conforme el grado del polinomio aumenta. Para segundo grado, se utilizaría la ecuación 2.7.

$$F(x) = a_0 + a_1x_1 + a_2x_2 \quad (2.6)$$

$$F(x) = a_0 + a_1x_1 + a_2x_2 + a_3x_1x_2 + a_4x_1^2 + a_5x_2^2 \quad (2.7)$$

2.5. Técnicas de validación

Una vez descritos los algoritmos de regresión y agrupamiento que se van a utilizar, se van a explicar las técnicas de validación utilizadas para valorar la calidad de los diferentes modelos obtenidos. En general, las medidas de evaluación utilizadas dependen de la tarea a la que esté orientado un modelo concreto; a continuación, se mencionan las más habituales [6]:

- *Clasificación.* Para evaluar un modelo de clasificación se mide su precisión predictiva, es decir, el porcentaje de clasificaciones acertadas en el conjunto de prueba frente al total de las clasificaciones realizadas.
No obstante, para la valoración de un modelo de clasificación también se pueden tener en cuenta las clasificaciones erróneas; las cuatro medidas básicas para clasificación serían los verdaderos positivos, los verdaderos negativos, los falsos positivos y los falsos negativos.
- *Regresión.* En este caso, la medida habitual que se suele emplear es el error cuadrático medio. Para cada dato del conjunto se mediría la diferencia entre el valor real y el valor predicho por el modelo, y se elevaría al cuadrado. La medida

2.5 Técnicas de validación

sería el promedio de este valor con todos los datos disponibles.

Al igual que para clasificación, esta no es la única medida, ya que también se puede usar el error cuadrático medio normalizado, el error absoluto medio o el error absoluto medio porcentual.

Para evaluar un modelo se suele utilizar un conjunto de datos diferente al empleado para entrenamiento. Así, los datos se dividen en dos conjuntos disjuntos: el primer subconjunto se denomina de entrenamiento (*training*) y se utiliza para el ajuste de los parámetros de los modelos; mientras que el segundo subconjunto, denominado de prueba (*test*), se emplea para valorar la calidad del modelo, utilizando estos datos con el algoritmo ajustado mediante los datos de entrenamiento.

En [8] se pueden consultar comparaciones entre distintos métodos de validación de modelos. En los siguientes apartados se detallan los métodos de validación *Hold-Out* y *Cross Validation* (validación cruzada).

2.5.1. Método *Hold out*

En este caso, la partición del conjunto de datos se realiza de forma aleatoria, dejando un porcentaje de datos para entrenamiento y otro para prueba [4]. La división más usual es 2/3 para *training*, y 1/3 para *test*; aunque el porcentaje no tiene porqué ser siempre el mismo.

Este es un método de simple implementación y rápida evaluación, pero presenta el problema de que su resultado depende de la forma en que se realice la partición. Además, al dividir los datos de manera aleatoria, el resultado que se obtenga al repetir el proceso completo de entrenamiento, puede diferir mucho de una vez a otra.

2.5.2. *Cross Validation* (Validación cruzada)

Para minimizar el problema mencionado de la técnica anterior, se recurre a la validación cruzada [6]. En este caso, el conjunto de datos se divide en un total de K -Fold subconjuntos disjuntos de similar tamaño. El entrenamiento se realizaría utilizando la unión de $K-1$ subconjuntos y el subconjunto restante se emplearía para valorar el modelo.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA
UNIVERSIDAD DE LA LAGUNA

Fecha: 20/09/2019 13:27:50

JOSÉ LUIS CALVO ROLLE
UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:29:29

Juan Albino Méndez Pérez
UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:30:46

Capítulo 2. Métodos

Este proceso se repetiría K -Fold veces hasta que todos los subconjuntos hayan formado parte de los datos de prueba del modelo. El resultado final se obtiene calculando el error seleccionado con todos los datos de prueba; que en este caso serían todos los datos disponibles (figura 2.4). Es habitual utilizar K -Fold igual a 10 [6].

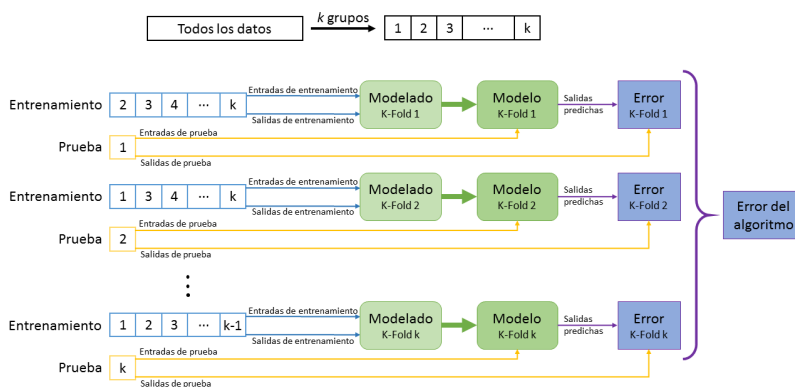


Figura 2.4: Validación cruzada (K -Fold Cross Validation)

El método de validación cruzada suele ser más preciso que el de *Hold out*, pero presenta el problema de que es lento desde el punto de vista computacional; hay que repetir el proceso completo de entrenamiento K -Fold veces.

2.5.3. Evaluación de los métodos de regresión

Para los modelos de regresión se suele estimar su calidad calculando la diferencia entre las predicciones del modelo y los datos utilizados para la prueba de validación [6]. En cada caso, se seleccionará el método de regresión que aporte un menor error.

Las medidas de evaluación que se utilizan para comparar los modelos son el error cuadrático medio [10], representado por MSE (*Mean Squared Error*) y que viene definido en la ecuación 2.8. El error cuadrático medio normalizado, definido en la ecuación 2.9, y representado por NMSE (*Normalized Mean Squared Error*). El error absoluto medio, representado por MAE (*Mean Absolute Error*) y definido en la ecuación 2.10. Y el error absoluto medio porcentual, definido en la ecuación 2.11, y representado por MAPE (*Mean Absolute Percentage Error*).

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015. Su autenticidad puede ser contrastada en la siguiente dirección https://sede.ull.es/validacion/	
Identificador del documento: 2141614	Código de verificación: B1ePGXal
Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_{i_{modelo}} - y_{i_{real}})^2 \quad (2.8)$$

$$NMSE = \frac{1}{n} \sum_{i=1}^n \frac{(y_{i_{modelo}} - y_{i_{real}})^2}{y_{i_{modelo}} \cdot y_{i_{real}}} \quad (2.9)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_{i_{modelo}} - y_{i_{real}}| \quad (2.10)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_{i_{modelo}} - y_{i_{real}}}{y_{i_{real}}} \right| \quad (2.11)$$

Siendo n el número de datos, e \bar{y} la media de la variable y .

Bibliografía

- [1] C. Bishop. *Pattern Recognition and Machine Learning (Information Science and Statistics)*. Springer-Verlag New York, Inc., Secaucus, NJ, USA, 2006. ISBN 0387310738.
- [2] J. Casteleiro-Roca, J. Calvo-Rolle, M. Meizoso-López, A. Piñón-Pazos, and B. Rodríguez-Gómez. New approach for the QCM sensors characterization. *Sensors and Actuators A: Physical*, 207(0):1–9, 2014. ISSN 0924-4247. doi: 10.1016/j.sna.2013.12.002.
- [3] N. Cristianini and J. Shawe-Taylor. *An introduction to support Vector Machines and other kernel-based learning methods*. Cambridge University Press, New York, NY, USA, 2000. ISBN 0-521-78019-5.
- [4] A. A. Freitas. *Data mining and knowledge discovery with evolutionary algorithms*. Springer Science & Business Media, 2013.
- [5] R. Heiberger and E. Neuwirth. Polynomial regression. In *R Through Excel*, Use R, pages 269–284. Springer New York, 2009. ISBN 978-1-4419-0051-7. doi: 10.1007/978-1-4419-0052-4{\.}11.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 2. Métodos

- [6] J. Hernández Orallo, C. Ferri Ramirez, and M. J. Ramirez Quintana. Introducción a la minería de datos. 2004.
- [7] S. Kaski, J. Sinkkonen, and A. Klami. Discriminative clustering. *Neurocomputing*, 69(1-3):18–41, 2005. ISSN 0925-2312. doi: 10.1016/j.neucom.2005.02.012.
- [8] R. Kohavi et al. A study of cross-validation and bootstrap for accuracy estimation and model selection. In *Ijcai*, volume 14, pages 1137–1145, 1995.
- [9] Y. Li, X. Shao, and W. Cai. A consensus least squares support vector regression (LS-SVR) for analysis of near-infrared spectra of plant samples. *Talanta*, 72(1): 217–222, 2007. ISSN 0039-9140. doi: 10.1016/j.talanta.2006.10.022.
- [10] J. H. Mathews and K. D. Fink. *Métodos numéricos con Matlab*. Pearson, 2000.
- [11] J. Osborn, D. Guzman, F. J. de Cos Juez, A. G. Basden, T. J. Morris, E. Gendron, T. Butterley, R. M. Myers, A. Guesalaga, F. Sanchez Lasheras, M. Gomez Victoria, M. L. Sánchez Rodríguez, D. Gratadour, and G. Rousset. Open-loop tomography with artificial neural networks on CANARY: on-sky results. *Monthly Notices of the Royal Astronomical Society*, 441(3):2508–2514, 2014. doi: 10.1093/mnras/stu758.
- [12] A. Qin and P. Suganthan. Enhanced neural gas network for prototype-based clustering. *Pattern Recogn.*, 38(8):1275–1288, 8 2005. ISSN 0031-3203. doi: 10.1016/j.patcog.2004.12.007.
- [13] J. Rynkiewicz. General bound of overfitting for MLP regression models. *Neurocomputing*, 90:106–110, 2012. ISSN 0925-2312. doi: 10.1016/j.neucom.2011.11.028.
- [14] P. Wasserman. *Advanced methods in neural computing*. John Wiley & Sons, Inc., New York, NY, USA, 1st edition, 1993. ISBN 0442004613.
- [15] X. Wu. *Optimal designs for segmented polynomial regression models and web-based implementation of optimal design software*. State University of New York at Stony Brook, Stony Brook, NY, USA, 2007. ISBN 978-0-549-91415-0.
- [16] J. Ye and T. Xiong. SVM versus least squares SVM. In *The 11th International Conference on Artificial Intelligence and Statistics (AISTATS)*, pages 640–647, 2007.
- [17] Z. Zeng and J. Wang. *Advances in neural network research and applications*. Springer Publishing Company, Incorporated, 1st edition, 2010. ISBN 3642129897, 9783642129896.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

2.5 Técnicas de validación

- [18] Z. Zhang and S. Chan. On kernel selection of multivariate local polynomial modeling and its application to image smoothing and reconstruction. *J. Signal Process. Syst.*, 64(3):361–374, 2011. ISSN 1939-8018. doi: 10.1007/s11265-010-0495-4.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 2. Métodos

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

CAPÍTULO 3

Propuesta de modelado

En este capítulo se describe de forma detallada la propuesta de modelado híbrido presentada en este trabajo, se explica inicialmente cómo hacer la selección de los mejores modelos para cada grupo de datos y, posteriormente, el procedimiento para la obtención de un modelo híbrido.

3.1. Técnicas inteligentes de modelado

Esta propuesta se basa en el modelo básico mostrado en la figura 3.1. Este modelo genérico de entradas y salidas tendría que adaptarse a la aplicación específica para cada caso donde se desee aplicar. Es importante remarcar que, aunque de antemano, el modelo no tiene relación con series temporales ni conocimiento de la dinámica del sistema, las entradas no son, de por sí, restrictivas. Teniendo en cuenta esto, se pueden incluir estados anteriores de las variables para contemplar ese tipo de información temporal (figura 3.2).




Figura 3.1: Esquema básico de un modelo de regresión

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA
UNIVERSIDAD DE LA LAGUNA

Fecha: 20/09/2019 13:27:50

JOSÉ LUIS CALVO ROLLE
UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:29:29

Juan Albino Méndez Pérez
UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:30:46

Capítulo 3. Propuesta de modelado

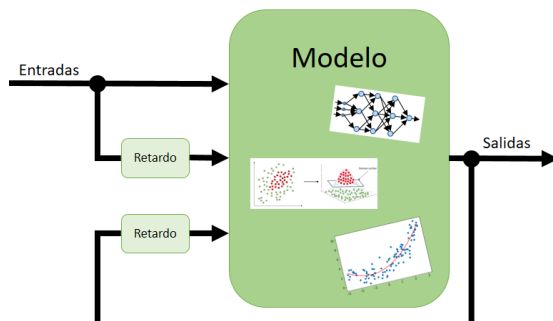


Figura 3.2: Modelo de regresión con estados anteriores de entradas y salidas

Una vez definido el modelo de regresión, se procede a entrenar las técnicas disponibles, incluyendo las diferentes configuraciones que se desee con cada una. De esta manera, una vez entrenados los algoritmos, se calcularía el error de validación de cada uno. De forma gráfica, en la figura 3.3 se presenta un diagrama de flujo mostrando la selección del mejor algoritmo basado en la medida del MSE.

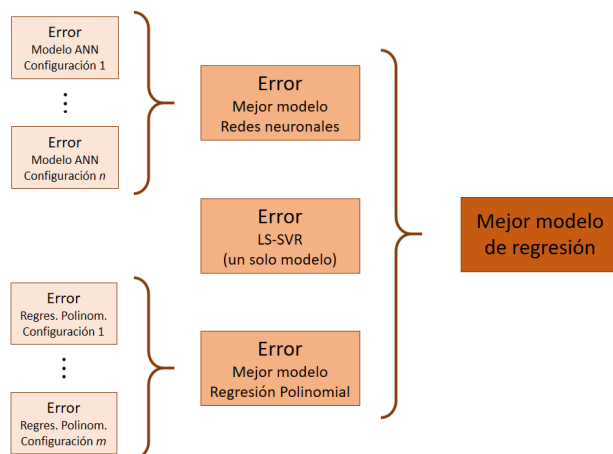


Figura 3.3: Selección del mejor algoritmo de regresión

Cabe destacar que el procedimiento mencionado aquí no es restrictivo ni en número de entradas ni de salidas, ni en el tipo de validación seleccionado. Sin embargo, hay que

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

3.2 Modelado híbrido con técnicas inteligentes

remarcar que en el caso de usar validación cruzada, el número de modelos entrenados aumenta. Por ejemplo, para el caso de un modelo donde se utilice validación *Hold out* se entrenaría un solo modelo; mientras que utilizando *Cross validation* con *K-Fold* igual a 10, se entrenarían 10 modelos. Además, la medida de error también se tendría que elegir para cada caso, ya que cada tipo de error enfatiza diferentes aspectos.

3.2. Modelado híbrido con técnicas inteligentes

Una vez explicado el método de selección del mejor algoritmo de regresión, se describe la creación de un modelo híbrido inteligente.

3.2.1. Agrupamiento de los datos - *Clustering*

Para crear un modelo híbrido, lo primero que habría que hacer sería dividir todo el conjunto de datos disponible en diferentes grupos. Para ello se utiliza el algoritmo K-Means explicado en el capítulo anterior. Esta técnica de aprendizaje no supervisado genera tantos grupos como se desee, basándose en la similitud de los datos entre sí.

En la figura 3.4 se esquematiza esta división, y se presenta lo que se llamará modelo global, que se trata de un sólo modelo calculado con todos los datos disponibles, y, los modelos locales creados con cada grupo de datos de manera independiente. Cabe destacar que la división de los datos se realiza teniendo en cuenta sólo los datos de entrada al modelo, ya que las salidas del mismo no son conocidas a priori, y no se podrían usar para asignar el *cluster* a una nueva muestra.

3.2.2. Modelos locales de regresión

Una vez se dispone de los datos de cada grupo, se realiza la selección del mejor algoritmo de regresión tal y como se explicó anteriormente. De esta forma, cada uno de los modelos internos representados en la figura 3.5 será el mejor para los datos disponibles en ese grupo.

Como la elección del número de grupos del modelo híbrido se realiza según el error

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA
UNIVERSIDAD DE LA LAGUNA

Fecha: 20/09/2019 13:27:50

JOSÉ LUIS CALVO ROLLE
UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:29:29

Juan Albino Méndez Pérez
UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:30:46

Capítulo 3. Propuesta de modelado

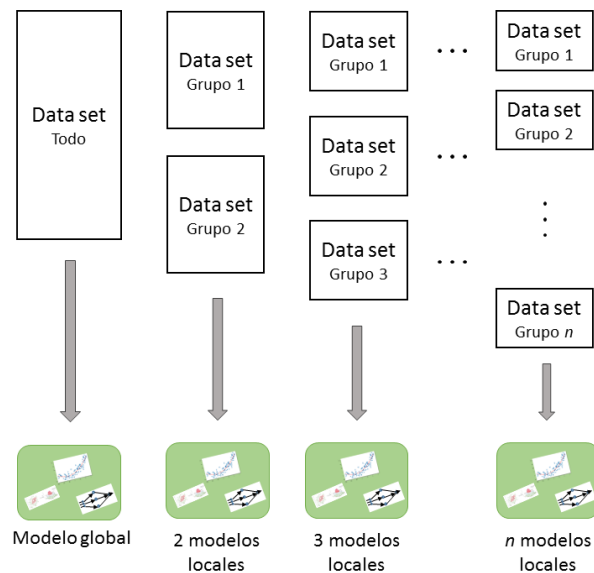


Figura 3.4: Esquema de la división de los datos en grupos

obtenido (siguiente apartado), la creación de los modelos locales implica un aumento considerable en el número de grupos, al no conocer la mejor agrupación de antemano. Por ejemplo, si se crea un modelo híbrido con hasta 5 *clusters*, habría que entrenar un total de 15 modelos, utilizando *Hold out* como técnica de validación: 1 modelo global, 2 modelos locales al dividir en 2 grupos, 3 modelos locales al dividir en 3 grupos, etc. En el caso de utilizar *Cross validation* con *K-Fold* igual a 5, el número de modelos aumentaría a 75: 5 modelos por cada uno de los mencionados anteriormente.

3.2.3. Selección de la mejor configuración híbrida

Para la selección del mejor modelo híbrido no se puede comparar el error de cada modelo de manera independiente. El error del modelo global se calcula directamente, ya que sólo hay un modelo pero, por ejemplo, si se dispone de dos modelos locales, el error del modelo híbrido no es el error de los modelos independientes.

Para obtener una medida adecuada de error para cada configuración del modelo

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015. Su autenticidad puede ser contrastada en la siguiente dirección https://sede.ull.es/validacion/	
Identificador del documento: 2141614	Código de verificación: B1ePGXal
Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

3.2 Modelado híbrido con técnicas inteligentes

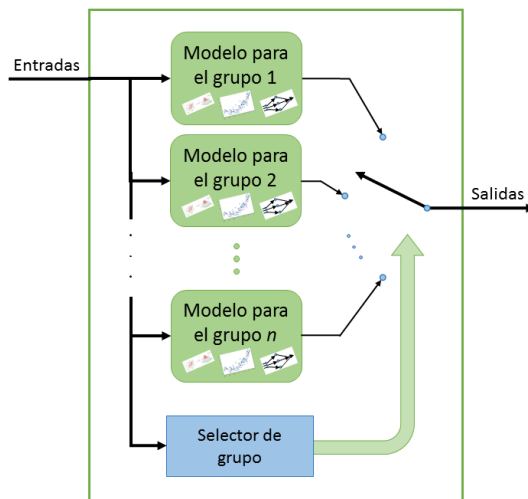


Figura 3.5: Diagrama interno genérico de un modelo híbrido

híbrido, se calcula el error como la media ponderada de cada modelo local. Los errores obtenidos por cada modelo local se multiplican por el número de muestras asignadas al grupo y se suman para cada configuración híbrida. De esta forma, un grupo que tenga más datos que otro, influye más en el error final que otro con menos. El menor valor del error total indica la mejor división para el modelo híbrido inteligente.

En la figura 3.6 se muestra un diagrama de flujo para la creación de un modelo híbrido. Como ya se ha mencionado, tanto las entradas como las salidas, así como el tipo de validación y la medida de error utilizada es específica para cada aplicación.




Figura 3.6: Diagrama de flujo para la creación de un modelo híbrido

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015. Su autenticidad puede ser contrastada en la siguiente dirección https://sede.ull.es/validacion/	
Identificador del documento: 2141614	Código de verificación: B1ePGXal
Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 3. Propuesta de modelado

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

CAPÍTULO 4

Hybrid intelligent system to perform fault detection on BIS sensor during surgeries

En este capítulo se presenta el primero de los artículos utilizado para la defensa de la tesis por compendio de artículos. A continuación se presentan los datos básicos del mismo, y después de incluirá todo el contenido del artículo copiado del artículo publicado. Se ha decidido no incluir el artículo original para mantener una uniformidad en la presentación de la tesis, pero se puede consultar a través del *doi* correspondiente.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA
UNIVERSIDAD DE LA LAGUNA

Fecha: 20/09/2019 13:27:50

JOSÉ LUIS CALVO ROLLE
UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:29:29

Juan Albino Méndez Pérez
UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:30:46

Capítulo 4. Hybrid intelligent system to perform fault detection on BIS sensor during surgeries

Datos generales del artículo:

Autores:

José-Luis Casteleiro-Roca¹, José Luis Calvo-Rolle¹, Juan Albino Méndez Pérez¹, Nieves Roqueñí Gutiérrez³, Francisco Javier de Cos Juez⁴

Afiliaciones:

¹ Departament of Industrial Engineering, University of A Coruña, A Coruña, Spain

² Departament of Computer Science and System Engineering, University of La Laguna, Tenerife, Spain

³ Project Engineering Area, Department of Exploitation and Exploration of Mines, University of Oviedo, Oviedo, Spain

⁴ Department of Mining Exploitation and Prospecting, University of Oviedo, Oviedo, Spain

Título: Hybrid intelligent system to perform fault detection on BIS sensor during surgeries

Revista: Sensors

Volumen: 17

Páginas: 1–17

Editorial: MDPI

Año de publicación: 2017

DOI: 10.3390/s17010179

Factor de impacto ISI JCR 2017: 2,475

Factor de impacto ISI JCR 2018: 3,031

Factor de impacto ISI JCR 2017 (5 años): 3,014

Factor de impacto ISI JCR 2018 (5 años): 3,302

Disciplina Chemistry, Analytical 2017: 31/81 - Q2

Disciplina Chemistry, Analytical 2018: 23/84 - Q2

Disciplina Electrochemistry 2017: 15/28 - Q3

Disciplina Electrochemistry 2018: 12/26 - Q2

Disciplina Instruments & Instrumentation 2017: 16/61 - Q2

Disciplina Instruments & Instrumentation 2018: 15/61 - Q1

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA
UNIVERSIDAD DE LA LAGUNA

Fecha: 20/09/2019 13:27:50

JOSÉ LUIS CALVO ROLLE
UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:29:29

Juan Albino Méndez Pérez
UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:30:46

Abstract

This paper presents a new fault detection system in hypnotic sensors used for general anesthesia during surgery. Drug infusion during surgery is based on information received from patient monitoring devices; accordingly, faults in sensor devices can put patient safety at risk. Our research offers a solution to cope with these undesirable scenarios. We focus on the anesthesia process using intravenous propofol as the hypnotic drug and employing a Bispectral Index (BISTM) monitor to estimate the patient's unconsciousness level. The method developed identifies BIS episodes affected by disturbances during surgery with null clinical value. Thus, the clinician—or the automatic controller—will not take those measures into account to calculate the drug dose. Our method compares the measured BIS signal with expected behavior predicted by the Propofol dose provider and the Electromyogram (EMG) signal. For the prediction of the BIS signal, a model based on a hybrid intelligent system architecture has been created. The model uses clustering combined with regression techniques. To validate its accuracy, a dataset taken during surgeries with general anesthesia was used. The proposed fault detection method for BIS sensor measures has also been verified using data from real cases. The obtained results prove the method's effectiveness.

keywords: EMG, BIS, Clustering, MLP, SVM, anesthesia, dosification

4.1. Introduction

Anesthesia control has aroused the attention of many scientists in recent years in order to move towards personalized drug infusion [9, 12], where the drug dose infused to the patient is calculated according to precise individualized measures in the operating room. The three main variables that the clinician has to pay attention to during surgery are hypnosis, analgesia and neuromuscular blockade. Hypnosis measures the patient's unconsciousness level, analgesia is related to pain mitigation, and neuromuscular blockade refers to immobility.

Although control of analgesia is still a challenge, significant advances have been made in the automatic control of hypnosis and neuromuscular blockade [20, 30]. For hypnosis control, different techniques using both signal-based and mode-based methodologies have been used successfully [22, 31, 17]. "Intelligent" techniques have also been

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 4. Hybrid intelligent system to perform fault detection on BIS sensor during surgeries

implemented [24].

Most commercial infusion systems implement open-loop strategies that predict the drug concentration in the patient according to precomputed models. In these devices there is no feedback of the real state of a patient for computing the dose delivered. A great advance in drug infusion appears when the whole system is operated in a closed-loop. Some new devices under this methodology are starting to be available but more advances in terms of reliability and patient-centered administration are needed.

The key point for infusion systems development for hypnosis control is the availability of reliable sensors to measure the patient's state. Different techniques have been proposed to measure hypnotic depth. One method to measure the hypnotic state, based on Shannon entropy, is called spectral entropy. With this method, it is possible to predict the value of electroencephalogram (EEG) amplitude, based on the distribution of the predicted variable previously detected over the signal [28, 40]. It is also possible to use the Patient State Index (PSI) to quantify EEG analysis. The PSI is achieved through comparative measures of changes in brain electrical activity when the patient come back to consciousness [32]. Auditory Evoked potentials have been also employed as a surrogate measure of the hypnotic effect [40]. More recently, a new index called QCON, obtained from the processing of the raw EEG, has been proposed to measure the patient's hypnotic level [15].

Nonetheless, the Bispectral Index (BIS) is the most commonly accepted EEG reading of the hypnotic state. Many studies during the last 15 years have been based on the use of BIS signal to measure the influence of anesthetic drugs. The BIS is obtained through EEG processing. If the BIS signal is considered as a process value under a controlled point of view during general anesthesia, it is necessary to provide the right dose of drug to ensure that the patient BIS value is between 40 and 60. It is common to select 50 as the target for the controller.

The reliability of the measured BIS signal is critical to the successful implementation of sedative and anesthesia strategies. The main issue is the quality of the signal, though signal disturbances are also a concern. Like many other devices, the BIS monitor provides a signal quality index that can be used to reject poor quality signals. Different sources of disturbances can affect the signal during surgery. Most are related to the surgical procedure itself: skin incision, blood loss, interaction with other drugs, etc. The BIS can vary due to these disturbances, and the clinician has to take this into account to modify the drug dose so that the BIS reaches again its target value.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

4.1 Introduction

Along with this, there are also disturbances that can affect raw EEG measures and consequently the performance of BIS monitoring during surgery. The main source of these disturbances is incorrect measures of muscular relaxation in the patient. Muscular relaxation is assessed by means of the electromyogram signal (EMG). Experience shows that inappropriate EMG episodes can affect the BIS signal. Thus, the clinician can observe a BIS value that does not correspond with the real state of the patient. Although after some time the BIS recovers its real value, it is important to detect these failures in the BIS measures so that the clinician does not make wrong decisions based on these mistaken values, thereby avoiding overdoses or awakening episodes during surgery.

This work presents an approach, based on artificial intelligence, for implementing a fault detection system in BIS monitoring, in order to increase reliable assessment of patient's hypnotic state.

Preliminary studies in this direction can be found in References [6] and [7], which, respectively, created a hybrid model for predicting the EMG trace using the propofol dose provided and the BIS, and predicted the BIS signal using the propofol dose and the EMG signal. In both works, a regression over a system with a very high non-linear component was necessary to model the process. Hence, clustering techniques followed by regression were applied over the resulting groups.

The approach described in the present work focuses on a robust BIS monitor system development capable of rejecting incorrect measures due to EMG disturbances, based on the hypothesis that the BIS signal is related to EMG and the drug dose supplied.

In Reference [18], sensor fault detection is defined as a sensor malfunction that causes a deflection form in the normal reading. It can occur due to several reasons: disturbances, damage to the reading device, bad sensor placement, and so on. Regardless of the solution to correct the malfunction, the first step is to detect the fault in the sensor reading because of the possible consequences on the patient. Physical redundancy could be a solution for sensor fault detection [27], but is difficult to implement because of concerns like viability, applicability, and cost. However, analytical redundancy could be applied. According to Reference [21], it is possible to divide sensor fault detection into three main groups: classification-based fault detection, signal-based fault detection in intelligent sensors, and model-based fault detection. For the first, one usually needs to know all the possible faults. If a new fault type appears, it may not be possible to detect because it is not part of the classification system. Signal-based fault detection usually employs correlation analysis between other sensors, which is not always possible.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 4. Hybrid intelligent system to perform fault detection on BIS sensor during surgeries

Because of the disadvantages of the first two methods, model-based fault detection is usually used to analytically study sensor fault detection.

There are fields where sensor fault detection was determined by employing model-based techniques. In Reference [48], current sensor fault detection and energy state estimation are performed at the same time. A new system identification technique and anomaly detection are described in Reference [23], based on the Bayesian belief network. A proposal for sensor anomaly detection in real time, based on the budding Strong Tracking Filter, is described in Reference [44]. The work in Reference [8] presents a sensor Fault Detection and Isolation implementation system for a condensation process, based on a nonlinear model.

The anesthetic state is a very delicate process, because the patient's life could be at risk if the professional responsibility for this task does not proceed suitably. As was explained previously, the present work focuses on the anesthesia process when the patient is monitored through BIS signal. It is mandatory to ensure correct sedation, and obviously doing so is linked to correct sensor operation. Whether the anesthesia process is manual or automatic, the detection of BIS sensors malfunctions is essential. The aim of the present research is to implement a fault detection system of BIS sensors during surgery; in order to accomplish this goal a hybrid intelligent system based on sensor fault detection was developed.

Many methods can be used to model sensor fault detection. Multiple regression analysis (MRA) techniques are the base of most accepted regression methods [5, 3, 36, 26]. Despite the limitations and poor performance of these techniques, they are widely used in many different applications [10]. Soft computing techniques are used with the aim of increasing performance. Simple or hybrid proposals are used in order to improve MRA techniques [19, 2, 25, 34].

Our BIS sensor fault detection system is based on the propofol drug infusion rate and the EMG signal. In developing the model, several regression techniques were applied to the data, which is divided into groups. The data groups were created using a K-means clustering algorithm. This algorithm divides the data into groups with similar behavior. Once the regression methods were applied to each group, the results were compared by the Mean squared error (MSE), and we chose the data set providing the lowest MSE.

This paper is divided as follows: after this introduction, the Bispectral Index is introduced. Then, the model approach and the tested algorithms taken into account

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

by our research are shown. The obtained results are described, identifying the best configuration achieved by the hybrid model. Finally, conclusions are drawn and future works are presented.

4.2. The Anesthesia Issue

The sensor fault detection system proposed in this work was designed to be used in the operating room when a patient is under surgery. Three main variables related to the anesthetic process are under medical control: hypnosis, analgesia and muscular relaxation. The drugs used to regulate each variable are propofol, remifentanil and rocuronium, respectively. All are administered intravenously. This paper focuses on hypnosis monitoring using the BIS signal. The objective is to use intelligent techniques to predict the patient BIS signal using information on the EMG and the propofol infusion rate. As is well known, remifentanil also influences the BIS signal. In this work, we will assume that the remifentanil infusion rate is kept constant and at a low dose throughout the process. That is why remifentanil is not explicitly considered as an input to the system. To achieve the proposed objective, a fault detection algorithm will be implemented to reject incorrect BIS measures.

4.2.1. Sensor technology for hypnosis assessment

As commented, one of the most extended monitoring systems to measure the level of unconsciousness in a patient is the BIS monitor. The BIS is obtained from the EEG signal and consists of a sensor, a digital signal converter, and a monitor. The sensor is placed in the forehead of the patient (see figure 4.1) to register the cerebral cortex electric activity. A combination of bispectral analysis, power spectral analysis, and time domain analysis is applied to the captured raw EEG signal. Then, an algorithm that obtains the optimum combination of these features using multivariate statistical modeling techniques is applied to obtain the BIS signal. As a result, an adimensional index whose values fluctuates between 100 (awake state) and 0 (maximal effect, brain without electrical activity) is obtained [37]. A BIS range from 60 to 80 is considered a state of sedation. When the BIS signal is between 40 and 60, it corresponds to general anesthesia region. The monitor includes a preprocessing subsystem to detect artifacts. Potential artifacts may be caused by poor skin contact (due to high impedance), muscle

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 4. Hybrid intelligent system to perform fault detection on BIS sensor during surgeries

activity or rigidity (due to inadequate muscular blockade), head and body motion, sustained eye movements, improper sensor placement and excessive electrical interference. Some of these artifacts can be detected by the monitor but some other can not be efficiently detected so that the resulting BIS signal should be interpreted with caution.

Currently, four different types of sensors are available for different clinical uses:

- BIS™ Quatro Sensor: four electrode sensor for general use.
- BIS™ Bilateral Sensor: for advanced monitoring applications. It can detect hemispheric differences in the brain.
- BIS™ Pediatric Sensor: for pediatric patients.
- BIS™ Extended Sensor: for use in ICU where long monitoring periods are common.



Figura 4.1: BIS Vista monitor

In this work, a BIS Vista monitor using a Quatro Sensor with four ZipPrep electrodes (both from Aspect Medical System, Newton, USA) was used to measure the BIS signal. The BIS monitor provides the BIS signal using a RS232 port connection to a laptop.

On the other hand, the laptop communicates with the Propofol infusion pump to monitor the infused drug dose. The pump used was a Graseby 3500 infusion pump (Graseby Medical Ltd, Watford, UK) administering propofol 1%, also connected via

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

4.3 Hybrid model proposal

RS232 port to the laptop. Monitoring software processed the information received from the devices and implemented the fault detection system. When a fault was detected a warning was activated and appropriate actions were taken.

4.2.2. Clinical study and protocol

This study considered a population of ASA I-II patients undergoing general anesthesia. The ASA score is the American Society of Anesthesiologists' physical status classification system, a scoring system that has some correlation with potential patient surgery risks according to their medical status or similar. ASA I corresponds to a normal healthy patient and ASA II to a patient with mild systemic disease. Patient population age was in the range 18–80 years. The criteria for exclusion were refusal by the patient, $ASA \geq III$, psychiatric or neurological disorder, or the presence of a pacemaker.

For the clinical setup, an intravenous cannula was placed with an antireflux valve in the preoperative room and a single midazolam dose of $0.02mg/kg$ was provided. The remifentanil infusion was started at $0.25mcg/kg/min$ at least 5 minutes before intubation. The patients received for induction a propofol bolus of $2mg/kg$ and rocuronium bromide ($0.6mg/kg$). Once the patients lost consciousness and their BIS value was around 50, they were intubated, and mechanical ventilation was maintained with oxygen + air (40%). Ten minutes after the initial dose, the infusion of remifentanil was decreased to $0.15mcg/kg/min$. This value was kept constant unless the patient's analgesic state required a variation. Approximately 15–20 minutes before the end of the surgery, rescue analgesia was administered with fentanyl ($1.5mcg/kg$) and dexketoprofen ($50mgiv$) or paracetamol ($1griiv$). To finish the surgery propofol was stopped. The input-output representation of the patient in the operating room is shown in Figure 4.2.

4.3. Hybrid model proposal

In this article the modeled approach is defined as shown in Figure 4.3. In this figure, two main blocks have been created: A hybrid intelligent models block and a fault detection block. The first one includes the models for the different signals to

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 4. Hybrid intelligent system to perform fault detection on BIS sensor during surgeries



Figura 4.2: The anesthesia issue. Input and Output definition

control. The models used in this research are hybrid intelligent models, and for each predicted signal a complete model was trained. Each model uses the necessary inputs to calculate the specific predicted signal.

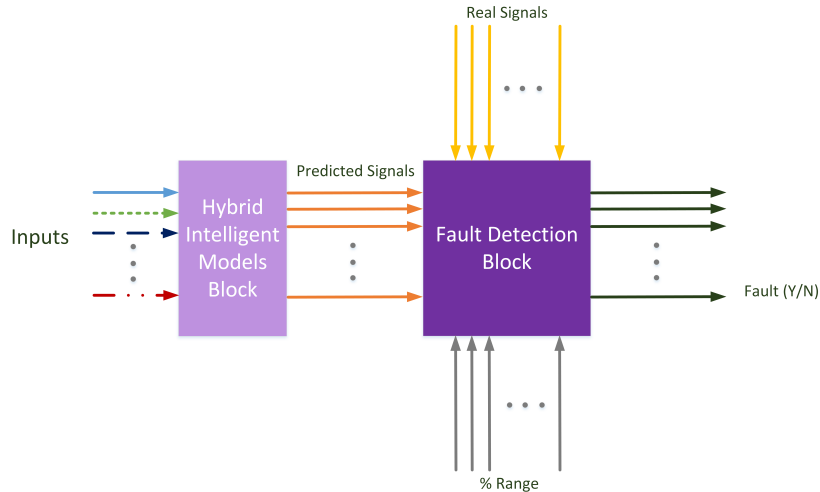


Figura 4.3: Hybrid model proposal

The second block, in Figure 4.3, is the one where fault detection algorithm is implemented. The signals predicted by the hybrid intelligent models are compared with the real measured signals. Generally speaking, each signal has a specific range for detecting, or failing to detect, a fault in the signal. This range is demarcated as the allowed signal variation before a fault situation is set. In other words, it is the predicted error allowed

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

4.3 Hybrid model proposal

by the system.

In Figure 4.4, the model used to predict the BIS signal is shown. The hybrid intelligent model consists of a set of local models valid for different situations of operation. As explained above, two input signals are feed into the models block: the EMG measured signal and the propofol infusion rate. The predicted BIS output is obtained as the output of the local model associated with the current situation. Once the predicted BIS signal is calculated, this signal is compared with the real BIS signal. Taking into account the specific range of possible error, an eventual fault situation can be detected.

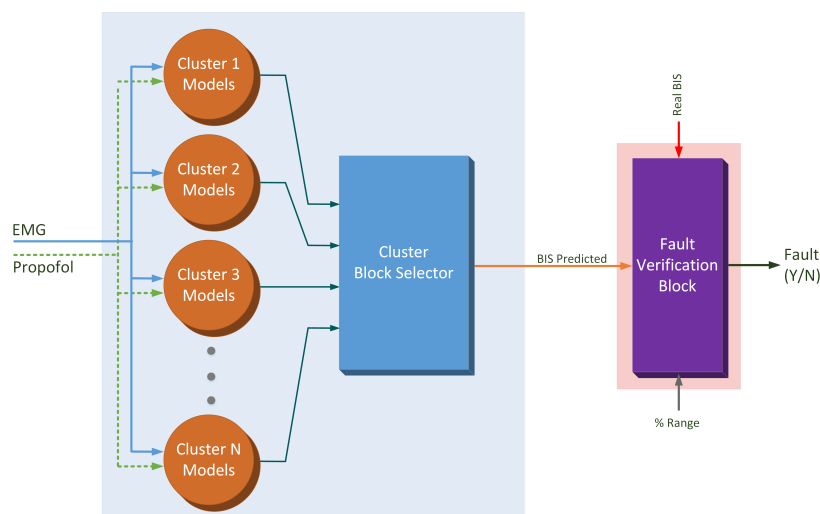


Figura 4.4: BIS case

Figure 4.5 shows the modeling process used to create each local intelligent model. To ensure better performance, the models were created using k-fold cross validation for each of the algorithms tested. Once all the folds were tested, the performances for all the algorithms were compared, and only the best configuration was selected.

Once the error value was computed for each cluster using the MSE as a performance measurement, each local model's combination error was calculated. This calculation took into account the number of samples in each cluster to ensure a valid performance comparison. The above modeling procedure is applied for each cluster and for the best local model combination. After the selection of the best model, all the data in the

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015. Su autenticidad puede ser contrastada en la siguiente dirección https://sede.ull.es/validacion/		
Identificador del documento: 2141614		Código de verificación: B1ePGXal
Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA		Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA		20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA		20/09/2019 13:30:46

Capítulo 4. Hybrid intelligent system to perform fault detection on BIS sensor during surgeries




Figura 4.5: Modeling process

cluster is used to train the best algorithm selected.

A fault situation means that an unexpected value is measured in the BIS sensor. Different reasons can lead to this situation. The most common could be a malfunction in this sensor. Another possibility is that the measured BIS value is correct but affected by other disturbances like an improper neuromuscular blockade. For instance, a sudden rise in the BIS signal can occur due to an increase in the EMG if a neuromuscular blockade is not correctly implemented. This increase is not related to the real hypnotic state of the patient, so the clinician should reject the measured BIS values when defining the propofol dose. A third possibility is that the fault could be caused by an unusual patient reaction during the surgery, indicating a possible 'patient fault' and not a 'sensor fault'. Thus, the system could be used not only to perform fault detection on the sensors used in surgeries but to detect an abnormal patient reaction. In this situation, the clinicians are warned to check the patient's state to ensure that the patient is not suffering any complication during the surgery.

It is important to note that the models were created with a dataset of healthy patients (ASA I/II following the ASA physical status classification system). If, for a specific patient, the system continuously detects faults in the evolution of the BIS signal, this information may be used to detect the presence of an undiagnosed pathology. One limitation of the proposed approach is related to interpatient variability. Thus, even if the models offer very good prediction performance, a specific patient could react in different ways to the same stimulus. In such cases, the system will indicate a potential

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

4.3 Hybrid model proposal

fault. The clinician must analyze the situation to take the correct decision.

4.3.1. The Dataset

In order to obtain the data used in this research, three variables (BIS, EMG and the propofol infusion rate) were monitored in several patients during surgery. Propofol was used as the surgical anesthesia. The variables for BIS and EMG had been preconditioned. In total, 50 patients were monitored to obtain the data. Due to the slow variations of the signals at the acquisition phase, measurement noise is superposed to the signals, thus a low pass filter was implemented for rejecting data. This study is focused on the results during the maintenance phase, since the induction and recovery phases were not considered. Consequently, the prediction of the EMG is valid only for the maintenance phase. The total dataset was built from 42,788 samples gathered according to the conditions detailed above.

4.3.2. Modelling Techniques

4.3.2.1. Data Clustering: the K-Means Algorithm

Clustering is a technique used for grouping data. These groups contain data samples with similarities between them [33, 16]. Clustering algorithms are unsupervised algorithms that organize unlabeled feature vectors into clusters or groups [16]. One of these clustering algorithms is K-means. It uses the square error to minimize the error function, as shown in Equation (4.1). This algorithm is a partitional clustering algorithm.

$$e = \sum_{k=1}^C \sum_{x \in Q_k} \|x - c_k\|^2 \quad (4.1)$$

where x is every samples, c_k is the closest cluster centroid for each case, Q_k is the number of samples in each cluster, and C is the number of clusters.

The number of clusters, K , and the initial cluster centroids determine the final

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 4. Hybrid intelligent system to perform fault detection on BIS sensor during surgeries

clustering. Determining the number of clusters requires prior knowledge of the data. This task is the most critical, because the data is highly doubtful. With the aim of obtaining an effective clustering, two conditions must be fulfilled: the data has to be close enough to its cluster and the cluster must be hyperspherical in shape and well-separated in the hyperspace.

4.3.2.2. Multi Layer Perceptron (MLP)

Based on a feedforward Artificial Neural Network (ANN), a Multi Layer Perceptron (MLP) [46, 49, 29] was defined. Thanks to its sturdiness and comparatively simple configuration, this kind of ANN is typical. Nevertheless, the architecture of the ANN must be well chosen to achieve satisfactory results. The composition of this type of ANN has an input layer, an output layer and one or more hidden layers. The layers are composed of neurons that have activation functions. This activation function can be tan-sigmoid, log-sigmoid, linear, or step. Usually all the activation functions of a layer are the same. The tan-sigmoid function is shown in Equation (4.2).

$$F(t) = \frac{e^t - e^{-t}}{e^t + e^{-t}} \quad (4.2)$$

The neurons between layers are linked through weighted connections.

It is possible to define the output of a MLP as shown in Equation (4.3) [35].

$$f_{\theta}(x) = \beta + \sum_{i=1}^k a_i \phi(w_i^T x + b_i) \quad (4.3)$$

where $x = (x(1), \dots, x(d))^T \in \mathbb{R}^d$ is the inputs vector, k is the hidden layers number, ϕ is a bounded transfer function, $\theta = (\beta, a_1, \dots, a_k, b_1, \dots, b_k, w_{11}, \dots, w_{kd})$ is the model parameter vector, β is the "offset" for all the net, a_i are the parameters that relation each layer with the next one, b_i is the "offset" for each layer, and $w_i = (w_{i1}, \dots, w_{id})^T \in \mathbb{R}^d$ is the parameter vector for the hidden unit i .

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

4.3.2.3. Support Vector Regression (SVR), Least Square Support Vector Regression (LS-SVR)

The Support Vector Regression is based on a classification algorithm, the Support Vector Machines (SVM), which was modified for regression purposes. The SVM uses non-linear mapping of the data into a high-dimensional feature space, F , then applies linear regression in this space [11, 38, 41, 42].

A further modification of this method is the least square formulation of SVM (LS-SVM). In this case, a system of linear equations is solved with the aim of obtaining an approximation of the solution. This modification provides generalization performance comparable to that of the SVM [39, 45]. LS-SVR is the given name of the application of LS-SVM to regression [13, 43]. A classical squared loss function is used instead of the insensitive loss function when the LS-SVR is applied. With this change, a linear KarushKuhn-Tucker is solved in order to build the Lagrangian:

$$\begin{bmatrix} 0 & I_n^T \\ I_n & K + \gamma_{-1}I \end{bmatrix} \begin{bmatrix} b_0 \\ b \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix} \quad (4.4)$$

where I_n is a vector of n ones, T means transpose of a matrix or vector, γ is a weight vector, b is the regression vector, b_0 is the model offset, and y is the desired output. The weight vector (γ) as well as the width of the kernel (σ) are the only variables needed in LS-SVR [43].

4.3.2.4. Polynomial regression

The polynomial regression model could be defined as the summation of basis functions [1, 4, 14, 47, 50]. The quantity of inputs determines the number of basis functions needed and the polynomial degree.

Equation (4.5) shows a degree one case defining the linear summation for two inputs, x_1 and x_2 . If the degree of the model increases it becomes more complex; for instance, Equation (4.6) is the equation for degree two, where it is possible to verify the increased complexity.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 4. Hybrid intelligent system to perform fault detection on BIS sensor during surgeries

$$F(x) = a_0 + a_1x_1 + a_2x_2 \quad (4.5)$$

$$F(x) = a_0 + a_1x_1 + a_2x_2 + a_3x_1x_2 + a_4x_1^2 + a_5x_2^2 \quad (4.6)$$

4.4. Results

The dataset used to create the models was processed to include, in each sample, the two previous values of all the signals: the EMG, the propofol dosage rate, and the BIS. This process takes into account the dynamic of the anesthetic process to create a more accurate model. Then, each sample for the model must include eight inputs and one output: the current and two previous values of the EMG, the current and previous values of the propofol dosage rate, and the two previous values of the BIS signal.

The output of the model is the current value of the BIS signal. Different simulation experiments were conducted to confirm that these values are sufficient to train the dynamic of the system. Our results demonstrated that the inclusion of greater regression vectors for the inputs is not necessary to improve the model accuracy.

4.4.1. Clustering and modeling results

The first step is to perform the clustering. During this process, the initial state must be taken into account, as the performance of the K-means algorithm is highly influenced by this condition. Random initialization was used to perform the process, which was carried out 20 times. The clusters that minimized the error function were stored. Different configurations were tested, from 2 to 10 clusters. These configurations were tested because the number of clusters is unknown at the beginning, so that the model was trained for all cases. In total, 10 different topologies were created, including nine different topologies from the clusters as well as the global model.

Remarkably, for some clustering configurations it was impossible to find a suitable dataset division. This limitation was caused by the constraint based on the minimum number of samples that each cluster should have: the procedure to create the clusters

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

4.4 Results

detects when a cluster is smaller than 15 samples. When the k-fold cross validation is used, no cluster with less than 15 samples are considered valid. Table 4.1 shows the number of samples in each cluster. In each cluster, the models were trained using five k-fold cross-validations to calculate the MSE to perform the statistical analysis.

N° of Clusters	Cluster 1	Cluster 2	Cluster 3	Cluster 4	Cluster 5
Global Model	100 %	-	-	-	-
2	0.8 %	99.2 %	-	-	-
3	0.4 %	0.7 %	98.9 %	-	-
4	0.4 %	0.7 %	38.3 %	60.6 %	-
5	0.4 %	0.7 %	1.7 %	40.6 %	56.7 %
6	0.2 %	0.4 %	0.7 %	1.7 %	41.0 %
7	0.2 %	0.3 %	0.3 %	0.7 %	1.7 %
8	0.1 %	0.2 %	0.2 %	0.3 %	0.7 %
9	0.1 %	0.2 %	0.2 %	0.3 %	0.7 %
10	0.1 %	0.2 %	0.2 %	0.3 %	0.7 %

N° of Clusters	Cluster 6	Cluster 7	Cluster 8	Cluster 9	Cluster 10
Global Model	-	-	-	-	-
2	-	-	-	-	-
3	-	-	-	-	-
4	-	-	-	-	-
5	-	-	-	-	-
6	56.0 %	-	-	-	-
7	41.1 %	55.7 %	-	-	-
8	1.7 %	41.1 %	55.7 %	-	-
9	1.7 %	27.2 %	31.3 %	38.4 %	-
10	1.7 %	13.1 %	19.2 %	24.8 %	39.7 %

Tabla 4.1: Number of samples in each cluster in percentage

The MLP-ANN regression algorithm consists of one hidden layer, at which the number of neurons used for the regression changes from 1 to 10, providing several configurations of the algorithm. Furthermore, these neurons are activated as a tan-sigmoid function even though the output layer is activated by a linear function. To perform the training, the Levenberg-Marquardt algorithm was used. Moreover, the learning algorithm was the gradient descent and, with the aim of measuring the performance, the

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA
 UNIVERSIDAD DE LA LAGUNA

Fecha: 20/09/2019 13:27:50

JOSÉ LUIS CALVO ROLLE
 UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:29:29

Juan Albino Méndez Pérez
 UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:30:46

Capítulo 4. Hybrid intelligent system to perform fault detection on BIS sensor during surgeries

mean squared error method was fixed.

A self auto-tuning developed by KULeuven-ESAT-SCD, which is implemented in the MatLab toolbox, was used to train the LS-SVR. The settings used for performing this training were the radial basis function (RBF) for the kernel of the model and 'function estimation' to perform regression. Finally, the optimization function was set to 'simplex' while 'leaveoneoutlssvm' with 'mse' was used as cost criterion.

The next method used in creating the model was polynomial regression. The polynomial was trained for first to second order regressions.

Table 4.2 shows the results obtained for each regression technique applied to each cluster and testing every configuration. The performance is measured by the MSE. The average value of the MSE obtained is shown in the column of the right. This means MSE is calculated taking into account the number of samples in each cluster to ensure a real measure of the MSE for each configuration. As mentioned, the model is not trained in all the clusters because the combinations shown include a cluster with fewer samples than the minimum set (represented as NA in the table).

After testing all regression techniques for all clusters, Table 4.3 summarizes the best model and its configuration. Tables 4.2 and 4.3 show that the division of the data into two clusters provides the best performance for the model. Table 4.4 presents a summary of the modelling results.

Once the best model is selected, the final hybrid intelligent model was created, using all the data to train the model with the corresponding algorithm.

4.4.2. Fault Detection System Results

To ensure accuracy of the fault detection system, the data from one complete surgery was isolated from the modeling procedure. This data was used as input to calculate a predicted BIS signal for all the surgery. In Figure 4.6 the real signal (top plot), and the predicted signal (bottom plot) are shown.

In Figure 4.6, data from all the surgeries is shown, but, to increase the accuracy of the model, the initial and final parts of the data were eliminated for the dataset. Figure

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

4.4 Results

N° of Clusters	Cluster 1	Cluster 2	Cluster 3	Cluster 4	Cluster 5	Clusters MSE
Global Model	0.8531	-	-	-	-	0.8531
2	$8.15 * 10^{-4}$	0.4129	-	-	-	0.4097
3	N/A	N/A	N/A	-	-	N/A
4	N/A	N/A	N/A	N/A	-	N/A
5	N/A	N/A	N/A	N/A	N/A	N/A
6	N/A	N/A	N/A	N/A	N/A	N/A
7	N/A	N/A	N/A	N/A	N/A	N/A
8	N/A	N/A	N/A	N/A	N/A	N/A
9	N/A	N/A	N/A	N/A	N/A	N/A
10	N/A	N/A	N/A	N/A	N/A	N/A

N° of Clusters	Cluster 6	Cluster 7	Cluster 8	Cluster 9	Cluster 10	Clusters MSE
Global Model	-	-	-	-	-	0.8531
2	-	-	-	-	-	0.4097
3	-	-	-	-	-	N/A
4	-	-	-	-	-	N/A
5	-	-	-	-	-	N/A
6	N/A	-	-	-	-	N/A
7	N/A	N/A	-	-	-	N/A
8	N/A	N/A	N/A	-	-	N/A
9	N/A	N/A	N/A	N/A	-	N/A
10	N/A	N/A	N/A	N/A	N/A	N/A

Tabla 4.2: Clusters MSE

4.7 shows the difference between real and predicted data in the middle of the surgery; the third plot represents the error between the other two signals.

The limits used in Figure 4.7 are selected as the percentage range for the model shown in Figure 4.4, but this value could change during surgery. For the BIS signal, the range is shown in absolute values, since that signal has no units and varies between 0 and 100. In this case, the range of failure detection is absolute (a percentage of the total valid limits for this signal).

In Figures 4.8 and 4.9 the previously shown data is used to test the fault detection

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 4. Hybrid intelligent system to perform fault detection on BIS sensor during surgeries

N° of Clusters	Cluster 1	Cluster 2	Cluster 3	Cluster 4	Cluster 5
Global Model	ANN-06	-	-	-	-
2	ANN-02	ANN-09	-	-	-
3	N/A	N/A	N/A	-	-
4	N/A	N/A	N/A	NA	-
5	N/A	N/A	N/A	NA	N/A
6	N/A	N/A	N/A	NA	N/A
7	N/A	N/A	N/A	NA	N/A
8	N/A	N/A	N/A	NA	N/A
9	N/A	N/A	N/A	NA	N/A
10	N/A	N/A	N/A	NA	N/A

N° of Clusters	Cluster 6	Cluster 7	Cluster 8	Cluster 9	Cluster 10
Global Model	-	-	-	-	-
2	-	-	-	-	-
3	-	-	-	-	-
4	-	-	-	-	-
5	-	-	-	-	-
6	N/A	-	-	-	-
7	N/A	N/A	-	-	-
8	N/A	N/A	N/A	-	-
9	N/A	N/A	N/A	NA	-
10	N/A	N/A	N/A	NA	N/A

Tabla 4.3: Best regression technique for each cluster

	Big-Cluster	Small-Cluster
ANN	9 neurons	2 neurons
Polynomial	1st order	1st order
ANN (MSE)	0.4129	$8.15 * 10^{-4}$
LSSVR (MSE)	0.8855	0.1680
Poly (MSE)	$1.45 * 10^{11}$	$3.34 * 10^3$

Tabla 4.4: Results of the chosen configuration

model. The top plots represent the real BIS signals, the middle plots show the BIS signals predicted by the hybrid intelligent model, and the bottom plots are the fault

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

4.4 Results




Figura 4.6: Real (top) and predicted (bottom) BIS signal for one complete surgery




Figura 4.7: Real (top), predicted (middle), and error (bottom) BIS signal for 100 samples during surgery

detection system. For Figure 4.8, the range used was only 10, and some failures appeared during surgery. However, when this range increases to 15 (Figure 4.9), the failures

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA
 UNIVERSIDAD DE LA LAGUNA

Fecha: 20/09/2019 13:27:50

JOSÉ LUIS CALVO ROLLE
 UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:29:29

Juan Albino Méndez Pérez
 UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:30:46

Capítulo 4. Hybrid intelligent system to perform fault detection on BIS sensor during surgeries

appear only at the first stage of the surgery. This is a known limitation, as the data to train the model do not include this part of surgery.




Figura 4.8: Complete surgery with fault detection Range of 10




Figura 4.9: Complete surgery with fault detection Range of 15

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

4.5. Conclusions

This study provides a methodology for detecting failure episodes in BIS sensors affected by disturbances. The proposal is based on a hybrid intelligent model to predict the BIS based on the EMG signal and propofol dosage provided to the patient. Once the BIS signal is predicted, it is compared with the real BIS signal measured by the sensor. The results of this comparison indicate whether a fault state may be activated.

The modelling part of the approach is based on a hybrid intelligent system, combining different regression techniques on local models.

This model was obtained from a real dataset. After testing, the analysis of the results shows that the best model configuration has two clusters. The regression techniques employed on the clusters were ANN with different configurations (two and nine neurons in the hidden layer). The best mean MSE obtained with this configuration was 0.4097. The k-fold cross validation procedure ensures a more realistic MSE, because all the data was used for training and for testing at the end of the modelling phase.

The fault detection system can select the range for detecting failures depending on the situation. Moreover, the system could change to detect a failure not only when one measurement is out of the expected range, but when there are two or three consecutive measurements out of range. The validation of the algorithm with real data offered satisfactory results for detecting faults in the BIS signal during surgery. The importance of the proposed methodology is that the clinician (or even an automatic infusion system) can have information of anomalous values of the BIS signal during surgery. This will improve the safety of patients in the operating room as the drug infusion depends on the information extracted from the monitoring system.

The proposed method opens new future research lines. On one hand, other scenarios can be considered: for instance, a varying remifentanil infusion. This will require the implementation of a new model using the remifentanil infusion as an input. Also, extension to inhalatory anesthesia can be explored. From a more general perspective, the proposed method can be extended to other sensor devices for health monitoring so that quality of patient monitoring will increased.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 4. Hybrid intelligent system to perform fault detection on BIS sensor during surgeries

Bibliografía

- [1] C. M. Bishop. *Pattern Recognition and Machine Learning (Information Science and Statistics)*. Springer-Verlag New York, Inc., Secaucus, NJ, USA, 2006. ISBN 0387310738.
- [2] J. L. Calvo-Rolle, J. L. Casteleiro-Roca, H. Quintián, and M. del Carmen Meizoso-Lopez. A hybrid intelligent system for PID controller using in a steel rolling process. *Expert Systems with Applications*, 40(13):5188–5196, 2013. ISSN 0957-4174. doi: 10.1016/j.eswa.2013.03.013.
- [3] J. L. Calvo-Rolle, O. Fontenla-Romero, B. Pérez-Sánchez, and B. Guijarro-Berdinas. Adaptive inverse control using an online learning algorithm for neural networks. *Informatica*, 25(3):401–414, 2014. ISSN 0868-4952. doi: 10.15388/Informatica.2014.20.
- [4] J. Casteleiro-Roca, J. Calvo-Rolle, M. Meizoso-López, A. Piñón-Pazos, and B. Rodríguez-Gómez. New approach for the QCM sensors characterization. *Sensors and Actuators A: Physical*, 207:1–9, 2014. ISSN 0924-4247. doi: 10.1016/j.sna.2013.12.002.
- [5] J. Casteleiro-Roca, J. Calvo-Rolle, M. Meizoso-López, A. P. nón Pazos, and B. Rodríguez-Gómez. Bio-inspired model of ground temperature behavior on the horizontal geothermal exchanger of an installation based on a heat pump. *Neurocomputing*, 150, Part A:90–98, 2015. ISSN 0925-2312. doi: 10.1016/j.neucom.2014.02.075.
- [6] J. L. Casteleiro-Roca, J. A. M. Pérez, A. J. Piñón-Pazos, J. L. Calvo-Rolle, and E. Corchado. Modeling the electromyogram (EMG) of patients undergoing anesthesia during surgery. In *10th International Conference on Soft Computing Models in Industrial and Environmental Applications*, pages 273–283, 2015. ISBN 978-3-319-19719-7. doi: 10.1007/978-3-319-19719-7{-}24.
- [7] J. L. Casteleiro-Roca, J. A. M. Pérez, J. A. Reboso-Morales, F. J. de Cos Juez, F. J. Pérez-Castelo, and J. L. Calvo-Rolle. An intelligent model for bispectral index (bis) in patients undergoing general anesthesia. In *International Joint Conference SOCO'16-CISIS'16-ICEUTE'16: San Sebastián, Spain, October 19th-21st, 2016 Proceedings*, pages 290–300, 2017. ISBN 978-3-319-47364-2. doi: 10.1007/978-3-319-47364-2{-}28.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

4.5 Conclusions

- [8] M. L. Castro, R. Escobar, L. Torres, J. G. Aguilar, J. Hernández, and V. Olivares-Peregrino. Sensor fault detection and isolation system for a condensation process. *ISA Transactions*, 2016. ISSN 0019-0578. doi: 10.1016/j.isatra.2016.08.004.
- [9] D. Copot, R. D. Keyser, and C. Ionescu. Drug interaction between propofol and remifentanyl in individualised drug delivery systems. *IFAC-PapersOnLine*, 48(20): 64–69, 2015. ISSN 2405-8963. doi: 10.1016/j.ifacol.2015.10.116.
- [10] M. J. Crespo-Ramos, I. Machón-González, H. López-García, and J. L. Calvo-Rolle. Detection of locally relevant variables using SOM-NG algorithm. *Engineering Applications of Artificial Intelligence*, 26(8):1992–2000, 2013. ISSN 0952-1976. doi: 10.1016/j.engappai.2013.04.012.
- [11] N. Cristianini and J. Shawe-Taylor. *An introduction to support Vector Machines and other kernel-based learning methods*. Cambridge University Press, New York, NY, USA, 2000. ISBN 0-521-78019-5.
- [12] M. Fang, Y. Tao, and Y. Wang. A subspace-based wiener system identification method for the individualized anesthesia care. *IFAC Proceedings Volumes*, 47(3): 11605–11610, 2014. ISSN 1474-6670. doi: 10.3182/20140824-6-ZA-1003.01739.
- [13] Y. Guo, X. Li, G. Bai, and J. Ma. Time series prediction method based on LS-SVR with modified gaussian RBF. In *Neural Information Processing*, pages 9–17, 2012. ISBN 978-3-642-34480-0. doi: 10.1007/978-3-642-34481-7{-}2.
- [14] R. Heiberger and E. Neuwirth. Polynomial regression. In *R Through Excel, Use R*, pages 269–284. Springer New York, 2009. ISBN 978-1-4419-0051-7. doi: 10.1007/978-1-4419-0052-4.11.
- [15] E. W. Jensen, J. F. Valencia, A. Lopez, T. Anglada, M. Agusti, Y. Ramos, R. Serra, M. Jospin, P. Pineda, and P. Gambus. Monitoring hypnotic effect and nociception with two EEG-derived indices, qCON and qNOX, during general anaesthesia. *Acta Anaesthesiologica Scandinavica*, 58(8):933–941, 2014. ISSN 1399-6576; 0001-5172. doi: 10.1111/aas.12359.
- [16] S. Kaski, J. Sinkkonen, and A. Klami. Discriminative clustering. *Neurocomputing*, 69(1-3):18–41, 2005. ISSN 0925-2312. doi: 10.1016/j.neucom.2005.02.012.
- [17] A. Khaqan and R. Riaz. Depth of hypnosis regulation using nonlinear control approach. In *2016 IEEE International Conference on Electro Information Technology (EIT)*, pages 100–104, 2016. doi: 10.1109/EIT.2016.7535222.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 4. Hybrid intelligent system to perform fault detection on BIS sensor during surgeries

- [18] A. Kusiak and Z. Song. Sensor fault detection in power plants. *Journal of Energy Engineering*, 135(4):127–137, 2009. doi: 10.1061/(ASCE)0733-9402(2009)135:4(127).
- [19] F. S. Lasheras, F. J. de Cos Juez, A. S. Sánchez, A. Krzemień, and P. R. Fernández. Forecasting the COMEX copper spot price by means of neural networks and ARIMA models. *Resources Policy*, 45:37–43, 2015. ISSN 0301-4207. doi: 10.1016/j.resourpol.2015.03.004.
- [20] J. Lemos, H. Magalhaes, T. Mendonca, and R. Dionisio. Control of neuromuscular blockade in the presence of sensor faults. *IEEE Transactions on Biomedical Engineering*, 52(11):1902–1911, 2005. doi: 10.1109/TBME.2005.856259.
- [21] E. Lughofer, E. P. Klement, J. Lujan, and C. Guardiola. Model-based fault detection in multi-sensor measurement systems. In *Intelligent Systems, 2004. Proceedings. 2004 2nd International IEEE Conference*, pages 184–189, 2004.
- [22] I. Martin-Mateos, J. A. Mendez Perez, J. A. Reboso, and A. Leon. Modelling propofol pharmacodynamics using BIS-guided anaesthesia. *Anaesthesia*, 68(11):1132–1140, 2013. ISSN 1365-2044; 0003-2409. doi: 10.1111/anae.12384.
- [23] N. Mehranbod, M. Soroush, and C. Panjapornpon. A method of sensor fault detection and identification. *Journal of Process Control*, 15(3):321–339, 2005. ISSN 0959-1524. doi: 10.1016/j.jprocont.2004.06.009.
- [24] J. A. Méndez, A. Marrero, J. A. Reboso, and A. León. Adaptive fuzzy predictive controller for anesthesia delivery. *Control Engineering Practice*, 46:1–9, 2016. ISSN 0967-0661. doi: 10.1016/j.conengprac.2015.09.009.
- [25] L. A. Menéndez, F. de Cos Juez, F. S. Lasheras, and J. A. Riesgo. Artificial neural networks applied to cancer detection in a breast screening programme. *Mathematical and Computer Modelling*, 52(7-8):983–991, 2010. ISSN 0895-7177. doi: 10.1016/j.mcm.2010.03.019.
- [26] P. G. Nieto, J. A. Fernández, F. S. Lasheras, F. de Cos Juez, and C. D. M. niz. A new improved study of cyanotoxins presence from experimental cyanobacteria concentrations in the trasona reservoir (northern spain) using the MARS technique. *Science of The Total Environment*, 430:88–92, 2012. ISSN 0048-9697. doi: 10.1016/j.scitotenv.2012.04.068.
- [27] A. Oliva. Sensor fault detection and analytical redundancy satellite launcher flight control system. *SBA Controle & Automação*, 9(3):156–164, 1998.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

4.5 Conclusions

- [28] G. A. Orliaguet, F. B. Lambert, T. Chazot, P. Glasman, M. Fischler, and N. Liu. Feasibility of closed-loop titration of propofol and remifentanil guided by the bispectral monitor in pediatric and adolescent patients: A prospective randomized study. *Anesthesiology*, 2014. ISSN 1528-1175; 0003-3022. doi: 10.1097/ALN.0000000000000577.
- [29] J. Osborn, D. Guzman, F. J. de Cos Juez, A. G. Basden, T. J. Morris, E. Gendron, T. Butterley, R. M. Myers, A. Guesalaga, F. Sanchez Lasheras, M. Gomez Victoria, M. L. Sánchez Rodríguez, D. Gratadour, and G. Rousset. Open-loop tomography with artificial neural networks on CANARY: on-sky results. *Monthly Notices of the Royal Astronomical Society*, 441(3):2508–2514, 2014. doi: 10.1093/mnras/stu758.
- [30] F. Ozturk Arikan, G. Turan, A. Ozgultekin, Z. Sivrikaya, B. Cosar, and D. Onder. Rocuronium: automatic infusion versus manual administration with TOF monitoring. *Journal of Clinical Monitoring and Computing*, 30(5):545–550, 2016. doi: 10.1007/s10877-015-9751-2.
- [31] J. Pérez, S. Torres, J. Reboso, and H. Reboso. Control strategies in anesthesia practice. *RIAI - Revista Iberoamericana de Automatica e Informatica Industrial*, 8(3):241–249, 2011. doi: 10.1016/j.riai.2011.06.011.
- [32] L. S. Prichep, L. D. Gugino, E. R. John, R. J. Chabot, B. Howard, H. Merkin, M. L. Tom, S. Wolter, L. Rausch, and W. J. Kox. The patient state index as an indicator of the level of hypnosis under general anaesthesia. *British Journal of Anaesthesia*, 92(3):393–399, 2004. ISSN 0007-0912; 0007-0912. doi: 10.1093/bja/ae082.
- [33] A. Qin and P. Suganthan. Enhanced neural gas network for prototype-based clustering. *Pattern Recogn.*, 38(8):1275–1288, 8 2005. ISSN 0031-3203. doi: 10.1016/j.patcog.2004.12.007.
- [34] H. Quintián, J. L. Calvo-Rolle, and E. Corchado. A hybrid regression system based on local models for solar energy prediction. *Informatica*, 25(2):265–282, 2014. ISSN 0868-4952. doi: 10.15388/Informatica.2014.14.
- [35] J. Rynkiewicz. General bound of overfitting for MLP regression models. *Neurocomputing*, 90:106–110, 2012. ISSN 0925-2312. doi: 10.1016/j.neucom.2011.11.028.
- [36] A. S. Sánchez, P. R. Fernández, F. S. Lasheras, F. de Cos Juez, and P. G. Nieto. Prediction of work-related accidents according to working conditions using support vector machines. *Applied Mathematics and Computation*, 218(7):3539–3552, 2011. ISSN 0096-3003. doi: 10.1016/j.amc.2011.08.100.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 4. Hybrid intelligent system to perform fault detection on BIS sensor during surgeries

- [37] J. C. Sigl and N. G. Chamoun. An introduction to bispectral analysis for the electroencephalogram. *Journal of Clinical Monitoring*, 10(6):392–404, 1994. ISSN 1573-2614. doi: 10.1007/BF01618421.
- [38] I. Steinwart and A. Christmann. *Support vector machines*. Springer Publishing Company, Incorporated, 1st edition, 2008. ISBN 0387772413.
- [39] J. Suykens and J. Vandewalle. Least squares support vector machine classifiers. *Neural Processing Letters*, 9(3):293–300, 1999. ISSN 1370-4621. doi: 10.1023/A:1018628609742.
- [40] A. L. Vanluchene, H. Vereecke, O. Thas, E. P. Mortier, S. L. Shafer, and M. M. Struys. Spectral entropy as an electroencephalographic measure of anesthetic drug effect: A comparison with bispectral index and processed midlatency auditory evoked response. *Anesthesiology*, 101(1):34–42, 2004.
- [41] V. Vapnik. *The nature of statistical learning theory*. Springer, 1995.
- [42] J. A. Vilán Vilán, J. R. Alonso Fernández, P. J. García Nieto, F. Sánchez Lasheras, F. J. de Cos Juez, and C. Díaz Muñiz. Support vector machines and multilayer perceptron networks used to evaluate the cyanotoxins presence from experimental cyanobacteria concentrations in the trasona reservoir (northern spain). *Water Resources Management*, 27(9):3457–3476, 2013. ISSN 1573-1650. doi: 10.1007/s11269-013-0358-4.
- [43] L. Wang and J. Wu. Neural network ensemble model using PPR and LS-SVR for stock et forecasting. In *Advanced Intelligent Computing*, pages 1–8, 2012. ISBN 978-3-642-24727-9. doi: 10.1007/978-3-642-24728-6_1.
- [44] L. Wang, L. Wu, Y. Guan, and G. Wang. Online sensor fault detection based on an improved strong tracking filter. *Sensors*, 15(2), 2015. ISSN 1424-8220. doi: 10.3390/s150204578.
- [45] R. Wang, A. Wang, and Q. Song. Research on the alkalinity of sintering process based on LS-SVM algorithms. In *Advances in Computer Science and Information Engineering*, pages 449–454, 2012. ISBN 978-3-642-30125-4. doi: 10.1007/978-3-642-30126-1{_}71.
- [46] P. Wasserman. *Advanced methods in neural computing*. John Wiley & Sons, Inc., New York, NY, USA, 1st edition, 1993. ISBN 0442004613.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

4.5 Conclusions

- [47] X. Wu. *Optimal designs for segmented polynomial regression models and web-based implementation of optimal design software*. State University of New York at Stony Brook, Stony Brook, NY, USA, 2007. ISBN 978-0-549-91415-0.
- [48] J. Xu, J. Wang, S. Li, and B. Cao. A method to simultaneously detect the current sensor fault and estimate the state of energy for batteries in electric vehicles. *Sensors*, 16(8), 2016. ISSN 1424–8220. doi: 10.3390/s16081328.
- [49] Z. Zeng and J. Wang. *Advances in neural network research and applications*. Springer Publishing Company, Incorporated, 1st edition, 2010. ISBN 3642129897, 9783642129896.
- [50] Z. Zhang and S. Chan. On kernel selection of multivariate local polynomial modeling and its application to image smoothing and reconstruction. *J. Signal Process. Syst.*, 64(3):361–374, 2011. ISSN 1939-8018. doi: 10.1007/s11265-010-0495-4.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 4. Hybrid intelligent system to perform fault detection on BIS sensor during surgeries

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

CAPÍTULO 5

Power cell SOC modelling for intelligent virtual sensor implementation

En este capítulo se presenta el segundo de los artículos utilizado para la defensa de la tesis por compendio de artículos. A continuación se presentan los datos básicos del mismo, y después de incluirá todo el contenido del artículo copiado del artículo publicado. Se ha decidido no incluir el artículo original para mantener una uniformidad en la presentación de la tesis, pero se puede consultar a través del *doi* correspondiente.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA
UNIVERSIDAD DE LA LAGUNA

Fecha: 20/09/2019 13:27:50

JOSÉ LUIS CALVO ROLLE
UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:29:29

Juan Albino Méndez Pérez
UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:30:46

Capítulo 5. Power cell SOC modelling for intelligent virtual sensor implementation

Datos generales del artículo:

Autores:

José-Luis Casteleiro-Roca¹, Esteban Jove¹, Fernando Sánchez-Lasheras², Juan-Albino Méndez-Pérez³, José-Luis Calvo-Rolle¹, Francisco Javier de Cos Juez⁴

Afiliaciones:

¹ Departament of Industrial Engineering, University of A Coruña, A Coruña, Spain

² Departament of Construction and Manufacturing Engineering, University of Oviedo, Oviedo, Spain

³ Departament of Computer Science and System Engineering, University of La Laguna, Tenerife, Spain

⁴ Departament of Mining Exploitation and Prospecting, University of Oviedo, Oviedo, Spain

Título: Power cell SOC modelling for intelligent virtual sensor implementation

Revista: Journal of Sensors

Volumen: 2017

Páginas: 1–10

Editorial: Hindawi

Año de publicación: 2017

DOI: 10.1155/2017/9640546

Factor de impacto ISI JCR 2017: 2,057

Factor de impacto ISI JCR 2018: 2,024

Factor de impacto ISI JCR 2017 (5 años): 2,031

Factor de impacto ISI JCR 2018 (5 años): 2,090

Disciplina *Engineering, Electrical & Electronic* 2017: 123/260 - Q2

Disciplina *Engineering, Electrical & Electronic* 2018: 140/265 - Q3

Disciplina *Instruments & Instrumentation* 2017: 25/61 - Q2

Disciplina *Instruments & Instrumentation* 2018: 30/61 - Q2

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Abstract

Batteries are one of the principal components in electric vehicles and mobile electronic devices. They operate based on electrochemical reactions, which are exhaustively tested to check their behavior and to determine their characteristics at each working point. One remarkable issue of batteries is their complex behavior. The power cell type under analysis in this research is a LFP (Lithium Iron Phosphate – LiFePO₄). The purpose of this research is to predict the power cell State of Charge (SOC) by creating a hybrid intelligent model. All the operating points measured from a real system during a Capacity Confirmation Test make up the dataset used to obtain the model. This dataset is clustered to obtain different behavior group, which are used to develop the final model. Different regression techniques such as Polynomial Regression, Support Vector Regression (SVR) and Artificial Neural Networks (ANN) have been implemented for each cluster. A combination of these methods is performed to achieve an intelligent model. The SOC of the power cell can be predicted by this hybrid intelligent model, and good results achieved.

keywords: Power cell, battery, clustering, neural networks, support vector regression, polynomial regression

5.1. Introduction

An electrical energy storage system is the most frequently used technology to solve the problem of intermittent energy production in renewable energy systems [11]. In renewable energy systems, the electric energy storage is used as a method of storing the energy when production is higher than demand and returning the energy when demand is higher than production. Also, these systems are used to supply portable devices or replace the fossil fuels in vehicles, such as in electric vehicles [11].

Nowadays, an increasing number of studies aim to improve electrical energy storage systems. Some research is focused on dealing with intermittent energy generation in renewable energy such as solar and wind power systems, proposing to implement those methods in Smart Grid systems [37]. Furthermore, the increasing use of portable devices like tablets or smartphones, which improve quality of life, demand higher autonomy, less charging time or less weight at the energy storage components [8].

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 5. Power cell SOC modelling for intelligent virtual sensor implementation

On the other hand, the electric vehicle forces the development and improvement of storage systems. Currently, a noticeable problem of the electric vehicle is the driving range, which is related to the storage system. Although the internal combustion engine is inefficient, it does at least provide long driving range due to the high energy density of fossil fuels [47].

This paper is focused on battery storage systems, and especially on a Lithium-Ion (Li-Ion) power cell, which is commonly utilized in electric vehicles. The frequent use of this type of cells makes it possible to identify different characteristics, such as ageing forecasts, charging and discharging behavior, etc. This information is very important to model the power cells properly.[27].

Li-Ion power cells are good candidates for electro-mobility and the renewable energy industry. The reasons why this battery is suitable for electric drive vehicles are its high power density, high voltage of the cell, low self-discharge, no memory effect and long life cycle [23]. Also, the Li-Ion batteries can be found in different chemistries and each one has its specific characteristics, such as energy cells or power cells, fitting the different requirements of the vehicle industry [46].

Due to the extensive use of these batteries in portable devices as well as in electric vehicles and the need for safety, the failure analysis and modelling of these batteries is very important [3].

Multiple Regression Analysis (MRA) methods are based on the traditional regression models [13]. These methods are used in several applications in different subjects due to their versatility [25, 21, 35]. [25] and [32] show a cost forecast in the early stage of projects, while [21, 16] evaluating the suppliers performance. The MRA methods are limited in some cases, like in [13] and in [10]. In these articles MRA techniques were used, but due to the non-linearity of the systems, a different approach was used. However, regression techniques based on soft computing can solve the problems of non-linear systems, as was done in [33, 40], where meta-classifiers were applied in a predictive control system with the aim of predicting the state of the model. In [24, 28], artificial neural networks were combined with multi-regression in order to optimize over-break prediction. As shown in [4], failures in wind turbines can be detected and predicted using intelligent model techniques.

Although some regression problems are addressed with the new methods mentioned above, in several cases it is difficult to obtain accurate models, for various reasons. For

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

instance, a model based on a highly non-linear system can lead to a bad performance. Dividing the initial dataset into different groups before carrying out the regression could be a complementary solution [31, 41]. With this objective in mind, the clustering algorithm K-means is commonly used [9, 19, 7]. This method consists of splitting up the entire dataset into a number of clusters. Each piece of data will belong to a particular cluster, depending on its characteristics. After this step, the regression technique is made over each cluster. Prior researches like [12, 6, 30, 15] solve other physical problems by using similar techniques.

This study develops an intelligent model that is able to predict the value of different system variables during a power cell test. Several clustering techniques were considered for grouping the data with similar behavior to implement the model. For each cluster, the three aforementioned regression methods were tested. The technique selection follows the minimum mean squared error criteria.

The present document is organized as follows. First, an introduction is described. Then, the case of study explains the test carried out and the process followed for obtaining the dataset. After the case study, the tested algorithms and the model approach considered in the study are presented. The obtained hybrid model and its configuration are shown in the results section. Finally, in the last section, future works and conclusions are presented.

5.2. Case study

This research presents the SOC model of a LFP power cell used in electric vehicle battery systems. This power cell was tested as shown in Figure 5.1, obtaining different measurements.

The test carried out and power cell are explained in the subsections in more detail.

5.2.1. The battery

One possible method of storing electric energy is by means of batteries. These devices store energy within an electrochemical medium, capable of storing and then

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46




Figura 5.1: Capacity confirmation test diagram

supplying electrical energy due to electrochemical reactions [11]. Batteries are composed of two electrodes and an electrolyte, where a redox reaction happens. During the discharging process, the cathode is reduced while the anode is oxidized, producing a current flow [11]. During the charging process, the reaction occurs in reverse order. The number of times that the cycle can be repeated is determined by the use of the battery, up to the point at which the capacity decreases to unusable levels [51].

The most common batteries used in portable devices are the Lithium-Ion batteries. They are widely used in electronic devices and, more recently, in electric vehicles [43]. The Li-Ion cells are characterized by their high energy density, due to the high voltage they can produce in comparison with other battery types, while weighing less [11]. They also show a long life cycle, low self-discharge and no memory effect [43, 51].

5.2.2. Capacity confirmation test

The capacity confirmation test, which was performed on the battery, measures the capacity of the battery in ampere-hour [1]. The measurement of the capacity was carried out at constant current. The test starts with the battery at full charge, so the SOC is at its maximum. Then, the battery starts to supply constant current until it reaches the discharge voltage, which is determined by the manufacturer [1]. At this point, the battery rests till the voltage is recovered, so the charging process can begin. Once the voltage has recovered to a certain value, the battery is again charged to its maximum voltage, also specified by the manufacturer [1]. These processes are performed with constant current and the present SOC is calculated at each instant.

A battery tester was used for the capacity confirmation test. This device is able to

5.2 Case study

charge and discharge the cell within the test parameters, in this case using a constant current, and making the corresponding measurements. The measurements made are the battery voltage, the current delivered or absorbed by the battery, the temperature at two different points and how long the test lasts.

Figure 5.1 shows the test scheme. This figure also shows the different measurement devices used and where they are placed: ammeter (A), voltmeter (V) and temperature sensors ($T1$ & $T2$). Given the fact that the temperature of the Li-Ion batteries is uniform, the sensors location does not affect theoretically the temperature measured. Two redundant temperature sensors are used to detect wrong measurements.

The testing device, which supplies or absorbs the current, is represented as a current source $i(t)$.

During this research, the power cell used was a LiFeBATT X-1P [2], which is a LiFePO4 cell. It is characterized by a nominal capacity of $8Ah$ and nominal voltage of $3.3V$.

Four different steps can be distinguished in the test (Figure 5.2):

- (1) Charge: the initial voltage is $3V$ and it is increased up to $3.65V$ due to the constant current flowing from the tester to the battery.
- (2) Rest after the charging process: no current flowing. During this step, the battery voltage reaches $3.3V$, which is the nominal value.
- (3) Discharge: the $3.3V$ achieved in the previous step are decreased to $2V$ due to the constant current flowing from the battery to the tester.
- (4) Rest after the discharging: no current flowing. The voltage of the battery goes from $2V$ to $3V$. A new cycle is ready to be started again.

Figure 5.2 shows the voltage and current variation measured in one cycle. During the charging, the current is flowing from the tester to the battery, so it is considered positive. On the other hand, when the current flows from the battery to the tester, it is considered negative.

The energy provided or absorbed during the process can be obtained by integrating the current over time, obtaining the energy in ampere-hour. The representation of

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 5. Power cell SOC modelling for intelligent virtual sensor implementation

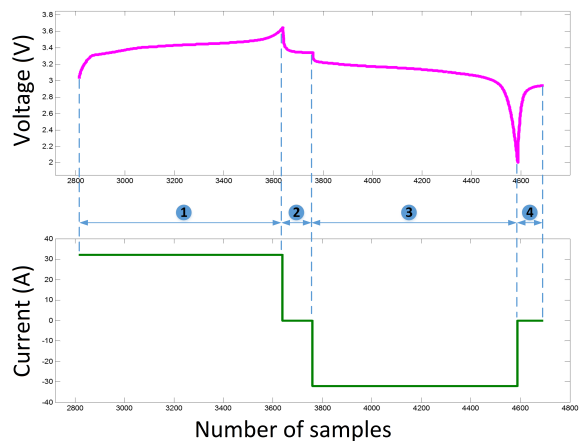


Figura 5.2: Current and voltage measured during one cycle

energy, at the top of Figure 5.3, shows how energy in the battery increases during the charging process and decreases during the discharging process. The representation of energy is shown as the SOC of the battery, which ranges from 100 % with the battery fully charged, up to 0 % with the battery completely discharged.




Figura 5.3: Energy and temperatures measured in one cycle

The two temperature sensors measure the temperature while the test is running.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA
 UNIVERSIDAD DE LA LAGUNA

Fecha: 20/09/2019 13:27:50

JOSÉ LUIS CALVO ROLLE
 UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:29:29

Juan Albino Méndez Pérez
 UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:30:46

5.3 Model approach

The measurement is made at two different locations. Their values also vary cyclically according to the state of the battery, depending on whether it is charging, discharging or resting, and also depending on the battery voltage.

The bottom of Figure 5.3 shows how the temperatures evolve in each operating region.

The full dataset used in this research has been obtained by testing a power cell, as explained before. The battery state is analyzed using the different parameters measured. Current and time are used to calculate the SOC of the battery at every moment. Furthermore, the temperatures were measured in order to detect a battery failure during the test. If values are far outside a typical range, a malfunction can be detected. All the data measured throughout the capacity battery test was labelled with the aim of determining the SOC.

5.3. Model approach

The model approach is defined by the scheme shown in Figure 5.4. Taking into consideration the magnitudes measured during the capacity battery test and how the system behaves, the dataset can be split into several operation ranges. Thus, different clusters are obtained and regression techniques are applied for each one. A global model scheme is presented in Figure 5.4. The two inputs of this model are the voltage and current, and its output is the SOC. The cluster selector links the selected model with the output. Each cluster represents the best model obtained. The criterion used to assign input data to a specific cluster is the minimum Euclidean distance between the cluster centroids and the input data.

The model is obtained as per the diagram of Figure 5.5. The figure shows only the data division for testing and training. However, a cross-validation technique (*k-fold*) was implemented to process the dataset with the aim of achieving better results. The validation of the *k-fold* model gives a more real performance and a better generalization [5].

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 5. Power cell SOC modelling for intelligent virtual sensor implementation




Figura 5.4: Model approach

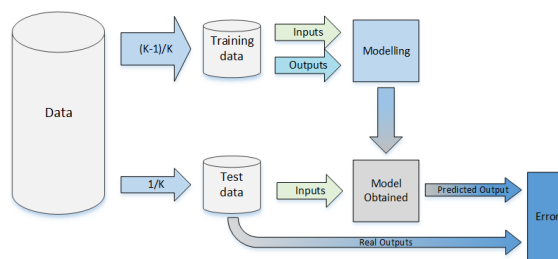


Figura 5.5: Modeling process

5.3.1. Techniques used

In this research, different techniques were used in order to accomplish the best model. These techniques are described below

5.3.1.1. Clustering

Principal Component Analysis PCA created by Pearson [36] and Hotelling [22]. This statistical technique describes the variation of multivariate data in terms of va-

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

5.3 Model approach

riables that are not correlated. Uncorrelated variables can be expressed as a linear combination of the initial variables. The aim of this technique is to derive new uncorrelated variables as a linear combination of the initial variables. This method may help to reduce the number of variables that represent the data.

Data Clustering. The K-means algorithm Clustering is technique of unsupervised data grouping used to measure similarity [38, 52]. The main aim of the data clustering technique is to organize unlabeled vectors into different groups. Thus, all similar data will belong to the same cluster [26]. The K-means algorithm is frequently used to divide datasets into clusters. This algorithm organizes the samples by minimizing the function shown in Equation 5.1, which represents the squared error function.

$$e = \sum_{k=1}^P \sum_{x \in Q_k} \|x - c_k\|^2 \quad (5.1)$$

Each cluster is set around a centroid, so the final clustering will depend on the amount of clusters and on the initial position of their centroids. The selection of the number of clusters is very important, and requires an initial study of the data composition. This value is extremely hard to estimate. The partitional algorithm K-means performs well when the data is near its cluster, and if each cluster is hyper-spherical in shape and sufficiently separated in hyperspace.

Neural PCA and Maximum Likelihood Hebbian Learning (MLHL) As mentioned above, PCA is a statistical compressing data method. The best linear compression of the data can be achieved in terms of LMSE. Some techniques of Artificial Neural Networks (ANN) can be used to carry out PCA e.g. [18, 34].

A PCA with a negative feedback network [18] can be used, according to the following definition. Given a $N \times 1$ input matrix x with and a $M \times 1$ output matrix y . A weight matrix W_{ij} links each output i with the input j , η being a learning rate. At the beginning of the training process, the network does not have an activation. The weights from the input layer neurons to the output layer neurons feedforward the input data. The output neuron activation value is implemented using a linear sum. It can be expressed as shown in Equation 5.2.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 5. Power cell SOC modelling for intelligent virtual sensor implementation

$$y_i = \sum_{j=1}^N W_{ij} x_j, \forall_i \quad (5.2)$$

A feedback of the activation function is performed with the same weights. Then it is subtracted from the inputs and the inhibition is performed (Equation 5.3).

$$e_j = x_j - \sum_{i=1}^M W_{ij} y_i, \forall_j \quad (5.3)$$

Then, simple Hebbian learning is carried out between the outputs and the inputs, as shown in Equation 5.4.

$$\Delta W_{ij} = \eta e_j y_i \quad (5.4)$$

The network learning stability is a consequence of the negative feedback. In a similar way to Oja's Subspace algorithm [34], this network can find the main components of the input data [18]. Therefore, the weights will find a subspace basis spanned by the current Principal Components whereas they will not find the theses components. MLHL [42] is described following the learning rules shown the following equations: a feedforward step (Equation 5.2), a feedback step (Equation 5.3) and finally, a weight modification, which is presented in Equation 5.5.

$$\Delta W_{ij} = \eta y_i \text{sign}(e_j) |e_j|^{p-1} \quad (5.5)$$

MLHL [42] is connected to the statistical standard method Exploratory Projection Pursuit (EPP) method [17].

5.3.1.2. Regression Techniques

Polynomial regression A model obtained with polynomial regression [5] can be described as a linear combination of basis functions. The number of inputs and the polynomial degree will affect the number of basis functions.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

5.3 Model approach

With a first degree polynomial, the linear summation performed can be described as shown in Equation 5.6 (for two inputs). If the polynomial degree increases, the model obtained will become more complex. A second degree polynomial is shown in Equation 5.7.

$$f(x) = b_0 + b_1y_1 + b_2y_2 \quad (5.6)$$

$$f(x) = b_0 + b_1y_1 + b_2y_2 + b_3y_1y_2 + b_4y_1^2 + b_5y_2^2 \quad (5.7)$$

MultiLayer Perceptron (MLP) The MultiLayer Perceptron can be defined as a feedforward artificial neural network (ANN) [50, 53]. Its robustness and relative simplicity make this ANN the one most frequently used. Despite these advantages, the good performance of this technique depends heavily on the ANN architecture selected. The MLP architecture has three different layers: the input, the output and one or more hidden ones.

A layer has a selected quantity of neurons, with a specific activation function. Commonly, the same activation function is used in all neurons of the same layer. Activation functions can be of three different types: linear, step, tan-sigmoid or log-sigmoid. In MLP, the neurons have weighted links between layers.

The MPL output can be defined as in Equation 5.8 [39].

$$f_{\vartheta}(x) = \xi + \sum_{i=1}^j a_i \phi(v_i^T y + b_i) \quad (5.8)$$

where:

- $y = (y(1), \dots, y(d))^T \in \mathfrak{R}^d$ - Inputs vector
- j - Hidden layers quantity
- ϕ - Transfer function bounded
- $\vartheta = (\xi, a_1, \dots, a_k, b_1, \dots, b_k, v_{11}, \dots, v_{kd})$ - Model parameter vector
- $v_i = (v_{i1}, \dots, v_{id})^T \in \mathfrak{R}^d$ - Hidden unit i parameter vector

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 5. Power cell SOC modelling for intelligent virtual sensor implementation

Least Square Support Vector Regression (LS-SVR) Support Vector Regression (SVR) is an adaptation of the Support Vector Machines (SVM) classification algorithm. The principal aim of SVR is to plot the data in a high-dimensional space F using non-linear mapping. Linear regression is then applied in the space F [14, 44].

The Least Square formulation of SVM, known as LS-SVM, is an approximation of the solution of a system. Its behavior is very similar to SVM in terms of general performance [45, 49]. The LS-SVR is the use of LS-SVM for regression [20, 48]. In LS-SVR, a typical squared loss function replaces an insensitive loss function. This squared loss function set up the Lagrangian matrix by solving a linear KarushKuhn-Tucker equation (Equation 5.9).

$$\begin{bmatrix} 0 & \iota_n^T \\ \iota_n & K + \gamma^{-1}I \end{bmatrix} \begin{bmatrix} a_0 \\ a \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix} \quad (5.9)$$

where:

- ι_n - n ones vector
- T - matrix or vector means transpose
- γ - weight vector
- a - regression vector
- a_0 - model offset

To implement this technique two parameters are required: γ and σ , where σ is the kernel width [29].

5.3.2. Preprocessing the dataset

The dataset was obtained during the described capacity confirmation test performed on the power cell. The State Of Charge was determined by the current and the time for each test. Voltage and current were monitored to determine the SOC. As explained in previous sections, temperatures were measured at two points of the battery in order to find malfunctions.

The SOC parameter of the battery should go sequentially from 0% to 100% and

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015. Su autenticidad puede ser contrastada en la siguiente dirección https://sede.ull.es/validacion/	
Identificador del documento: 2141614	Código de verificación: B1ePGXal
Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

5.4 Results

then, from 100 % to 0 %. All incomplete cycles which did not fulfill this condition were discarded. After the data filtering, only completed cycles were taken into consideration for the implementation of the model. The measured data was registered with a sample of 1 Hertz. After this discard, the dataset for implementing the model was reduced from 18131 to 16370 samples.

The cycle consists of four different states: charge (1), rest (2), discharge (3), and rest (4). During the test, all data measured was labelled with the current state of the power cell.

Before developing the regression models, clustering algorithms were applied to the dataset. For this purpose, an analysis with MHLH and PCA was performed. The analysis showed that four different groups of samples could be appreciated, as Figures 5.6 and 5.7 show. Following the criteria suggested by PCA and MHLH, K-means algorithm was applied to create the four clusters. Each group represents the four different states of the battery during the test.

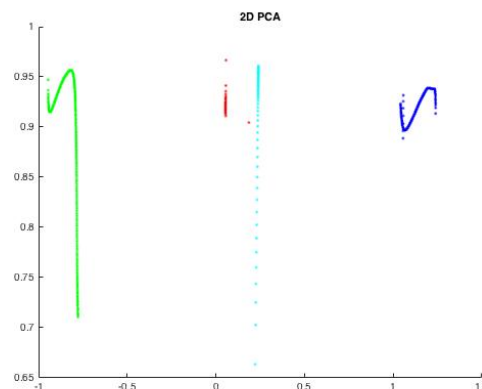


Figura 5.6: PCA Analysis

The number of samples assigned to each cluster is shown in Table 5.1. It is remarkable the fact that the cluster distribution corresponds to the four steps of the capacity confirmation test mentioned in subsection 2.2. Polynomial regression, MLP-ANN and LS-SVR were the three techniques trained for the clusters.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 5. Power cell SOC modelling for intelligent virtual sensor implementation

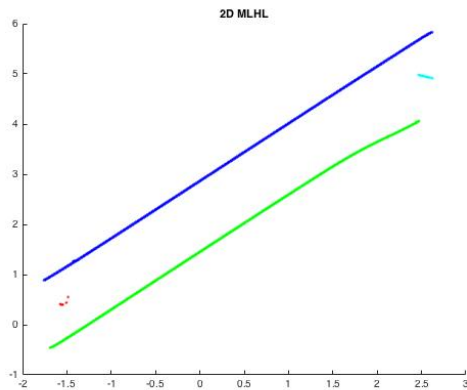


Figura 5.7: MLHL Analysis

Cluster	Samples
(1) - Charge	6619
(2) - Rest	1089
(3) - Discharge	7451
(4) - Rest	1211
Total	16370

Tabla 5.1: Samples assigned to clusters

5.4. Results

The real state of the cell labeled during the test was compared with the data distribution obtained as a result of the clustering. The dataset has the requisite characteristics to be applied by K-Means and the clusters accomplished had 100 % correct assignation. Due to the good performance achieved, the model approach is not required to know the state of the cycle.

The MLP-ANN algorithm was implemented with different configurations; the number of hidden layer neurons changed from 2 to 15, while only one hidden layer was used. All hidden layer neurons shared the same activation function (tan-sigmoid). A linear activation function was used as an output layer neuron. The Levenberg-Marquardt algorithm was applied on the training process. Learning algorithm was based on the

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA
 UNIVERSIDAD DE LA LAGUNA

Fecha: 20/09/2019 13:27:50

JOSÉ LUIS CALVO ROLLE
 UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:29:29

Juan Albino Méndez Pérez
 UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:30:46

5.4 Results

gradient decrease, and MSE was set as the criterion.

The LS-SVR regression algorithm was trained with the auto-tuning implemented in the Matlab toolbox developed by KULeuven-ESAT-SCD. The chosen model kernel was Radial Basis Function (RBF), and 'Function Estimation' the kind selected to make the regression. The cost-criterion is 'leaveoneoutlssvm', with an MSE performance function and an optimization function type 'simplex'.

The Polynomial regression technique was applied varying polynomial order from 1 to 10.

The Mean Square Error (MSE) value is used to compare the accuracy of the models. The lowest MSEs obtained for each technique are shown in table 5.2.

In table 5.3 the best regression results are shown, as well as the technique applied to achieve them.

The technique selection takes into consideration the computational cost when the MSEs achieved for two or more techniques are similar.

Cycle state	MLP	Poly	LS-SVR
(1) - Charge	0.1094	23.9967	0.1392
(2) - Rest	0.0921	0.0904	0.0902
(3) - Discharge	0.4767	17.8144	0.5052
(4) - Rest	0.0917	0.0930	0.0865

Tabla 5.2: Best MSE achieved for each technique

Cycle state	Model	MSE
(1) - Charge	MLP, 10 neurons	0.1392
(2) - Rest	MLP, 8 neurons	0.4767
(3) - Discharge	LS-SVR	0.0902
(4) - Rest	LS-SVR	0.0865

Tabla 5.3: MSE for the best methods

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 5. Power cell SOC modelling for intelligent virtual sensor implementation




Figura 5.8: Boxplot of MSE by cluster

5.4.1. Statistical Analysis

Here, the results of the statistical analysis are shown with the aim of determining the accuracy of the selected models compared with that of those non selected.

For each cluster, the best model selected is compared statistically with the others, in terms of MSE, to determine if there is a difference between their MSEs.

Figure 5.8 shows the boxplot for each cluster using ANN-MLP, Polynomial regression and LS-SVR, while the results of the statistical analysis using a t -test analysis with an 5% α -level are shown in Table 5.4.

Based on the results of table 5.4 it may be concluded that:

- Cluster 1: there is no statistical difference between ANN-MLP, 10 neurons and LS-SVR
- Cluster 2: there is no statistical difference between any of the three models

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

5.5 Conclusions and future works

Cluster	Selected Model	Compared Model	p-value
1	ANN-MLP, 10 neurons	Polynomial	$9.44 \cdot 10^{-5}$
1	ANN-MLP, 10 neurons	SVR	0.1364
2	LS-SVR	ANN-MLP, 10 neurons	0.0695
2	LS-SVR	Polynomial	0.0735
3	ANN-MLP, 8 neurons	Polynomial	$2.876 \cdot 10^{-9}$
3	ANN-MLP, 8 neurons	SVR	0.4789
4	LS-SVR	ANN-MLP, 10 neurons	0.4970
4	LS-SVR	Polynomial	0.8713

Tabla 5.4: p-value for each model in each cluster

- Cluster 3: there is no statistical difference between ANN-MLP, 10 neurons and LS-SVR
- Cluster 4: there is no statistical difference between any of the three models

In any of the previous cases the difference between the MSE, in the best case, is lower than 0.0052 so it can be considered that the model selected does not significantly affect to the results.

5.5. Conclusions and future works

The approach used in this study presents remarkable results. The MSE average is 0.1815, varying from 0.0865 to 0.4767, depending on the variable and the cycle state.

The State Of Charge value for the confirmation of the battery capacity can be predicted in real time. The model obtained is capable of checking that the power cell test is functioning correctly when it offers wrong results.

The overall efficiency of this novel approach is increased if a hybrid model is implemented. This way, each local model was obtained by training one group of the initial dataset. Better results were achieved by employing MLPs and LS-SVR. However, the difference between the two, in terms of MSE, is not statistically great, so both models may be used in any of the clusters.

Capítulo 5. Power cell SOC modelling for intelligent virtual sensor implementation

The temperature measured in the cell is highly important parameter relating to health of the device. Using the temperatures measured in the tests, a study and a modeling of these parameters will be undertaken to detect deviations in behavior. This new model would be used with the one-class classifier algorithm in order to detects any faults in this type of systems.

Bibliografía

- [1] *PNGV Battery Test Manual*, 2 2001.
- [2] *LiFeBATT X-1P 8Ah 38123 Cell*, 3 2011.
- [3] J. Álvarez Antón, P. García Nieto, F. de Cos Juez, F. Sánchez Lasheras, C. Blanco Viejo, and N. Roqueñí? Gutiérrez. Battery state-of-charge estimator using the mars technique. *Power Electronics, IEEE Transactions on*, 28(8):3798–3805, 8 2013. ISSN 0885-8993. doi: 10.1109/TPEL.2012.2230026.
- [4] A. Alvarez-Huerta, R. Gonzalez-Miguel, D. Garcia-Metola, and A. Noriega-Gonzalez. Failure detection and prediction in wind turbines by using scada data. *Dyna*, 86(4):467–473, 2011. ISSN 0012-7361. doi: 10.6036/4025.
- [5] C. M. Bishop. *Pattern Recognition and Machine Learning (Information Science and Statistics)*. Springer-Verlag New York, Inc., Secaucus, NJ, USA, 2006. ISBN 0387310738.
- [6] J. L. Calvo-Rolle, J. L. Casteleiro-Roca, H. Quintián, and M. C. Meizoso-Lopez. A hybrid intelligent system for PID controller using in a steel rolling process. *Expert Systems with Applications*, 40(13):5188–5196, 2013. ISSN 0957-4174. doi: 10.1016/j.eswa.2013.03.013.
- [7] J.-L. Casteleiro-Roca, J. Calvo-Rolle, J. Méndez Pérez, N. Roqueñí Gutiérrez, and F. de Cos Juez. Hybrid intelligent system to perform fault detection on BIS sensor during surgeries. *Sensors*, 17(1):179, 1 2017. ISSN 1424-8220. doi: 10.3390/s17010179.
- [8] N. Chaturvedi, R. Klein, J. Christensen, J. Ahmed, and A. Kojic. Modeling, estimation, and control challenges for lithium-ion batteries. *American Control Conference (ACC)*, pages 1997–2002, 6 2010. ISSN 0743-1619. doi: 10.1109/ACC.2010.5531623.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

5.5 Conclusions and future works

- [9] A. Cherif, H. Cardot, and R. Boné. SOM time series clustering and prediction with recurrent neural networks. *Neurocomput.*, 74(11):1936–1944, 5 2011. ISSN 0925-2312. doi: 10.1016/j.neucom.2010.11.026.
- [10] Y. Cho and H. B. Awbi. A study of the effect of heat source location in a ventilated room using multiple regression analysis. *Building and Environment*, 42(5):2072–2082, 2007. ISSN 0360-1323. doi: 10.1016/j.buildenv.2006.03.008.
- [11] C. Chukwuka and K. Folly. Batteries and super-capacitors. *Power Engineering Society Conference and Exposition in Africa (PowerAfrica), 2012 IEEE*, pages 1–6, 7 2012. doi: 10.1109/PowerAfrica.2012.6498634.
- [12] M. J. Crespo-Ramos, I. Machón-González, H. López-García, and J. L. Calvo-Rolle. Detection of locally relevant variables using SOM-NG algorithm. *Engineering Applications of Artificial Intelligence*, 26(8):1992–2000, 2013. ISSN 0952-1976. doi: 10.1016/j.engappai.2013.04.012.
- [13] C. Crespo-Turrado, M. d. C. Meizoso-Lopez, F. Sanchez-Lasheras, B. A. Rodriguez-Gomez, J. L. Calvo-Rolle, and F. J. de Cos Juez. Missing data imputation of solar radiation data under different atmospheric conditions. *Sensors*, 14(11):20382, 2014. ISSN 1424-8220. doi: 10.3390/s141120382.
- [14] N. Cristianini and J. Shawe-Taylor. *An introduction to support Vector Machines and other kernel-based learning methods*. Cambridge University Press, New York, NY, USA, 2000. ISBN 0-521-78019-5.
- [15] J. A. Fernández, C. D. Muñoz, P. G. Nieto, F. de Cos Juez, F. S. Lasheras, and M. Roqueñí. Forecasting the cyanotoxins presence in fresh waters: A new model based on genetic algorithms combined with the MARS technique. *Ecological engineering*, 53:68–78, 2013. doi: 10.1016/j.ecoleng.2012.12.015.
- [16] G. Flórez, P. A. Saiz, P. García-Portilla, F. J. De Cos, S. Dapia, S. Álvarez, L. Nogueiras, and J. Bobes. Predictors of posttreatment drinking outcomes in patients with alcohol dependence. *European addiction research*, 21(1):19–30, 2014. doi: 10.1159/000358194.
- [17] J. Friedman and J. Tukey. A projection pursuit algorithm for exploratory data analysis. *Computers, IEEE Transactions on*, C-23(9):881–890, 9 1974. ISSN 0018-9340. doi: 10.1109/T-C.1974.224051.
- [18] C. Fyfe. A neural network for PCA and beyond. *Neural Processing Letters*, 6(1-2): 33–41, 1997. ISSN 1370-4621. doi: 10.1023/A:1009606706736.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 5. Power cell SOC modelling for intelligent virtual sensor implementation

- [19] M. H. Ghaseminezhad and A. Karami. A novel self-organizing map (SOM) neural network for discrete groups of data clustering. *Appl. Soft Comput.*, 11(4):3771–3778, 6 2011. ISSN 1568-4946. doi: 10.1016/j.asoc.2011.02.009.
- [20] Y. Guo, X. Li, G. Bai, and J. Ma. Time series prediction method based on LS-SVR with modified gaussian RBF. In *Neural Information Processing*, pages 9–17, 2012. ISBN 978-3-642-34480-0. doi: 10.1007/978-3-642-34481-7_2.
- [21] L.-H. Ho, S.-Y. Feng, Y.-C. Lee, and T.-M. Yen. Using modified IPA to evaluate supplier’s performance: Multiple regression analysis and DEMATEL approach. *Expert Systems with Applications*, 39(8):7102–7109, 2012. ISSN 0957-4174. doi: 10.1016/j.eswa.2012.01.034.
- [22] H. Hotelling. Analysis of a complex of statistical variables into principal components. *Journal of educational psychology*, 24(6), 1933. ISSN ISSN de la revista. doi: 10.1037/h0071325.
- [23] N. Ismail and S. Toha. State of charge estimation of a lithium-ion battery for electric vehicle based on particle swarm optimization. In *2013 IEEE International Conference on Smart Instrumentation, Measurement and Applications (ICSIMA)*, pages 1–4, 2013. doi: 10.1109/ICSIMA.2013.6717978.
- [24] H. Jang and E. Topal. Optimizing overbreak prediction based on geological parameters comparing multiple regression analysis and artificial neural network. *Tunnelling and Underground Space Technology*, 38(0):161–169, 2013. ISSN 0886-7798. doi: 10.1016/j.tust.2013.06.003.
- [25] R. Jin, K. Cho, C. Hyun, and M. Son. MRA-based revised CBR model for cost prediction in the early stage of construction projects. *Expert Systems with Applications*, 39(5):5214–5222, 2012. ISSN 0957-4174. doi: 10.1016/j.eswa.2011.11.018.
- [26] S. Kaski, J. Sinkkonen, and A. Klami. Discriminative clustering. *Neurocomputing*, 69(1-3):18–41, 2005. ISSN 0925-2312. doi: 10.1016/j.neucom.2005.02.012.
- [27] O. Konig, S. Jakubek, and G. Prochart. Battery impedance emulation for hybrid and electric powertrain testing. *Vehicle Power and Propulsion Conference (VPPC), 2012 IEEE*, pages 627–632, 8 2012. doi: 10.1109/VPPC.2012.6422636.
- [28] F. S. Lasheras, F. J. de Cos Juez, A. S. Sánchez, A. Krzemień, and P. R. Fernández. Forecasting the COMEX copper spot price by means of neural networks and ARIMA models. *Resources Policy*, 45:37–43, 2015. ISSN 0301-4207. doi: 10.1016/j.resourpol.2015.03.004.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

5.5 Conclusions and future works

- [29] Y. Li, X. Shao, and W. Cai. A consensus least squares support vector regression (LS-SVR) for analysis of near-infrared spectra of plant samples. *Talanta*, 72(1): 217–222, 2007. ISSN 0039-9140. doi: 10.1016/j.talanta.2006.10.022.
- [30] I. Machón-González, H. López-García, and J. L. Calvo-Rolle. Neuro-robust controller for non-linear systems. *Dyna*, 86(6):308–317, 2011. doi: 10.6036/3949.
- [31] D. Martínez-Rego, O. Fontenla-Romero, and A. Alonso-Betanzos. Efficiency of local models ensembles for time series prediction. *Expert Syst. Appl.*, 38(6):6884–6894, 6 2011. ISSN 0957-4174. doi: 10.1016/j.eswa.2010.12.036.
- [32] P. G. Nieto, J. A. Fernández, F. S. Lasheras, F. de Cos Juez, and C. D. M. niz. A new improved study of cyanotoxins presence from experimental cyanobacteria concentrations in the trasona reservoir (northern spain) using the MARS technique. *Science of The Total Environment*, 430:88–92, 2012. ISSN 0048-9697. doi: 10.1016/j.scitotenv.2012.04.068.
- [33] J. Nieves-Acedo, I. Santos-Grueiro, and P. Garcia-Bringas. Enhancing the prediction stage of a model predictive control systems through meta-classifiers. *Dyna*, 88(3):290–298, 2013. ISSN 0012-7361. doi: 10.6036/5426.
- [34] E. Oja. Neural networks, principal components, and subspaces. *International Journal of Neural Systems*, 1(1):61–68, 1989. doi: 10.1142/S0129065789000475.
- [35] J. Osborn, D. Guzman, F. J. de Cos Juez, A. G. Basden, T. J. Morris, E. Gendron, T. Butterley, R. M. Myers, A. Guesalaga, F. Sanchez Lasheras, M. Gomez Victoria, M. L. Sánchez Rodríguez, D. Gratadour, and G. Rousset. Open-loop tomography with artificial neural networks on CANARY: on-sky results. *Monthly Notices of the Royal Astronomical Society*, 441(3):2508–2514, 2014. doi: 10.1093/mnras/stu758.
- [36] K. Pearson. On lines and planes of closest fit to systems of points in space. *Philosophical Magazine*, 2(6):559–572, 1901. doi: 10.1080/14786440109462720.
- [37] H. Qian, J. Zhang, and J.-S. Lai. A grid-tie battery energy storage system. *Control and Modeling for Power Electronics (COMPEL), 2010 IEEE 12th Workshop on*, pages 1–5, 6 2010. doi: 10.1109/COMPEL.2010.5562425.
- [38] A. Qin and P. Suganthan. Enhanced neural gas network for prototype-based clustering. *Pattern Recogn.*, 38(8):1275–1288, 8 2005. ISSN 0031-3203. doi: 10.1016/j.patcog.2004.12.007.
- [39] J. Rynkiewicz. General bound of overfitting for MLP regression models. *Neuro-computing*, 90:106–110, 2012. ISSN 0925-2312. doi: 10.1016/j.neucom.2011.11.028.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 5. Power cell SOC modelling for intelligent virtual sensor implementation

- [40] A. S. Sánchez, P. R. Fernández, F. S. Lasheras, F. J. de Cos Juez, and P. G. Nieto. Prediction of work-related accidents according to working conditions using support vector machines. *Applied Mathematics and Computation*, 218(7):3539–3552, 2011. doi: 10.1016/j.amc.2011.08.100.
- [41] A. S. Sánchez, F. J. Iglesias-Rodríguez, P. R. Fernández, and F. de Cos Juez. Applying the k-nearest neighbor technique to the classification of workers according to their risk of suffering musculoskeletal disorders. *International Journal of Industrial Ergonomics*, 52:92–99, 2016. doi: 10.1016/j.ergon.2015.09.012.
- [42] M. Sağsan, İhsan Tolga Medeni, and T. D. Medeni. Knowledge management paradigms: Implementation through individual fuzzy-based education. *Procedia Computer Science*, 102:259–266, 2016. ISSN 1877-0509. doi: 10.1016/j.procs.2016.09.399.
- [43] A. Sparacino, G. Reed, R. Kerestes, B. Grainger, and Z. Smith. Survey of battery energy storage systems and modeling techniques. *Power and Energy Society General Meeting, 2012 IEEE*, Volumen de la revista:1–8, 7 2012. ISSN 1944-9925. doi: 10.1109/PESGM.2012.6345071.
- [44] I. Steinwart and A. Christmann. *Support vector machines*. Springer Publishing Company, Incorporated, 1st edition, 2008. ISBN 0387772413.
- [45] J. Suykens and J. Vandewalle. Least squares support vector machine classifiers. *Neural Processing Letters*, 9(3):293–300, 1999. ISSN 1370-4621. doi: 10.1023/A:1018628609742.
- [46] M. Swierczynski, D.-I. Stroe, A.-I. Stan, R. Teodorescu, and S. Kaer. Lifetime estimation of the nanophosphate LiFePO₄ battery chemistry used in fully electric vehicles. *Industry Applications, IEEE Transactions on*, 51(4):3453–3461, 7 2015. ISSN 0093-9994. doi: 10.1109/TIA.2015.2405500.
- [47] S. Vukosavic. *Electrical Machines*. Power Electronics and Power Systems. Springer, 2012. ISBN 9781461404002.
- [48] L. Wang and J. Wu. Neural network ensemble model using PPR and LS-SVR for stock et forecasting. In *Advanced Intelligent Computing*, pages 1–8, 2012. ISBN 978-3-642-24727-9. doi: 10.1007/978-3-642-24728-6{-}1.
- [49] R. Wang, A. Wang, and Q. Song. Research on the alkalinity of sintering process based on LS-SVM algorithms. In *Advances in Computer Science and Information Engineering*, pages 449–454, 2012. ISBN 978-3-642-30125-4. doi: 10.1007/978-3-642-30126-1-71.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

5.5 Conclusions and future works

- [50] P. Wasserman. *Advanced methods in neural computing*. John Wiley & Sons, Inc., New York, NY, USA, 1st edition, 1993. ISBN 0442004613.
- [51] Wikipedia. Lithium-ion battery - wikipedia, the free encyclopedia, 2014. URL http://en.wikipedia.org/w/index.php?title=Lithium-ion_battery&oldid=592970854. [Online; accessed 30-January-2014].
- [52] J. Ye and T. Xiong. SVM versus least squares SVM. *Journal of Machine Learning Research - Proceedings Track*, 2:644–651, 2007. doi: 10.1145/505282.505283.
- [53] Z. Zeng and J. Wang. *Advances in neural network research and applications*. Springer Publishing Company, Incorporated, 1st edition, 2010. ISBN 3642129897, 9783642129896.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 5. Power cell SOC modelling for intelligent virtual sensor implementation

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

CAPÍTULO 6

Hybrid model for the ANI index prediction using Remifentanil drug and EMG signal

En este capítulo se presenta el tercero de los artículos utilizado para la defensa de la tesis por compendio de artículos. A continuación se presentan los datos básicos del mismo, y después de incluirá todo el contenido del artículo copiado del artículo publicado. Se ha decidido no incluir el artículo original para mantener una uniformidad en la presentación de la tesis, pero se puede consultar a través del *doi* correspondiente.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 6. Hybrid model for the ANI index prediction using Remifentanil drug and EMG signal

Datos generales del artículo:

Autores:

José Luis Casteleiro-Roca^{1,2}, Esteban Jove^{1,2}, Jose M. Gonzalez-Cava², Juan-Albino Méndez-Pérez², José Luis Calvo-Rolle¹, Francisco Blanco Alvarez³

Afiliaciones:

¹ Departament of Industrial Engineering, University of A Coruña, A Coruña, Spain

² Departament of Computer Science and System Engineering, University of La Laguna, Tenerife, Spain

³ Departamento de Ciencia de los Materiales e Ingeniería Metalúrgica, University of Oviedo, Oviedo, Spain

Título: Hybrid model for the ANI index prediction using Remifentanil drug and EMG signal

Revista: Neural Computing & Applications

Páginas: 1–10

Editorial: Springer

Año de publicación: 2018

DOI: 10.1007/s00521-018-3605-z

Factor de impacto ISI JCR 2018: 4,664

Factor de impacto ISI JCR 2018 (5 años): 3,570

Disciplina *Computer Science, Artificial Intelligence* **2018:** 21/133 - Q1

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Abstract

With the aim to control and reduce the pain of patients during a surgery with general anesthesia, one of the main challenges is the proposal of safe an optimal and efficient methods of drugs administering. First steps to achieve this goal is the proposal and development of right indexes that correlate satisfactory with analgesia. One of this index, that gives the most hopeful results is the ANI (Analgesia Nociception Index). The present research work deals the ANI response of patients during surgeries with general anesthesia with intravenous drug infusion. The main aim is to predict the ANI signal behavior regarding of the analgesic infusion rate. To do that, a hybrid intelligent model is developed, using clustering and regression techniques based on Artificial Neural Networks and Support Vector Regression. The proposal was validated with a dataset of surgeries real cases of patients undergoing general anesthesia. The achieved results attest for the potential of the proposed technique.

keywords: EMG (ElectroMyoGram signal), ANI (Analgesia Nociception Index), MLP (Multi-Layer Perceptron), SVR (Support Vector Regression)

6.1. Introduction

Supplying the proper dose of drug in patients undergoing general anesthesia has become an important challenge in medicine. Anesthesiologist must control the level of hypnosis, analgesia and muscle relaxation during surgery. As a general rule, they evaluate the state of patients by means of clinical signs and then decide whether increasing or decreasing the corresponding drug dose manually. Nowadays, different automatic controllers have been proposed in order to adapt the drug titration automatically. Specifically, automatic control of hypnosis has been widely researched [28, 27]. However, the automatic control of analgesia is still a problem to face. Closed-loop control strategies are based on the use of a feedback variable. Nevertheless, the absence of a feedback variable capable of measuring the analgesic state of patient has become the main problem for the automation.

Traditional methods have been based on the evaluation of the autonomic reactions [23]. Currently, new monitors and sensors [9, 16] have been proposed in order to measure analgesia [15]. Among the different possibilities, the Analgesia Nociception Index (ANI),

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 6. Hybrid model for the ANI index prediction using Remifentanil drug and EMG signal

developed by Moloris Medical Systems, is supposed to be designed to optimize drug delivery in the analgesic process. It is able to compute an index that ranges from 0 to 100 in order to quantify the parasympathetic activity in patients undergoing surgery. Previous successful results have been reached when using the ANI to guide analgesic delivery [21, 4, 22]. However, more research is needed in order to validate the Analgesia Nociception Index as a measure of analgesia.

On the other hand, not only the presence of a feedback variable, but also the availability of a mathematical model is necessary when trying to automate the analgesic process. Despite of hypnosis, where pharmacokinetic / pharmacodynamics models have been widely studied [1, 35, 34], analgesic models for patients are still a challenge for experts. In this sense, proposing a model able to relate the drug infusion of analgesic with the ANI index would make the automation of analgesia easier.

This work is based on the techniques used in [11], where a hybrid model was created for predicting the ElectroMyoGram signal (EMG) and Bispectral index signal (BIS), taking into account different variables involved in the surgery. For this research, the hypothesis is that the ANI index is correlated, not only to the infusion rate of analgesic, but also to the EMG as a measure of the painful surgical stimuli. Then, the objective is to predict the ANI in terms of EMG and Remifentanil rate. Understanding this index, as well as the variables involved would let the development of new strategies applied to the analgesia control. Specifically, the availability of a model able to predict a wide time horizon would let the application of predictive control strategies.

For the ANI prediction, many different methods can be considered. The accepted regression methods are typically based on Multiple Regression Analysis techniques, that are very usual in applications in different fields [20, 8, 7]. However, these methods have limitations and do not provide a good performance [8, 10, 26]. In order to increase this feature, many new proposals have been developed. These proposals are based on Soft Computing techniques, both simple or hybrid [2, 33]. As it is shown in [18, 6, 19, 31, 32] these techniques improve the first ones mentioned above.

This study implements a global model to predict the ANI signal from the EMG signal and the Remifentanil infusion rate. Two regression methods (ANNs, Artificial Neural Networks, and SVR, Support Vector Regression) and different configurations were verified to select the best one based on the lowest Mean Squared Error (MSE) reached.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

6.3 Model approach

This paper is structured in the following way. After the present section, the case of study is described. Then, the model approach and the tested algorithms taken into account in the research are shown. The results section shows the best configuration achieved by the hybrid model. After the results, the conclusions and future works are presented.

6.2. Case of Study

Data for the analysis were obtained from fifteen patients scheduled for cholecystectomy surgery at the Hospital Universitario de Canarias. All patients included received an informative document about the study and an informed consent was signed. A Total IntraVenous Anesthesia with Propofol and Remifentanil (hypnotic and analgesic drugs respectively) was performed. Drugs were manually delivered according to the anesthesiologist criteria using two intravenous Graseby 3500 pumps. For the control of hypnosis, BIS monitor was used as a guidance variable. Propofol dose was changed in order to obtain an adequate level of hypnosis, with a BIS target of 50. On the other hand, Remifentanil dose was adjusted depending on autonomic reactions and the presence of surgical events. During the surgery, ANI index as well as EMG signal and Remifentanil rate (mcg/kg/min) were automatically registered with a sample time of 5 seconds using a laptop via RS232 interfaces. Although ANI was registered, this information was not visible for the clinician to avoid conditioning their decisions based on traditional clinical parameters. In patients undergoing anesthesia, it is supposed that the ANI level will vary depending on the concentration of Remifentanil and the external disturbances that will be considered taking the EMG information into account.

The studied problem could be represented as shown in Figure 6.1.

6.3. Model approach

The model approach used in this research is shown in Figure 6.2. In this figure, two of the model inputs are measured signals (Remifentanil drug -Remi- and the ElectroMyoGram -EMG-) and the third input represents feedback of the predicted Analgesia Nociception Index -ANI-. As the model is used to predict the future value of ANI, the inputs are the actual and the 4 previous values of the signals; and the output is the

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 6. Hybrid model for the ANI index prediction using Remifentanil drug and EMG signal



Figura 6.1: Case of study. Input/Output representation

predicted ANI value at the next 40 seconds.




Figura 6.2: Model approach

The time values that appear in Figure 6.3 are the real surgery time; but as the acquisition system uses a sample time of 5 seconds, the model uses the 4 previous value to predict the value in the next 8th instant. These previous values allow the intelligent model to predict the signal including the dynamic on the process.

Moreover, Figure 6.4 shows the internal layout of the Hybrid intelligent model. Each internal model is selected to achieve the best global results, then, the training phase is taking into account all the different clusters and the different regression algorithms used (and its configuration).

The dataset used in the training process was divided using K-Fold Cross-Validation with 10 Folds. This type of Cross-Validation ensures more general parameters to calculate the error for each regression technique. Figure 6.5 shows the modeling process, this training repeats K times until all the training data is used with each algorithm. Once all the K-Fold were trained, the error for each specific algorithm is calculate as shown in Figure 6.6.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015. Su autenticidad puede ser contrastada en la siguiente dirección https://sede.ull.es/validacion/	
Identificador del documento: 2141614	Código de verificación: B1ePGXal
Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

6.3 Model approach

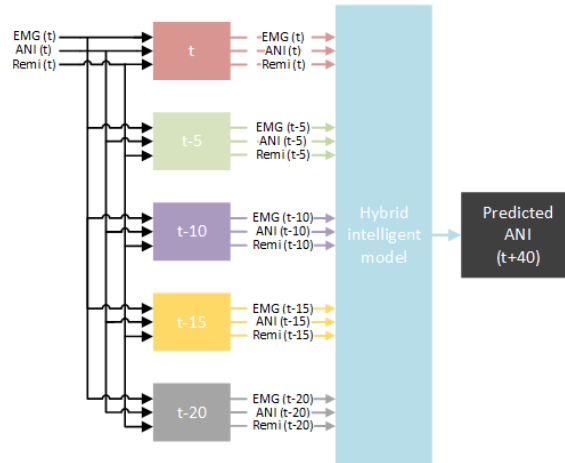


Figura 6.3: Model approach with the timed variables indicated




Figura 6.4: Hybrid intelligent model

6.3.1. Dataset Obtaining and Description

The dataset has been obtained from 15 patients undergoing general anesthesia. The three variables used on this research (Remifentanil drug infusion rate, EMG and ANI) have been monitored during surgeries. A preconditioning stage was considered for the

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA
 UNIVERSIDAD DE LA LAGUNA

Fecha: 20/09/2019 13:27:50

JOSÉ LUIS CALVO ROLLE
 UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:29:29

Juan Albino Méndez Pérez
 UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:30:46

Capítulo 6. Hybrid model for the ANI index prediction using Remifentanyl drug and EMG signal

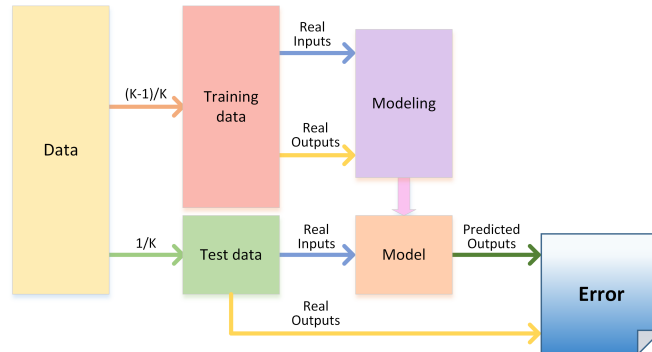


Figura 6.5: Modeling process

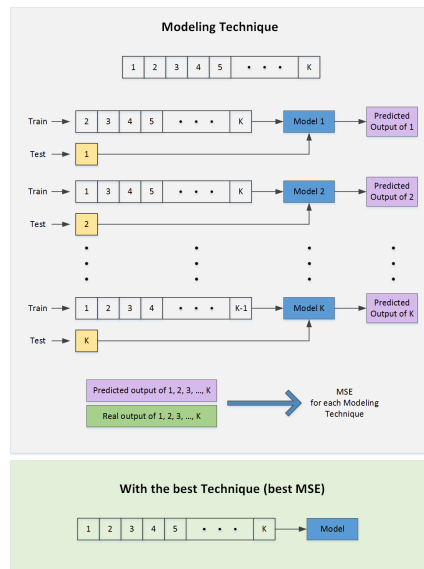


Figura 6.6: K-Fold Training process

signals. The dataset is composed with the data of all patients, recording new set of values with a sample time of 5 seconds. The dataset was initially inspected visually to detect outliers. Additionally, missing measurements were recovered by performing simple interpolation on each data with its neighbours. The induction phase and the

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

6.3 Model approach

recovery phase were not considered in this study; only the maintenance phase of surgery has been used. With the conditions exposed above, the employed dataset contains 19441 samples.

The data registered for two patients was separate in the first processing step to perform the validation at the end of the modeling process; with this validation, the dataset was reduce until 17356 samples. As the model predicts future signals, the dataset had to be prepared in a specific way, and the final dataset had 17200 samples. The last 12 samples for each patient were not used, they do not have the future ANI signal to train the model.

6.3.2. Used Techniques

In this section, the different regression algorithm used to achieved the final Hybrid intelligent model are described. Different configurations for the intelligent regression techniques are tested. The best algorithm and its configuration is chosen based on MSE criteria, using 10 K-Fold Cross-Validation to allow a more general measure than when Hold-Out is used. Moreover, as the Hybrid intelligent model is divided internally in different clusters, a mean MSE (taking into account the number of samples in each cluster) of local model is used to compare the different clusters configurations.

6.3.2.1. Data Clustering - The K-means algorithm

Clustering techniques make data grouping measuring the similarity between samples [30, 24]. These algorithms organize unlabeled data in groups; the samples within a cluster are similar to each other [24]. K-means is a frequently used clustering algorithm with square-error criterion, which minimizes the specific error function shows in Equation 6.1.

$$e = \sum_{k=1}^C \sum_{x \in Q_k} \|x - c_k\|^2 \quad (6.1)$$

where:
 x - new input vector

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 6. Hybrid model for the ANI index prediction using Remifentanil drug and EMG signal

c_k - centroid of cluster k

The obtained clusters depend on the initial centroids and on the K value (number of groups). The most critical election is the choice of K value because it needs certain knowledge of total clusters present in the data and, sometimes, it is extremely uncertain. The K-means clustering algorithm is computationally effective, it works well when the data are close to its cluster, the cluster is hyperspherical in shape and they are well-separated in the hyperspace.

6.3.2.2. Artificial Neural Networks (ANN). Multi-Layer Perceptron (MLP)

A Multi-Layer Perceptron is the most known feedforward Artificial Neural Network [37, 38]. It is due to its simple configuration and its robustness. Despite of that, the ANN architecture must be carefully chosen in order to achieve satisfactory results. MLP is made of one input layer, one or more hidden layers and one output layer. The layers have neurons with an activation function. In a typical configuration, all layer neurons have the same activation function, but this is not a restriction. This function could be step, linear, log-sigmoid or tan-sigmoid.

6.3.2.3. Support Vector Regression (SVR), Least Square Support Vector Regression (LS-SVR)

Support Vector Regression is based on the algorithm of the Support Vector Machines (SVM) for classification. In SVR the data is mapped into a high-dimensional feature space F through a nonlinear plotting and linear regression is done in this space [36].

The Least Square algorithm of SVM is called LS-SVM (Least Square Support Vector Machines). The solution estimation is obtained by solving a system of linear equations, and it is similar to SVM in terms of performance generalization [24, 13, 17]. The use of LS-SVM algorithm to regression is well-known as LS-SVR [25, 12]. In LS-SVR, the insensitive loss function is replaced by a classical squared loss function, which makes the Lagrangian by solving a linear Karush-Kuhn-Tucker.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

6.4. Results

As it was explained, the model was obtained using the current and previous values of the variables to predict the ANI signal in the next 40 seconds. To improve the prediction, a Hybrid intelligent model is selected in this paper.

The MLP-ANN regression algorithm was trained for different configurations; always with one hidden layer, but the number of neurons in the hidden layer varies from 1 to 8. The activation function of this neurons was tan-sigmoid for all tests, and the output layer neuron had a linear activation function to perform regression. The used optimization algorithm was Levenberg-Marquardt; gradient descent was used to finish the training phase, and the performance function was set to mean squared error.

The LS-SVR was trained with the self auto-tuning implemented in the toolbox for MatLab developed by KULeuven-ESAT-SCD. The kernel of the model was set to Radial Basis Function, and the type was 'Function Estimation' to perform regression. The optimization function is 'simplex' and the cost-criterion is 'leaveoneoutlssvm' with 'mse' as a performance function.

Table 6.1 shows the best MAE (Mean Absolute Error) in each cluster. It was decided to show the MAE because, as the ANI signal has a range from 0 to 100, this value is a real percentage of error.

The regression techniques for each cluster are shown in Table 6.2, where the best Hybrid configuration is marked in bold. This choice was made according to the less hybrid MSE, shown in Table 6.3, that was obtained taking into account the number of samples in each cluster.

Once the best configuration is selected, another model is trained with all the data from the 13 patients (without K-Fold Cross-Validation). Given the small size of the dataset and the difficulty of obtaining more data from patients during surgery, the model was validated with the data from 2 patients undergoing a complete surgery. The chart of the real (blue continuous line) and predicted (red dashed line) ANI signals for the first patient are shown in Figure 6.7. In this figure, the black dotted lines are included to represent the times with failures in ANI signal.

The charts figures are divided in different subfigures, and it is possible to appreciate

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 6. Hybrid model for the ANI index prediction using Remifentanil drug and EMG signal

N° of Clusters	Cluster 1	Cluster 2	Cluster 3	Cluster 4	Cluster 5
Global Model	8.2671	-	-	-	-
2	8.6724	7.8817	-	-	-
3	10.3670	7.8255	7.9929	-	-
4	12.3109	7.3376	7.7564	8.2283	-
5	8.4106	12.3932	7.3711	7.7617	8.1807
6	8.5501	13.0157	7.6364	6.8030	8.6106
7	7.0869	8.7982	12.9908	6.8433	7.5856
8	6.8502	8.4535	13.0756	7.5731	6.4382
9	8.3157	6.8406	8.8573	13.0720	7.5834
10	11.2199	11.0361	6.7533	8.4414	12.9735

N° of Clusters	Cluster 6	Cluster 7	Cluster 8	Cluster 9	Cluster 10
Global Model	-	-	-	-	-
2	-	-	-	-	-
3	-	-	-	-	-
4	-	-	-	-	-
5	-	-	-	-	-
6	7.8270	-	-	-	-
7	8.6617	7.8577	-	-	-
8	8.6511	8.1463	8.0148	-	-
9	6.5073	8.6156	8.1677	7.9807	-
10	7.2847	6.4954	8.6857	8.0276	7.8395

Tabla 6.1: Best MAE for each cluster

that the part where the predicted signal has more errors occurs when the real ANI signal has failures (black dotted line). In Figure 6.8, the charts for the second testing patient are shown, and it is possible to confirm that the model achieved good results with no dependence of the patient.

Table 6.4 shows different performance measures calculated with the validation data (not used in the modeling phase). These measures are the MSE, the MAE, and also the NMSE (Normalized MSE) and the MAPE (Mean Absolute Percentage Error).

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

6.5 Conclusions

Nº of Clusters	Cluster 1	Cluster 2	Cluster 3	Cluster 4	Cluster 5
Global Model	ANN8	-	-	-	-
2	ANN7	ANN8	-	-	-
3	LS-SVR	ANN5	ANN6	-	-
4	LS-SVR	ANN7	ANN7	ANN7	-
5	ANN4	LS-SVR	ANN5	ANN7	ANN5
6	LS-SVR	LS-SVR	LS-SVR	LS-SVR	ANN5
7	LS-SVR	ANN2	LS-SVR	LS-SVR	LS-SVR
8	LS-SVR	LS-SVR	LS-SVR	LS-SVR	LS-SVR
9	ANN2	LS-SVR	LS-SVR	LS-SVR	LS-SVR
10	LS-SVR	ANN1	LS-SVR	ANN1	LS-SVR

Nº of Clusters	Cluster 6	Cluster 7	Cluster 8	Cluster 9	Cluster 10
Global Model	-	-	-	-	-
2	-	-	-	-	-
3	-	-	-	-	-
4	-	-	-	-	-
5	-	-	-	-	-
6	ANN6	-	-	-	-
7	ANN4	ANN5	-	-	-
8	ANN6	ANN3	ANN6	-	-
9	ANN2	ANN4	ANN5	ANN5	-
10	LS-SVR	LS-SVR	ANN2	ANN2	ANN4

Tabla 6.2: Best algorithm for each cluster

Nº of Clusters	Cluster 1	Cluster 2	Cluster 3	Cluster 4	Cluster 5
Hybrid MSE	113.0991	112.4629	111.6747	111.8557	112.8173

Nº of Clusters	Cluster 6	Cluster 7	Cluster 8	Cluster 9	Cluster 10
Hybrid MSE	112.2949	112.9054	113.1251	113.2711	111.8772

Tabla 6.3: Hybrid MSE for each combination

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA
 UNIVERSIDAD DE LA LAGUNA

Fecha: 20/09/2019 13:27:50

JOSÉ LUIS CALVO ROLLE
 UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:29:29

Juan Albino Méndez Pérez
 UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:30:46

Capítulo 6. Hybrid model for the ANI index prediction using Remifentanyl drug and EMG signal

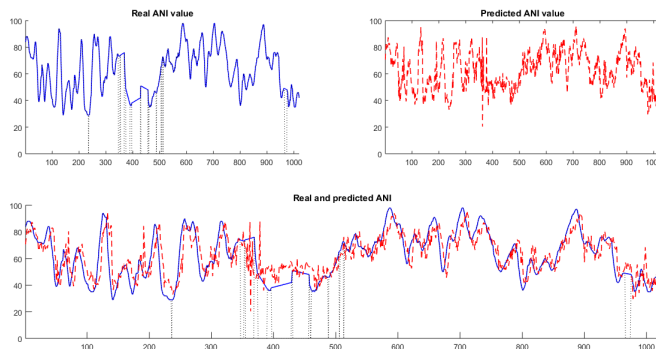


Figura 6.7: All the surgery ANI signal for the first testing patient. Real (blue continuous) and predicted (red dashed) ANI signals




Figura 6.8: All the surgery ANI signal for the second testing patient. Real (blue continuous) and predicted (red dashed) ANI signals

Validation patient	MSE	MAE	NMSE	MAPE
First patient	116.6117	8.2676	0.5672	14.9489 %
Second patient	131.7943	8.8820	0.5570	14.6742 %

Tabla 6.4: Validation performance measures

6.5. Conclusions

Very good results are achieved with the model described in this research. The main aim of the study was to predict the ANI signal. The validation tests using data from

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA
 UNIVERSIDAD DE LA LAGUNA

Fecha: 20/09/2019 13:27:50

JOSÉ LUIS CALVO ROLLE
 UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:29:29

Juan Albino Méndez Pérez
 UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:30:46

6.6 Future works

two patients during a complete surgery showed that the output of the model fits the real signal with very small error.

This model was obtained from a real dataset of 13 patients using a 10 K-Fold Cross-Validation method. The approach is based on intelligent techniques, selecting the best algorithm configuration to train the final model. The tests performed on the Hybrid intelligent model showed that the regression technique whose model leads to lowest MSE is a combination of LS-SVR and ANN with 5 and 6 neurons in the hidden layer. This model achieves an error of at most a 10 % in the prediction, which is very good performance, taking into consideration that the ANI signal range goes from 0 to 100 and the model predicts the signal with 40 second in advance.

From a clinical point of view, the proposal of this Hybrid intelligence model involves different enhancements. Minto proposed a pharmacokinetic model trying to correlate the Remifentanil infusion rate to the effect site concentration in patients [14]. Pharmacodynamics models have been also proposed to relate the effect site concentration to clinical signs [29]. However, this is the first study that establishes a preliminary correlation between the Remifentanil dose and novel measure proposed as a measurement of analgesia. As a result, the Analgesia Nociception Index may be related to the supply of Remifentanil and the presence of painful stimuli considering the EMG information.

The model proposed could be applied to several systems related to different fields with the aim of improving specifications or predicting signals. It is important to emphasize that quite satisfactory results have been obtained with the approach proposed in this research.

6.6. Future works

The present work opens new future research lines. The most important work for accomplishing, could be to increase the prediction time, with the aim to give more reaction time to the medical staff. Then, some advantages are achieving like the fitness drug delivery, problems detection in advance, deviations detection due to other clinical reasons, and so on.

From the automatic control perspective, the availability of a model makes it possible to test new control strategies for the closed-loop of analgesia. Different studies have

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 6. Hybrid model for the ANI index prediction using Remifentanil drug and EMG signal

concluded that closed-loop systems for hypnotic drug supply shows better performance than manual administration [5]. Specifically, the application of predictive control strategies has been applied to the anesthetic scenario due to the results obtained [28, 3]. The model proposed in this study is able to predict the ANI response for a wide time interval. As a result, model based predictive controllers could be also applied.

It could be developed an ANI sensor fault detection based on the deviation of the real signal with the prediction. With the same principle, it could be possible to detect patient problems when there are the above deviations and the sensor is not the problem reason.

Another possible research line is to include more monitored variables during the surgery, with the aim to increase the accurate, and to explore possible interactions between the different administrated drugs. As future works, the possibility of obtaining a wider dataset could enable the authors to validate the final model using nested cross-validation.

Under a more general point of view, the proposed method can be extended to other indicators for health monitoring so that quality of patient monitoring will increased.

6.7. Acknowledgements

Jose M. Gonzalez-Cava's research was supported by the Spanish Ministry of Education, Culture and Sport (www.mecd.gob.es), under the "Formación de Profesorado" grant FPU15/03347.

Conflict of Interests

The authors declare no conflict of interest.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Bibliografía

- [1] A. R. Absalom, V. Mani, T. De Smet, and M. M. R. F. Struys. Pharmacokinetic models for propofol-defining and illuminating the devil in the detail. *British Journal of Anaesthesia*, 103(1):26–37, 2009. ISSN 0007-0912. doi: 10.1093/bja/aep143.
- [2] H. Alaiz Moretón, J. Calvo Rolle, I. García, and A. Alonso Alvarez. Formalization and practical implementation of a conceptual model for pid controller tuning. *Asian Journal of Control*, 13(6):773–784, 2011. doi: 10.1002/asjc.264.
- [3] J. Albino Mendez, S. Torres, J. Antonio Reboso, and H. Reboso. Adaptive computer control of anesthesia in humans. *Computer Methods in Biomechanics and Biomedical Engineering*, 12(6):727–734, 2009. ISSN 1025-5842. doi: 10.1080/10255840902911528.
- [4] E. Boselli, M. Daniela-Ionescu, G. Begou, L. Bouvet, R. Dabouz, C. Magnin, and B. Allaouchiche. Prospective observational study of the non-invasive assessment of immediate postoperative pain using the analgesia/nociception index (ANI). *British Journal of Anaesthesia*, 111(3):453–459, 2013. ISSN 0007-0912. doi: 10.1093/bja/aet110.
- [5] E. Brogi, S. Cyr, R. Kazan, F. Giunta, and T. M. Hemmerling. Clinical performance and safety of closed-loop systems: A systematic review and meta-analysis of randomized controlled trials. *Anesthesia and Analgesia*, 124(2):446–455, 2017. ISSN 0003-2999. doi: 10.1213/ANE.0000000000001372.
- [6] J. L. Calvo-Rolle, J. L. Casteleiro-Roca, H. Quintián, and M. del Carmen Meizoso-Lopez. A hybrid intelligent system for PID controller using in a steel rolling process. *Expert Systems with Applications*, 40(13):5188–5196, 2013. ISSN 0957-4174. doi: 10.1016/j.eswa.2013.03.013.
- [7] J. L. Calvo-Rolle, O. Fontenla-Romero, B. Pérez-Sánchez, and B. Guijarro-Berdinas. Adaptive inverse control using an online learning algorithm for neural networks. *Informatica*, 25(3):401–414, 2014. ISSN 0868-4952. doi: 10.15388/Informatica.2014.20.
- [8] J. L. Calvo-Rolle, H. Quintian-Pardo, E. Corchado, M. del Carmen Meizoso-López, and R. F. García. Simplified method based on an intelligent model to obtain the extinction angle of the current for a single-phase half wave controlled rectifier with resistive and inductive load. *Journal of Applied Logic*, 13(1):37–47, 2015. ISSN 1570-8683. doi: 10.1016/j.jal.2014.11.010.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 6. Hybrid model for the ANI index prediction using Remifentanil drug and EMG signal

- [9] J. Casteleiro-Roca, J. Calvo-Rolle, M. Meizoso-Lopez, A. P. non Pazos, and B. Rodríguez-Gómez. New approach for the QCM sensors characterization. *Sensors and Actuators A: Physical*, 207:1–9, 2014. ISSN 0924-4247. doi: 10.1016/j.sna.2013.12.002.
- [10] J. Casteleiro-Roca, J. Calvo-Rolle, M. Meizoso-López, A. P. nón Pazos, and B. Rodríguez-Gómez. Bio-inspired model of ground temperature behavior on the horizontal geothermal exchanger of an installation based on a heat pump. *Neurocomputing*, 150, Part A:90–98, 2015. ISSN 0925-2312. doi: 10.1016/j.neucom.2014.02.075.
- [11] J. L. Casteleiro-Roca, J. A. M. Pérez, A. J. Piñón-Pazos, J. L. Calvo-Rolle, and E. Corchado. Modeling the electromyogram (EMG) of patients undergoing anesthesia during surgery. In *10th International Conference on Soft Computing Models in Industrial and Environmental Applications*, pages 273–283, 2015. ISBN 978-3-319-19719-7. doi: 10.1007/978-3-319-19719-7_24.
- [12] J. L. Casteleiro-Roca, H. Quintián, J. L. Calvo-Rolle, E. Corchado, M. del Carmen Meizoso-López, and A. Piñón-Pazos. An intelligent fault detection system for a heat pump installation based on a geothermal heat exchanger. *Journal of Applied Logic*, 17:36–47, 2016. doi: 10.1016/j.jal.2015.09.007.
- [13] J.-L. Casteleiro-Roca, J. Calvo-Rolle, J. Méndez Pérez, N. Roqueñí Gutiérrez, and F. de Cos Juez. Hybrid intelligent system to perform fault detection on BIS sensor during surgeries. *Sensors*, 17(1):179, 1 2017. ISSN 1424-8220. doi: 10.3390/s17010179.
- [14] M. C.F., S. T.W., and S. S.L. Pharmacokinetics and pharmacodynamics of remifentanil. model application. *Anesthesiology*, 86:24–33, 1997. doi: 10.1097/0000542-199701000-00005.
- [15] R. Cowen, M. K. Stasiowska, H. Laycock, and C. Bantel. Assessing pain objectively: the use of physiological markers. *Anaesthesia*, 70(7):828–847, 2015. ISSN 1365-2044. doi: 10.1111/anae.13018.
- [16] M. J. Crespo-Ramos, I. Machón-González, H. López-García, and J. L. Calvo-Rolle. Detection of locally relevant variables using SOM-NG algorithm. *Engineering Applications of Artificial Intelligence*, 26(8):1992–2000, 2013. ISSN 0952-1976. doi: 10.1016/j.engappai.2013.04.012.
- [17] L. A. Fernández-Serantes, R. E. Vázquez, J. L. Casteleiro-Roca, J. L. Calvo-Rolle, and E. Corchado. Hybrid intelligent model to predict the SOC of a LFP power

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

6.7 Acknowledgements

- cell type. In *International Conference on Hybrid Artificial Intelligence Systems*, pages 561–572, 2014.
- [18] R. F. García, J. L. C. Rolle, M. R. Gomez, and A. D. Catoira. Expert condition monitoring on hydrostatic self-levitating bearings. *Expert Systems with Applications*, 40(8):2975–2984, 2013. ISSN 0957-4174. doi: 10.1016/j.eswa.2012.12.013.
- [19] R. F. García, J. L. C. Rolle, J. P. Castelo, and M. R. Gomez. On the monitoring task of solar thermal fluid transfer systems using NN based models and rule based techniques. *Engineering Applications of Artificial Intelligence*, 27:129–136, 2014. ISSN 0952-1976. doi: 10.1016/j.engappai.2013.06.011.
- [20] A. Ghanghermeh, G. Roshan, J. A. Orosa, J. L. Calvo-Rolle, and A. M. Costa. New climatic indicators for improving urban sprawl: A case study of tehran city. *Entropy*, 15(3):999–1013, 2013. ISSN 1099-4300. doi: 10.3390/e15030999.
- [21] A. Gritsan, N. Dovbish, D. Kurnosov, and E. Gritsan. Control of the adequacy of analgesia during general anesthesia with the use of the monitor 'analgesia nociception index'. *Anesthesia and Analgesia*, 123(3 supplement):769, 2016. doi: 10.1213/01.ane.0000492984.63279.34.
- [22] M. Gruenewald, T. Schoenherr, J. Herz, C. Ilies, A. Fudickar, and B. Bein. Analgesia nociception index (ANI) for detection of noxious stimulation during sevofluran-remifentanil anaesthesia: 14AP7-8. *European Journal of Anaesthesiology*, 30:223, 2013. ISSN 0265-0215.
- [23] B. Guignard. Monitoring analgesia. *Best Practice & Research Clinical Anaesthesiology*, 20(1):161–180, 2006. ISSN 1521-6896. doi: 10.1016/j.bpa.2005.09.002.
- [24] S. Kaski, J. Sinkkonen, and A. Klami. Discriminative clustering. *Neurocomputing*, 69(1-3):18–41, 2005. ISSN 0925-2312. doi: 10.1016/j.neucom.2005.02.012.
- [25] Y. Li, X. Shao, and W. Cai. A consensus least squares support vector regression (LS-SVR) for analysis of near-infrared spectra of plant samples. *Talanta*, 72(1):217–222, 2007. ISSN 0039-9140. doi: 10.1016/j.talanta.2006.10.022.
- [26] I. Machón-González, H. López-García, and J. L. Calvo-Rolle. A hybrid batch SOM-NG algorithm. In *Neural Networks (IJCNN), The 2010 International Joint Conference on*, pages 1–5, 2010.
- [27] A. Marrero, J. A. Méndez, J. A. Reboso, I. Martín, and J. L. Calvo. Adaptive fuzzy modeling of the hypnotic process in anesthesia. *Journal of Clinical Monitoring and Computing*, 31(2):319–330, 2017. doi: 10.1007/s10877-016-9868-y.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 6. Hybrid model for the ANI index prediction using Remifentanil drug and EMG signal

- [28] J. A. Mendez, A. Marrero, J. A. Rebozo, and A. Leon. Adaptive fuzzy predictive controller for anesthesia delivery. *Control Engineering Practice*, 46:1–9, 2016. ISSN 0967-0661. doi: 10.1016/j.conengprac.2015.09.009.
- [29] C. F. Minto, T. W. Schnider, K. M. Gregg, T. K. Henthorn, and S. L. Shafer. Using the time of maximum effect site concentration to combine pharmacokinetics and pharmacodynamics. *Anesthesiology*, 99(2):324–333, 2003. ISSN 0003-3022. doi: 10.1097/00000542-200308000-00014.
- [30] A. Qin and P. Suganthan. Enhanced neural gas network for prototype-based clustering. *Pattern Recogn.*, 38(8):1275–1288, 8 2005. ISSN 0031-3203. doi: 10.1016/j.patcog.2004.12.007.
- [31] H. Quintián, J. L. Calvo-Rolle, and E. Corchado. A hybrid regression system based on local models for solar energy prediction. *Informatica*, 25(2):265–282, 2014. ISSN 0868-4952. doi: 10.15388/Informatica.2014.14.
- [32] H. Quintian Pardo, J. L. Calvo Rolle, and O. Fontenla Romero. Application of a low cost commercial robot in tasks of tracking of objects. *Dyna*, 79(175):24–33, 2012.
- [33] J. Rolle, I. Gonzalez, and H. Garcia. Neuro-robust controller for non-linear systems. *Dyna*, 86(3):308–317, 2011. doi: 10.6036/3949.
- [34] T. W. Schnider, C. F. Minto, P. L. Gambus, C. Andresen, D. B. Goodale, S. L. Shafer, and E. J. Youngs. The influence of method of administration and covariates on the pharmacokinetics of propofol in adult volunteers. *ANESTHESIOLOGY*, 88(5):1170–1182, 1998. ISSN 0003-3022. doi: 10.1097/00000542-199805000-00006.
- [35] T. W. Schnider, C. F. Minto, S. L. Shafer, P. L. Gambus, C. Andresen, D. B. Goodale, and E. J. Youngs. The influence of age on propofol pharmacodynamics. *ANESTHESIOLOGY*, 90(6):1502–1516, 1999. ISSN 0003-3022. doi: 10.1097/00000542-199906000-00003.
- [36] V. Vapnik. *The nature of statistical learning theory*. Springer, 1995.
- [37] P. Wasserman. *Advanced methods in neural computing*. John Wiley & Sons, Inc., New York, NY, USA, 1st edition, 1993. ISBN 0442004613.
- [38] Z. Zeng and J. Wang. *Advances in neural network research and applications*. Springer Publishing Company, Incorporated, 1st edition, 2010. ISBN 3642129897, 9783642129896.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

CAPÍTULO 7

Conclusiones

Las principales conclusiones generales que se pueden extraer de este trabajo de investigación se relacionan en los siguientes puntos:

- Se ha desarrollado un procedimiento de obtención de un modelo híbrido inteligente para aplicar a variados tipos de sistemas.
- El modelo híbrido permite obtener mejores resultados que aplicando modelos globales.
- La versatilidad del procedimiento permite poder seleccionar tanto el error como el método de validación que se considere oportuno en cada caso.

Como conclusiones específicas del primer caso de estudio presentado, se puede mencionar que se ha creado un modelo híbrido para predecir la evolución de la señal BIS durante operaciones quirúrgicas. El mejor error se obtuvo con un modelo híbrido con dos grupos, utilizando dos redes neuronales independientes en cada uno, con un MSE de 0.4097. Este modelo se utilizó para realizar detección de fallos en el sensor del BIS, comparando las lecturas reales con las predichas por el modelo. En todas las pruebas realizadas con datos de operaciones reales, el modelo consiguió detectar el fallo en el sensor.

Del segundo caso de estudio, se puede remarcar que el modelo propuesto ha servido para la creación de un sensor virtual. En esta ocasión se modeló el estado de carga de una batería, y se obtuvieron unos resultados altamente satisfactorios. Hay que tener en cuenta que no existe un sensor específico para poder medir esa variable, y se han utilizado sensores de temperatura, tensión y corriente como entradas al modelo. En este caso, además, la asignación de grupos tenía un significado físico, ya que los 4 grupos representaban cada uno a los 4 estados posibles en las pruebas de la batería.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Capítulo 7. Conclusiones

En el tercer y último trabajo presentado, el modelo predice el valor de la señal ANI en un tiempo futuro, durante la sedación de un paciente. Concretamente, el modelo obtiene el valor mencionado con 20 segundos de adelanto. En este caso, a pesar de que los errores obtenidos son más altos que en los casos anteriores, la validez del modelo radica en la predicción de la tendencia, y no tanto en el valor específico de la señal. Se considera de especial importancia este modelo, ya que hasta ahora no se conoce ninguno similar para este tipo de señal.

Cabría destacar, después de estas menciones específicas, que el modelo desarrollado es válido para múltiples y variados tipos de sistemas y aplicaciones. El no tener limitaciones a la hora de definir entradas, métodos de validación ni tipos de error, permite ajustar el modelo híbrido a cada sistema, obteniendo en todos los casos los mejores resultados.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

CAPÍTULO 8



Trabajos futuros

Son múltiples las posibilidades de estudio que se pueden abordar a partir de los logros alcanzados en el presente trabajo de investigación. Han surgido, además, gran cantidad de ideas a partir de las experiencias, consecuencia de aplicación de los diferentes métodos contemplados en la propuesta.

De forma más concreta, como continuidad de esta tesis doctoral, se relacionan a continuación algunas de las diversas líneas a abordar en el futuro :

- Experimentar alternativos o nuevos métodos, no contemplados, de regresión y detección de variables significativas, que contribuyan a conseguir mejores resultados que los del presente trabajo. Incluso con los métodos empleados, se contempla la posibilidad de conseguir mejoras incorporando nuevas variables de las que se pueda disponer de los diferentes casos de estudio.
- Comparar como influye en el modelado híbrido descrito la utilización de diferentes algoritmos de agrupamiento (DBSCAN, EM-GMM, AHC, etc.).
- Descubrir y desarrollar nuevos métodos que contemplen otro tipo de obtención de conocimiento, con el fin de complementar y hacer los modelos más precisos y fiables.
- Teniendo en cuenta que los sistemas reales son variantes en el tiempo, se plantea establecer una metodología para la creación de modelos *Ad-Hoc*, que sirvan de base para obtener una mejor predicción.
- Por la misma razón que el punto anterior, se plantea estudiar la implementación de alguna metodología adaptativa, que permita mejorar la validez del modelo en el tiempo.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA
UNIVERSIDAD DE LA LAGUNA

Fecha: 20/09/2019 13:27:50

JOSÉ LUIS CALVO ROLLE
UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:29:29

Juan Albino Méndez Pérez
UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:30:46

Capítulo 8. Trabajos futuros

- Estudiar la posibilidad de creación de una base de conocimiento para dar apoyo a la nueva casuística. La base se iría formando con los modelos generados para cada caso concreto y que puedan tener cierta similitud en sistemas semejantes.
- Intentar conseguir mayores horizontes de predicción cuando se trate de predecir el comportamiento de una determinada variable en el tiempo, .

Como trabajos futuros específicos de los casos de estudio expuestos en el presente documento se recogen los siguientes:

- Desde un punto de vista clínico, por un lado, se pueden considerar otros escenarios como una infusión de Remifentanil variable. Esto requerirá la implementación de un nuevo modelo utilizando la infusión de este fármaco como entrada. Además, se puede explorar la extensión a la anestesia inhalatoria. Desde una perspectiva más general, el método propuesto se puede extender también a otros dispositivos sensores para la monitorización de la salud, de modo que la calidad de la supervisión del paciente se incrementará, previsiblemente, de forma significativa.
- La temperatura medida en la celda de una batería es un parámetro muy importante relacionado con el correcto funcionamiento del dispositivo. Utilizando las temperaturas medidas en las pruebas, se podría realizar un estudio y un modelado de estos parámetros con el fin de detectar desviaciones en el comportamiento. Este nuevo modelo se usaría junto con un algoritmo clasificador para detectar cualquier fallo o anomalía en este tipo de sistemas.
- Uno de los retos más importantes es aumentar el horizonte de predicción, con el objetivo de dar más tiempo de reacción al personal médico. Con esto se estarían logrando algunas ventajas como la administración de medicamentos para el estado físico, la detección anticipada de problemas, la detección de desviaciones debido a otras razones clínicas, etc.
- Desde una perspectiva del control automático, la disponibilidad de un modelo permite probar nuevas estrategias de control de analgesia. Diferentes estudios han concluido que los sistemas en lazo cerrado para el suministro de medicamentos hipnóticos, muestran un mejor rendimiento que la administración manual del fármaco. Concretamente, se han aplicado estrategias de control predictivo al escenario anestésico, obteniendo buenos resultados. El modelo propuesto en este estudio es capaz de predecir la respuesta ANI durante un amplio intervalo de

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

tiempo. En consecuencia, también se podrían aplicar controladores predictivos basados en modelos.

- Se prevé la posibilidad de desarrollar un método de detección de anomalías, basado en la desviación de la señal real del sensor ANI y su valor predicho. Con el mismo principio, se podría estudiar la posibilidad de detectar problemas en el paciente cuando existen las desviaciones mencionadas, y el sensor está funcionando de forma correcta.
- Otra posible línea de investigación sería incluir más variables monitorizadas durante la cirugía, con el objetivo de aumentar la precisión y explorar posibles interacciones entre los diferentes medicamentos administrados al paciente. También se plantea la posibilidad de obtener un conjunto de datos más amplio que permita validar el modelo final mediante validación del modelo.
- Desde un punto de vista más general, el método propuesto se puede extender a otros indicadores monitorizados durante la intervención quirúrgica, de modo que el paciente esté sometido a un mayor control.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA
UNIVERSIDAD DE LA LAGUNA

Fecha: 20/09/2019 13:27:50

JOSÉ LUIS CALVO ROLLE
UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:29:29

Juan Albino Méndez Pérez
UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:30:46

Capítulo 8. Trabajos futuros

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Justificantes de los artículos

Se incluyen a continuación las portadas de los artículos presentados en los capítulos 4, 5 y 6.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46



Article

Hybrid Intelligent System to Perform Fault Detection on BIS Sensor During Surgeries

José-Luis Casteleiro-Roca ^{1,*†}, José Luis Calvo-Rolle ^{1,*†‡}, Juan Albino Méndez Pérez ^{2,†},
Nieves Roqueñi Gutiérrez ^{3,†} and Francisco Javier de Cos Juez ^{4,†}

¹ Department of Industrial Engineering, Universidade da Coruña, 15405 Coruña, Spain

² Departamento de Ingeniería Informática y de Sistemas, Universidad de La Laguna, Apdo. 456; 38200 La Laguna, Spain; jamendez@ull.edu.es

³ Project Engineering Area, Department of Exploitation and Exploration of Mines, University of Oviedo, 33004 Oviedo, Spain; nievesr@uniovi.es

⁴ Prospecting and Exploitation of Mines Department, University of Oviedo, 33004 Oviedo, Spain; fcos@uniovi.es

* Correspondence: jose.luis.casteleiro@udc.es (J.-L.C.-R.); jlcavo@udc.es (J.L.C.-R.); Tel.: +34-881-013-119 (J.-L.C.-R.)

† These authors contributed equally to this work.

‡ Current address: Department of Industrial Engineering, University of Coruña, 15405 Coruña, Spain.

Academic Editor: Gonzalo Pajares Martinsanz

Received: 31 October 2016; Accepted: 12 January 2017; Published: 18 January 2017

Abstract: This paper presents a new fault detection system in hypnotic sensors used for general anesthesia during surgery. Drug infusion during surgery is based on information received from patient monitoring devices; accordingly, faults in sensor devices can put patient safety at risk. Our research offers a solution to cope with these undesirable scenarios. We focus on the anesthesia process using intravenous propofol as the hypnotic drug and employing a Bispectral Index (BIS™) monitor to estimate the patient's unconsciousness level. The method developed identifies BIS episodes affected by disturbances during surgery with null clinical value. Thus, the clinician—or the automatic controller—will not take those measures into account to calculate the drug dose. Our method compares the measured BIS signal with expected behavior predicted by the propofol dose provider and the electromyogram (EMG) signal. For the prediction of the BIS signal, a model based on a hybrid intelligent system architecture has been created. The model uses clustering combined with regression techniques. To validate its accuracy, a dataset taken during surgeries with general anesthesia was used. The proposed fault detection method for BIS sensor measures has also been verified using data from real cases. The obtained results prove the method's effectiveness.

Keywords: EMG; BIS; clustering; MLP; SVM; anesthesia; dosification

1. Introduction

Anesthesia control has aroused the attention of many scientists in recent years in order to move towards personalized drug infusion [1,2], where the drug dose infused to the patient is calculated according to precise individualized measures in the operating room. The three main variables that the clinician has to pay attention to during surgery are hypnosis, analgesia, and neuromuscular blockade. Hypnosis measures the patient's unconsciousness level, analgesia is related to pain mitigation, and neuromuscular blockade refers to immobility.

Although control of analgesia is still a challenge, significant advances have been made in the automatic control of hypnosis and neuromuscular blockade [3,4]. For hypnosis control, different techniques using both signal-based and mode-based methodologies have been used successfully [5–7]. “Intelligent” techniques have also been implemented [8].

Sensors **2017**, *17*, 179; doi:10.3390/s17010179

www.mdpi.com/journal/sensors

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46



Research Article

Power Cell SOC Modelling for Intelligent Virtual Sensor Implementation

José-Luis Casteleiro-Roca,¹ Esteban Jove,¹ Fernando Sánchez-Lasheras,²
Juan-Albino Méndez-Pérez,³ José-Luis Calvo-Rolle,¹ and Francisco Javier de Cos Juez⁴

¹Department of Industrial Engineering, University of A Coruña, A Coruña, Spain

²Department of Construction and Manufacturing Engineering, University of Oviedo, Oviedo, Spain

³Department of Computer Science and System Engineering, University of La Laguna, Tenerife, Spain

⁴Department of Mining Exploitation and Prospecting, University of Oviedo, Oviedo, Spain

Correspondence should be addressed to Fernando Sánchez-Lasheras; sanchezfernando@uniovi.es

Received 8 February 2017; Revised 15 June 2017; Accepted 10 July 2017; Published 28 August 2017

Academic Editor: Eduard Llobet

Copyright © 2017 José-Luis Casteleiro-Roca et al. This is an open access article distributed under the Creative Commons Attribution License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.

Batteries are one of the principal components in electric vehicles and mobile electronic devices. They operate based on electrochemical reactions, which are exhaustively tested to check their behavior and to determine their characteristics at each working point. One remarkable issue of batteries is their complex behavior. The power cell type under analysis in this research is a LFP (Lithium Iron Phosphate LiFePO₄). The purpose of this research is to predict the power cell State of Charge (SOC) by creating a hybrid intelligent model. All the operating points measured from a real system during a capacity confirmation test make up the dataset used to obtain the model. This dataset is clustered to obtain different behavior groups, which are used to develop the final model. Different regression techniques such as polynomial regression, support vector regression (SVR), and artificial neural networks (ANN) have been implemented for each cluster. A combination of these methods is performed to achieve an intelligent model. The SOC of the power cell can be predicted by this hybrid intelligent model, and good results are achieved.

1. Introduction

An electrical energy storage system is the most frequently used technology to solve the problem of intermittent energy production in renewable energy systems [1]. In renewable energy systems, the electric energy storage is used as a method of storing the energy when production is higher than demand and returning the energy when demand is higher than production. Also, these systems are used to supply portable devices or replace the fossil fuels in vehicles, such as in electric vehicles [1].

Nowadays, an increasing number of studies aim to improve electrical energy storage systems. Some research is focused on dealing with intermittent energy generation in renewable energy such as solar and wind power systems, proposing to implement those methods in Smart Grid systems [2]. Furthermore, the increasing use of portable devices like tablets or smartphones, which improve quality of life,

demands higher autonomy, less charging time, or less weight at the energy storage components [3].

On the other hand, the electric vehicle forces the development and improvement of storage systems. Currently, a noticeable problem of the electric vehicle is the driving range, which is related to the storage system. Although the internal combustion engine is inefficient, it does at least provide long driving range due to the high energy density of fossil fuels [4].

This paper is focused on battery storage systems and especially on a Lithium-Ion (Li-Ion) power cell, which is commonly utilized in electric vehicles. The frequent use of this type of cells makes it possible to identify different characteristics, such as ageing forecasts, charging, and discharging behavior. This information is very important to model the power cells properly [5].

Li-Ion power cells are good candidates for electromobility and the renewable energy industry. The reasons why this battery is suitable for electric drive vehicles are its high

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA
UNIVERSIDAD DE LA LAGUNA

Fecha: 20/09/2019 13:27:50

JOSÉ LUIS CALVO ROLLE
UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:29:29

Juan Albino Méndez Pérez
UNIVERSIDAD DE LA LAGUNA

20/09/2019 13:30:46

120

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46



Hybrid model for the ANI index prediction using Remifentanil drug and EMG signal

José-Luis Casteleiro-Roca^{1,2} · Esteban Jove^{1,2} · Jose M. Gonzalez-Cava² · Juan Albino Méndez Pérez² · José Luis Calvo-Rolle¹ · Francisco Blanco Alvarez³

Received: 13 February 2018 / Accepted: 23 June 2018
© The Natural Computing Applications Forum 2018

Abstract

With the aim to control and reduce the pain of patients during a surgery with general anesthesia, one of the main challenges is the proposal of safe an optimal and efficient methods of drugs administering. First step to achieve this goal is the proposal and development of right indexes that correlate satisfactory with analgesia. One of this index gives the most hopeful results is the Analgesia Nociception Index (ANI). The present research work deals the ANI response of patients during surgeries with general anesthesia with intravenous drug infusion. The main aim is to predict the ANI signal behavior regarding of the analgesic infusion rate. To do that, a hybrid intelligent model is developed, using clustering and regression techniques based on artificial neural networks and support vector regression. The proposal was validated with a dataset of surgeries real cases of patients undergoing general anesthesia. The achieved results attest for the potential of the proposed technique.

Keywords ElectroMyoGram signal (EMG) · Analgesia Nociception Index (ANI) · Multi-layer perceptron (MLP) · Support vector regression (SVR)

1 Introduction

Supplying the proper dose of drug in patients undergoing general anesthesia has become an important challenge in medicine. Anesthesiologist must control the level of hypnosis, analgesia and muscle relaxation during surgery. As a general rule, they evaluate the state of patients by means of clinical signs and then decide whether increasing or decreasing the corresponding drug dose manually. Nowadays, different automatic controllers have been proposed in

order to adapt the drug titration automatically. Specifically, automatic control of hypnosis has been widely researched [1, 2]. However, the automatic control of analgesia is still a problem to face. Closed-loop control strategies are based on the use of a feedback variable. Nevertheless, the absence of a feedback variable capable of measuring the analgesic state of patient has become the main problem for the automation.

Traditional methods have been based on the evaluation of the autonomic reactions [3]. Currently, new monitors and sensors [4, 5] have been proposed in order to measure analgesia [6]. Among the different possibilities, the Analgesia Nociception Index (ANI), developed by Moloris Medical Systems, is supposed to be designed to optimize drug delivery in the analgesic process. It is able to compute an index that ranges from 0 to 100 in order to quantify the parasympathetic activity in patients undergoing surgery. Previous successful results have been reached when using the ANI to guide analgesic delivery [7–9]. However, more research is needed in order to validate the Analgesia Nociception Index as a measure of analgesia.

✉ José-Luis Casteleiro-Roca
jose.luis.casteleiro@udc.es

- ¹ Department of Industrial Engineering, University of A Coruña, Avda. 19 de febrero s/n, 15495 Ferrol, A Coruña, Spain
- ² Department of Computer Science and System Engineering, University of La Laguna, Avda. Astrof. Francisco Sánchez s/n, 38200 S/C de Tenerife, Spain
- ³ Departamento de Ciencia de los Materiales e Ingeniería Metalúrgica, University of Oviedo, Calle San Francisco, 1, 33004 Oviedo, Spain

Published online: 06 July 2018



Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

122

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Publicaciones del doctorando

En este capítulo se recogen las publicaciones del doctorando que indican la calidad y difusión de su actividad investigadora. Se presentan por orden cronológico, y según el tipo de publicación.

■ Publicaciones científicas indexadas en el JCR

1. A hybrid intelligent system for PID controller using in a steel rolling process [7]
2. New approach for the QCM sensors characterization [10]
3. Bio-inspired model of ground temperature behavior on the horizontal geothermal exchanger of an installation based on a heat pump [11]
4. Expert system development to assist on the verification of “TACAN” system performance [55]
5. An intelligent fault detection system for a heat pump installation based on a geothermal heat exchanger [16]
6. El sector eléctrico desde su inicio hasta la segunda guerra mundial [5]
7. Hybrid Intelligent System to Perform Fault Detection on BIS Sensor During Surgeries [17]
8. Gestión de almacenamiento energético para instalaciones de generación-distribución [59]
9. Evolución del sector eléctrico tras la Segunda Guerra Mundial [57]
10. Power cell SOC modelling for intelligent virtual sensor implementation [18]
11. A novel fuzzy algorithm to Introduce new variables in the drug supply decision-making process in medicine [30]
12. Hybrid intelligent system to predict the individual academic performance of engineering students [43]
13. Hybrid model for the ANI index prediction using remifentanil drug and EMG signal [21]

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

14. Modelling the hypnotic patient response in general anaesthesia using intelligent models [40]
 15. Fuel cell output current prediction with a hybrid intelligent system [22]
 16. Intelligent model for electromyogram (EMG) signal prediction during anaesthesia [25]
 17. A fault detection system based on unsupervised techniques for industrial control loops [45]
 18. Short-term energy demand forecast in hotels using hybrid intelligent modeling [24]
 19. A fault detection system for a geothermal heat exchanger sensor based on intelligent techniques [2]
 20. Electromyogram prediction during anaesthesia by using a hybrid intelligent model [23]
 21. Anomaly detection based on intelligent techniques over a bicomponent production plant used on wind generator blades manufacturing [50]
 22. Intelligent hybrid system for the prediction of the voltage-current characteristic curve of a hydrogen-based fuel cell [26]
- Publicaciones científicas indexadas de acuerdo con un índice de calidad relativo
 1. Posibilidades para la gestión de almacenamiento energético para instalaciones de generación-distribución [67]
 - Congresos internacionales indexados de acuerdo con un índice de calidad relativo
 1. Intelligent model for fault detection on geothermal exchanger of a heat pump [13]
 2. Intelligent model to obtain initial and final conduction angle of a diode in a half wave rectifier with a capacitor filter [14]
 3. Study of the effect of a geothermal heat exchanger over the ground [9]
 4. Modeling of bicomponent mixing system used in the manufacture of wind generator blades [36]
 5. Hybrid intelligent model to predict the SOC of a LFP power cell type [28]
 6. Modeling the electromyogram (EMG) of patients undergoing anaesthesia during surgery [15]
 7. A new way to improve subject selection in engineering degree studies [54]

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

8. Student performance prediction applying missing data imputation in electrical engineering studies degree [27]
 9. Hybrid intelligent model for fault detection of a lithium iron phosphate power cell used in electric vehicles [63]
 10. An intelligent model for bispectral index (BIS) in patients undergoing general anesthesia [19]
 11. PID-ITS: An intelligent tutoring system for PID tuning learning process [37]
 12. A machine learning based system for analgesic drug delivery [29]
 13. An intelligent model to predict ANI in patients undergoing general anesthesia [41]
 14. Attempts prediction by missing data imputation in engineering degree [38]
 15. Bioclimatic house heat exchanger behavior prediction with time series modeling [6]
 16. A new approach for system malfunctioning over an industrial system control loop based on unsupervised techniques [46]
 17. Prediction of the energy demand of a hotel using an artificial intelligence-based model [20]
 18. Sensor fault detection and recovery methodology for a geothermal heat exchanger [1]
 19. Remifentanyl dose prediction for patients during general anesthesia [42]
 20. Outlier generation and anomaly detection based on intelligent one-class techniques over a bicomponent mixing system [47]
 21. Anomaly detection on patients undergoing general anesthesia [49]
 22. A global classifier implementation for detecting anomalies by using one-class techniques over a laboratory plant [48]
 23. Anomaly detection over an ultrasonic sensor in an industrial plant [44]
 24. Prediction of student performance through an intelligent hybrid model [3]
- Congresos nacionales
1. Ajuste automático en lazo abierto del regulador de un horno didáctico [31]
 2. Exposición para alumnos de bachiller de una planta de laboratorio de control automático [32]
 3. Introducción histórica a la automática. Primera lección de fundamentos de automática [52]

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

4. Inicio de la automatización del cálculo. Del ábaco al ordenador [53]
5. Redes neuronales artificiales en un regulador PID para control automático del rumbo de un buque [33]
6. Sistema de control por computador - Unificación de criterios [35]
7. La administración de recursos aplicada al mantenimiento de dispositivos de campo [65]
8. Administración de recursos reforzada mediante supervisión de elementos finales de control [66]
9. Diseño de un regulador Fuzzy para planta de laboratorio [34]
10. Sistema híbrido para la predicción del funcionamiento de una celda de combustible basada en hidrógeno, empleada en el almacenamiento de energía [51]
11. Aprendizaje de sensorizado de entornos IoT mediante BeagleBone [4]

■ Libros

1. Investigación de nuevos métodos prácticos de enseñanza en control [12]
2. Estudio y análisis de métodos y técnicas de control de temperatura [39]
3. Estudio de sistemas de control con equipos industriales comerciales: análisis y estudio [64]

■ Capítulos de libros

1. Regression methods to a gain scheduling PID controller to guarantee the automatic steering of ships [62]
2. Knowledge model approach based in rules for TACAN air navigation system [68]
3. Energy management strategies to improve electrical networks using storage systems [56]
4. Intelligent expert system to optimize the quartz crystal microbalance (QCM) characterization test: intelligent system to optimize the QCM characterization test [8]
5. Energy management strategies to improve electrical networks using storage systems [58]
6. An energy storage system: experimental proposal for the efficiency improvement of the electrical network management [60]

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

- Patentes

1. QCM'CH v1.0 - Registro de software [61]

- Premios y reconocimientos

1. Premio al mejor artículo científico presentado en los congresos internacionales PAAMS, DCAI, Isaml, PACBB, Mis4tel, Blockchain y Decom [48]

Bibliografía

- [1] H. Alaiz-Moretón, J. L. Casteleiro-Roca, L. F. Robles, E. Jove, M. Castejón-Limas, and J. L. Calvo-Rolle. Sensor fault detection and recovery methodology for a geothermal heat exchanger. In F. J. de Cos Juez, J. R. Villar, E. A. de la Cal, Á. Herrero, H. Quintián, J. A. Sáez, and E. Corchado, editors, *Hybrid Artificial Intelligent Systems*, pages 171–184, Cham, 2018. Springer International Publishing. ISBN 978-3-319-92639-1.
- [2] H. Alaiz-Moretón, M. Castejón-Limas, J.-L. Casteleiro-Roca, E. Jove, L. Fernández Robles, and J. L. Calvo-Rolle. A fault detection system for a geothermal heat exchanger sensor based on intelligent techniques. *Sensors*, 19(12), 2019. ISSN 1424-8220. doi: 10.3390/s19122740.
- [3] H. Alaiz-Moretón, J. A. L. Vázquez, H. Quintián, J.-L. Casteleiro-Roca, E. Jove, and J. L. Calvo-Rolle. Prediction of student performance through an intelligent hybrid model. In H. Pérez García, L. Sánchez González, M. Castejón Limas, H. Quintián Pardo, and E. Corchado Rodríguez, editors, *Hybrid Artificial Intelligent Systems*, pages 710–721, Cham, 2019. Springer International Publishing. ISBN 978-3-030-29859-3.
- [4] C. B.-B. F. F. S. J.-L. C.-R.-H. A.-M.-T. G.-A. Alejandro Millan del Rio, José Alberto Benítez Andrades. Aprendizaje de sensorizado de entornos IoT mediante BeagleBone. In *XL Jornadas de Automática*, Ferrol, 2019. doi: 10.17979/spudc.9788497497169.302.
- [5] J. Aurelio Montero-Sousa, J. Luis Casteleiro-Roca, and J. Luis Calvo-Rolle. The electricity sector since its inception until the second world war. *DYNA*, 92(1): 43–47, 2017.
- [6] B. Baruque, E. Jove, J. L. Casteleiro-Roca, S. Porras, J. L. Calvo-Rolle, and E. Corchado. Bioclimatic house heat exchanger behavior prediction with time

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

series modeling. In H. Pérez García, J. Alfonso-Cendón, L. Sánchez González, H. Quintián, and E. Corchado, editors, *International Joint Conference SOCO'17-CISIS'17-ICEUTE'17 León, Spain, September 6–8, 2017, Proceeding*, pages 112–124, Cham, 2018. Springer International Publishing. ISBN 978-3-319-67180-2.

- [7] J. L. Calvo-Rolle, J. L. Casteleiro-Roca, H. Quintián, and M. del Carmen Meizoso-Lopez. A hybrid intelligent system for pid controller using in a steel rolling process. *Expert Systems with Applications*, 40(13):5188–5196, 2013. ISSN 0957-4174. doi: 10.1016/j.eswa.2013.03.013.
- [8] J. L. Calvo-Rolle, J. L. Casteleiro-Roca, M. del Carmen Meizoso-López, A. J. Piñón-Pazos, and J. A. Mendez-Perez. Intelligent expert system to optimize the quartz crystal microbalance (qcm) characterization test: Intelligent system to optimize the qcm characterization test. In *Handbook of Research on Soft Computing and Nature-Inspired Algorithms*, pages 469–488. IGI Global, 2017. ISBN 978-1-5225-2128-0.
- [9] J. Casteleiro-Roca, L. Fernández-Serantes, J. Calvo-Rolle, I. Machón-González, M. Crespo-Ramos, and H. López-García. Study of the effect of a geothermal heat exchanger over the ground. In *2013 International Conference on New Concepts in Smart Cities: Fostering Public and Private Alliances (SmartMILE)*, pages 1–6, 2013. doi: 10.1109/SmartMILE.2013.6708197.
- [10] J. Casteleiro-Roca, J. Calvo-Rolle, M. Meizoso-Lopez, A. Piñón-Pazos, and B. Rodríguez-Gómez. New approach for the QCM sensors characterization. *Sensors and Actuators A: Physical*, 207:1–9, 2014. ISSN 0924-4247. doi: 10.1016/j.sna.2013.12.002.
- [11] J. Casteleiro-Roca, J. Calvo-Rolle, M. Meizoso-López, A. Piñón-Pazos, and B. Rodríguez-Gómez. Bio-inspired model of ground temperature behavior on the horizontal geothermal exchanger of an installation based on a heat pump. *Neurocomputing*, 150:90–98, 2015. ISSN 0925-2312. doi: 10.1016/j.neucom.2014.02.075.
- [12] J. L. Casteleiro-Roca and J. L. Calvo-Rolle. *Investigación de nuevos métodos prácticos de enseñanza en control*. Editorial Académica Española, 2012. ISBN 978-3-8443-3587-3.
- [13] J. L. Casteleiro-Roca, H. Quintián, J. L. Calvo-Rolle, E. Corchado, and M. del Carmen Meizoso-López. Intelligent model for fault detection on geothermal exchanger of a heat pump. In Á. Herrero, B. Baroque, F. Klett, A. Abraham, V. Snášel, A. C.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

de Carvalho, P. G. Bringas, I. Zelinka, H. Quintián, and E. Corchado, editors, *International Joint Conference SOCO'13-CISIS'13-ICEUTE'13*, pages 237–247, Cham, 2014. Springer International Publishing. ISBN 978-3-319-01854-6.

- [14] J. L. Casteleiro-Roca, H. Quintián, J. L. Calvo-Rolle, E. Corchado, and M. del Carmen Meizoso-López. Intelligent model to obtain initial and final conduction angle of a diode in a half wave rectifier with a capacitor filter. In Á. Herrero, B. Baruque, F. Klett, A. Abraham, V. Snášel, A. C. de Carvalho, P. G. Bringas, I. Zelinka, H. Quintián, and E. Corchado, editors, *International Joint Conference SOCO'13-CISIS'13-ICEUTE'13*, pages 121–130, Cham, 2014. Springer International Publishing. ISBN 978-3-319-01854-6.
- [15] J. L. Casteleiro-Roca, J. A. M. Pérez, A. J. Piñón-Pazos, J. L. Calvo-Rolle, and E. Corchado. Modeling the electromyogram (EMG) of patients undergoing anesthesia during surgery. In Á. Herrero, J. Sedano, B. Baruque, H. Quintián, and E. Corchado, editors, *10th International Conference on Soft Computing Models in Industrial and Environmental Applications*, pages 273–283, Cham, 2015. Springer International Publishing. ISBN 978-3-319-19719-7.
- [16] J. L. Casteleiro-Roca, H. Quintián, J. L. Calvo-Rolle, E. Corchado, M. del Carmen Meizoso-López, and A. Piñón-Pazos. An intelligent fault detection system for a heat pump installation based on a geothermal heat exchanger. *Journal of Applied Logic*, 17:36–47, 2016. ISSN 1570-8683. doi: 10.1016/j.jal.2015.09.007.
- [17] J.-L. Casteleiro-Roca, J. L. Calvo-Rolle, J. A. Méndez Pérez, N. Roqueñí Gutiérrez, and F. J. De Cos Juez. Hybrid intelligent system to perform fault detection on BIS sensor during surgeries. *Sensors*, 17(1), 2017. ISSN 1424-8220. doi: 10.3390/s17010179.
- [18] J.-L. Casteleiro-Roca, E. Jove, F. Sánchez-Lasheras, J.-A. Méndez-Pérez, J.-L. Calvo-Rolle, and F. J. de Cos Juez. Power cell SOC modelling for intelligent virtual sensor implementation. *Journal of Sensors*, 2017, 2017.
- [19] J. L. Casteleiro-Roca, J. A. M. Pérez, J. A. Rebozo-Morales, F. J. de Cos Juez, F. J. Pérez-Castelo, and J. L. Calvo-Rolle. An intelligent model for bispectral index (BIS) in patients undergoing general anesthesia. In M. Graña, J. M. López-Guede, O. Etxaniz, Á. Herrero, H. Quintián, and E. Corchado, editors, *International Joint Conference SOCO'16-CISIS'16-ICEUTE'16*, pages 290–300, Cham, 2017. Springer International Publishing. ISBN 978-3-319-47364-2.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

- [20] J.-L. Casteleiro-Roca, J. F. Gómez-González, J. L. Calvo-Rolle, E. Jove, H. Quintián, J. F. A. Martín, S. G. Perez, B. G. Diaz, F. Calero-Garcia, and J. A. Méndez-Perez. Prediction of the energy demand of a hotel using an artificial intelligence-based model. In F. J. de Cos Juez, J. R. Villar, E. A. de la Cal, Á. Herrero, H. Quintián, J. A. Sáez, and E. Corchado, editors, *Hybrid Artificial Intelligent Systems*, pages 586–596, Cham, 2018. Springer International Publishing. ISBN 978-3-319-92639-1.
- [21] J.-L. Casteleiro-Roca, E. Jove, J. M. Gonzalez-Cava, J. A. Méndez Pérez, J. L. Calvo-Rolle, and F. Blanco Alvarez. Hybrid model for the ANI index prediction using remifentanyl drug and EMG signal. *Neural Computing and Applications*, 2018. ISSN 1433-3058. doi: 10.1007/s00521-018-3605-z.
- [22] J.-L. Casteleiro-Roca, A. J. Barragán, F. Segura, J. L. Calvo-Rolle, and J. M. Andújar. Fuel cell output current prediction with a hybrid intelligent system. *Complexity*, 2019, 2019.
- [23] J.-L. Casteleiro-Roca, M. Gomes, J. A. Méndez-Pérez, H. Alaiz-Moretón, M. d. C. Meizoso-López, B. A. Rodríguez-Gómez, and J. L. Calvo-Rolle. Electromyogram prediction during anesthesia by using a hybrid intelligent model. *Journal of Ambient Intelligence and Humanized Computing*, 2019. ISSN 1868-5145. doi: 10.1007/s12652-019-01426-8.
- [24] J.-L. Casteleiro-Roca, J. F. Gómez-González, J. L. Calvo-Rolle, E. Jove, H. Quintián, B. Gonzalez Diaz, and J. A. Mendez Perez. Short-term energy demand forecast in hotels using hybrid intelligent modeling. *Sensors*, 19(11), 2019. ISSN 1424-8220. doi: 10.3390/s19112485.
- [25] J.-L. CASTELEIRO-ROCA, J. A. M. PÉREZ, A. J. PIÑÓN-PAZOS, J. L. CALVO-ROLLE, and E. CORCHADO. Intelligent model for electromyogram (EMG) signal prediction during anesthesia. *Journal of Multiple-Valued Logic & Soft Computing*, 32(3/4):205–220, 2019. ISSN 15423980.
- [26] J.-L. Casteleiro-Roca, A. J. Barragán, F. Segura, J. L. Calvo-Rolle, and J. M. Andújar. Sistema híbrido inteligente para la predicción de tensión de una pila de combustible basada en hidrógeno. *Revista Iberoamericana de Automática e Informática industrial*, Articles in press(xx):1–10, xxxx. ISSN 1697-7920. doi: 10.4995/riai.2019.10986.
- [27] C. Crespo-Turrado, J. L. Casteleiro-Roca, F. Sánchez-Lasheras, J. A. López-Vázquez, F. J. de Cos Juez, J. L. Calvo-Rolle, and E. Corchado. Student performance prediction applying missing data imputation in electrical engineering

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

- studies degree. In F. Martínez-Álvarez, A. Troncoso, H. Quintián, and E. Corchado, editors, *Hybrid Artificial Intelligent Systems*, pages 126–135, Cham, 2016. Springer International Publishing. ISBN 978-3-319-32034-2.
- [28] L. A. Fernández-Serantes, R. Estrada Vázquez, J. L. Casteleiro-Roca, J. L. Calvo-Rolle, and E. Corchado. Hybrid intelligent model to predict the SOC of a LFP power cell type. In M. Polycarpou, A. C. P. L. F. de Carvalho, J.-S. Pan, M. Woźniak, H. Quintian, and E. Corchado, editors, *Hybrid Artificial Intelligence Systems*, pages 561–572, Cham, 2014. Springer International Publishing. ISBN 978-3-319-07617-1.
- [29] J. M. Gonzalez-Cava, R. Arnay, J. A. Méndez Pérez, A. León, M. Martín, E. Jove-Perez, J. L. Calvo-Rolle, J. L. Casteleiro-Roca, and F. J. de Cos Juez. A machine learning based system for analgesic drug delivery. In H. Pérez García, J. Alfonso-Cendón, L. Sánchez González, H. Quintián, and E. Corchado, editors, *International Joint Conference SOCO'17-CISIS'17-ICEUTE'17 León, Spain, September 6–8, 2017, Proceeding*, pages 461–470, Cham, 2018. Springer International Publishing. ISBN 978-3-319-67180-2.
- [30] J. M. Gonzalez-Cava, J. A. Reboso, J. L. Casteleiro-Roca, J. L. Calvo-Rolle, and J. A. Méndez Pérez. A novel fuzzy algorithm to introduce new variables in the drug supply decision-making process in medicine. *Complexity*, 2018, 2018.
- [31] H. Q.-P. A. D. C. José Luis Casteleiro-Roca, José Luis Calvo-Rolle. Ajuste automático en lazo abierto del regulador de un horno didáctico. In *XXXIII Jornadas de Automática*, Vigo, 2012.
- [32] H. Q.-P. M. R. G. José Luis Casteleiro-Roca, José Luis Calvo-Rolle. Exposición para alumnos de bachiller de una planta de laboratorio de control automático. In *XXXIII Jornadas de Automática*, Vigo, 2012.
- [33] M. S. José Luis Casteleiro-Roca, José Luis Calvo-Rolle. Redes neuronales artificiales en un regulador pid para control automático del rumbo de un buque. In *XXXIV Jornadas de Automática*, Terrassa, 2013.
- [34] M. S. José Luis Casteleiro-Roca, José Luis Calvo-Rolle. Diseño de un regulador fuzzy para planta de laboratorio. In *XXXV Jornadas de Automática*, Valencia, 2014.
- [35] R. F. G. José Luis Casteleiro-Roca, José Luis Calvo-Rolle. Sistema de control por computador - unificación de criterios. In *XXXIV Jornadas de Automática*, Terrassa, 2013.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

- [36] E. Jove, H. Aláiz-Moretón, J. L. Casteleiro-Roca, E. Corchado, and J. L. Calvo-Rolle. Modeling of bicomponent mixing system used in the manufacture of wind generator blades. In E. Corchado, J. A. Lozano, H. Quintián, and H. Yin, editors, *Intelligent Data Engineering and Automated Learning – IDEAL 2014*, pages 275–285, Cham, 2014. Springer International Publishing. ISBN 978-3-319-10840-7.
- [37] E. Jove, H. Alaiz-Moretón, I. García-Rodríguez, C. Benavides-Cuellar, J. L. Casteleiro-Roca, and J. L. Calvo-Rolle. PID-ITS: An intelligent tutoring system for PID tuning learning process. In H. Pérez García, J. Alfonso-Cendón, L. Sánchez González, H. Quintián, and E. Corchado, editors, *International Joint Conference SOCO'17-CISIS'17-ICEUTE'17 León, Spain, September 6–8, 2017, Proceeding*, pages 726–735, Cham, 2018. Springer International Publishing. ISBN 978-3-319-67180-2.
- [38] E. Jove, P. Blanco-Rodríguez, J. L. Casteleiro-Roca, J. Moreno-Arboleda, J. A. López-Vázquez, F. J. de Cos Juez, and J. L. Calvo-Rolle. Attempts prediction by missing data imputation in engineering degree. In H. Pérez García, J. Alfonso-Cendón, L. Sánchez González, H. Quintián, and E. Corchado, editors, *International Joint Conference SOCO'17-CISIS'17-ICEUTE'17 León, Spain, September 6–8, 2017, Proceeding*, pages 167–176, Cham, 2018. Springer International Publishing. ISBN 978-3-319-67180-2.
- [39] E. Jove, L. A. Fernández-Serantes, J. L. Casteleiro-Roca, H. Q. Pardo, and J. L. C. Rolle. *Estudio y análisis de métodos y técnicas de control de temperatura*. Editorial Académica Española, 2018. ISBN 978-620-2-24868-6.
- [40] E. Jove, J. M. Gonzalez-Cava, J.-L. Casteleiro-Roca, J.-A. Méndez-Pérez, J. Antonio Rebozo-Morales, F. Javier Pérez-Castelo, F. Javier de Cos Juez, and J. Luis Calvo-Rolle. Modelling the hypnotic patient response in general anaesthesia using intelligent models. *Logic Journal of the IGPL*, 27(2):189–201, 2018. ISSN 1367-0751. doi: 10.1093/jigpal/jzy032.
- [41] E. Jove, J. M. Gonzalez-Cava, J. L. Casteleiro-Roca, J. A. M. Pérez, J. L. Calvo-Rolle, and F. J. de Cos Juez. An intelligent model to predict ANI in patients undergoing general anesthesia. In H. Pérez García, J. Alfonso-Cendón, L. Sánchez González, H. Quintián, and E. Corchado, editors, *International Joint Conference SOCO'17-CISIS'17-ICEUTE'17 León, Spain, September 6–8, 2017, Proceeding*, pages 492–501, Cham, 2018. Springer International Publishing. ISBN 978-3-319-67180-2.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

- [42] E. Jove, J. M. Gonzalez-Cava, J.-L. Casteleiro-Roca, H. Quintián, J. A. Méndez-Pérez, J. L. Calvo-Rolle, F. J. de Cos Juez, A. León, M. Martín, and J. Rebo-so. Remifentanil dose prediction for patients during general anesthesia. In F. J. de Cos Juez, J. R. Villar, E. A. de la Cal, Á. Herrero, H. Quintián, J. A. Sáez, and E. Corchado, editors, *Hybrid Artificial Intelligent Systems*, pages 537–546, Cham, 2018. Springer International Publishing. ISBN 978-3-319-92639-1.
- [43] E. Jove, J. A. V. López, I. Fernández-Ibáñez, J. L. Casteleiro-Roca, and J. L. Calvo-Rolle. Hybrid intelligent system to predict the individual academic performance of engineering students. *The International journal of engineering education*, 34(3): 895–904, 2018.
- [44] E. Jove, J.-L. Casteleiro-Roca, J. M. González-Cava, H. Quintián, H. Alaiz-Moretón, B. Baruque, J. A. Méndez-Pérez, and J. L. Calvo-Rolle. Anomaly detection over an ultrasonic sensor in an industrial plant. In H. Pérez García, L. Sánchez González, M. Castejón Limas, H. Quintián Pardo, and E. Corchado Rodríguez, editors, *Hybrid Artificial Intelligent Systems*, pages 492–503, Cham, 2019. Springer International Publishing. ISBN 978-3-030-29859-3.
- [45] E. Jove, J.-L. Casteleiro-Roca, H. Quintián, J. A. Méndez-Pérez, and J. L. Calvo-Rolle. A fault detection system based on unsupervised techniques for industrial control loops. *Expert Systems*, 36(4):e12395, 2019. doi: 10.1111/exsy.12395.
- [46] E. Jove, J.-L. Casteleiro-Roca, H. Quintián, J. A. Méndez-Pérez, and J. L. Calvo-Rolle. A new approach for system malfunctioning over an industrial system control loop based on unsupervised techniques. In M. Graña, J. M. López-Guede, O. Etxaniz, Á. Herrero, J. A. Sáez, H. Quintián, and E. Corchado, editors, *International Joint Conference SOCO'18-CISIS'18-ICEUTE'18*, pages 415–425, Cham, 2019. Springer International Publishing. ISBN 978-3-319-94120-2.
- [47] E. Jove, J.-L. Casteleiro-Roca, H. Quintián, J. A. Méndez-Pérez, and J. L. Calvo-Rolle. Outlier generation and anomaly detection based on intelligent one-class techniques over a bicomponent mixing system. In F. Martínez Álvarez, A. Troncoso Lora, J. A. Sáez Muñoz, H. Quintián, and E. Corchado, editors, *14th International Conference on Soft Computing Models in Industrial and Environmental Applications (SOCO 2019)*, pages 399–410, Cham, 2020. Springer International Publishing. ISBN 978-3-030-20055-8.
- [48] E. Jove, J.-L. Casteleiro-Roca, H. Quintián, J.-A. Méndez-Pérez, and J. L. Calvo-Rolle. A global classifier implementation for detecting anomalies by using one-class techniques over a laboratory plant. In E. Herrera-Viedma, Z. Vale, P. Nielsen,

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

A. Martin Del Rey, and R. Casado Vara, editors, *Distributed Computing and Artificial Intelligence, 16th International Conference, Special Sessions*, pages 149–160, Cham, 2020. Springer International Publishing. ISBN 978-3-030-23946-6.

- [49] E. Jove, J. M. Gonzalez-Cava, J.-L. Casteleiro-Roca, H. Quintián, J. A. Méndez-Pérez, and J. L. Calvo-Rolle. Anomaly detection on patients undergoing general anesthesia”, booktitle=“international joint conference: 12th international conference on computational intelligence in security for information systems (CISIS 2019) and 10th international conference on european transnational education (ICEUTE 2019). pages 141–152, Cham, 2020. Springer International Publishing. ISBN 978-3-030-20005-3.
- [50] E. Jove, J.-L. Casteleiro-Roca, H. Quintián, J. A. Méndez-Pérez, and J. L. Calvo-Rolle. Detección de anomalías basada en técnicas inteligentes de una planta de obtención de material bicomponente empleado en la fabricación de palas de aerogenerador. *Revista Iberoamericana de Automática e Informática industrial*, Articles in press(xx):1–10, xxxx. ISSN 1697-7920. doi: 10.4995/riai.2019.11055.
- [51] J.-L. C.-R. H. Q. J. L. C.-R. H. A.-M. T. G.-A. Juan Aurelio Montero-Sousa, Esteban Jove. Sistema híbrido para la predicción del funcionamiento de una celda de combustible basada en hidrógeno, empleada en el almacenamiento de energía. In *XL Jornadas de Automática*, Ferrol, 2019. doi: 10.17979/spudc.9788497497169.200.
- [52] J. L. C.-R. H. Q.-P. Juan Aurelio Montero Sousa, José Luis Casteleiro-Roca. Introducción histórica a la automática. primera lección de fundamentos de automática. In *XXXIII Jornadas de Automática*, Vigo, 2012.
- [53] J. L. C.-R. H. Q.-P. Juan Aurelio Montero Sousa, José Luis Casteleiro-Roca. Inicio de la automatización del cálculo. del ábaco al ordenador. In *XXXIII Jornadas de Automática*, Vigo, 2012.
- [54] J. A. López-Vázquez, J. A. Orosa, J. L. Calvo-Rolle, F. J. de Cos Juez, J. L. Casteleiro-Roca, and A. M. Costa. A new way to improve subject selection in engineering degree studies. In Á. Herrero, B. Baruque, J. Sedano, H. Quintián, and E. Corchado, editors, *International Joint Conference*, pages 533–545, Cham, 2015. Springer International Publishing. ISBN 978-3-319-19713-5.
- [55] X. Manuel Vilar-Martinez, J. Aurelio Montero-Sousa, J. Luis Calvo-Rolle, and J. Luis Casteleiro-Roca. Expert system development to assist on the verification of “TACAN” system performance. *Dyna*, 89(1):112–121, 2014.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

- [56] J. A. Montero-Sousa, L. A. Fernández-Serantes, J.-L. Casteleiro-Roca, X. M. Vilar-Martínez, and J. L. Calvo-Rolle. Energy management strategies to improve electrical networks using storage systems. In *Handbook of Research on Emerging Technologies for Electrical Power Planning, Analysis, and Optimization*, pages 63–75. IGI Global, 2016. ISBN 978-1-4666-9911-3.
- [57] J.-A. Montero-Sousa, J.-L. Casteleiro-Roca, and J.-L. Calvo-Rolle. Evolution of the electricity sector after the 2nd world war. *DYNA*, 92(3):280–284, 2017.
- [58] J. A. Montero-Sousa, L. A. Fernández-Serantes, J.-L. Casteleiro-Roca, X. M. Vilar-Martínez, and J. L. Calvo-Rolle. Energy management strategies to improve electrical networks using storage systems. In *Renewable and Alternative Energy: Concepts, Methodologies, Tools, and Applications*, pages 1500–1514. IGI Global, 2017. ISBN 978-1-5225-1671-2.
- [59] J.-A. Montero-Sousa, L.-A. Fernandez-Serantes, J.-L. Casteleiro-Roca, X.-M. Vilar-Martinez, and J.-L. Calvo-Rolle. Energy storage management for generation-distribution facilities. *DYNA*, 92(2):140–141, 2017.
- [60] J. A. Montero-Sousa, T. González-Ayuso, X. M. V. Martínez, L. A. Fernandez-Serantes, E. Jove, H. Quintián, J.-L. Casteleiro-Roca, and J. L. C. Rolle. An energy storage system: Experimental proposal for the efficiency improvement of the electrical network management. In *Novel Advancements in Electrical Power Planning and Performance*, pages 337–356. IGI Global, 2020. ISBN 978-1-5225-8553-4.
- [61] A. J. P. nón Pazos, J. L. C. Roca, M. del Carmen Meizoso López, and J. L. C. Rolle. QCM^{CH} v.1.0 - software registrado, 12 2014.
- [62] H. Quintián, J. L. Calvo-Rolle, J. L. Casteleiro-Roca, and J. A. O. García. Regression methods to a gain scheduling pid controller to guarantee the automatic steering of ships. In *Ships and Shipbuilding: Types, Design Considerations and Environmental Impact*, pages 63–84. Nova Science Publishers, 2013. ISBN 978-1-62618-787-0.
- [63] H. Quintián, J.-L. Casteleiro-Roca, F. J. Perez-Castelo, J. L. Calvo-Rolle, and E. Corchado. Hybrid intelligent model for fault detection of a lithium iron phosphate power cell used in electric vehicles. In F. Martínez-Álvarez, A. Troncoso, H. Quintián, and E. Corchado, editors, *Hybrid Artificial Intelligent Systems*, pages 751–762, Cham, 2016. Springer International Publishing. ISBN 978-3-319-32034-2.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

- [64] H. Quintián, J. L. Casteleiro-Roca, E. Jove, and J. L. Calvo-Rolle. *Estudio de sistemas de control con equipos industriales comerciales: análisis y estudio*. Editorial Académica Española, 2019. ISBN 978-613-9-40265-6.
- [65] J. L. C.-R.-M. R. G. Ramón Ferreiro García, José Luis Calvo-Rolle. La administración de recursos aplicada al mantenimiento de dispositivos de campo. In *XXXIV Jornadas de Automática*, Terrassa, 2013.
- [66] J. L. C.-R.-M. R. G.-A. D. C. Ramón Ferreiro García, José Luis Calvo-Rolle. Administración de recursos reforzada mediante supervisión de elementos finales de control. In *XXXIV Jornadas de Automática*, Terrassa, 2013.
- [67] L. A. F. SERANTES, J. A. M. SOUSA, J. L. C. ROCA, X. M. V. MARTINEZ, and J. L. C. ROLLE. Posibilidades para la gestión de almacenamiento energético para instalaciones de generación-distribución. *DYNA Energía y Sostenibilidad*, 5 (1), 2016.
- [68] X. Vilar-Martínez, J. A. M. Sousa, J. L. Calvo-Rolle, J. L. Casteleiro-Roca, and J. A. O. García. Knowledge model approach based in rules for tacan air navigation system. In *Ships and Shipbuilding: Types, Design Considerations and Environmental Impact*, pages 85–104. Nova Science Publishers, 2013. ISBN 978-1-62618-787-0.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

Referencias

- [1] *PNGV Battery Test Manual*, 2 2001.
- [2] *LiFeBATT X-1P 8Ah 38123 Cell*, 3 2011.
- [3] A. R. Absalom, V. Mani, T. De Smet, and M. M. R. F. Struys. Pharmacokinetic models for propofol-defining and illuminating the devil in the detail. *British Journal of Anaesthesia*, 103(1):26–37, 2009. ISSN 0007-0912. doi: 10.1093/bja/aep143.
- [4] C. C. Aggarwal. *Data classification: algorithms and applications*. CRC press, 2014.
- [5] H. Alaiz Moretón, J. Calvo Rolle, I. García, and A. Alonso Alvarez. Formalization and practical implementation of a conceptual model for pid controller tuning. *Asian Journal of Control*, 13(6):773–784, 2011. doi: 10.1002/asjc.264.
- [6] J. Albino Mendez, S. Torres, J. Antonio Reboso, and H. Reboso. Adaptive computer control of anesthesia in humans. *Computer Methods in Biomechanics and Biomedical Engineering*, 12(6):727–734, 2009. ISSN 1025-5842. doi: 10.1080/10255840902911528.
- [7] J. Álvarez Antón, P. García Nieto, F. de Cos Juez, F. Sánchez Lasheras, C. Blanco Viejo, and N. Roqueñí Gutiérrez. Battery state-of-charge estimator using the mars technique. *Power Electronics, IEEE Transactions on*, 28(8):3798–3805, 8 2013. ISSN 0885-8993. doi: 10.1109/TPEL.2012.2230026.
- [8] A. Alvarez-Huerta, R. Gonzalez-Miguel, D. Garcia-Metola, and A. Noriega-Gonzalez. Failure detection and prediction in wind turbines by using scada data. *Dyna*, 86(4):467–473, 2011. ISSN 0012-7361. doi: 10.6036/4025.
- [9] A. Bemporad and M. Morari. Control of systems integrating logic, dynamics, and constraints. *Automatica*, 35(3):407–427, 1999. ISSN 0005-1098. doi: 10.1016/S0005-1098(98)00178-2.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

- [10] A. Bemporad, G. Ferrari-Trecate, D. Mignone, M. Morari, and F. D. Torrisi. Model predictive control — ideas for the next generation. In *1999 European Control Conference (ECC)*, pages 3880–3885, 1999. doi: 10.23919/ECC.1999.7099937.
- [11] C. M. Bishop. *Pattern Recognition and Machine Learning (Information Science and Statistics)*. Springer-Verlag New York, Inc., Secaucus, NJ, USA, 2006. ISBN 0387310738.
- [12] E. Boselli, M. Daniela-Ionescu, G. Begou, L. Bouvet, R. Dabouz, C. Magnin, and B. Allaouchiche. Prospective observational study of the non-invasive assessment of immediate postoperative pain using the analgesia/nociception index (ANI). *British Journal of Anaesthesia*, 111(3):453–459, 2013. ISSN 0007-0912. doi: 10.1093/bja/aet110.
- [13] E. Brogi, S. Cyr, R. Kazan, F. Giunta, and T. M. Hemmerling. Clinical performance and safety of closed-loop systems: A systematic review and meta-analysis of randomized controlled trials. *Anesthesia and Analgesia*, 124(2):446–455, 2017. ISSN 0003-2999. doi: 10.1213/ANE.0000000000001372.
- [14] J. L. Calvo-Rolle, J. L. Casteleiro-Roca, H. Quintián, and M. C. Meizoso-Lopez. A hybrid intelligent system for PID controller using in a steel rolling process. *Expert Systems with Applications*, 40(13):5188–5196, 2013. ISSN 0957-4174. doi: 10.1016/j.eswa.2013.03.013.
- [15] J. L. Calvo-Rolle, O. Fontenla-Romero, B. Pérez-Sánchez, and B. Guijarro-Berdinas. Adaptive inverse control using an online learning algorithm for neural networks. *Informatica*, 25(3):401–414, 2014. ISSN 0868-4952. doi: 10.15388/Informatica.2014.20.
- [16] J. L. Calvo-Rolle, H. Quintian-Pardo, E. Corchado, M. del Carmen Meizoso-López, and R. F. García. Simplified method based on an intelligent model to obtain the extinction angle of the current for a single-phase half wave controlled rectifier with resistive and inductive load. *Journal of Applied Logic*, 13(1):37–47, 2015. ISSN 1570-8683. doi: 10.1016/j.jal.2014.11.010.
- [17] J. Casteleiro-Roca, J. Calvo-Rolle, M. Meizoso-López, A. Piñón-Pazos, and B. Rodríguez-Gómez. New approach for the QCM sensors characterization. *Sensors and Actuators A: Physical*, 207(0):1–9, 2014. ISSN 0924-4247. doi: 10.1016/j.sna.2013.12.002.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

- [18] J. Casteleiro-Roca, J. Calvo-Rolle, M. Meizoso-López, A. P. P. Pazos, and B. Rodríguez-Gómez. Bio-inspired model of ground temperature behavior on the horizontal geothermal exchanger of an installation based on a heat pump. *Neurocomputing*, 150, Part A:90–98, 2015. ISSN 0925-2312. doi: 10.1016/j.neucom.2014.02.075.
- [19] J. L. Casteleiro-Roca, J. A. M. Pérez, A. J. Piñón-Pazos, J. L. Calvo-Rolle, and E. Corchado. Modeling the electromyogram (EMG) of patients undergoing anesthesia during surgery. In *10th International Conference on Soft Computing Models in Industrial and Environmental Applications*, pages 273–283, 2015. ISBN 978-3-319-19719-7. doi: 10.1007/978-3-319-19719-7_24.
- [20] J. L. Casteleiro-Roca, H. Quintián, J. L. Calvo-Rolle, E. Corchado, M. del Carmen Meizoso-López, and A. Piñón-Pazos. An intelligent fault detection system for a heat pump installation based on a geothermal heat exchanger. *Journal of Applied Logic*, 17:36–47, 2016. doi: 10.1016/j.jal.2015.09.007.
- [21] J.-L. Casteleiro-Roca, J. Calvo-Rolle, J. Méndez Pérez, N. Roqueñi Gutiérrez, and F. de Cos Juez. Hybrid intelligent system to perform fault detection on BIS sensor during surgeries. *Sensors*, 17(1):179, 1 2017. ISSN 1424-8220. doi: 10.3390/s17010179.
- [22] J. L. Casteleiro-Roca, J. A. M. Pérez, J. A. Reboso-Morales, F. J. de Cos Juez, F. J. Pérez-Castelo, and J. L. Calvo-Rolle. An intelligent model for bispectral index (BIS) in patients undergoing general anesthesia. In *International Joint Conference SOCO'16-CISIS'16-ICEUTE'16: San Sebastián, Spain, October 19th-21st, 2016 Proceedings*, pages 290–300, 2017. ISBN 978-3-319-47364-2. doi: 10.1007/978-3-319-47364-2_28.
- [23] M. L. Castro, R. Escobar, L. Torres, J. G. Aguilar, J. Hernández, and V. Olivares-Peregrino. Sensor fault detection and isolation system for a condensation process. *ISA Transactions*, 2016. ISSN 0019-0578. doi: 10.1016/j.isatra.2016.08.004.
- [24] M. C.F., S. T.W., and S. S.L. Pharmacokinetics and pharmacodynamics of remifentanyl. model application. *Anesthesiology*, 86:24–33, 1997. doi: 10.1097/0000542-199701000-00005.
- [25] N. Chaturvedi, R. Klein, J. Christensen, J. Ahmed, and A. Kojic. Modeling, estimation, and control challenges for lithium-ion batteries. *American Control Conference (ACC)*, pages 1997–2002, 6 2010. ISSN 0743-1619. doi: 10.1109/ACC.2010.5531623.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

- [26] A. Cherif, H. Cardot, and R. Boné. SOM time series clustering and prediction with recurrent neural networks. *Neurocomput.*, 74(11):1936–1944, 5 2011. ISSN 0925-2312. doi: 10.1016/j.neucom.2010.11.026.
- [27] Y. Cho and H. B. Awbi. A study of the effect of heat source location in a ventilated room using multiple regression analysis. *Building and Environment*, 42(5):2072–2082, 2007. ISSN 0360-1323. doi: 10.1016/j.buildenv.2006.03.008.
- [28] C. Chukwuka and K. Folly. Batteries and super-capacitors. *Power Engineering Society Conference and Exposition in Africa (PowerAfrica), 2012 IEEE*, pages 1–6, 7 2012. doi: 10.1109/PowerAfrica.2012.6498634.
- [29] D. Copot, R. D. Keyser, and C. Ionescu. Drug interaction between propofol and remifentanil in individualised drug delivery systems. *IFAC-PapersOnLine*, 48(20):64–69, 2015. ISSN 2405-8963. doi: 10.1016/j.ifacol.2015.10.116.
- [30] R. Cowen, M. K. Stasiowska, H. Laycock, and C. Bantel. Assessing pain objectively: the use of physiological markers. *Anaesthesia*, 70(7):828–847, 2015. ISSN 1365-2044. doi: 10.1111/anae.13018.
- [31] M. J. Crespo-Ramos, I. Machón-González, H. López-García, and J. L. Calvo-Rolle. Detection of locally relevant variables using SOM-NG algorithm. *Engineering Applications of Artificial Intelligence*, 26(8):1992–2000, 2013. ISSN 0952-1976. doi: 10.1016/j.engappai.2013.04.012.
- [32] C. Crespo-Turrado, M. d. C. Meizoso-Lopez, F. Sanchez-Lasheras, B. A. Rodriguez-Gomez, J. L. Calvo-Rolle, and F. J. de Cos Juez. Missing data imputation of solar radiation data under different atmospheric conditions. *Sensors*, 14(11):20382, 2014. ISSN 1424-8220. doi: 10.3390/s141120382.
- [33] N. Cristianini and J. Shawe-Taylor. *An introduction to support Vector Machines and other kernel-based learning methods*. Cambridge University Press, New York, NY, USA, 2000. ISBN 0-521-78019-5.
- [34] M. Fang, Y. Tao, and Y. Wang. A subspace-based wiener system identification method for the individualized anesthesia care. *IFAC Proceedings Volumes*, 47(3):11605–11610, 2014. ISSN 1474-6670. doi: 10.3182/20140824-6-ZA-1003.01739.
- [35] J. A. Fernández, C. D. Muñoz, P. G. Nieto, F. de Cos Juez, F. S. Lasheras, and M. Roqueñí. Forecasting the cyanotoxins presence in fresh waters: A new model based on genetic algorithms combined with the MARS technique. *Ecological engineering*, 53:68–78, 2013. doi: 10.1016/j.ecoleng.2012.12.015.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

- [36] L. A. Fernández-Serantes, R. E. Vázquez, J. L. Casteleiro-Roca, J. L. Calvo-Rolle, and E. Corchado. Hybrid intelligent model to predict the SOC of a LFP power cell type. In *International Conference on Hybrid Artificial Intelligence Systems*, pages 561–572, 2014.
- [37] G. Flórez, P. A. Saiz, P. García-Portilla, F. J. De Cos, S. Dapia, S. Álvarez, L. Nogueiras, and J. Bobes. Predictors of posttreatment drinking outcomes in patients with alcohol dependence. *European addiction research*, 21(1):19–30, 2014. doi: 10.1159/000358194.
- [38] A. A. Freitas. *Data mining and knowledge discovery with evolutionary algorithms*. Springer Science & Business Media, 2013.
- [39] J. Friedman and J. Tukey. A projection pursuit algorithm for exploratory data analysis. *Computers, IEEE Transactions on*, C-23(9):881–890, 9 1974. ISSN 0018-9340. doi: 10.1109/T-C.1974.224051.
- [40] C. Fyfe. A neural network for PCA and beyond. *Neural Processing Letters*, 6 (1-2):33–41, 1997. ISSN 1370-4621. doi: 10.1023/A:1009606706736.
- [41] R. F. García, J. L. C. Rolle, M. R. Gomez, and A. D. Catoira. Expert condition monitoring on hydrostatic self-levitating bearings. *Expert Systems with Applications*, 40(8):2975–2984, 2013. ISSN 0957-4174. doi: 10.1016/j.eswa.2012.12.013.
- [42] R. F. García, J. L. C. Rolle, J. P. Castelo, and M. R. Gomez. On the monitoring task of solar thermal fluid transfer systems using NN based models and rule based techniques. *Engineering Applications of Artificial Intelligence*, 27:129–136, 2014. ISSN 0952-1976. doi: 10.1016/j.engappai.2013.06.011.
- [43] A. Ghanghermeh, G. Roshan, J. A. Orosa, J. L. Calvo-Rolle, and A. M. Costa. New climatic indicators for improving urban sprawl: A case study of tehran city. *Entropy*, 15(3):999–1013, 2013. ISSN 1099-4300. doi: 10.3390/e15030999.
- [44] M. H. Ghaseminezhad and A. Karami. A novel self-organizing map (SOM) neural network for discrete groups of data clustering. *Appl. Soft Comput.*, 11(4):3771–3778, 6 2011. ISSN 1568-4946. doi: 10.1016/j.asoc.2011.02.009.
- [45] A. Gritsan, N. Dovbish, D. Kurnosov, and E. Gritsan. Control of the adequacy of analgesia during general anesthesia with the use of the monitor 'analgesia nociception index'. *Anesthesia and Analgesia*, 123(3 supplement):769, 2016. doi: 10.1213/01.ane.0000492984.63279.34.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

- [46] M. Gruenewald, T. Schoenherr, J. Herz, C. Ilies, A. Fudickar, and B. Bein. Analgesia nociception index (ANI) for detection of noxious stimulation during sevofluran-remifentanil anaesthesia: 14AP7-8. *European Journal of Anaesthesiology*, 30:223, 2013. ISSN 0265-0215.
- [47] B. Guignard. Monitoring analgesia. *Best Practice & Research Clinical Anaesthesiology*, 20(1):161–180, 2006. ISSN 1521-6896. doi: 10.1016/j.bpa.2005.09.002.
- [48] Y. Guo, X. Li, G. Bai, and J. Ma. Time series prediction method based on LS-SVR with modified gaussian RBF. In *Neural Information Processing*, pages 9–17, 2012. ISBN 978-3-642-34480-0. doi: 10.1007/978-3-642-34481-7_2.
- [49] R. Heiberger and E. Neuwirth. Polynomial regression. In *R Through Excel, Use R*, pages 269–284. Springer New York, 2009. ISBN 978-1-4419-0051-7. doi: 10.1007/978-1-4419-0052-4_11.
- [50] J. Hernández Orallo, C. Ferri Ramirez, and M. J. Ramirez Quintana. Introducción a la minería de datos. 2004.
- [51] L.-H. Ho, S.-Y. Feng, Y.-C. Lee, and T.-M. Yen. Using modified IPA to evaluate supplier’s performance: Multiple regression analysis and DEMATEL approach. *Expert Systems with Applications*, 39(8):7102–7109, 2012. ISSN 0957-4174. doi: 10.1016/j.eswa.2012.01.034.
- [52] H. Hotelling. Analysis of a complex of statistical variables into principal components. *Journal of educational psychology*, 24(6), 1933. ISSN ISSN de la revista. doi: 10.1037/h0071325.
- [53] N. Ismail and S. Toha. State of charge estimation of a lithium-ion battery for electric vehicle based on particle swarm optimization. In *2013 IEEE International Conference on Smart Instrumentation, Measurement and Applications (ICSIMA)*, pages 1–4, 2013. doi: 10.1109/ICSIMA.2013.6717978.
- [54] H. Jang and E. Topal. Optimizing overbreak prediction based on geological parameters comparing multiple regression analysis and artificial neural network. *Tunnelling and Underground Space Technology*, 38(0):161–169, 2013. ISSN 0886-7798. doi: 10.1016/j.tust.2013.06.003.
- [55] E. W. Jensen, J. F. Valencia, A. Lopez, T. Anglada, M. Agusti, Y. Ramos, R. Serra, M. Jospin, P. Pineda, and P. Gambus. Monitoring hypnotic effect and nociception with two EEG-derived indices, qCON and qNOX, during general anaesthesia. *Acta Anaesthesiologica Scandinavica*, 58(8):933–941, 2014. ISSN 1399-6576; 0001-5172. doi: 10.1111/aas.12359.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

- [56] R. Jin, K. Cho, C. Hyun, and M. Son. MRA-based revised CBR model for cost prediction in the early stage of construction projects. *Expert Systems with Applications*, 39(5):5214–5222, 2012. ISSN 0957-4174. doi: 10.1016/j.eswa.2011.11.018.
- [57] S. Kaski, J. Sinkkonen, and A. Klami. Discriminative clustering. *Neurocomputing*, 69(1–3):18–41, 2005. ISSN 0925-2312. doi: 10.1016/j.neucom.2005.02.012.
- [58] A. Khaqan and R. Riaz. Depth of hypnosis regulation using nonlinear control approach. In *2016 IEEE International Conference on Electro Information Technology (EIT)*, pages 100–104, 2016. doi: 10.1109/EIT.2016.7535222.
- [59] R. Kohavi et al. A study of cross-validation and bootstrap for accuracy estimation and model selection. In *Ijcai*, volume 14, pages 1137–1145, 1995.
- [60] O. Konig, S. Jakubek, and G. Prochart. Battery impedance emulation for hybrid and electric powertrain testing. *Vehicle Power and Propulsion Conference (VPPC), 2012 IEEE*, pages 627–632, 8 2012. doi: 10.1109/VPPC.2012.6422636.
- [61] A. Kusiak and Z. Song. Sensor fault detection in power plants. *Journal of Energy Engineering*, 135(4):127–137, 2009. doi: 10.1061/(ASCE)0733-9402(2009)135:4(127).
- [62] F. S. Lasheras, F. J. de Cos Juez, A. S. Sánchez, A. Krzemień, and P. R. Fernández. Forecasting the COMEX copper spot price by means of neural networks and ARIMA models. *Resources Policy*, 45:37–43, 2015. ISSN 0301-4207. doi: 10.1016/j.resourpol.2015.03.004.
- [63] J. Lemos, H. Magalhaes, T. Mendonca, and R. Dionisio. Control of neuromuscular blockade in the presence of sensor faults. *IEEE Transactions on Biomedical Engineering*, 52(11):1902–1911, 2005. doi: 10.1109/TBME.2005.856259.
- [64] Y. Li, X. Shao, and W. Cai. A consensus least squares support vector regression (LS-SVR) for analysis of near-infrared spectra of plant samples. *Talanta*, 72(1):217–222, 2007. ISSN 0039-9140. doi: 10.1016/j.talanta.2006.10.022.
- [65] E. Lughofer, E. P. Klement, J. Lujan, and C. Guardiola. Model-based fault detection in multi-sensor measurement systems. In *Intelligent Systems, 2004. Proceedings. 2004 2nd International IEEE Conference*, pages 184–189, 2004.
- [66] I. Machón-González, H. López-García, and J. L. Calvo-Rolle. A hybrid batch SOM-NG algorithm. In *Neural Networks (IJCNN), The 2010 International Joint Conference on*, pages 1–5, 2010.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

- [67] I. Machón-González, H. López-García, and J. L. Calvo-Rolle. Neuro-robust controller for non-linear systems. *Dyna*, 86(3):308–317, 2011. doi: 10.6036/3949.
- [68] A. Marrero, J. A. Méndez, J. A. Reboso, I. Martín, and J. L. Calvo. Adaptive fuzzy modeling of the hypnotic process in anesthesia. *Journal of Clinical Monitoring and Computing*, 31(2):319–330, 2017. doi: 10.1007/s10877-016-9868-y.
- [69] I. Martín-Mateos, J. A. Mendez Perez, J. A. Reboso, and A. Leon. Modelling propofol pharmacodynamics using BIS-guided anaesthesia. *Anaesthesia*, 68(11): 1132–1140, 2013. ISSN 1365-2044; 0003-2409. doi: 10.1111/anae.12384.
- [70] D. Martínez-Rego, O. Fontenla-Romero, and A. Alonso-Betanzos. Efficiency of local models ensembles for time series prediction. *Expert Syst. Appl.*, 38(6):6884–6894, 6 2011. ISSN 0957-4174. doi: 10.1016/j.eswa.2010.12.036.
- [71] J. H. Mathews and K. D. Fink. *Métodos numéricos con Matlab*. Pearson, 2000.
- [72] N. Mehranbod, M. Soroush, and C. Panjapornpon. A method of sensor fault detection and identification. *Journal of Process Control*, 15(3):321–339, 2005. ISSN 0959-1524. doi: 10.1016/j.jprocont.2004.06.009.
- [73] J. A. Méndez, A. Marrero, J. A. Reboso, and A. León. Adaptive fuzzy predictive controller for anesthesia delivery. *Control Engineering Practice*, 46:1–9, 2016. ISSN 0967-0661. doi: 10.1016/j.conengprac.2015.09.009.
- [74] L. A. Menéndez, F. de Cos Juez, F. S. Lasheras, and J. A. Riesgo. Artificial neural networks applied to cancer detection in a breast screening programme. *Mathematical and Computer Modelling*, 52(7-8):983–991, 2010. ISSN 0895-7177. doi: 10.1016/j.mcm.2010.03.019.
- [75] C. F. Minto, T. W. Schnider, K. M. Gregg, T. K. Henthorn, and S. L. Shafer. Using the time of maximum effect site concentration to combine pharmacokinetics and pharmacodynamics. *Anesthesiology*, 99(2):324–333, 2003. ISSN 0003-3022. doi: 10.1097/00000542-200308000-00014.
- [76] P. G. Nieto, J. A. Fernández, F. S. Lasheras, F. de Cos Juez, and C. D. M. niz. A new improved study of cyanotoxins presence from experimental cyanobacteria concentrations in the trasona reservoir (northern spain) using the MARS technique. *Science of The Total Environment*, 430:88–92, 2012. ISSN 0048-9697. doi: 10.1016/j.scitotenv.2012.04.068.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

- [77] J. Nieves-Acedo, I. Santos-Grueiro, and P. Garcia-Bringas. Enhancing the prediction stage of a model predictive control systems through meta-classifiers. *Dyna*, 88(3):290–298, 2013. ISSN 0012-7361. doi: 10.6036/5426.
- [78] E. Oja. Neural networks, principal components, and subspaces. *International Journal of Neural Systems*, 1(1):61–68, 1989. doi: 10.1142/S0129065789000475.
- [79] A. Oliva. Sensor fault detection and analytical redundancy satellite launcher flight control system. *SBA Controle & Automação*, 9(3):156–164, 1998.
- [80] G. A. Orliaguet, F. B. Lambert, T. Chazot, P. Glasman, M. Fischler, and N. Liu. Feasibility of closed-loop titration of propofol and remifentanyl guided by the bispectral monitor in pediatric and adolescent patients: A prospective randomized study. *Anesthesiology*, 2014. ISSN 1528-1175; 0003-3022. doi: 10.1097/ALN.0000000000000577.
- [81] J. Osborn, D. Guzman, F. J. de Cos Juez, A. G. Basden, T. J. Morris, E. Gendron, T. Butterley, R. M. Myers, A. Guesalaga, F. Sanchez Lasheras, M. Gomez Victoria, M. L. Sánchez Rodríguez, D. Gratadour, and G. Rousset. Open-loop tomography with artificial neural networks on CANARY: on-sky results. *Monthly Notices of the Royal Astronomical Society*, 441(3):2508–2514, 2014. doi: 10.1093/mnras/stu758.
- [82] F. Ozturk Arikan, G. Turan, A. Ozgultekin, Z. Sivrikaya, B. Cosar, and D. Onder. Rocuronium: automatic infusion versus manual administration with TOF monitorisation. *Journal of Clinical Monitoring and Computing*, 30(5):545–550, 2016. doi: 10.1007/s10877-015-9751-2.
- [83] K. Pearson. On lines and planes of closest fit to systems of points in space. *Philosophical Magazine*, 2(6):559–572, 1901. doi: 10.1080/14786440109462720.
- [84] J. Pérez, S. Torres, J. Reboso, and H. Reboso. Control strategies in anesthesia practice. *RIAI - Revista Iberoamericana de Automatica e Informatica Industrial*, 8(3):241–249, 2011. doi: 10.1016/j.riai.2011.06.011.
- [85] L. S. Pritchep, L. D. Gugino, E. R. John, R. J. Chabot, B. Howard, H. Merkin, M. L. Tom, S. Wolter, L. Rausch, and W. J. Kox. The patient state index as an indicator of the level of hypnosis under general anaesthesia. *British Journal of Anaesthesia*, 92(3):393–399, 2004. ISSN 0007-0912; 0007-0912. doi: 10.1093/bja/ah082.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

- [86] H. Qian, J. Zhang, and J.-S. Lai. A grid-tie battery energy storage system. *Control and Modeling for Power Electronics (COMPEL)*, 2010 IEEE 12th Workshop on, pages 1–5, 6 2010. doi: 10.1109/COMPEL.2010.5562425.
- [87] A. Qin and P. Suganthan. Enhanced neural gas network for prototype-based clustering. *Pattern Recogn.*, 38(8):1275–1288, 8 2005. ISSN 0031-3203. doi: 10.1016/j.patcog.2004.12.007.
- [88] H. Quintián, J. L. Calvo-Rolle, and E. Corchado. A hybrid regression system based on local models for solar energy prediction. *Informatica*, 25(2):265–282, 2014. ISSN 0868-4952. doi: 10.15388/Informatica.2014.14.
- [89] H. Quintian Pardo, J. L. Calvo Rolle, and O. Fontenla Romero. Application of a low cost commercial robot in tasks of tracking of objects. *Dyna*, 79(175):24–33, 2012.
- [90] J. Rolle, I. Gonzalez, and H. Garcia. Neuro-robust controller for non-linear systems. *Dyna*, 86(3):308–317, 2011. doi: 10.6036/3949.
- [91] J. Rynkiewicz. General bound of overfitting for MLP regression models. *Neurocomputing*, 90:106–110, 2012. ISSN 0925-2312. doi: 10.1016/j.neucom.2011.11.028.
- [92] A. S. Sánchez, P. R. Fernández, F. S. Lasheras, F. J. de Cos Juez, and P. G. Nieto. Prediction of work-related accidents according to working conditions using support vector machines. *Applied Mathematics and Computation*, 218(7):3539–3552, 2011. doi: 10.1016/j.amc.2011.08.100.
- [93] A. S. Sánchez, F. J. Iglesias-Rodríguez, P. R. Fernández, and F. de Cos Juez. Applying the k-nearest neighbor technique to the classification of workers according to their risk of suffering musculoskeletal disorders. *International Journal of Industrial Ergonomics*, 52:92–99, 2016. doi: 10.1016/j.ergon.2015.09.012.
- [94] M. Sağsan, İhsan Tolga Medeni, and T. D. Medeni. Knowledge management paradigms: Implementation through individual fuzzy-based education. *Procedia Computer Science*, 102:259–266, 2016. ISSN 1877-0509. doi: 10.1016/j.procs.2016.09.399.
- [95] T. W. Schnider, C. F. Minto, P. L. Gambus, C. Andresen, D. B. Goodale, S. L. Shafer, and E. J. Youngs. The influence of method of administration and covariates on the pharmacokinetics of propofol in adult volunteers. *Anesthesiology*, 88(5):1170–1182, 1998. ISSN 0003-3022. doi: 10.1097/00000542-199805000-00006.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

- [96] T. W. Schnider, C. F. Minto, S. L. Shafer, P. L. Gambus, C. Andresen, D. B. Goodale, and E. J. Youngs. The influence of age on propofol pharmacodynamics. *Anesthesiology*, 90(6):1502–1516, 1999. ISSN 0003-3022. doi: 10.1097/00000542-199906000-00003.
- [97] J. C. Sigl and N. G. Chamoun. An introduction to bispectral analysis for the electroencephalogram. *Journal of Clinical Monitoring*, 10(6):392–404, 1994. ISSN 1573-2614. doi: 10.1007/BF01618421.
- [98] A. Sparacino, G. Reed, R. Kerestes, B. Grainger, and Z. Smith. Survey of battery energy storage systems and modeling techniques. *Power and Energy Society General Meeting, 2012 IEEE*, Volumen de la revista:1–8, 7 2012. ISSN 1944-9925. doi: 10.1109/PESGM.2012.6345071.
- [99] I. Steinwart and A. Christmann. *Support vector machines*. Springer Publishing Company, Incorporated, 1st edition, 2008. ISBN 0387772413.
- [100] J. Suykens and J. Vandewalle. Least squares support vector machine classifiers. *Neural Processing Letters*, 9(3):293–300, 1999. ISSN 1370-4621. doi: 10.1023/A:1018628609742.
- [101] M. Swierczynski, D.-I. Stroe, A.-I. Stan, R. Teodorescu, and S. Kaer. Lifetime estimation of the nanophosphate LiFePo battery chemistry used in fully electric vehicles. *Industry Applications, IEEE Transactions on*, 51(4):3453–3461, 7 2015. ISSN 0093-9994. doi: 10.1109/TIA.2015.2405500.
- [102] A. L. Vanluchene, H. Vereecke, O. Thas, E. P. Mortier, S. L. Shafer, and M. M. Struys. Spectral entropy as an electroencephalographic measure of anesthetic drug effect: A comparison with bispectral index and processed midlatency auditory evoked response. *Anesthesiology*, 101(1):34–42, 2004.
- [103] V. Vapnik. *The nature of statistical learning theory*. Springer, 1995.
- [104] J. A. Vilán Vilán, J. R. Alonso Fernández, P. J. García Nieto, F. Sánchez Lashe-ras, F. J. de Cos Juez, and C. Díaz Muñiz. Support vector machines and multi-layer perceptron networks used to evaluate the cyanotoxins presence from exper-imental cyanobacteria concentrations in the trasona reservoir (northern Spain). *Water Resources Management*, 27(9):3457–3476, 2013. ISSN 1573-1650. doi: 10.1007/s11269-013-0358-4.
- [105] S. Vukosavic. *Electrical Machines*. Power Electronics and Power Systems. Springer, 2012. ISBN 9781461404002.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46

- [106] L. Wang and J. Wu. Neural network ensemble model using PPR and LS-SVR for stock et forecasting. In *Advanced Intelligent Computing*, pages 1–8, 2012. ISBN 978-3-642-24727-9. doi: 10.1007/978-3-642-24728-6_1.
- [107] L. Wang, L. Wu, Y. Guan, and G. Wang. Online sensor fault detection based on an improved strong tracking filter. *Sensors*, 15(2), 2015. ISSN 1424-8220. doi: 10.3390/s150204578.
- [108] R. Wang, A. Wang, and Q. Song. Research on the alkalinity of sintering process based on LS-SVM algorithms. In *Advances in Computer Science and Information Engineering*, pages 449–454, 2012. ISBN 978-3-642-30125-4. doi: 10.1007/978-3-642-30126-1_71.
- [109] P. Wasserman. *Advanced methods in neural computing*. John Wiley & Sons, Inc., New York, NY, USA, 1st edition, 1993. ISBN 0442004613.
- [110] Wikipedia. Lithium-ion battery - wikipedia, the free encyclopedia, 2014. URL http://en.wikipedia.org/w/index.php?title=Lithium-ion_battery&oldid=592970854. [Online; accessed 30-January-2014].
- [111] X. Wu. *Optimal designs for segmented polynomial regression models and web-based implementation of optimal design software*. State University of New York at Stony Brook, Stony Brook, NY, USA, 2007. ISBN 978-0-549-91415-0.
- [112] J. Xu, J. Wang, S. Li, and B. Cao. A method to simultaneously detect the current sensor fault and estimate the state of energy for batteries in electric vehicles. *Sensors*, 16(8), 2016. ISSN 1424–8220. doi: 10.3390/s16081328.
- [113] J. Ye and T. Xiong. SVM versus least squares SVM. In *The 11th International Conference on Artificial Intelligence and Statistics (AISTATS)*, pages 640–647, 2007.
- [114] J. Ye and T. Xiong. SVM versus least squares SVM. *Journal of Machine Learning Research - Proceedings Track*, 2:644–651, 2007. doi: 10.1145/505282.505283.
- [115] Z. Zeng and J. Wang. *Advances in neural network research and applications*. Springer Publishing Company, Incorporated, 1st edition, 2010. ISBN 3642129897, 9783642129896.
- [116] Z. Zhang and S. Chan. On kernel selection of multivariate local polynomial modeling and its application to image smoothing and reconstruction. *J. Signal Process. Syst.*, 64(3):361–374, 2011. ISSN 1939-8018. doi: 10.1007/s11265-010-0495-4.

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015.
 Su autenticidad puede ser contrastada en la siguiente dirección <https://sede.ull.es/validacion/>

Identificador del documento: 2141614 Código de verificación: B1ePGXal

Firmado por: JOSE LUIS CASTELEIRO ROCA UNIVERSIDAD DE LA LAGUNA	Fecha: 20/09/2019 13:27:50
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:29:29
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	20/09/2019 13:30:46