



ESCUELA DE DOCTORADO Y ESTUDIOS DE POSGRADO

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

TESIS DOCTORAL

Advanced anomaly detection algorithms based on virtual sensors and one-class techniques

Author: Esteban Jove Pérez

Directors: José Luis Calvo Rolle
Juan Albino Méndez Pérez

La Laguna, December 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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11



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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11




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 “*Advanced anomaly detection algorithms based on virtual sensors and one-class techniques*”, realizada por D. Esteban Jove Pérez, 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 15 de noviembre de 2019


Firmado digitalmente por CALVO ROLLE
JOSE LUIS - 32672840Y
Nombre de reconocimiento (DN): cn=ES,
serialNumber=IDCES-32672840Y,
givenName=JOSE LUIS, sn=CALVO ROLLE,
cn=CALVO ROLLE JOSE LUIS - 32672840Y
Fecha: 2019.11.15 17:25:40 +01'00'

Dr. José Luis Calvo Rolle

MEÑEZ
PEREZ JUAN
ALBINO -
52824630R
Firmado digitalmente
por MENDEZ PEREZ
JUAN ALBINO -
52824630R
Fecha: 2019.11.15
16:56:53 Z

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11



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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

*A mi hermano, por ser un referente y confiar en mí desde el día que nació.
A mis padres, por ser siempre un ejemplo a seguir. Porque fuisteis, soy.
A ella, por ponerme los pelos de punta.*

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11



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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Acknowledgements

Quiero agradecer a los directores de esta Tesis Doctoral, por su apoyo y dedicación durante este largo, pero provechoso proceso.

Por supuesto, es imposible olvidarse del Despacho 300, por ser fuente de sabiduría, inspiración y, sobre todo, buen rollo.

Y, a riesgo de ser reiterativo, gracias a Rolle, por inculcarme la rigurosidad, la constancia y el buen hacer, en todos los aspectos de la vida.

La Laguna, December 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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Abstract

This research deals with the analysis and implementation of anomaly detection systems based on intelligent techniques. Specifically, two of the most commonly used strategies for this purpose have been implemented and studied. The first consists on the virtual sensor development based on a hybrid intelligent model capable of detecting anomalous situations. The second strategy is based on the use of one-class techniques, used to implement anomalies detection classifiers. Therefore, an analysis and a comparison of both strategies are accomplished, highlighting the performance of each one.

This work is made following to the compendium of publications modality. It presents a common line according to the research carried out, which reflects the progress and the successive concatenated contributions, with the three articles presented. The first work deals with the implementation of a virtual sensor, used to detect anomalies in a machine for the bicomponent material obtaining, used in the wind turbine blades manufacture. In this case, the virtual sensor is developed based on a hybrid intelligent regression model. The deviations between the predicted and the real value read by the sensor, is presented as a criteria for the anomaly detection. This contribution involves the need of an expert user to set the proper threshold that determines the anomalous event. Consequently, in the second work, it has been decided the use of one-class intelligent systems. The application of this kind of techniques is implemented over a laboratory plant, whose aim is to control the water level in a tank, and then, anomalies are induced during its right operation. The results are highly satisfactory, and the implemented system detects the induced anomalies over the plant. Due to the good performance of this technique in this contribution, the third accomplished research work implements the failures detection of the bicomponent material mixing plant used at the first of the works, whose complexity is significantly higher. The application of this strategy offers very good results.

Keywords: *Anomaly detection, Intelligent systems, Non-linear systems, Virtual sensors, One-class, Artificial Intelligence*

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Resumen

La presente investigación aborda el análisis e implementación de sistemas de detección de anomalías basados en técnicas inteligentes. Concretamente, se lleva a cabo el estudio de dos de las estrategias más comúnmente empleadas. La primera consiste en el desarrollo de un sensor virtual a partir de un modelo híbrido e inteligente capaz de detectar situaciones anómalas. La segunda de las estrategias, se basa en el uso de técnicas *one-class*, a partir de las cuales se implementan clasificadores capaces de determinar la aparición de anomalías en base al comportamiento esperado. Se realizan, por tanto, un análisis y una comparativa de ambas estrategias, poniendo de relieve el desempeño de cada una.

Este trabajo, realizado de acuerdo a la modalidad de compendio de publicaciones, presenta un hilo conductor de acuerdo a la investigación efectuada, en el cual se reflejan el avance y las aportaciones sucesivas y concatenadas, con los tres artículos presentados. El primero de los trabajos, aborda la implementación de un sensor virtual, empleado para detectar anomalías en una máquina de obtención del material bicomponente, utilizado en la fabricación de palas de aerogenerador. En este caso, el sensor virtual se desarrolla a través de un modelo de regresión híbrido e inteligente. La aparición de desviaciones entre el valor predicho y real de la lectura del sensor, se presenta como criterio para detectar la anomalía. Esta aportación conlleva la necesidad de disponer de un usuario con cierto conocimiento acerca del umbral que determine la aparición de una anomalía. En consecuencia, en el segundo trabajo, se decide emplear sistemas inteligentes de tipo *one-class*. Se propone la aplicación de este tipo de técnicas sobre una planta de laboratorio, cuyo objetivo es controlar el nivel de agua en un depósito, a la que se le provocan anomalías durante el correcto funcionamiento. Los resultados son altamente satisfactorios, consiguiendo que el sistema implementado detecte los fallos provocados sobre la planta. Como consecuencia del buen rendimiento de este tipo de técnicas en esta aportación, el tercero de los trabajos aborda, con ellas, la detección de fallos sobre la planta de mezclado de compuesto bicomponente del primero de los trabajos, cuya complejidad es notablemente superior. La aplicación de esta estrategia ofrece muy buenos resultados.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Palabras clave: *Detección de anomalías, Sistemas inteligentes, Sensores Virtuales, One-class, Inteligencia Artificial*

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

General Index

1. Introduction	1
1.1. The problem of anomaly detection	1
1.2. Anomaly detection methods	2
1.3. Motivation	4
1.4. Objectives	5
1.5. Methodology	6
1.6. Structure	7
2. Methods	11
2.1. Hybrid intelligent modelling	11
2.1.1. Clustering algorithm. K-Means	11
2.1.2. Intelligent regression techniques	14
2.1.2.1. Artificial Neural Network. Multilayer Perceptron	14
2.1.2.2. Support Vector Regression	17
2.2. One-class intelligent techniques	19
2.2.1. Approximate Convex Hull	20
2.2.2. Artificial Neural Network. Autoencoder	23
2.2.3. One-class Support Vector Machine	25
2.2.4. Principal Component Analysis	26
2.3. Performance analysis	28
2.3.1. Hybrid model assessment	28
2.3.1.1. Performance parameters	29
2.3.1.2. Model validation	31
2.3.2. One-class classifier assessment	32
2.3.2.1. Performance parameters	32
2.3.2.2. Anomaly generation	35
2.3.2.3. Classifier validation	37
3. Anomaly detection approach	43
3.1. Fault detection virtual sensor approach	43
3.1.1. Hybrid intelligent model block	44
3.1.2. Virtual sensor fault detection block	46
3.2. One-class classifier approach	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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

4. Virtual sensor for fault detection, isolation and data recovery for bi-component mixing machine monitoring	49
4.1. Introduction	51
4.2. Case of study	53
4.2.1. Bicomponent mixing system	53
4.2.2. Variables monitored	54
4.2.3. Virtual sensor implementation	55
4.3. Soft Computing Techniques	56
4.3.1. K-means algorithm. Data clustering	56
4.3.2. Artificial neural networks (ANN). Multilayer perceptron (MLP)	57
4.3.3. Support vector regression (SVR), least square support vector regression (LS SVR)	57
4.4. Model approach	58
4.4.1. Hybrid Intelligent Models	58
4.4.2. Model selection	59
4.4.3. Fault Detection Block	61
4.4.4. Dataset description	63
4.5. Results	63
4.6. Conclusions	67
5. Anomaly detection based on one-class intelligent techniques over a control level plant	73
5.1. Introduction	75
5.2. Case study	78
5.2.1. Tank level control	78
5.2.2. Control System Implementation	79
5.2.3. Dataset	81
5.3. Soft Computing Techniques Used	82
5.3.1. Approximate Convex Hull	82
5.3.2. Artificial neural networks. Autoencoder	83
5.3.3. Support Vector Machine	85
5.4. Experiments and results	86
5.4.1. Approximate Convex Hull Classifier	87
5.4.2. Artificial Neural Network Autoencoder Classifier	87
5.4.3. SVM Classifier	89
5.5. Conclusions and future works	90
6. Detección de anomalías basada en técnicas inteligentes de una planta	

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

de obtención de material bicomponente empleado en la fabricación de palas de aerogenerador	99
6.1. Introducción	101
6.2. Caso de estudio	104
6.2.1. Sistema de mezclado	105
6.2.2. Conjunto de datos	106
6.3. Técnicas empleadas	108
6.3.1. Contornos Convexos Aproximados	108
6.3.2. Autoencoders	109
6.3.3. Máquinas de Vector Soporte	111
6.3.4. Análisis de Componentes Principales	113
6.4. Experimentos y resultados	113
6.4.1. Clasificador mediante Contornos Convexos Aproximados	114
6.4.2. Clasificador mediante Autoencoder	116
6.4.3. Clasificador SVM	118
6.4.4. Clasificador PCA	119
6.5. Conclusiones y trabajos futuros	121
 7. Conclusions	 127
 8. Future works	 129
 9. Publications	 131
 Articles proofs	 139
 References	 147

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Figures index

2.1. Cluster division depending on the value of K	12
2.2. Clusters, centroids and test samples over a dataset in \mathbb{R}^2	13
2.3. First artificial neuron approach	14
2.4. Multilayer perceptron structure	15
2.5. Tangent hyperbolic activation function	16
2.6. Classification problem in \mathbb{R}^2	18
2.7. Nonlinear transformation to \mathbb{R}^3 to solve the classification problem	18
2.8. Example of convex hull calculation in \mathbb{R}^2	21
2.9. Example of convex hull calculation in \mathbb{R}^3	21
2.10. Modification of the initial convex hull using λ	22
2.11. ACH with two projections	23
2.12. Autoencoder structure with one hidden layer.	24
2.13. Reconstruction error calculation	25
2.14. An example of dimensional reduction using PCA	27
2.15. Training set, PCA components and outlier appearance	28
2.16. Reconstruction error using PCA	29
2.17. Unbalanced data cluster distribution	30
2.18. $k - fold$ cross validation with $k = 3$	32
2.19. Confusion matrix	33
2.20. Receiving Operating Curve of classifier A and B	36
2.21. Discrete AUC value	36
2.22. Anomaly generation with 4 samples in \mathbb{R}^3	37
2.23. $k - fold$ cross validation with $k = 3$	38
3.1. Generic view of the virtual sensor proposed	43
3.2. General description of hybrid modeling process with $c = 3$	44
3.3. Modeling process of a cluster c	45
3.4. Hybrid intelligent model block with three clusters	45
3.5. Virtual sensor fault detection block	46
3.6. General description of the one-class methods evaluation	47
3.7. One-class classifier topology	47
4.1. Variables measured during system operation	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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

4.2. Bicomponent mixing system scheme	55
4.3. An example of the output flow with erroneous measurements	56
4.4. Failure detection and virtual sensor diagram	60
4.5. Modeling process	61
4.6. K-Fold performance calculation	62
4.7. Proposal of the virtual sensor model	63
4.8. Data to test the Fault Detection and Diagnostic system	66
4.9. Fault Detection and Diagnostic system simulation	68
5.1. Anomaly example in \mathbb{R}^2	76
5.2. Scheme of the plant of liquid level control	79
5.3. Picture of the plant of liquid level control	80
5.4. Control scheme of laboratory plant	80
5.5. Anomaly point in \mathbb{R}^3	83
5.6. Comparative of ACH performance depending its configuration	88
5.7. Comparative of Autoencoder performance depending its configuration	90
5.8. Comparative of SVM performance depending its configuration	92
6.1. Diagrama del proceso	105
6.2. Variación de la viscosidad del catalizador con el esfuerzo cortante al que se ve sometido	106
6.3. Variables originales y modificadas artificialmente	108
6.4. Anomalía en R^3	110
6.5. Error de reconstrucción obtenido con 9 neuronas y los datos sin normalizar	118

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Tables index

2.1. Performance of the same classifier depending on the class distribution	34
2.2. Scores given by two different classifiers over an example set	34
2.3. Classifier <i>A</i> performance depending on the set threshold	35
2.4. Classifier <i>B</i> performance depending on the set threshold	35
4.1. Clusters MSE	65
4.2. Mean MSE for each model depending on the number of clusters	66
4.3. Best regression technique for each cluster depending on the number of clusters	67
5.1. Best results obtained with ACH Classifier	87
5.2. Best results obtained Autoencoder Classifier	89
5.3. Best results obtained with SVM Classifier	91
5.4. Average results for ACH	91
5.5. Average results for Autoencoder	91
5.6. Average results for SVM	93
6.1. Resultados obtenidos con Contornos Convexos Aproximados	115
6.2. Resultados obtenidos con Autoencoder	117
6.3. Resultados obtenidos con SVM	119
6.4. Resultados obtenidos con PCA	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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

CHAPTER 1



Introduction

This chapter presents an introduction that contextualizes and defines the objectives proposed in the present research work. Initially, a detailed description of the background related to the anomaly detection is presented in the first section. Then, the main issues that motivates this work are exposed. From these motivations, different specific goals are proposed in the Objectives section. That section is followed by the applied Methodology to achieve the proposed goals and, finally, the document Structure is described.

1.1. The problem of anomaly detection

The vertiginous technological development of modern societies, has provided an increase in the life standards of most human beings . This development is especially significant in areas such as transport, telecommunications [13], medicine [5] or industrial processes [12], among others [11]. These improvements entail a systems features enhance by adding them a significant sophistication [8].

In addition to the technological advances, the current economic globalization context, has lead to an increase in the competitiveness. This means that the processes must be optimized, reducing factors like process cost, the corrective and predictive maintenance expenses or the product rejection rates. Furthermore, especially in developed nations, the policies tend to promote an environmental impact reduction, and high safety, reliability and quality standards. In short, the processes optimization, the minimum consumption and environmental impact have become crucial [15].

The context exposed in the previous paragraphs reveals the importance of ensuring the correct operation of every process. For this reason, the early detection of any kind of anomaly plays a key role, especially in critical-safety and high cost processes [14]. The source of the anomaly may have different nature depending on the application: malware

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 1. Introduction

attack, sensor malfunction, plant aging, actuator malfunction, etc... The previously mentioned sophistication increase, along with the availability of systems information due to the strong digitalization, and the complex intelligent systems development, make the anomaly detection a problem that focus the attention of the scientific community.

From a generic point of view, anomalies are data patterns that conform an unexpected behaviour in a given application [4, 6]. To face this problem, each data sample must be assigned to a known class (target or positive class) or to the rest of possible classes (non-target or negative class) [17, 10]. Hence, a sample data is considered anomalous if presents a significant deviation from the common pattern. Despite the simplicity of this definition, the anomaly detection must face a wide variety of challenges, that makes this process especially complex [4].

1.2. Anomaly detection methods

In most applications, there is not prior knowledge about the anomalies behaviour. This issue is specially significant in processes if the safety is crucial or if it is not possible to force the system to anomalous situations. It is also important to emphasize that the anomaly source and evolution is hard to predict. Another common problem appears when the dataset presents noise that may distort the model or classifier performance.

As this works deals with the anomaly detection in industrial processes, the different approaches to address this problem are detailed:

- **Virtual sensors** [1]. As stated above, a common source of anomalies is the inaccurate measurements derived from sensors and transducers malfunctioning. Even though an occasional wrong measurement is not an important issue, the consequences of a permanent malfunction would propagate through the systems, and the consequences could be harmful in terms of control, optimization, and of course, plant monitoring [16]. In this context, the use of intelligent techniques become important.

Virtual sensors (or soft sensors) are software components that, using measures from different sources, can estimate the value of a new quantity that cannot be measured directly. Its implementation can be achieved by using conventional mathematical models or intelligent ones [7]. Once it is implemented, the anomaly

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

1.2 Anomaly detection methods

detection criteria is based on the deviation between the real sensor measurement and the virtual sensor predicted values.

In [7], a virtual sensor to measure the folding/unfolding wings system of an aircraft is implemented to detect anomalies. This objective is achieved by generating nonlinear models of the system dynamics. Then, the fault is detected from the residuals of the actual sweeping angle and the value estimated by the model. When these residuals exceed a certain threshold level, the fault is detected.

One important application of anomaly detection is in the medicine field. In [3], a fault detection system was implemented using the concept of virtual sensor. In this case, a hybrid intelligent model was used to predict the hypnotic state of a patient undergoing general anesthesia. As in the work mentioned in previous paragraph, the anomaly criteria here is based on the difference between the real sensor value and the predicted one [3].

- **One-class classifiers.** Typically, a classification problem can not be solved using simple known rules. Thus, the classifier implementation must face a learning process from a set of training objects. The specific case in which the classifier must distinguish between a known class (target) and an unknown class (non-target), is defined as one-class. Three different approaches can be taken into consideration to implement a one-class classifier [17]:
 - Density estimation methods. The most direct method to achieve a one-class classification is based on establishing a threshold in the density estimation of the training data. The use of different density distributions, such as Gaussian, Poisson or Parzen Density, have been proven to be successful [17]. However, a high amount of training data is needed to achieve good results [17].
 - Boundary methods. This method consists of determining the geometric limits of the training instances [17]. Hence, once the boundaries are set, the criteria to identify a non-target class object, is based on the distance to the decision boundary. In comparison with density methods, this approach gives better results when the training data size is lower.
 - Reconstruction methods. With this method, a model is achieved from the training data with the aim of minimizing the reconstruction error. Once the model is obtained, objects from non-target class would lead to high reconstruction error, and the outlier is detected.

As for the virtual sensor approach, the use of one-class techniques has also presented interesting results. In [19] faces the anomaly detection in shaft bearings

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 1. Introduction

subjected to a constant radial load in a test rig. In this work, the use of one-class classification techniques is applied to model the training set.

In [2] the three different one-class approaches are tested using 5 artificial datasets, 82 one-class problems from 23 UCI repository datasets and 2 datasets from walking patterns and text categorization problems. In all cases, the different one-class methods achieve a successful performance.

Once the most common strategies to perform anomaly detection are summarized, it is interesting to remark that there is not prior guidance about comparative strengths and weaknesses of each approach. Although both approaches are analyzed separately, it would be desirable to have, for given a specific application, a comparative analysis of which method is recommended to be applied.

1.3. Motivation

As stated in the previous section, the possibility of having efficient mechanisms to detect and isolate anomalies, plays a significant role in the safety and optimization of an industrial process, with the resulting economic and environmental consequences, among others.

The recovery from an anomalous event can be efficiently done using adequate hardware redundancy systems [9]. Two main considerations have to be taken into account. First, this kind of solutions involves high investments [18]. In many applications the costs associated to this solution cannot be afforded and alternative solutions have to be found. On the other hand, the activation of redundant instrumentation occurs after the anomaly has been detected. So, there is still a need for anomaly detection and isolation systems even if redundancy is present in the plant.

As commented, two of the main strategies that exist to perform anomaly detection are implemented and analyzed. The first is based on the use of virtual sensors, and the second one uses one-class intelligent classifiers.

In these categories different approaches can be found. For instance, virtual sensors can be implemented using conventional identification techniques (state observers) or can be implemented using models trained with artificial intelligence (AI) methods. Several

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

1.4 Objectives

reasons are boosting the use of this intelligent techniques. On one hand, the industrial digital transformation provides access to massive operating data in real time. On the other hand, the computational power of both general purpose and embedded systems has grown exponentially in last years. This allow for the use of complex AI methods from the control room to the field level. Thus, the applications of AI methods in different industrial applications is constantly increasing in many areas: artificial vision, control systems, predictive maintenance, etc. Thus, one of the motivations of this research is to contribute to the effective application of artificial intelligence techniques in the industry, and more precisely, for anomaly detection.

From a practical point of view, when applying AI techniques, given the complexity of industrial processes, it is necessary to cluster the data between operating ranges. After this, a model has to be synthesized for each range to achieve a hybrid intelligent model. This research tries to make contributions in these hybrid modelling methods for virtual sensors. As an alternative to virtual sensors, another aim of the research was to explore new possibilities in the use of on-class classifiers for anomaly detection. The motivation of this research was to explore these techniques by combining theoretical analysis and modelling with real applications where the methods could be tested.

In spite of the extensive literature related to anomaly detection, its use over real industrial systems lacks guidance about which method fits better over a given application. Then, the need of a comparative analysis between strategies becomes clear.

Hence, the performance of each anomaly detection approach when it is implemented over a real industrial application should be more detailed. This means that a deeper comparison between the overall performance, the influence of the different parameters configuration, and the main features of each method is mandatory. The work presented here tried to offer this perspective to the research proposed, thus connecting the theoretical methods with the practical application.

1.4. Objectives

The main proposed objective in this doctoral thesis, derived from the previous motivation, is the design and implementation of advanced anomaly detection algorithms using virtual sensor created with a hybrid intelligent model and one-class techniques. More precisely, the proposed subobjectives are the following:

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 1. Introduction

- Design of an algorithm to implement a virtual sensor using intelligent techniques based on hybrid modelling.
- Design of an anomaly detection system based on one-class classification techniques.
- Validation of the proposed algorithms applying both virtual sensor and one-class approaches over industrial processes. In particular, the proposal will be validated in the following industrial plants:
 - Development of a virtual sensor for fault detection in a bicomponent mixing machine, with the possibility of recovering data. In this case, the industrial system is used to obtain the wind generator blades material. From real data acquired during system operation, the virtual sensor is implemented by achieving a hybrid model. Typical sensor faults are artificially generated to validate the approach.
 - One-class anomaly detection proposal for a laboratory plant with built-in industrial equipment, used to control the water level in a tank. This proposal addresses the anomaly detection with different one-class intelligent techniques. The performance of each classifier is assessed and validated with real created faults, achieving successful overall results.
 - Development of a one-class classifier to detect anomalies in a bicomponent mixing machine. With the data previously used to develop the virtual sensor, the one-class approach is validated. In this case, instead of sensor faults, the anomalies are created by deviating the correct value of any system parameter a certain percentage, achieving interesting results.
- Comparative analysis of the different approaches, in terms of performance, suitability for each application, strengths and weaknesses.

1.5. Methodology

The methodology followed to achieve the proposed objectives can be summarized according to the next points:

- Detailed review of the bibliographic background related to the anomaly detection problem.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

- Analysis and selection of the used techniques to implement the hybrid intelligent models and the one-class classifiers.
- Algorithm adaptation to implement the techniques selected in the previous step.
- Development of a procedure to obtain and validate the hybrid model used to implement the virtual sensor implementation.
- Development of a procedure to achieve and validate the one-class classifiers to perform anomaly detection.
- Check the correct performance of the developed approaches in different specific applications.
- Analysis and comparison of performance of the proposed solutions.

1.6. Structure

The global structure of this document is divided into eight chapters. After the present introduction chapter, the chapter 2 describes the used techniques to achieve the anomaly detection. Then, the chapter 3 presents different fault detection approaches considered to achieve the stated objectives. Since this research work is presented through a compendium of publications modality, chapter 4, 5 and 6, correspond to the articles published resulting from this work. For ease of understanding, the content of each article, along with the thread that links each one, is summarized in the lines below.

The paper presented in chapter 4 deals with the implementation of a virtual sensor for fault detection, which has the possibility of recovering erroneous measurements. The proposal is applied over an industrial system used to produce the wind generator blades material, by mixing two primary fluids. From an initial dataset, comprised of eight monitored system variables, an intelligent regression model for one of the sensors is proposed. Given the system complexity, a hybrid topology is used. This means that the dataset is divided into different groups, according to a clustering algorithm criteria and then, a local model is obtained for each group. This hybrid intelligent model is used as a virtual sensor capable of predicting the magnitude to measure. An anomaly is detected when there is a certain deviation between the real sensor value and the virtual sensor value. A key feature of this proposal is that the criteria to determine 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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 1. Introduction

deviation threshold is set by the user. Hence, this proposal is supervised and rely upon the user expertise.

Given the supervised nature of the system proposed in chapter 4, the need of proposing a unsupervised system arises. This is the key reason to implement one-class techniques. Chapter 5, presents the first one-class approach validated over a laboratory plant, whose main objective is to control the water level in a tank. The dataset is comprised of five system variables, and the one-class classifiers are trained with data from one operating point. Then, different intelligent techniques are applied and the classifiers are tested by opening an output valve progressively. Unlike the article of chapter 4, this anomaly detection solution does not need the user assistance.

Once the good performance of one-class techniques is checked over a laboratory plant, its use in an industrial system is implemented in Chapter 6. This is a key step, since the noise appearance in an industrial environment could distort the one-class classifier performance. This third article deals with the same system exposed in Chapter 4. However, this approach tries to reduce the presence of an expert by applying one-class techniques. After their use, the classifiers performed well in case of any system parameter deviation.

After the third article, chapter 7 presents the general and the specific conclusions reached in each article. Future works are stated in chapter 8 and, finally, the publications resulting from this work, the proofs of each paper, and the bibliography are presented.

Bibliography

- [1] J. Carvajal-Godinez, J. Guo, and E. Gill. Agent-based algorithm for fault detection and recovery of gyroscope's drift in small satellite missions. *Acta Astronautica*, 139: 181–188, 2017.
- [2] P. Casale, O. Pujol, and P. Radeva. Approximate polytope ensemble for one-class classification. *Pattern Recognition*, 47(2):854–864, 2014.
- [3] 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, 2017.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

- [4] V. Chandola, A. Banerjee, and V. Kumar. Anomaly detection: A survey. *ACM computing surveys (CSUR)*, 41(3):15, 2009.
- [5] T. J. Cleophas, A. H. Zwinderman, and H. I. Cleophas-Allers. *Machine learning in medicine*. Springer, 2013.
- [6] E. Eskin, A. Arnold, M. Prerau, L. Portnoy, and S. Stolfo. A geometric framework for unsupervised anomaly detection. In *Applications of data mining in computer security*, pages 77–101. Springer, 2002.
- [7] G. Heredia and A. Ollero. Virtual sensor for failure detection, identification and recovery in the transition phase of a morphing aircraft. *Sensors*, 10(3):2188–2201, 2010.
- [8] M. Hobday. Product complexity, innovation and industrial organisation. *Research policy*, 26(6):689–710, 1998.
- [9] I. Hwang, S. Kim, Y. Kim, and C. E. Seah. A survey of fault detection, isolation, and reconfiguration methods. *IEEE Transactions on Control Systems Technology*, 18(3):636–653, 2010.
- [10] S. S. Khan and M. G. Madden. A survey of recent trends in one class classification. In *Irish conference on artificial intelligence and cognitive science*, pages 188–197. Springer, 2009.
- [11] C. Kruegel and G. Vigna. Anomaly detection of web-based attacks. In *Proceedings of the 10th ACM conference on Computer and communications security*, pages 251–261. ACM, 2003.
- [12] L. Martí, N. Sanchez-Pi, J. Molina, and A. Garcia. Anomaly detection based on sensor data in petroleum industry applications. *Sensors*, 15(2):2774–2797, 2015.
- [13] O. Mazhelis. One-class classifiers: a review and analysis of suitability in the context of mobile-masquerader detection. *South African Computer Journal*, 2006(36):29–48, 2006.
- [14] D. Miljković. Fault detection methods: A literature survey. In *MIPRO, 2011 proceedings of the 34th international convention*, pages 750–755. IEEE, 2011.
- [15] T. Nicholson. *Optimization in Industry: Volume 1, Optimization Techniques*. Routledge, 2017.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 1. Introduction

- [16] A. B. Sharma, L. Golubchik, and R. Govindan. Sensor faults: Detection methods and prevalence in real-world datasets. *ACM Transactions on Sensor Networks (TOSN)*, 6(3):23, 2010.
- [17] D. M. J. Tax. One-class classification: concept-learning in the absence of counter-examples [ph. d. thesis]. *Delft University of Technology*, 2001.
- [18] S. Wang and J. Cui. Sensor-fault detection, diagnosis and estimation for centrifugal chiller systems using principal-component analysis method. *Applied Energy*, 82(3): 197–213, 2005.
- [19] M. Zeng, Y. Yang, S. Luo, and J. Cheng. One-class classification based on the convex hull for bearing fault detection. *Mechanical Systems and Signal Processing*, 81:274–293, 2016.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

CHAPTER 2



Methods

The different techniques used to perform the anomaly detection are described in this chapter. It is important to emphasize that a thorough analysis of these techniques is out of the scope of this work. However, a detailed description of the basis and the main features of each technique is presented.

As mentioned in the introduction section, two approaches has been applied: the first one tackles the issue of anomaly detection by using a virtual sensor based on hybrid intelligent regression models, and the second one makes use of one-class intelligent techniques. Hence, this chapter is structured in two main blocks corresponding to the mentioned strategies.

2.1. Hybrid intelligent modelling

The hybrid modelling process is divided into a clustering stage and a later regression modelling stage. Both techniques are exposed in the next subsections.

2.1.1. Clustering algorithm. K-Means

The K-Means is an unsupervised algorithm commonly used in different fields, such as machine learning, image processing or pattern recognition [14]. This algorithm aims to divide the dataset into homogeneous groups comprised of data with similar features, called clusters [12, 22].

From a given set $X = \{x_1, x_2, \dots, x_N\}$, where $x_i \in \mathbb{R}^n$, the K-Means algorithm divides the data into K subsets G_1, G_2, \dots, G_K , with their corresponding centroids $C =$

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 2. Methods

$\{c_1, c_2, \dots, c_K\}$, where $c_j \in \mathbb{R}^n$, following a clustering error criterion [14]. This error is usually computed as the sum of all the euclidean distances of each point $x_i \in \mathbb{R}^n$ to its centroid c_j , according to Equation 2.1, where $I(A) = 1$ only if A is true.

$$E(c_1, \dots, c_K) = \sum_{i=1}^N \sum_{j=1}^K I(x_i \in G_j) \|x_i - c_j\| \quad (2.1)$$

The number of clusters K must be selected by the user. This choice has a very significant influence, as shown in Figure 2.1, where different number of clusters are checked over dataset in \mathbb{R}^2 .

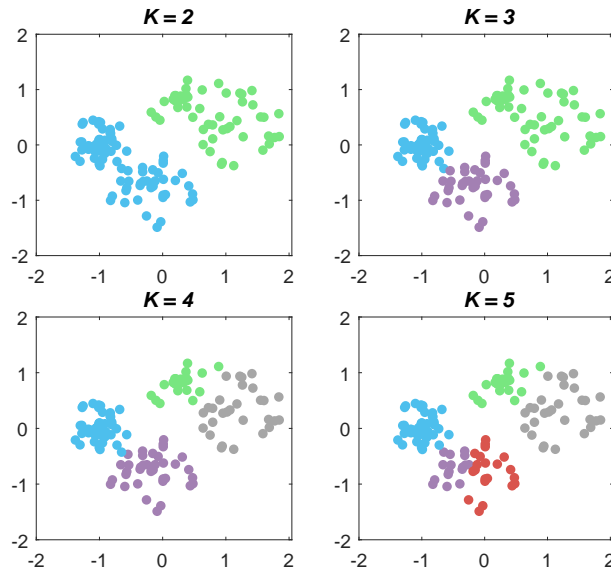


Figure 2.1: Cluster division depending on the value of K

During the training phase, the centroids are initially randomly assigned. As can be seen in Equation 2.1, the centroids position plays an important role in the clustering error. Then, the centroid positions are shifted step by step until the clustering error is minimized [14]. Hence, the training process finishes when the cluster centroids do not change.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

2.1 Hybrid intelligent modelling

This method presents the weakness of the high sensitivity to the centroids initial position. A very common way to overcome this issue consist of repeating the training process and modifying the initial centroids positions [12].

Once the position of each centroid is computed, a new test data belongs to the cluster whose centroid euclidean distance is the lowest. This algorithm gives better results when the training dataset is uniformly distributed in the hyperspace, and the data groups are hyper-spherical [12].

An example of how the K-Means algorithm distributes a random dataset into three clusters is shown in Figure 2.2. The centroid of each cluster is marked with \times and three test data assigned to their clusters are presented with \diamond .




Figure 2.2: Clusters, centroids and test samples over a dataset in \mathbb{R}^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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

2.1.2. Intelligent regression techniques

The approach presented in this work aims to achieve a better regression performance by obtaining an intelligent model for each of the groups identified by the K-Means algorithm. The contemplated intelligent techniques to obtain the models are described in this subsection.

2.1.2.1. Artificial Neural Network. Multilayer Perceptron

The use of Artificial Neural Networks (ANN) has been applied to solve a wide variety of problems, such as pattern recognition, prediction or image processing, among others [11]. The first artificial neuron proposed in 1940 [18] and its topology is shown in Figure 2.3. This model, based on the biological neuron, aimed to approximate an output function y with n inputs, by giving different weights to each input and adding the result. Also, a bias value u is considered. Then, a step function f_{θ} is set at the output [11]. The scheme shown in Figure 2.3, can be represented according to Equation 2.2.




Figure 2.3: First artificial neuron approach

$$y = f_{\theta} \left(\sum_{j=1}^n x_j w_j + u \right) \quad (2.2)$$

From this initial approach, the ANN progressed in form of more complex structures with different nonlinear activation functions. At the present time, one of the most common ANN is the Multilayer Perceptron (MLP), whose main structure is shown in Figure 2.4. This ANN presents a feedforward structure, since the input patterns move forward the output through the hidden layers without an internal feedback [33].

2.1 Hybrid intelligent modelling




Figure 2.4: Multilayer perceptron structure

The basic structure of an MLP has an input layer, an output layer and one or more hidden layers, and the neurons of each layer are connected with the neurons of adjacent layers. The main features of each layer are the following.

- Input layer: the number of neurons must be the same as the number of features of the input pattern. This layer propagates the input vector to the first hidden layer.
- Hidden layers: the number of neurons is not constrained and it can be modified by the user.
- Output layer: the number of neurons must be the same as the number of features of the output pattern.

Each link between neurons has a specific weight assigned. As noted above, different activation functions can be configured at each output neuron. These can be hyperbolic tangent, sigmoid, gaussian, linear or step, among others. For regression tasks, the most common activation function in the hidden layers is the hyperbolic tangent (Figure 2.5). A linear activation function is usually applied at the output layer.

Just as the scheme of Figure 2.3, the hidden and output layer neurons have a bias

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 2. Methods




Figure 2.5: Tangent hyperbolic activation function

input, and also receive the products of the previous layer neurons and their weighted connections. All these inputs are added, and then, the activation function is applied.

If we consider an MLP with one hidden layer, the output vector of the hidden layer h is computed following the Equation 2.3 [10]. The output vector of the MLP y is calculated from 2.4.

$$h = f_{\theta_1}(xW_1 - u_1) \quad (2.3)$$

Where:

- f_{θ_1} is the activation function of the hidden layer.
- x is input vector.
- W_1 is the weight matrix from the input to the hidden layer.
- u_1 is the bias vector of the hidden layer neurons.

$$y = f_{\theta_2}(hW_2 - u_2) \quad (2.4)$$

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

2.1 Hybrid intelligent modelling

Where:

- f_{θ_2} is the activation function of the output layer.
- h is output of the hidden layer.
- W_2 is the weight matrix from the hidden layer to the output.
- u_2 is the bias vector of the output layer neurons.

The weight matrices and bias vectors are adjusted during the training stage to minimize the difference between the output pattern and the MLP output (Equation 2.4) [25].

2.1.2.2. Support Vector Regression

The well-known Support Vector Machine (SVM) is a machine learning method used for classification that can be applied on regression tasks, known as Support Vector Regression (SVR). The main idea of SVM is to map the data into a high dimensional feature space F using a nonlinear transformation. Then, this technique aims to find an hyperplane that separates the different classes.

An example of a nonlinear transformation used to map an initial dataset \mathbb{R}^2 into a feature space in \mathbb{R}^3 is shown in Figure 2.6 and Figure 2.7. In this case, this process helps to classify two different classes by using adding a new dimension $z = \sqrt{x^2 + y^2}$, from the origin.

The transformation applied to map the data into a high dimensional feature space is known as kernels. It can polynomial (Equation 2.5), Radial Basis Function (RBF) (Equation 2.6) or Gaussian (Equation 2.7), among others. [31].

$$k(x_i, x_j) = (ax_i^T x_j + b)^c \tag{2.5}$$

$$k(x_i, x_j) = e^{-\frac{\|x_i - x_j\|}{\mu}} \tag{2.6}$$

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015. <i>Su autenticidad puede ser contrastada en la siguiente dirección https://sede.ull.es/validacion/</i>	
Identificador del documento: 2307538	Código de verificación: Ejyc0z4z
Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 2. Methods




Figure 2.6: Classification problem in \mathbb{R}^2




Figure 2.7: Nonlinear transformation to \mathbb{R}^3 to solve the classification problem

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

2.2 One-class intelligent techniques

$$k(x_i, x_j) = e^{-\frac{\|x_i - x_j\|^2}{2\sigma^2}} \quad (2.7)$$

Where:

- $(x_i - x_j)$ are the feature vector of the input space.
- $a, b, c, \mu, \sigma \in \mathbb{R}$ are kernel parameters.

When the SVM is used to solve regression problems, after the nonlinear transformation to the feature space, a linear regression is performed.

The formulation of Least Square Support Vector Machine (LSSVM) is applied to optimally control nonlinear Karush-Kun-Tucker systems for regression and classification. Training process of LSSVM is simpler than SVM, since linear equations are solved instead of quadratic programming to optimize the hyperplane parameter [31]. As with SVM, LSSVM is also applied to regression (LSSVR), being the regression function the one shown in Equation 2.8.

$$y = f(X) = w^T \delta(x) + b \quad (2.8)$$

Where:

- x is the training data sample $\in \mathbb{R}^n$.
- y is the output $\in \mathbb{R}$.
- δ high dimensional mapping $\mathbb{R}^n \rightarrow \mathbb{R}^p$.
- w and b are the hyperplane parameters.

2.2. One-class intelligent techniques

The use one-class intelligent classifiers is a very common strategy to tackle the anomaly detection issue [28]. These classifiers become useful when the initial dataset

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

has only objects belonging to a known class (target or positive class), which represent the correct operation. Then, the potential anomalies are considered unknown (non-target or negative classes). The used one-class classification techniques, also known as novelty detection [1] or outlier detection [24] techniques, are detailed in this section.

2.2.1. Approximate Convex Hull

A widely used approach to achieve the one-class classification problem consists of obtaining the geometrical structure of the target set [7]. Then, computing the convex hull of an original dataset $X \subset \mathbb{R}^n$, comprised by target class objects, can be an approximation of its geometric boundaries.

The convex hull $CH(X)$ of a finite set of points X is the minimal convex set containing X , and it is defined as the convex combination of points according to Equation 2.9 [32, 21].

$$CH(X) = \left\{ \sum_{i=1}^N \alpha_i x_i \mid \sum_{i=1}^N \alpha_i = 1, 0 \leq \alpha_i \leq 1 \right\} \quad (2.9)$$

Where:

- α_i are the coefficient of x_i .
- N is the number of observations in X .

The convex hull calculations over two different random dataset in \mathbb{R}^2 , \mathbb{R}^3 are shown in Figure 2.8 and Figure 2.9, respectively.

Then, a direct one-class approach would be the following: if a test data is outside the convex hull, it is labeled as an outlier. Furthermore, depending on the application, it could be desirable to contract or enlarge the hull [7]. Then, to do that, from the centroid $c = (1/|X|) \sum_i x_i, \forall x_i \in X$, the initial convex hull vertexes v can be converted to v^λ using a parameter $\lambda \in [0, +\infty)$ following the Equation 2.10.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

2.2 One-class intelligent techniques




Figure 2.8: Example of convex hull calculation in \mathbb{R}^2

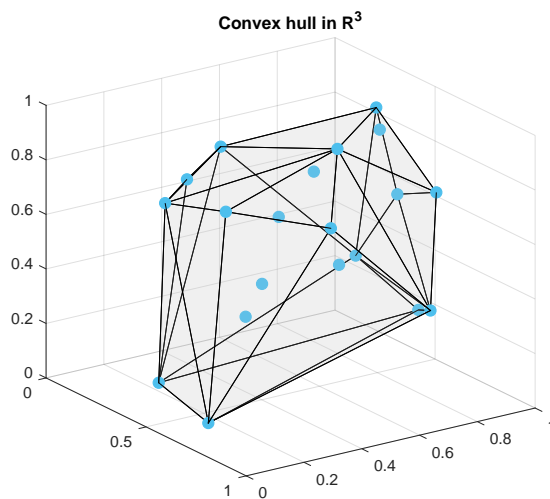


Figure 2.9: Example of convex hull calculation in \mathbb{R}^3

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

$$v^\lambda : \{\lambda v + (1 - \lambda)c \mid v \in CH(X)\} \quad (2.10)$$

Therefore, values of λ lower than 1 lead to convex hull contraction, and values greater than 1 expand convex hull. The proper value of λ depends on the shape of the dataset. An example of this feature is shown in Figure 2.10, where the dots (\bullet) represent the original convex hull, the diamonds (\blacklozenge) delimit the enlarged convex hull and the squares (\blacksquare) represent the area contracted. This vertexes modification is performed from the centroid, identified with a cross (+).




Figure 2.10: Modification of the initial convex hull using λ

Although the convex hull can be a good approximation of the dataset boundaries, its calculation has a significant computational cost. Considering a training set of N samples and n variables, the computational cost is $O(N^{(n/2)+1})$ [3]. This handicap is the main motivation to use the Approximate Convex Hull (ACH) method.

The ACH of a given set consists of making p projections of the original data over random $2D$ planes. Then, the convex limits of each projection represents a good approximation of the convex hull.

According to this approach, when the convex hull approximation is obtained from

2.2 One-class intelligent techniques

the training dataset, the following classification criteria for test data is used: if the data is out of at least one of the p projections, it is considered an anomaly. Figure 2.11 shows a 2D example where an anomaly point in \mathbb{R}^3 space is out of one of the original data projections.

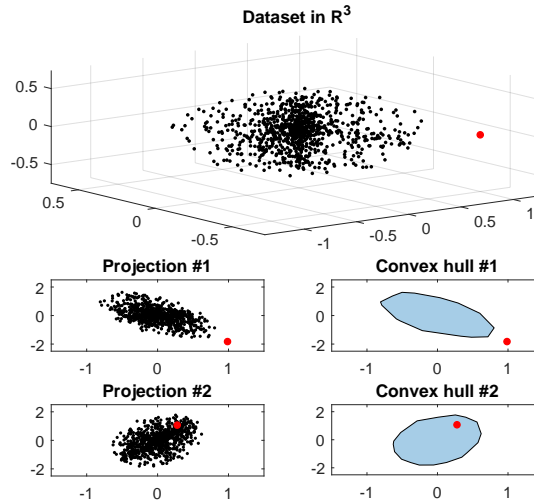


Figure 2.11: ACH with two projections

This one-class classification has performed well in anomaly detection tasks in many different fields [3, 7]. It offers successful results on different UCI learning machine repositories [3].

2.2.2. Artificial Neural Network. Autoencoder

The Autoencoder is a dimensional reduction technique that uses an artificial neural network, whose main goal is to replicate the input pattern at the output [26]. The key feature of the Autoencoder is the dimensional nonlinear reduction applied in the hidden layer, since each layer neuron presents a nonlinear activation function (see Subsection 2.1.2.1).

The scheme shown in Figure 2.12 represents the Autoencoder architecture with

Chapter 2. Methods

only one hidden layer. In this case, the input dataset $x_i \in \mathbb{R}^n$ is reconstructed at the output x_{ri} . Hence, the number of neurons of the input and output layers must be the same. The dimensional reduction is achieved by having in the hidden layer, at least, one less neuron than the input/output one. This means that the vector $x_i \in \mathbb{R}^n$ is converted to a lower dimensional vector $v_i \in \mathbb{R}^m$, where $n > m$ as shown in Equation 2.11 [26].

The dimensional reduction makes the assumption that some data variables are correlated, and can be embedded into a lower dimension space, where normal and anomalous samples are significantly different [26].

Then, after the hidden layer, the information is decompressed and projected at the output, that must replicate the input pattern, according to Equation 2.12 [26].




Figure 2.12: Autoencoder structure with one hidden layer.

$$v = f_1(W_1x + b_1) \quad (2.11)$$

where:

- W_1 - Weight matrix between input and hidden layer.
- b_1 - Bias 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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

2.2 One-class intelligent techniques

$$x_r = f_2(W_2v + b_2) \tag{2.12}$$

where:

- W_2 - Weight matrix between hidden and output layer.
- b_2 - Bias vector.

The criteria to detect a novelty is based on the reconstruction error, calculated according to Figure 2.13 and Equation 2.13. This value should be low when test instances are similar to the train instances. On the other hand, the error should be high with anomalous objects.




Figure 2.13: Reconstruction error calculation

$$Error = \sqrt{(x - x_r)^2} \tag{2.13}$$

This technique is commonly applied to different tasks, such as denoising data or anomaly detection [9, 29, 19, 15].

2.2.3. One-class Support Vector Machine

As presented in Subsection 2.1.2.2, the basic idea of SVM is to map the training set into a feature space, and find an hyperplane that separates two classes [8, 4]. This approach can be also applied to one-class classification by maximizing the distance between the mapped data and the origin. The hyperplane parameters are computed by solving the Equation 2.14, subjected to Equation 2.15 [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: 2307538	Código de verificación: Ejyc0z4z
Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

$$\min \left(0.5 \|w\|^2 + \frac{1}{\nu l} \sum_{i=1}^l \xi_i - b \right) \quad (2.14)$$

$$(w \cdot \delta(x_i)) \geq b - \xi_i, \xi_i \geq 0 \quad (2.15)$$

Where

- w and b are the hyperplane parameters.
- δ is the kernel function.
- $\nu \in (0, 1]$ is the asymptotic fraction of outliers.
- ξ is a slack variable.

Lower values of ν leads to low number of support vectors and, hence, a softer decision hyperplane. However, higher values of ν may lead to overfitting.

For a new test point x , the novelty is detected when it falls outside the hyperplane constructed during the training process [27, 16].

2.2.4. Principal Component Analysis

The Principal Component Analysis (PCA) is an algorithm used to reduce data dimensionality with the minimum loss of information. This goal is achieved by identifying the main directions, known as components, where the data variation are highest [23]. The use of this technique leads to interesting results when the subspace is clearly linear [28].

PCA creates new variables through linear combinations of the original ones. The linear subspace is defined by the eigenvalues of the covariance matrix, and the principal data axis are calculated as the eigenvectors with the highest eigenvalues [28]. An example of PCA application is shown in Figure 2.14. It is interesting to remark that the first principal component (purple line) captures the direction with largest variation. On the other hand, the second component (brown line) presents lower variation.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

2.2 One-class intelligent techniques

In this figure is also represented the data reduction from \mathbb{R}^2 to \mathbb{R}^1 using two different linear transformations. The number of components, must be, at most, the same as the dimension of the initial dataset.

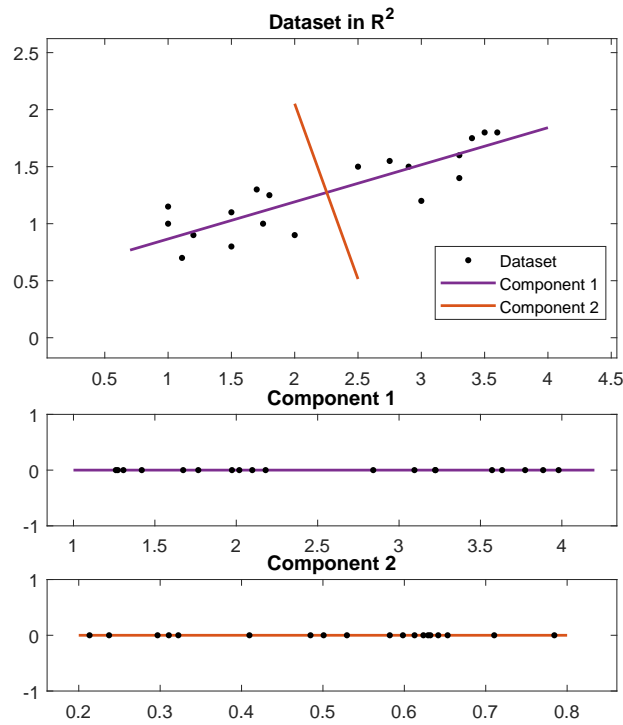


Figure 2.14: An example of dimensional reduction using PCA

This widely used dimensional reduction technique, can also be applied to one-class using a reconstruction error criteria. The reconstruction error (Equation 2.16) is computed as the difference between an original point x and its projection x_{pr} . Then, when the reconstruction error of a test data is above a specific threshold, the anomaly is detected.

$$e(x) = \|x - x_{pr}\| \quad (2.16)$$

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 2. Methods

Let suppose the training set shown in Figure 2.15, whose principal components are represented in purple and brown lines. If an anomalous test data is checked, the distance from this point to the component projection is evaluated. This circumstance can be seen in Figure 2.16, where the reconstruction error of the training set are clearly lower than the one obtained with the anomaly.




Figure 2.15: Training set, PCA components and outlier appearance

2.3. Performance analysis

This section discusses the different parameters taken into consideration to determine the performance of the techniques proposed in the previous subsection.

2.3.1. Hybrid model assessment

The model assessment is divided into two parts, first, the considered parameters to evaluate the model performance are described, and then, the proposed approach for the validation is explained.

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: 2307538	Código de verificación: Ejyc0z4z
Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

2.3 Performance analysis

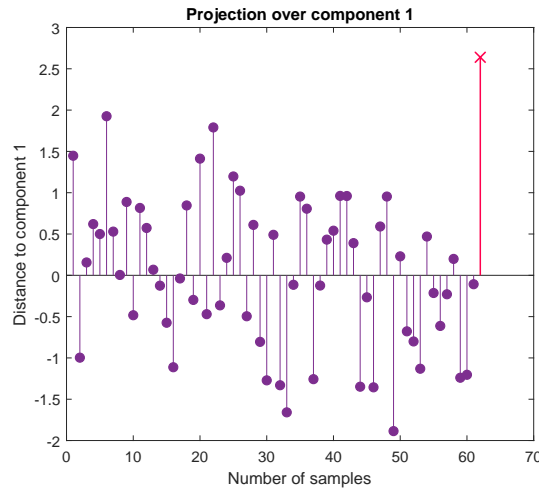


Figure 2.16: Reconstruction error using PCA

2.3.1.1. Performance parameters

A very common metric to compare a model performance is the Mean Squared Error (MSE), defined in Equation 2.17 [17].

$$MSE = \frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2 \quad (2.17)$$

Where:

- N is the number of instances.
- y_i is the real value.
- \hat{y}_i is the value predicted by the model.

As mentioned in previous sections, the approach combines the clustering algorithm with intelligent regression systems. Then, for a given hybrid system with different local

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 2. Methods

models, a MSE value is obtained for each model. However, it is desirable to obtain a single value to assess the hybrid topology performance. Hence, it is interesting to determine the average hybrid model performance. As the cluster data distribution may be unbalanced (Figure 2.17), it is necessary to compute the Average MSE obtained considering the number of samples at each cluster (Equation 2.18).

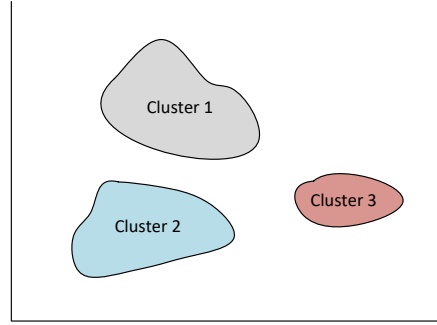


Figure 2.17: Unbalanced data cluster distribution

$$\text{Average MSE} = \frac{1}{N} \sum_{i=1}^C \text{MSE}_i \cdot n_i \quad (2.18)$$

Where:

- C is the number of models or clusters.
- MSE_i is the MSE of the i^{th} model.
- n_i is the size of the training set of i^{th} model.

In addition to this parameter, the Normalized Mean Squared Error (NMSE) (Equation 2.19), Mean Absolute Error (MAE) (Equation 2.20), and Mean Absolute Percentage Error (MAPE) (Equation 2.21), can be considered.

$$\text{NMSE} = \frac{1}{N} \sum_{i=1}^N \frac{(\hat{y}_i - y_i)^2}{\hat{y} \cdot \bar{y}} \quad (2.19)$$

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

2.3 Performance analysis

Where:

- $\bar{\hat{y}}$ is the mean value of \hat{y} .
- \bar{y} is the mean value of y .

$$MAE = \frac{1}{N} \sum_{i=1}^N |\hat{y}_i - y_i| \quad (2.20)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (2.21)$$

2.3.1.2. Model validation

To validate each model performance, a $k - fold$ cross validation is proposed. The steps followed are the next:

1. The data is divided into k random groups.
2. A model is trained with $(k - 1)/k$ of the data.
3. Once the model is obtained, it is tested with the $1/k$ remaining data.
4. The steps 2 and 3 are repeated k times.

An example of a 3 $k - fold$ is shown in Figure 2.18, where the initial dataset is separated into three random groups. Hence, k different models are obtained, ensuring that all target data is used to test and train. The mean MSE value of each iteration represents a reliable measure of the model performance [13]. This process is followed in both global and local 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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

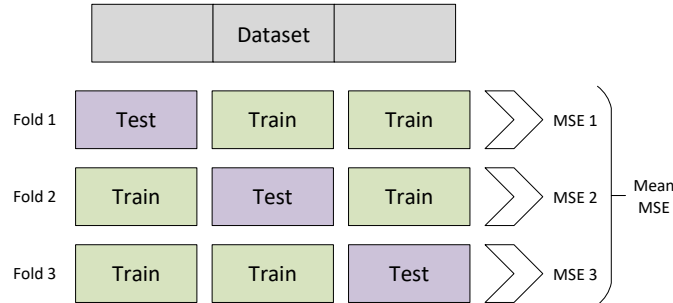


Figure 2.18: k – fold cross validation with $k = 3$

2.3.2. One-class classifier assessment

The classifier assessment is divided into two parts, first, the considered parameters to assess the classifier performance are described, and then, the proposed approach to validate it is explained.

2.3.2.1. Performance parameters

To evaluate a classifier performance, there are many parameters that give an idea of the classifier goodness. Focusing on one-class classification, two different classes must be distinguished by the classifier: target or positive class, and non-target or negative class. A typical way to represent the classifier performance is the confusion matrix shown in Figure 2.19 [2, 5].

However, it could be desirable to determine the classifier performance using a single measure [2]. In this sense, different parameters are proposed [6]:

- Precision: determines how many of the predicted positives were correctly determined (2.22). This value does not take into consideration the classifier performance with the negative class.

$$precision = \frac{TP}{TP + FP} \quad (2.22)$$

2.3 Performance analysis

		Predicted class		
		Positive	Negative	
Real class	Positive	True Positives (<i>TP</i>)	False Negatives (<i>FN</i>)	<i>TP+FN=P</i>
	Negative	False Positives (<i>FP</i>)	True Negatives (<i>TN</i>)	<i>FP+TN=N</i>

Figure 2.19: Confusion matrix

- Specificity: determines how many of the predicted negatives were correctly determined (2.23). This value does not take into consideration the classifier performance with the positive class.

$$specificity = \frac{TN}{TN + FN} \quad (2.23)$$

- Accuracy: measures the success rate of the classifier 2.24.

$$accuracy = \frac{TP + TN}{P + N} \quad (2.24)$$

- True positive rate (tp_r): measures the relationship between the true positives and the number of instances belonging to the positive class (2.25). It can be also defined as recall or sensitivity.

$$tp_r = \frac{TP}{P} = \frac{TP}{TP + FN} \quad (2.25)$$

- False positive rate (fp_r): represents the relationship between the false positives and the number of instances belonging to the negative class (2.26). It can be also defined as false alarm rate.

$$fp_r = \frac{FP}{N} = \frac{FP}{TN + FP} \quad (2.26)$$

Metrics such as *precision*, *specificity* or *accuracy* present the important weakness of using values from both rows of the confusion matrix. Hence, a change in the class

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 2. Methods

distribution implies a change in these metrics. To illustrate this issue, let's consider the performance evaluation of a classifier with a set, whose number of observations is varied. The first set A is composed of 14 target objects and 12 anomalies, and the second one B has 140 target objects and 12 anomalies, which means that the class distribution is different. The performance parameters of the same classifier, when it is tested with the two sets, are shown in Table 2.1. From this example, it can be seen that, although both classifiers have the same performance with both classes, a change in the class distribution leads to a change in the classifier metrics.

Set	TP	FN	TN	FP	tp_r	fp_r	$Prec.$	$Spec.$	$Acc.$
A	10	4	11	1	0,71	0,08	0,91	0,73	0,81
B	100	40	11	1	0,71	0,08	0,99	0,22	0,73

Table 2.1: Performance of the same classifier depending on the class distribution

This is the main motivation for using the Receiving Operating Characteristic (ROC) curve, that relates the tp_r (vertical axis) and fp_r (horizontal axis). These two measures do not depend on the class distribution (see Table 2.1).

To explain the ROC calculation, an example with two different classifiers is shown. Let's suppose two different classifiers A and B , that give an score for each test sample p_i , as shown in Table 2.2.

Samples	Class	Score A	Score B
p_1	positive	0,9	0,9
p_2	positive	0,8	0,8
p_3	negative	0,7	0,4
p_4	positive	0,4	0,7
p_5	negative	0,2	0,2

Table 2.2: Scores given by two different classifiers over an example set

The classifier performance depending on the score threshold is shown in Tables 2.3 (A) and Table 2.4 (B). The resulting ROC curve for each classifier is shown in Figure 2.20. It can be derived from the figure and the tables, that the second classifier achieves better results.

However, it is interesting to convert this ROC curve into a scalar value. With this purpose, a very common method consists on calculate the Area Under the ROC Curve (AUC). Since the ROC curve is plotted over a unit square, the AUC value can vary

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

2.3 Performance analysis

from 0 to 1, being 1 the best possible value [6].

Threshold	TP	FP	TN	FN	tp_r	tn_r
≥ 1	0	0	2	3	0,00	0,00
$\geq 0,9$	1	0	2	2	0,33	0,00
$\geq 0,8$	2	0	2	1	0,67	0,00
$\geq 0,7$	2	1	1	1	0,67	0,50
$\geq 0,4$	3	1	1	0	1,00	0,50
$\geq 0,2$	3	2	0	0	1,00	1,00

Table 2.3: Classifier A performance depending on the set threshold

Threshold	TP	FP	TN	FN	tp_r	tn_r
≥ 1	0	0	2	3	0,00	0,00
$\geq 0,9$	1	0	2	2	0,33	0,00
$\geq 0,8$	2	0	2	1	0,67	0,00
$\geq 0,7$	3	0	2	0	1,00	0,00
$\geq 0,4$	3	1	1	0	1,00	0,50
$\geq 0,2$	3	2	0	0	1,00	1,00

Table 2.4: Classifier B performance depending on the set threshold

In terms of statistics, the AUC value represents the probability that the classifier will rank a random positive instance higher than a random negative one. When there is no threshold and the ROC value has a single point, the AUC value is represented using the area under the trapezoid. The AUC calculation of a discrete classifier with $tp_r = 0,9$ $fp_r = 0,1$ is shown in Figure 2.21 [6].

2.3.2.2. Anomaly generation

It is important to emphasize that the lack of information about anomalous situations represents an important issue when the performance of a one-class classifier is tested. This situation may happen due to different reasons. In some applications, it is not feasible to detect all the potential anomaly sources, and how they would behave. Furthermore, although they are defined, it is not desirable to force any system to anomalous situations, especially the safety-critical ones.

Then, it is necessary to create artificial anomalies from a target set. In [20], the anomaly generation task is performed by applying linear transformations, and in [30],

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 2. Methods

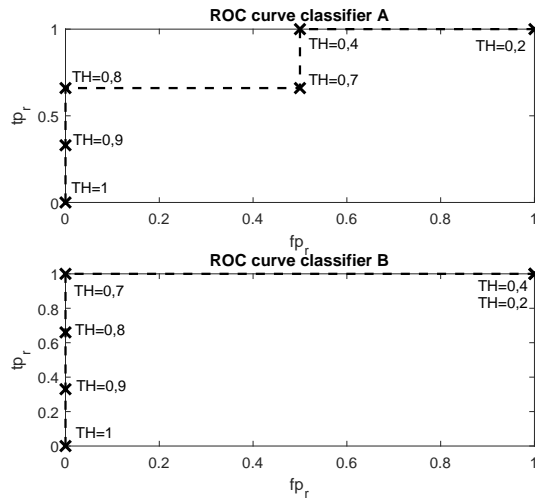


Figure 2.20: Receiving Operating Curve of classifier A and B

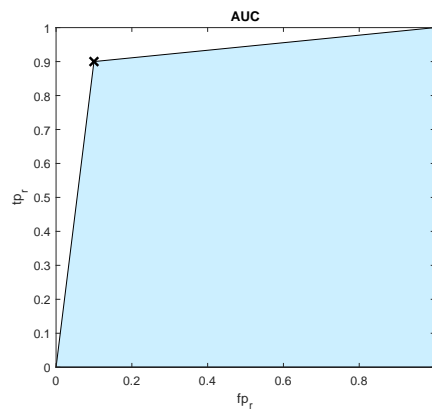


Figure 2.21: Discrete AUC value

the anomalies are generated by shifting the data points out of the target set boundaries.

In this work, a different approach is used. Lets suppose that the target samples to modify are stored in a matrix $A \in \mathbb{R}^{n \times q}$, where n is the number of samples and q 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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

2.3 Performance analysis

number of variables per sample. For each instance, one random variable is modified a by a specific percentage $\pm p\%$.

An example of the anomaly generation with 4 instances in \mathbb{R}^3 is illustrated in Figure 2.22, were the altered variable is randomly chosen for each sample.




Figure 2.22: Anomaly generation with 4 samples in \mathbb{R}^3

2.3.2.3. Classifier validation

To validate a classifier performance, a $k - fold$ cross validation is proposed. It is important to emphasize that, in this case, only target objects are considered to train the classifier. Therefore, the $k - fold$ process is slightly different than the one proposed for the hybrid intelligent model:

1. The target class data is divided into k random groups.
2. The classifier is trained with $(k - 1)/k$ of the target class data.
3. Once the classifier is obtained, it is tested using both anomalous samples and the $1/k$ remaining target instances.
4. The steps 2 and 3 are repeated k times.

An example of a 3 $k - fold$ is shown in Figure 2.23, where the target set is divided into three random groups $T1$, $T2$ and $T3$, and the outlier set is A . As for the hybrid intelligent model, k different classifiers are obtained, ensuring that all data is used to test and train, obtaining the mean AUC value of each iteration.

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: 2307538	Código de verificación: Ejyc0z4z
Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

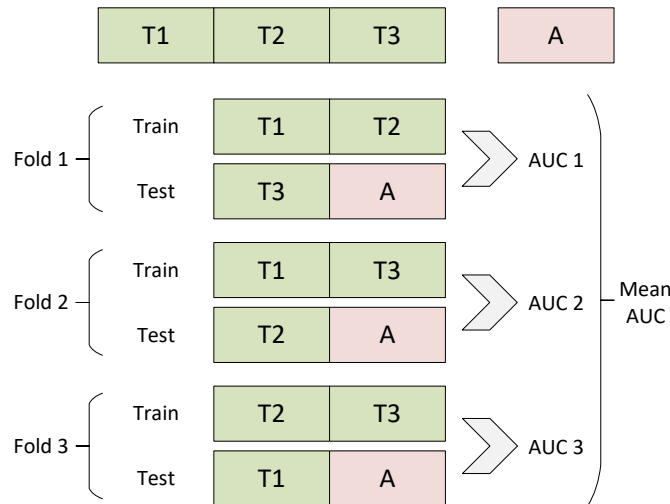


Figure 2.23: k -fold cross validation with $k=3$

Bibliography

- [1] C. M. Bishop. Novelty detection and neural network validation. *IEE Proceedings-Vision, Image and Signal processing*, 141(4):217–222, 1994.
- [2] A. P. Bradley. The use of the area under the roc curve in the evaluation of machine learning algorithms. *Pattern recognition*, 30(7):1145–1159, 1997.
- [3] P. Casale, O. Pujol, and P. Radeva. Approximate convex hulls family for one-class classification. In C. Sansone, J. Kittler, and F. Roli, editors, *Multiple Classifier Systems*, pages 106–115, Berlin, Heidelberg, 2011. Springer Berlin Heidelberg. ISBN 978-3-642-21557-5.
- [4] Y. Chen, X. S. Zhou, and T. S. Huang. One-class svm for learning in image retrieval. In *ICIP (1)*, pages 34–37. Citeseer, 2001.
- [5] B. Chidlovskii and M. Hovelynck. Multi-modality classification for one-class classification in social networks, Feb. 26 2013. US Patent 8,386,574.
- [6] T. Fawcett. An introduction to roc analysis. *Pattern recognition letters*, 27(8): 861–874, 2006.

2.3 Performance analysis

- [7] D. Fernández-Francos, ó. Fontenla-Romero, and A. Alonso-Betanzos. One-class convex hull-based algorithm for classification in distributed environments. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, pages 1–11, 2018. ISSN 2168-2216. doi: 10.1109/TSMC.2017.2771341.
- [8] A. B. Gardner, A. M. Krieger, G. Vachtsevanos, and B. Litt. One-class novelty detection for seizure analysis from intracranial eeg. *Journal of Machine Learning Research*, 7(Jun):1025–1044, 2006.
- [9] I. Goodfellow, Y. Bengio, A. Courville, and Y. Bengio. *Deep learning*, volume 1. MIT press Cambridge, 2016.
- [10] K. Hemalatha and K. U. Rani. Advancements in multi-layer perceptron training to improve classification accuracy. *International Journal on Recent and Innovation Trends in Computing and Communication*, 5(6):353–357, 2017.
- [11] A. K. Jain, J. Mao, and K. M. Mohiuddin. Artificial neural networks: A tutorial. *Computer*, 29(3):31–44, 1996.
- [12] 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.
- [13] 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.
- [14] A. Likas, N. Vlassis, and J. J. Verbeek. The global k-means clustering algorithm. *Pattern recognition*, 36(2):451–461, 2003.
- [15] A. Maas, Q. V. Le, T. M. O’neil, O. Vinyals, P. Nguyen, and A. Y. Ng. Recurrent neural networks for noise reduction in robust asr. 2012.
- [16] L. M. Manevitz and M. Yousef. One-class svms for document classification. *Journal of machine Learning research*, 2(Dec):139–154, 2001.
- [17] J. H. Mathews and K. D. Fink. *Métodos numéricos con Matlab*. Pearson, 2000.
- [18] W. S. McCulloch and W. Pitts. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4):115–133, 1943.
- [19] A. Ng et al. Sparse autoencoder. *CS294A Lecture notes*, 72(2011):1–19, 2011.
- [20] Y. Pei and O. Zaïane. A synthetic data generator for clustering and outlier analysis. 2006.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 2. Methods

- [21] F. P. Preparata and M. I. Shamos. *Computational geometry: an introduction*. Springer Science & Business Media, 2012.
- [22] 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.
- [23] M. Ringnér. What is principal component analysis? *Nature biotechnology*, 26(3): 303, 2008.
- [24] G. Ritter and M. T. Gallegos. Outliers in statistical pattern recognition and an application to automatic chromosome classification. *Pattern Recognition Letters*, 18(6):525–539, 1997.
- [25] 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.
- [26] M. Sakurada and T. Yairi. Anomaly detection using autoencoders with nonlinear dimensionality reduction. In *Proceedings of the MLSDA 2014 2nd Workshop on Machine Learning for Sensory Data Analysis*, page 4. ACM, 2014.
- [27] B. Schölkopf, J. C. Platt, J. Shawe-Taylor, A. J. Smola, and R. C. Williamson. Estimating the support of a high-dimensional distribution. *Neural computation*, 13(7):1443–1471, 2001.
- [28] D. M. J. Tax. One-class classification: concept-learning in the absence of counter-examples [ph. d. thesis]. *Delft University of Technology*, 2001.
- [29] P. Vincent, H. Larochelle, I. Lajoie, Y. Bengio, and P.-A. Manzagol. Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion. *Journal of Machine Learning Research*, 11(Dec):3371–3408, 2010.
- [30] C.-K. Wang, Y. Ting, Y.-H. Liu, and G. Hariyanto. A novel approach to generate artificial outliers for support vector data description. In *Industrial Electronics, 2009. ISIE 2009. IEEE International Symposium on*, pages 2202–2207. IEEE, 2009.
- [31] D. K. Wornyo and X.-J. Shen. Coupled least squares support vector ensemble machines. *Information*, 10(6):195, 2019.
- [32] M. Zeng, Y. Yang, S. Luo, and J. Cheng. One-class classification based on the convex hull for bearing fault detection. *Mechanical Systems and Signal Processing*, 81:274–293, 2016.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

2.3 Performance analysis

- [33] 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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 2. 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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

CHAPTER 3



Anomaly detection approach

This chapter describes the different approaches to perform the anomaly detection using the methods described in Chapter 2.

3.1. Fault detection virtual sensor approach

The procedure to obtain the fault detection virtual sensor proposed in this work is divided into two stages. First, a regression model to predict the sensor measurement is achieved by using a hybrid topology. Then, the fault is detected based on the difference between the sensor predicted signal value and the real one. Figure 3.1 shows the generic topology of the proposal, whose operation is described in next subsections.




Figure 3.1: Generic view of the virtual sensor proposed

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

3.1.1. Hybrid intelligent model block

The process to achieve a regression model capable of predicting the sensor value can be summarized in the following the next steps.

1. The initial dataset is composed of different system operation instances, structured as inputs and outputs.
2. To improve the model performance, the input data is divided into c clusters.
3. For each cluster, a modeling process is made.

To illustrate this procedure, a representative example of these steps with $c = 3$ is shown in Figure 3.2. It is important to remark that, with the aim of modeling the system dynamics, the input data can include data from the current state and previous states of the system.

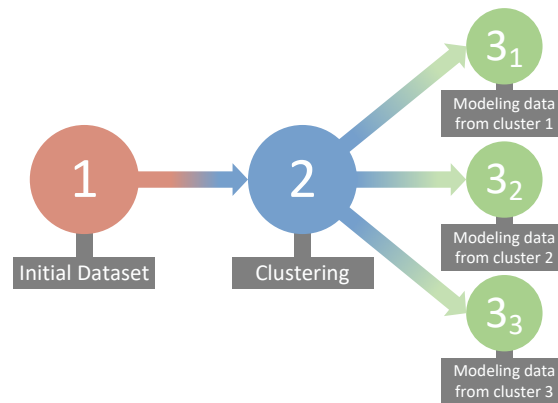


Figure 3.2: General description of hybrid modeling process with $c = 3$

However, the modeling process (step 3) shown in Figure 3.2 is simplified. A more detailed description of the procedure to obtain the model of one cluster, known as local model, can be seen in Figure 3.3, where the modeling process already includes the $k - fold$ process stated in section 2.3.1.2 of chapter 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: 2307538	Código de verificación: Ejyc0z4z
Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

3.1 Fault detection virtual sensor approach

Then, m different regression methods m are evaluated (in this work, MLP and LS SVR are tested) and, for each one, n different hyperparameters are swept. For instance, the MLP is commonly tested with different hidden layer neurons. Hence, an MSE is obtained for each hyperparameter n of both methods m , according to the k -fold process. The best local model is the one with the lowest MSE.




Figure 3.3: Modeling process of a cluster c

Finally, once the best method and configuration of each cluster is chosen, the hybrid topology is implemented. For a new input sample, it is selected which cluster it belong to and the output value is predicted. An example with three clusters is shown in Figure 3.4, where $Model_1$, $Model_2$ and $Model_3$ are the best models for each cluster.

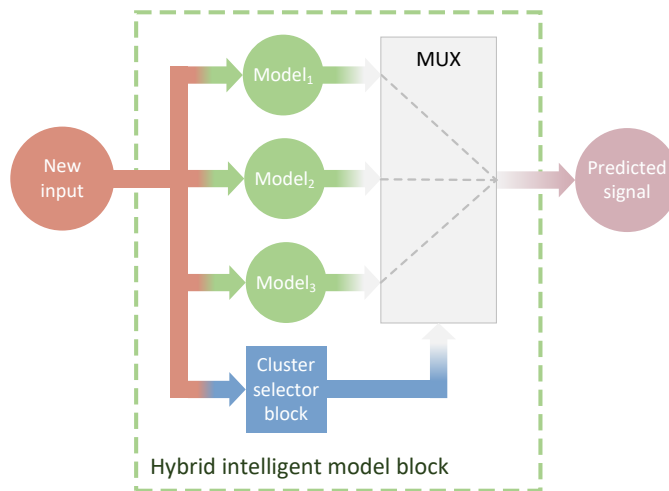


Figure 3.4: Hybrid intelligent model block with three clusters

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

3.1.2. Virtual sensor fault detection block

Once the hybrid model is implemented, the fault detection block is in charge of detecting deviations from the normal operation and replace wrong sensor readings when an anomaly is detected. This is carried out according to the structure of Figure 3.5, and it is composed by three different blocks:

- Fault block: it compares the deviation between the real sensor value and the predicted sensor value (see Figure 3.4). If the deviation is above the *Range* threshold, the anomaly is detected.
- Output selector block: it multiplexes the real and the predicted value depending on the fault block output.
- Counter block: it determines a failure when the number of consecutive faults is higher than the value *Max fails*. In this case, the sensor output is disconnected.

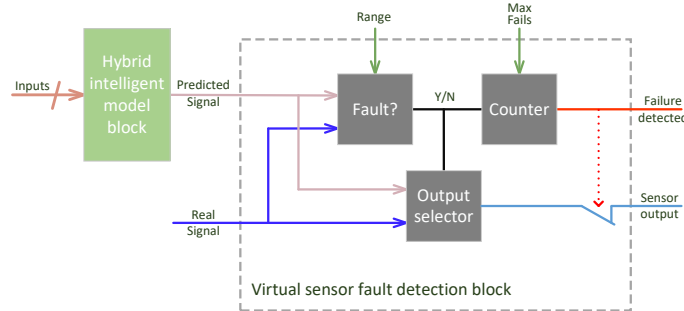


Figure 3.5: Virtual sensor fault detection block

3.2. One-class classifier approach

The process followed to determine the best one-class classifier can be seen in Figure 3.6. As mentioned in section 2.3.2.3 of chapter 2, the target objects are used to train and test the classifier according to a k -fold cross validation, and the anomalies are only used during the test process.

3.2 One-class classifier approach

The training and test phases are performed with m different one-class methods (ACH, Autoencoder, SVM and PCA, in this work) and, for each one, n different hyperparameters are swept. For instance, the number of projections used in ACH is commonly swept. Therefore, an AUC value is calculated for each hyperparameter n of both methods m , according to the k -fold process. The best classifier is the one with the highest AUC.

To illustrate this procedure, a representative example is shown in Figure in 3.6.




Figure 3.6: General description of the one-class methods evaluation

Finally, once the best method and configuration is achieved, the classifier topology is the one shown in Figure 3.7. For a new input sample, the classifier determines if it belongs to the target or the anomaly class.




Figure 3.7: One-class classifier topology

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 3. Anomaly detection approach

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

CHAPTER 4



Virtual sensor for fault detection, isolation and data recovery for bicomponent mixing machine monitoring

This chapter corresponds to the first article used to present this research work through the compendium of publications modality. With the aim of having a homogeneous format in the document, the original article format has been adapted. The main information of this contribution is presented below. It is important to note that the article has been accepted but it has not been published yet.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 4. Virtual sensor for fault detection, isolation and data recovery for bicomponent mixing machine monitoring

General information:

Authors:

Esteban Jove^{1,2}, José-Luis Casteleiro-Roca¹, Héctor Quintián¹, Juan Albino Méndez Pérez² y José Luis Calvo-Rolle¹.

Affiliations:

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.

Title: Virtual sensor for fault detection, isolation and data recovery for bicomponent mixing machine monitoring.

Journal: Informatica.

Volume: N/A.

Pages: N/A.

Publisher: Vilnius University Institute of Data Science and Digital Technologies.

Year: 2019.

DOI: N/A.

Impact factor ISI JCR 2017: 1,386.

Impact factor ISI JCR 2018: 1,928.

Impact factor ISI JCR 2017 (5 years): 1.245.

Impact factor ISI JCR 2018 (5 years): 1,775.

Category Computer Science, Information Systems 2017: 93/148 - Q3.

Category Computer Science, Information Systems 2018: 86/155 - Q3.

Category Mathematics, Applied 2017: 71/252 - Q2.

Category Mathematics, Applied 2018: 43/254 - 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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Abstract

The present research shows the implementation of a virtual sensor for fault detection with the feature of recovering data. The proposal was implemented over a bicomponent mixing machine used for the wind generator blades manufacture based on carbon fiber. The virtual sensor is necessary due to permanent problems with wrong sensors measurements. The solution proposed uses an intelligent model able to predict the sensor measurements, which are compared with the measured value. If this value belongs to a specified range, it is valid. Otherwise, the prediction is replaced by the read value. It has been added the process fault detection feature to the proposal, based on consecutive erroneous readings, obtaining satisfactory results.

Keywords: Virtual sensor, Fault detection, Recovery, FDD, FDR

4.1. Introduction

Not long ago, the majority of industrial activities were focused on increasing productivity and putting new processes and systems in operation. Regardless the kind of application, system optimization has become a common goal. One of the reasons for this is the increasing competitiveness in every field [17]. To become more competitive, industries tend to decrease the consumption of energy in their productive processes, reduce environmental impact, minimize product failures, increase the general quality... In short, the optimization of production processes with minimum consumption and environmental impact has become a current goal for industries [15]. Any contribution, no matter how small, can help to achieve this objective.

One of the biggest problems experienced in the production process are the different anomalies that may occur during plant operation. They contribute to process failures and consequently, to the deterioration of the overall quality of a product or a service. Usually, one of the typical problems that gives rise to these operating anomalies are inaccurate readings produced by malfunctioning sensors and transducers. This issue may seem to be a minor problem. However, when a process relies on the values read, the consequences of using incorrect values can be very critical [23].

In [29], two different kinds of errors in sensors are described: complete failure 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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 4. Virtual sensor for fault detection, isolation and data recovery for bicomponent mixing machine monitoring

bias error. The first case is relatively easy to solve. However, the second one requires close attention, even failure detection is not easy to identify. From the point of view of an operating plant, bias failures could entail problems in terms of control, Fault Detection and Diagnosis (FDD), optimization, and of course, plant monitoring.

With the aim of preventing sensor failures and consequently, the above mentioned problems, one of the common methods consists in the implementation of physical redundancy, for both fault detection and accomplishment of diagnosis tasks [11]. In some critical applications, like nuclear energy plants, the use of this kind of redundancy is very common. However, the use of this method has been reduced significantly in the last years due to its high cost and complex implementation, among others reasons [29].

A suitable alternative, used especially in applications that are not very critical, consists in using virtual sensors for failure detection. Besides, this alternative could be applied as a complementary tool for critical applications.

With this method, it is possible to detect both errors, complete failure and bias deviation. When a sensor reads a value incorrectly, it will be possible to estimate the percentage of its error if necessary [14]. There are some proposals where an algorithm is created to accomplish fault detection and, when there is a fault, it is isolated and recovered [2].

Due to the rise in the popularity of automated processes, it is necessary to measure a huge quantity of variables to fulfil different tasks, such as monitoring or control. To accomplish this goal successfully, the correct functioning of all sensors of the system is mandatory. This is not an easy task, because normally sensors operating in industrial environments [24] experience some failures. In a typical process, it is possible for one or more of those anomalies to occur: faults in actuators, disturbances in the process, sensor faults and measurement noise [2]. With the aim of mitigating the above mentioned possibilities, it would be necessary to develop an algorithm for fault detection which would isolate the errors in its first step and then would recover the correct data [9].

This work addresses the problem of an automatic mixing machine for obtaining a bicomponent product used in the manufacture of wind generator blades, whose primary element is carbon fiber. In this case specifically, the mixture consists of two products, the first one is an epoxy resin, and the second one is a catalyst. If the proportions of those two products are correct and stable in the mixture, the product acquires the desired properties. This process is very difficult to control due to the Non-Newtonian

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

nature of the primary components, because their properties depend on the fluid stress [4]. Also, the system is located in an industrial environment and is therefore affected by all the sensor-related problems. Thus, the implementation of a virtual sensor is proposed for fault detection, error isolation and recovery of the correct data. Furthermore, the algorithm should be able to detect sensor and process failures when they provide inaccurate readings consecutively.

The structure of this work is organized as follows. After the present section, the next section describes the system, the existing variables, and provides a brief introduction to the virtual sensor developed to detect the incorrect readings and system failures. Then, the implemented model and the applied algorithms are shown. After that section, the results obtained with the implementation of this novel model are presented. Finally, the conclusions and the possible future lines of research are listed.

4.2. Case of study

4.2.1. Bicomponent mixing system

Prior to sensor modeling, an initial description of the installation under study is developed in this section. The wind generator blades are manufactured using the bicomponent material obtained at the output of the mixing machine installation. This material is the result of mixing two different fluids (*Fluid 1* and *Fluid 2*), which are initially stored in separated tanks. The fluids are pumped by two gear pumps, which are coupled to electric engines actuated by two variable frequency drives that follow the control signals provided by the controller. The two pumped fluids are mixed through a mixing valve which gives the necessary objective material throughout the wind generator blade.

The graphs shown in Figure 4.1 represent an example with the values of different system variables during the blade manufacture. As the blade shape is not uniform, the output flow rate is not constant (1). Hence, the pressures of pumps 1 and 2 change depending on the part to be manufactured (2, 3). These variations lead to fluctuations in the product proportion of the final mixed product (4).

To achieve a representative model, all the operating ranges of the installation must

Chapter 4. Virtual sensor for fault detection, isolation and data recovery for bicomponent mixing machine monitoring

be taken into account.

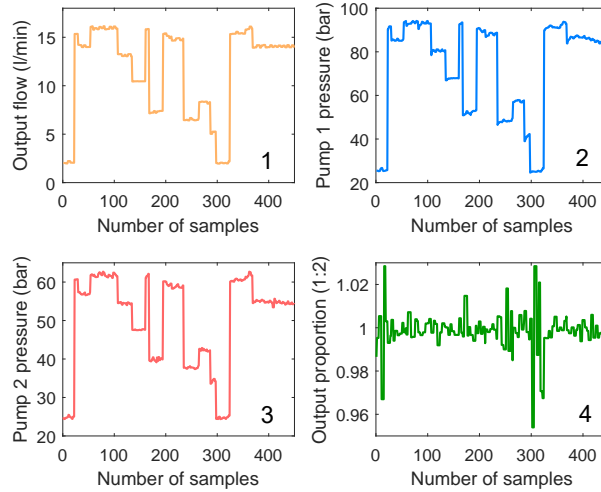


Figure 4.1: Variables measured during system operation

4.2.2. Variables monitored

For each operating range, all the values measured by the sensors located along the installation were recorded during its normal operation. This is a key step in the implementation of the virtual sensor. This research uses a dataset that consists of different plant parameters measured during normal system operation.

Three flowmeters are located in the different pipelines of the mixing machine. They measure the flows of *Fluid 1*, *Fluid 2* and the final material, in liters per minute (*Flow 1*, *Flow 2*, *Output Flow*). Also, four pressure sensors are used to monitor the pressure (bar) along the circuit. Two of them are located after each pump (*Pump 1 pressure*, *Pump 2 pressure*) and the other two sensors are deployed after the flowmeters of lines 1 and 2 (*Flowmeter 1 pressure*, *Flowmeter 2 pressure*).

Besides the measured variables, there are some system variables that are recorded. These monitored variables are the desired and the real proportions of materials 1 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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

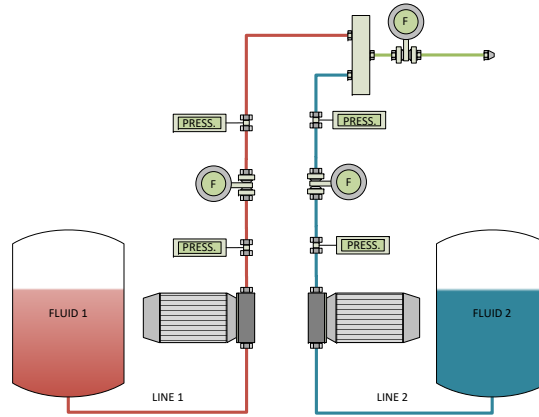


Figure 4.2: Bicomponent mixing system scheme

2 (*Proportion Set Point, Output Proportion*) and also the speeds of both pumps 1 and 2 (*Pump speed 1, Pump speed 2*), in rpm.

The diagram shown in Figure 4.2 represents the sensors located in the mixing machine installation.

4.2.3. Virtual sensor implementation

Some failures might occur during the mixing process. Figure 4.3 shows the measured *Output Flow* with missing values due to sensor failure.

This research aims to design a virtual sensor that ensures that only the correct values are used in processes by replacing erroneous measurements values with the output values given by the model. Moreover, if the measurement of the real sensor is different from the predicted value in some samples, the virtual sensor should detect a failure in the system. A failure can have two possible sources, either a sensor or the system. Since the model is trained with data from correct system operation, the values that deviate considerably from the predicted ones indicate that the system is not functioning properly.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 4. Virtual sensor for fault detection, isolation and data recovery for bicomponent mixing machine monitoring




Figure 4.3: An example of the output flow with erroneous measurements

4.3. Soft Computing Techniques

The soft computing techniques used to create our novel hybrid system are described in detail below.

4.3.1. K-means algorithm. Data clustering

Clustering, a key unsupervised learning algorithm [13], consists in the process of distributing different data into groups that have a common feature. A cluster is defined as a set of objects that presents similarity between them and have different features than the ones located in other clusters [20, 31].

Among the great variety of cluster algorithms, they can be divided into agglomerative hierarchical clustering methods and iterative square-error partitional clustering methods [16].

Partitional clustering algorithms split the initial dataset into a number of clusters specified by the user, minimizing specific criteria. Agglomerative clustering algorithms begin by agglomerating all the data in a singleton cluster and then, nearby clusters are united. When the stop criteria are reached, the clustering is completed.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

4.3 Soft Computing Techniques

The commonly used *K-means* [12] is a clustering algorithm based on two input arguments: the number of clusters K into which the dataset will be divided and the centroid location of each cluster. The training process consists in assigning each data sample to the nearest group centroid. When the groups are formed, the centroids locations are recalculated. This procedure is repeated until no changes are produced in all centroids. The use of *K-means* leads to successful results, especially when clusters are hyperspherical and separated enough in the hyperspace [6].

4.3.2. Artificial neural networks (ANN). Multilayer perceptron (MLP)

An artificial neural network (ANN) is a system designed to emulate the specific brain operations. In the last years, ANN have been applied successfully to solve real and challenging problems [30, 32, 7, 18, 22]. One of the most used supervised learning ANN is the Multilayer Perceptron (MLP) due to its simple structure and robustness [30, 32]. It has one input layer, one output layer and one or more hidden layers. These layers are made of neurons and weighted connections link different layer neurons. The weights of each connection are tuned to decrease the error if the output of the network does not coincide with a known target output. Despite the simplicity of its architecture, the ANN parameter must be chosen properly in order to achieve satisfactory results. In the most common configuration, the same activation function is assigned to all neurons in a layer. The activation function can be linear, step, tan-sigmoid or log-sigmoid.

In this work, the MLP-ANN algorithm used for regression is composed by only one hidden layer and the number of neurons is tested from 1 to 15. The activation functions are tan-sigmoid at the hidden layer neurons and linear at the output.

The employed learning algorithm was Gradient descent, and the algorithm for model training was Levenberg-Marquardt. Also, to measure the network performance, the MSE (Mean Squared Error) method was applied.

4.3.3. Support vector regression (SVR), least square support vector regression (LS SVR)

The support vector machine (SVM) is a supervised form of machine learning that is normally used in classification problems [21, 19]. However, it is also used in regression

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 4. Virtual sensor for fault detection, isolation and data recovery for bicomponent mixing machine monitoring

tasks [5, 10].

For binary classification problems, the aim of SVM is to design a hyperplane for the classification of all the training data into two classes by finding the maximum distance between the locations of the closest data points of both classes and the hyperplane. The training instances presented near the hyperplane are defined as support vectors. Therefore, SVMs perform the projection of the training dataset in a high dimensional feature space using a kernel operator.

SVM can also be used for regression (SVR) by performing minor changes in the original algorithm used for classification problems. The SVR represents the initial dataset in terms of a multi-dimensional feature space F using a non-linear mapping and then, linear regression in F [3, 25].

Least Square formulations of the SVM are known as LS SVM. This technique obtains the solution by solving a linear equations system, which, in terms of performance and generalization, is similar to SVM [26, 28]. LS SVR is defined as the application of LS SVM to regression [8, 27]. In this case, a squared loss function replaces the insensitive loss function.

In this paper, the KULeuven-ESAT-SCD self-tuning was implemented. The selected parameters were 'Function Estimation' to conduct the regression and Radial Basis Function (RBF) for the model kernel. The used cost criteria was 'leaveoneoutlssvm' with 'mse' and the optimization function was configured as 'simplex'.

4.4. Model approach

This section describes the different blocks used to obtain the virtual sensor developed in this paper.

4.4.1. Hybrid Intelligent Models

The first step in the development of a virtual sensor capable of detecting anomalies in the plant under study, consists of using intelligent regression techniques, combined

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

4.4 Model approach

with clustering algorithms. In the specific case explained in this paper, the real sensor under study, whose measurements are predicted, is the *Flow 1*. Then, the signals used to obtain the regression models are: *Output Flow*, *Flow 2*, *Pump 1 pressure*, *Pump 2 pressure*, *Floumeter 1 pressure* and *Floumeter 2 pressure*. Also, the two previous states of each signal are taken into account, including the previous states of *Flow 1*, the output of the model.

As the dataset may consist of data with different behaviors, clustering algorithms are applied to group them accordingly. Then, the hybrid intelligent model used in this research, is based on local models in order to increase the global performance of the predicted signal. This means that, for each cluster, a new model is obtained by using the intelligent regression techniques.

Figure 4.4 represents the hybrid model internally, with the connections to the fault detection block presented in next subsection. The cluster selector block (Figure 4.4) is used to internally assign the input data to its cluster according to its nature. The specific model of that cluster is used to predict the output. When the sensor signal is predicted, it is routed to the fault detection block.

4.4.2. Model selection

To achieve the best model performance, Global and Local models have been considered. As a hybrid model consists of some clusters, the global model is the one that only has one cluster division. Once the data is divided into different clusters using the *K-means* algorithm, the described regression techniques are applied to each group. In all cases (Global and Local models), the k-fold modeling process is shown in Figure 4.5, and follows the subsequent steps:

- Given a specific value of K , the dataset (which consists of the whole data or the data of just one cluster) is divided into two different groups: training and test data.
- Model training: an intelligent model with the regression techniques described in subsections 3.2 and 3.3 (MLP and LS SVR) is implemented. The training data, composed by $(1 - K)/K$ samples, is used to train an intelligent model.
- Model test: once the model is obtained, its performance is checked using the test

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 4. Virtual sensor for fault detection, isolation and data recovery for bicomponent mixing machine monitoring

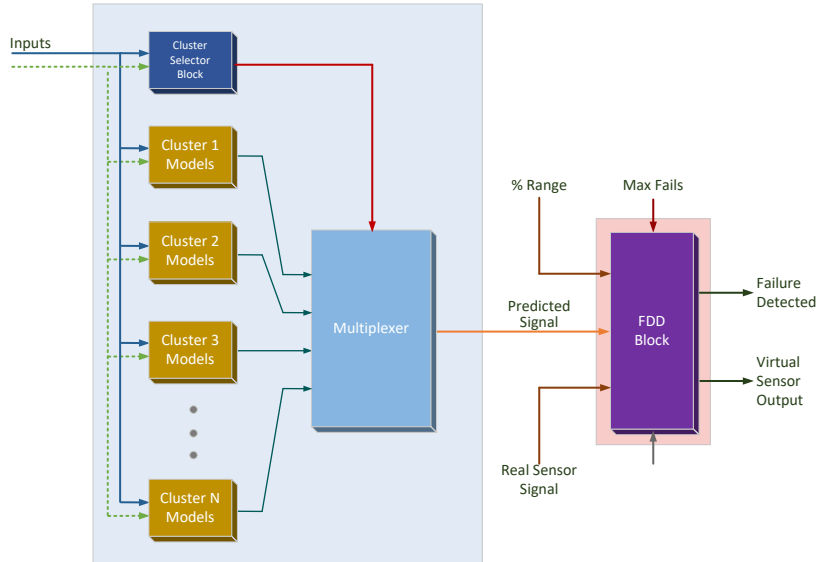


Figure 4.4: Failure detection and virtual sensor diagram

data, composed by $1/K$ samples that are used as inputs of the trained model.

- The outputs predicted by the model are compared with the real outputs and then, the error is calculated.

To achieve a better generalization and a more real model performance, the content of training data and test data are shifted as shown in Figure 4.6 [1]. Hence, for a specific regression technique with a $K = 10$, ten different models are created. Then, an averaged Mean Squared Error (MSE) is calculated from the results of each of the ten models.

Therefore, the process shown in Figure 4.5 and Figure 4.6 is followed to assess the performance of different techniques. The criteria for the selection of the best technique is based on the lowest MSE. As explained before, the $k - fold$ can be applied over one cluster when the $K - means$ algorithm is used, or it can be applied over the complete dataset to obtain a global model.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

4.4 Model approach

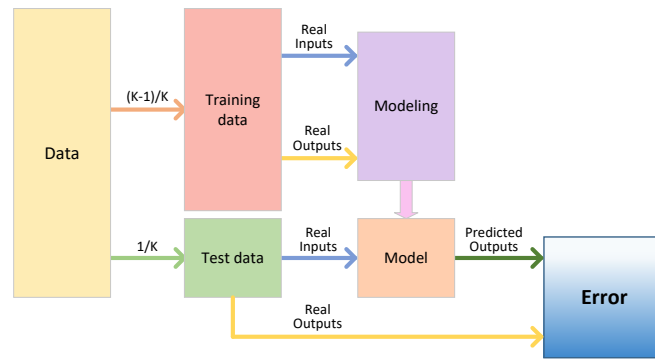


Figure 4.5: Modeling process

4.4.3. Fault Detection Block

Once the hybrid intelligent model predicts the measurement of the sensor, the model approach for the virtual sensor is presented in Figure 4.7.

The fault detection algorithm is applied according to the green block in Figure 4.7. For greater clarity, the figure includes a description of the workflow of this block. The real and the predicted signals are compared and the maximum allowed error between the two values is defined by *Range* signal, a virtual sensor input. If the real signal fits within the specified range, the output of the virtual sensor will be the same as the real value measured by the sensor. If this is not the case, the predicted signal will be used. The fault detection algorithm only allows this fault situation for several consecutive samples. The maximum number of failures allowed is defined by the input signal "Max.Fails". If the number of consecutive failures exceeds the number of failures defined by this input, the *Failedetected* signal is set, and the output of the virtual sensor is turned off. The specific configuration in *Range* and *Max.Fails* depends on the sensor and the system in which the virtual sensor is implemented.

The proposed FDD system is designed to allow for a maximum of 5 inaccurate measurements in consecutive order before the fault detection alarm is set. These 5 samples allow the system to filter incorrect measurements like the ones shown in Figure 4.3, and also make it possible to detect a failure in the sensor. It is necessary to remark

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: 2307538	Código de verificación: Ejyc0z4z
Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 4. Virtual sensor for fault detection, isolation and data recovery for bicomponent mixing machine monitoring

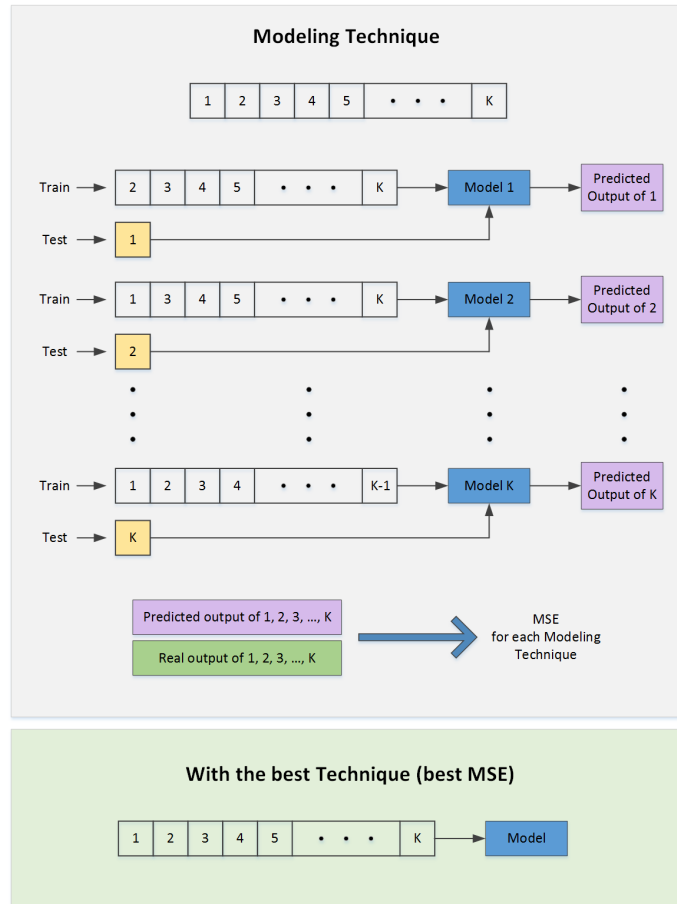


Figure 4.6: K-Fold performance calculation

that, when a failure is detected, it might not be caused by a fault in the sensor, it could be a system failure. In such cases, all the sensors take inaccurate measurements and the model does not predict correct values. In this situation, the detection system is unable to recognize if the incorrect signal is caused by the sensor under supervision or by the predicted signal.

If the rest of the sensors (the model inputs) have incorrect values, a failure 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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

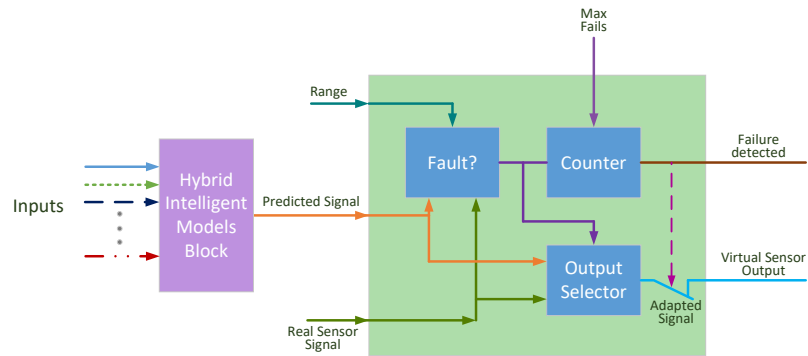


Figure 4.7: Proposal of the virtual sensor model

process could not be detected. However, if all the sensors have similar FDD system as the one described in this paper, an incorrect value in all FDD would mean a process failure.

4.4.4. Dataset description

The dataset used in this research was created by means of many different tests carried out during the operating process.

The original dataset consisted of a total of 9511 samples. After the pre-processing, which consisted in removing the incorrect measurements, the final dataset used to generate the novel model contains 8549 samples, with the variables *Output Flow*, *Flow 1*, *Flow 2*, *Pump 1 pressure*, *Pump 2 pressure*, *Flowmeter 1 pressure*, *Flowmeter 2 pressure*.

4.5. Results

The predictive model is designed to take into account the last two measures of each sensor (six sensors and the predicted sensor value). This way, the model can reflect

Chapter 4. Virtual sensor for fault detection, isolation and data recovery for bicomponent mixing machine monitoring

the system dynamics, achieving a better performance in the prediction. Therefore, the model has 20 inputs: the two previous values of *Flow 1* and the values of the current and the two previous measures of the sensors *Output Flow*, *Flow 2*, *Pump 1 pressure*, *Pump 2 pressure*, *Flowmeter 1 pressure* and *Flowmeter 2 pressure*.

The model output represents the current prediction of value of the *Flow 1* sensor. Different simulation tests were performed in order to check that these values are enough to learn system dynamics. Results demonstrate that including a higher input regression vector does not lead to an improvement in model accuracy.

A statistical analysis was conducted using a *10 K-fold* cross-validation to obtain the MSE of each cluster model.

Once the model for each technique is obtained, the criteria for the choice of the best technique performance is based on the MSE. Table 4.1 represents the lowest MSE in the *Flow1* prediction, depending on the number of clusters. For example, if the dataset is grouped in two clusters, the error obtained is $0.1856e-3$ if the data belongs to cluster 1 and $0.1920e-3$ if it belongs to cluster 2.

To assess the relationship between the number of clusters and the general performance of each cluster configuration, the mean MSE value is calculated (Table 4.2). This average MSE is obtained considering the number of samples at each cluster to ensure a representative measurement of each configuration. Then, Table 4.2 shows that dividing the data into 7 clusters leads to the best model performance.

As a hybrid model is proposed, the technique used to predict the measurements of *Flow1* sensor depends on the cluster configuration. Table 4.3 summarizes the best regression technique for each cluster. Considering the example with two clusters, proposed in the previous paragraph, the sensor measurement is predicted using a neural network with 5 hidden layer neurons, if the input data belongs to cluster 1. Otherwise, a neural network with 8 hidden layer neurons would be used.”

Once the best model is chosen, the resulting hybrid intelligent model was implemented taking into account the best algorithm for each cluster.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

4.5 Results

Nº of clusters	Cl. 1	Cl. 2	Cl. 3	Cl. 4	Cl. 5
1	0.1502e-3	-	-	-	-
2	0.1856e-3	0.1920e-3	-	-	-
3	0.2001e-3	0.1654e-3	0.1338e-3	-	-
4	0.2108e-3	0.1191e-3	0.2119e-3	0.1312e-3	-
5	0.2890e-3	0.0815e-3	0.2149e-3	0.1845e-3	0.0937e-3
6	0.1245e-3	0.1249e-3	0.2358e-3	0.0956e-3	0.1963e-3
7	0.1652e-3	0.1594e-3	0.0979e-3	0.0552e-3	0.1837e-3
8	0.1660e-3	0.3115e-3	0.1117e-3	0.1213e-3	0.2123e-3
9	0.1981e-3	0.1667e-3	0.4204e-3	0.0479e-3	0.1557e-3
10	0.1400e-3	0.1759e-3	0.1188e-3	0.3019e-3	0.1192e-3
Nº of clusters	Cl. 6	Cl. 7	Cl. 8	Cl. 9	Cl. 10
1	-	-	-	-	-
2	-	-	-	-	-
3	-	-	-	-	-
4	-	-	-	-	-
5	-	-	-	-	-
6	0.1464e-3	-	-	-	-
7	0.1637e-3	0.1221e-3	-	-	-
8	0.2321e-3	0.1845e-3	0.0926e-3	-	-
9	0.1117e-3	0.0888e-3	0.2480e-3	0.1205e-3	-
10	0.4108e-3	0.1912e-3	0.0983e-3	0.2047e-3	0.1222e-3

Table 4.1: Clusters MSE

Fault detection system results

To test the FDD system, two types of errors are simulated. In Figure 4.8 it is possible to see the test data used by the system; in the upper side, the real value of the sensor is shown in blue-continuous line. In the middle of the figure, the predicted output from the model is plotted in red-dash line; in the bottom side, the error signal is shown in black-dotted line.

To test the FDD system, some failures are introduced into the value data of real sensor. Figure 4.9 shows one of the tests performed. In this case, the graph on the top gives the real sensor values (blue continuous line), where the different simulated sensor failures can be observed. The tested failures are the most typical failures, such

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 4. Virtual sensor for fault detection, isolation and data recovery for bicomponent mixing machine monitoring

Nº of Clusters	Mean Squared Error
1	0.1502e-3
2	0.1894e-3
3	0.1602e-3
4	0.1584e-3
5	0.1485e-3
6	0.1528e-3
7	0.1314e-3
8	0.1522e-3
9	0.1553e-3
10	0.1698e-3

Table 4.2: Mean MSE for each model depending on the number of clusters




Figure 4.8: Data to test the Fault Detection and Diagnostic system

as the missing data or sensor saturation. Moreover, at the end of the plot, a failure in the sensor is simulated as a degradation in the measured value until it completely fails. The second plot (red-dashed line) represents the values predicted according to the model. The previous values used as inputs are the output of the FDD system, not the sensor value. In case of detecting a measurement that is out of the defined range, the output will be the predicted value, and is the one used as previous value in the model. The third graph is the alarm situation signal, which is activated when the error signal is greater than the range set. However, the system continues working until more than 5 consecutive alarms are detected. The bottom of Figure 4.9 is the output of the system, where it can be seen that the incorrect measurements were replaced by the predicted values, until the error samples had more than 5 errors in a row; that is when the system

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

4.6 Conclusions

Nº of clusters	Cl. 1	Cl. 2	Cl. 3	Cl. 4	Cl. 5
1	ANN-11	-	-	-	-
2	ANN-5	ANN-8	-	-	-
3	ANN-5	ANN-5	ANN-8	-	-
4	ANN-3	ANN-4	ANN-3	ANN-9	-
5	ANN-1	ANN-4	ANN-1	ANN-8	ANN-8
6	ANN-1	ANN-7	ANN-4	ANN-6	ANN-3
7	ANN-1	ANN-1	ANN-7	ANN-5	ANN-3
8	LS SVR	ANN-1	ANN-4	ANN-1	ANN-2
9	LS SVR	ANN-1	LS SVR	ANN-4	ANN-1
10	ANN-4	ANN-2	ANN-4	LS SVR	ANN-1
Nº of clusters	Cl. 6	Cl. 7	Cl. 8	Cl. 9	Cl. 10
1	-	-	-	-	-
2	-	-	-	-	-
3	-	-	-	-	-
4	-	-	-	-	-
5	-	-	-	-	-
6	ANN-15	-	-	-	-
7	ANN-3	ANN-8	-	-	-
8	ANN-2	ANN-3	ANN-10	-	-
9	ANN-10	ANN-4	ANN-1	ANN-13	-
10	LS SVR	ANN-2	ANN-5	ANN-4	ANN-7

Table 4.3: Best regression technique for each cluster depending on the number of clusters

stops working.

4.6. Conclusions

This paper has proposed a virtual sensor for fault detection, isolation and data recovery in a bicomponent mixing machine. The virtual sensor uses a hybrid intelligent model to predict the signal value in a specific sensor. In the described case, the catalyst flow sensor is studied. The model output is the predicted measurement of the sensor under study. The model inputs are the current value and last two values of the other sensors, and the last two states of the output.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 4. Virtual sensor for fault detection, isolation and data recovery for bicomponent mixing machine monitoring




Figure 4.9: Fault Detection and Diagnostic system simulation

All models are capable of predicting the readings of sensor *Flow1* with a maximum error of $0.1894e-3$. The best performance is achieved when the dataset is grouped in 7 clusters, with a mean error of $0.1314e-3$. Moreover, this hybrid model, which combines different intelligent techniques, proves to be a very good predictor of the current state of the sensor.

This feature plays a key role in the implementation of the FDD system by comparing the measured value with the predicted one. The method was validated in terms of three different kinds of failures; a missing measurement, sensor saturation and sensor degradation. In all cases, the system has been able to detect the failures and to replace the inaccurate data successfully.

The virtual sensor works by selecting between the real and the predicted measurement when failures are detected. The permitted range of deviation between the real and the predicted signal can be changed by user. Another input that can be adjusted, is the maximum number of samples needed to detect a fault. The system allows a specific number of consecutive failures. When this signal alerts of a failure, the output of the virtual sensor is opened, because it could be necessary to check the sensor.

The use of the FDD system proposed in this work can be used as a very useful tool for the detection of anomalies on an industrial plant. Anomaly detection is a crucial step in the improvement of plant performance, maintenance planning, product quality, energy optimization, and more.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Bibliography

- [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. Carvajal-Godinez, J. Guo, and E. Gill. Agent-based algorithm for fault detection and recovery of gyroscope's drift in small satellite missions. *Acta Astronautica*, 139: 181–188, 2017.
- [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] H. Fan, C. K. Y. Wong, and M. M. F. Yuen. Prediction of material properties of epoxy materials using molecular dynamic simulation. In *Thermal, Mechanical and Multiphysics Simulation and Experiments in Micro-Electronics and Micro-Systems, 2006. EuroSime 2006. 7th International Conference on*, pages 1–4. IEEE, 2006.
- [5] C.-W. Fei and G.-C. Bai. Distributed collaborative probabilistic design for turbine blade-tip radial running clearance using support vector machine of regression. *Mechanical Systems and Signal Processing*, 49(1):196 – 208, 2014. ISSN 0888-3270. doi: <https://doi.org/10.1016/j.ymssp.2014.04.013>. URL <http://www.sciencedirect.com/science/article/pii/S0888327014001198>.
- [6] L. Garg, S. McClean, B. Meenan, and P. Millard. Phase-type survival trees and mixed distribution survival trees for clustering patients' hospital length of stay. *Informatica*, 22(1):57–72, jan 2011. ISSN 0868-4952.
- [7] S. González, J. Sedano, J. R. Villar, E. Corchado, Á. Herrero, and B. Baroque. Features and models for human activity recognition. *Neurocomputing*, 167:52–60, 2015. doi: 10.1016/j.neucom.2015.01.082. URL <https://doi.org/10.1016/j.neucom.2015.01.082>.
- [8] Y. Guo, X. Li, G. Bai, and J. Ma. Time series prediction method based on LS-SVR with modified gaussian RBF. In T. Huang, Z. Zeng, C. Li, and C. Leung, editors, *Neural Information Processing*, volume 7664 of *Lecture Notes in Computer Science*, pages 9–17. Springer Berlin Heidelberg, 2012. ISBN 978-3-642-34480-0. doi: 10.1007/978-3-642-34481-7{_}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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 4. Virtual sensor for fault detection, isolation and data recovery for bicomponent mixing machine monitoring

- [9] G. Heredia and A. Ollero. Virtual sensor for failure detection, identification and recovery in the transition phase of a morphing aircraft. *Sensors*, 10(3):2188–2201, 2010.
- [10] J. Hu, J. Hu, H. Lin, X. Li, C. Jiang, X. Qiu, and W. Li. State-of-charge estimation for battery management system using optimized support vector machine for regression. *Journal of Power Sources*, 269(Supplement C):682 – 693, 2014. ISSN 0378-7753. doi: <https://doi.org/10.1016/j.jpowsour.2014.07.016>. URL <http://www.sciencedirect.com/science/article/pii/S0378775314010593>.
- [11] I. Hwang, S. Kim, Y. Kim, and C. E. Seah. A survey of fault detection, isolation, and reconfiguration methods. *IEEE Transactions on Control Systems Technology*, 18(3):636–653, 2010.
- [12] A. K. Jain. Data clustering: 50 years beyond k-means. *Pattern Recognition Letters*, 31(8):651–666, 2010. doi: 10.1016/j.patrec.2009.09.011. URL <https://doi.org/10.1016/j.patrec.2009.09.011>.
- [13] S. Kaski, J. Sinkkonen, and A. Klami. Discriminative clustering. *Neurocomputing*, 69(13):18–41, 2005. ISSN 0925-2312. doi: <http://dx.doi.org/10.1016/j.neucom.2005.02.012>.
- [14] S. R. Naidu, E. Zafiriou, and T. J. McAvoy. Use of neural networks for sensor failure detection in a control system. *IEEE Control Systems Magazine*, 10(3):49–55, 1990.
- [15] T. Nicholson. *Optimization in Industry: Volume 1, Optimization Techniques*. Routledge, 2017.
- [16] N. Pal and J. Biswas. Cluster validation using graph theoretic concepts. *Pattern Recognition*, 30(6):847–857, 1997. ISSN 0031-3203. doi: [http://dx.doi.org/10.1016/S0031-3203\(96\)00127-6](http://dx.doi.org/10.1016/S0031-3203(96)00127-6).
- [17] I. Parmee and P. Hajela. *Optimization in industry*. Springer Science & Business Media, 2012.
- [18] C. Pinzón, J. F. de Paz, J. Bajo, Á. Herrero, and E. Corchado. AIIDA-SQL: an adaptive intelligent intrusion detector agent for detecting SQL injection attacks. In *10th International Conference on Hybrid Intelligent Systems (HIS 2010), Atlanta, GA, USA, August 23-25, 2010*, pages 73–78, 2010. doi: 10.1109/HIS.2010.5600026. URL <https://doi.org/10.1109/HIS.2010.5600026>.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

4.6 Conclusions

- [19] Z. Qi, Y. Tian, and Y. Shi. Robust twin support vector machine for pattern classification. *Pattern Recognition*, 46(1):305 – 316, 2013. ISSN 0031-3203. doi: <https://doi.org/10.1016/j.patcog.2012.06.019>. URL <http://www.sciencedirect.com/science/article/pii/S0031320312002890>.
- [20] A. Qin and P. Suganthan. Enhanced neural gas network for prototype-based clustering. *Pattern Recogn.*, 38(8):1275–1288, aug 2005. ISSN 0031-3203. doi: [10.1016/j.patcog.2004.12.007](https://doi.org/10.1016/j.patcog.2004.12.007).
- [21] P. Reberntrost, M. Mohseni, and S. Lloyd. Quantum support vector machine for big data classification. *Phys. Rev. Lett.*, 113:130503, Sep 2014. doi: [10.1103/PhysRevLett.113.130503](https://doi.org/10.1103/PhysRevLett.113.130503). URL <https://link.aps.org/doi/10.1103/PhysRevLett.113.130503>.
- [22] R. Sánchez, Á. Herrero, and E. Corchado. Visualization and clustering for SNMP intrusion detection. *Cybernetics and Systems*, 44(6-7):505–532, 2013. doi: [10.1080/01969722.2013.803903](https://doi.org/10.1080/01969722.2013.803903). URL <https://doi.org/10.1080/01969722.2013.803903>.
- [23] A. B. Sharma, L. Golubchik, and R. Govindan. Sensor faults: Detection methods and prevalence in real-world datasets. *ACM Transactions on Sensor Networks (TOSN)*, 6(3):23, 2010.
- [24] H. Shen, Z.-G. Wu, and J. H. Park. Reliable mixed passive h-infinite filtering for semi-markov jump systems with randomly occurring uncertainties and sensor failures. *International Journal of Robust and Nonlinear Control*, 25(17):3231–3251, 2015.
- [25] I. Steinwart and A. Christmann. *Support vector machines*. Springer Publishing Company, Incorporated, 1st edition, 2008. ISBN 0387772413.
- [26] 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](https://doi.org/10.1023/A:1018628609742).
- [27] L. Wang and J. Wu. Neural network ensemble model using PPR and LS-SVR for stock market forecasting. In D.-S. Huang, Y. Gan, V. Bevilacqua, and J. Figueroa, editors, *Advanced Intelligent Computing*, volume 6838 of *Lecture Notes in Computer Science*, pages 1–8. Springer Berlin Heidelberg, 2012. ISBN 978-3-642-24727-9. doi: [10.1007/978-3-642-24728-6_{_}1](https://doi.org/10.1007/978-3-642-24728-6_{_}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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 4. Virtual sensor for fault detection, isolation and data recovery for bicomponent mixing machine monitoring

- [28] R. Wang, A. Wang, and Q. Song. Research on the alkalinity of sintering process based on LS-SVM algorithms. In D. Jin and S. Lin, editors, *Advances in Computer Science and Information Engineering*, volume 168 of *Advances in Intelligent and Soft Computing*, pages 449–454. Springer Berlin Heidelberg, 2012. ISBN 978-3-642-30125-4. doi: 10.1007/978-3-642-30126-1{_}71.
- [29] S. Wang and J. Cui. Sensor-fault detection, diagnosis and estimation for centrifugal chiller systems using principal-component analysis method. *Applied Energy*, 82(3): 197–213, 2005.
- [30] P. Wasserman. *Advanced methods in neural computing*. John Wiley & Sons, Inc., New York, NY, USA, 1st edition, 1993. ISBN 0442004613.
- [31] J. Ye and T. Xiong. Svm versus least squares SVM. *Journal of Machine Learning Research - Proceedings Track*, 2:644–651, 2007.
- [32] 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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

CHAPTER 5



Anomaly detection based on one-class intelligent techniques over a control level plant

This chapter corresponds to the second paper used to present this research work through the compendium of publications modality. With the aim of having a homogeneous format in the document, the original article format has been adapted. The main information of this contribution is presented below. It is important to note that the article has been accepted but it has not been published yet.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 5. Anomaly detection based on one-class intelligent techniques over a control level plant

General information:

Authors:

Esteban Jove ^{1,2}, José-Luis Casteleiro-Roca¹, Héctor Quintián¹, Dragan Simić³, Juan Albino Méndez Pérez² y José Luis Calvo-Rolle¹.

Affiliations:

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 Faculty of Technical Sciences, University of Novi Sad, Novi Sad, Serbia.

Title: Anomaly detection based on one-class intelligent techniques over a control level plant.

Journal: Logic Journal of the IGPL.

Volume: N/A.

Pages: N/A.

Publisher: Oxford University Press.

Year: 2019.

DOI: N/A.

Impact factor ISI JCR 2017: 0,449.

Impact factor ISI JCR 2018: 0,609.

Impact factor ISI JCR 2017 (5 years): 0,484.

Impact factor ISI JCR 2018 (5 years): 0,446.

Category Mathematics, Applied 2017: 239/252 - Q4.

Category Mathematics, Applied 2018: 217/254 - Q3.

Category Mathematics 2017: 261/310 - Q4.

Category Mathematics 2018: 206/314 - Q4.

Category Logic 2017: 16/20 - Q4.

Category Logic 2018: 8/20 - 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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Abstract

A large part of technological advances, especially in the field of industry, have been focused on the optimization of productive processes. However, the detection of anomalies has turned out to be a great challenge in fields like industry, medicine or stock markets. The present work addresses anomaly detection on a control level plant. We propose the application of different intelligent techniques which allow to obtain one-class classifiers using real data taken from the correct plant operation. The performance of each classifier is assessed and validated with real created faults, achieving successful overall results.

Keywords: Fault detection, One-Class, ACH, Autoencoder, SVM

5.1. Introduction

Over the last decades, the technological advances in different industrial fields, such as automation or instrumentation, have led to the development and optimization of most industrial processes [15, 10]. Also, the high safety, reliability and quality standards for the performance of industrial processes have made them more sophisticated. Additional factors, that must be taken into account in the optimization process of every industrial plant, include environmental impact, reduction of product rejection rates or increased competitiveness [17, 13].

Then, the correct operation of every process is very important. For this reason, the early detection of any kind of anomaly plays a key role, especially in safety-critical and high cost processes [26]. Generally, an anomaly can be caused by actuator malfunction, sensors misreadings and changes in different process parameters [8, 1]. Due to the strong digitalization of most industrial processes and increased power of computation systems, the anomaly detection problem has been receiving a lot of attention within the scientific community [12, 28].

From a generic point of view, anomalies are data patterns that conform an unexpected behavior in a given application [7]. Figure 5.1 illustrates an example of two normal data groups T_1 and T_2 , and four data samples that are outside of the expected normal behaviour a_1 , a_2 , a_3 and a_k .

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 5. Anomaly detection based on one-class intelligent techniques over a control level plant

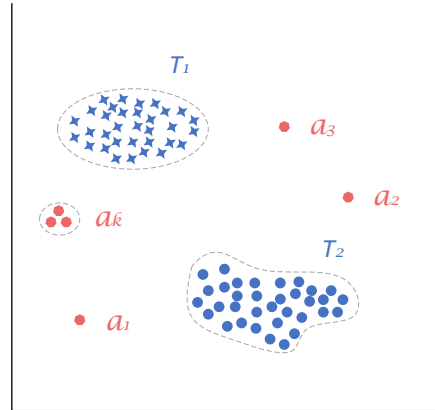


Figure 5.1: Anomaly example in \mathbb{R}^2

Looking at the problem from the industrial point of view, an anomaly is a deviation of at least one variable or property of the system from the correct and usual condition.

Overall, anomaly detection is an area that faces many challenges [7]:

- When the abnormal data conform a relatively big group, the risk of considering it as normal is very likely.
- Defining the boundary between normal and abnormal operation data is not an easy task.
- In many applications, the initial behavior of a system can evolve naturally and change due to its use. However, this does not necessarily imply an anomaly. For example, a shift lever gear can work perfectly even if it presents slight wear after one year of use.
- In spite of the feasibility of acquiring high amount of data from an industrial plant operation, it is difficult to identify a fault situation without a register of the empirical data from that event. Even if data from an anomaly situation is acquired, it does not represent all possible abnormal events occurred in a process.
- Data can contain noise that may lead to erroneous anomaly 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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

5.1 Introduction

Depending on the information about the initial dataset, three main cases of anomaly detection are considered [16]:

- Type 1: the dataset is prelabeled as normal, as all the available data is conformed only by normal data or normal data with several anomalies. In this type, the classifier is trained with normal data and an anomaly is identified when a data with different features arrives. The techniques used for this kind of detection can be considered as semi-supervised because the data is preclassified only as normal. The use of these techniques, known as one-class, is widespread because it does not require anomaly information.
- Type 2: the dataset is not prelabeled, since the nature of the initial dataset is unknown, it is possible that it contains normal and abnormal data. Using unsupervised techniques, the dataset can be distributed in groups according to its nature. When a new piece of test data arrives, it is classified by comparing it with the training data acquired during system operation. These techniques render well in cases where the dataset is large, has good coverage and the data is well separated from outliers.
- Type 3: the initial dataset is divided into data prelabeled as normal and abnormal. Therefore, supervised algorithms are used in this case. The common approach in these cases consists in implementing a predictive model for normal data, and another one for abnormal data. Then, a new piece of data is compared with these models to determine its class. Also, the normal class can be classified as a single class, or can be divided into different classes.

Anomaly detection has a wide range of applications, such as fraud detection in credit card usage, fault detection in industrial processes, intrusion detection in surveillance systems, medicine diagnosis and so on [7]. Depending on the application and the prior knowledge of the data, different approaches can be applied [34]. Some techniques identify data deviations depending on the density estimation of data patterns. In [9], a one-class classifier is implemented using the Parzen Density Estimator. Other techniques establish spatial boundaries of the dataset to detect an anomaly, when the data is outside these boundaries. In [11], a one-class for distributed environments is implemented using the data convex hull. The last approach focuses on reconstructing data patterns and detecting anomalies, if the reconstruction error is visibly high. In [21], the anomalies detection is performed on patients undergoing general anesthesia using the neural network reconstruction 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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 5. Anomaly detection based on one-class intelligent techniques over a control level plant

This research addresses anomaly detection on an industrial control level plant, where the initial dataset is acquired during correct operation. Hence, during the training process, the anomaly data is not statistically representative or even remains unknown. As mentioned above, different one-class classifiers are implemented to identify faults on the plant. To obtain the one-class classifiers capable of detecting anomalies on a control level plant, the techniques Approximate Convex Hull (ACH), Autoencoder and Support Vector Machine (SVM) are applied.

The proposed approach was validated on a real laboratory plant used to control the fluid level in a tank. The pump speed is controlled to maintain the fluid level, while it is being emptied through an output valve, whose opening width is varied to create anomalies.

The rest of the paper is organized as follows. Section 2 describes the case study briefly. Then, the techniques applied to achieve the fault detection one-class classifiers are explained. Section 4 details the experiments and obtained results and finally, the conclusions and future lines of research are described in Section 5.

5.2. Case study

This section describes the plant on which anomaly detection is performed. Moreover, the general features of the dataset are described below.

5.2.1. Tank level control

The main goal of this study is to test, in a real-life scenario, the performance of different fault detection classifiers based on one-class techniques. The used laboratory plant contains industrial equipment.

The plant scheme is shown in Figure 5.2, and its appearance is also illustrated in Figure 5.3. As stated above, the system was designed to control the level of liquid in a tank (1), by measuring it with an ultrasonic sensor (2). The fluid is initially stored in a different tank (3) placed at a lower level, and it is pumped by a three-phase pump (4) driven by a variable frequency driver (5). The fluid flow rate pumped to the objective

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

5.2 Case study

tank depends on the pump speed. The objective tank, has two built-in output valves (6), one of them is a proportional electric valve and the other one is manual. They are used as a path for returning the fluid back to the storage tank.




Figure 5.2: Scheme of the plant of liquid level control

5.2.2. Control System Implementation

The control system is a virtual controller that reads the current state of the plant through a data acquisition card. The set point signal represents the desired liquid level and the process value is the real level of liquid in the tank. The control signal value is sent by the computer and represents the speed of the centrifugal pump. The scheme shown in Figure 5.4 shows this single input single output (SISO) system, in which the desired liquid level of a tank is achieved by controlling the pumping speed.

A National Instruments data acquisition card (model USB-6008 12-bit 10 KS /s Multifunction I/O) was used to connect the plant and the computer.

Due to the strong nonlinearity of the plant under control, an adaptive PID control is implemented. The first step consisted in identifying the laboratory plant on-line as a second order transfer function using the Recursive Least Squares (RLS) algorithm, according to the Equation 5.1 [3]:

$$G_{plant}(z^{-1}) = \frac{b_0 \cdot z^{-k}}{1 - a_1 \cdot z^{-1} - a_2 \cdot z^{-2}} \quad (5.1)$$

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: 2307538	Código de verificación: Ejyc0z4z
Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 5. Anomaly detection based on one-class intelligent techniques over a control level plant




Figure 5.3: Picture of the plant of liquid level control




Figure 5.4: Control scheme of laboratory plant

where:

- b_0 - Open loop gain.
- k - System delay.
- a_1 - First order coefficient.
- a_2 - Second order coefficient.

Then, from the transfer function identified during process operation, an adaptive PID is self-tuned following the 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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

5.2 Case study

$$G_{controller}(z^{-1}) = \frac{p_0 + p_1 \cdot z^{-1} + p_2 \cdot z^{-2}}{1 - z^{-1}} \quad (5.2)$$

and:

- $p_0 = \frac{1}{b_0 \cdot T_c^2 \cdot (2 \cdot K_c + 1)}$
- $p_1 = -a_1 \cdot p_0$
- $p_2 = -a_2 \cdot p_0$

where:

- T_c - Critical period.
- K_c - Critical gain.

5.2.3. Dataset

During plant operation, the control signal, error signal, process value, set value and the plant coefficients are registered with a sample rate of 0.5 seconds. All tests were performed with a desired tank level of 50 %, and the proportional electric valve was configured during plant operation to generate different anomalies. To perform the one-class classification, the following signals and parameters have been considered:

- Control signal: it drives the three phase pump. Its value varies between 0 and 100 for a 0 to 50 Hz variation.
- Error: it represents the difference between the desired and the current fluid level.
- b_0, a_1, a_2 : are the parameters described in Equation 5.1.

The process value is not taken into account as it is always fixed at 50 %. This research aims to obtain different one-class classifiers for the detection of anomalies in an industrial plant in operation. With this objective, different techniques were used to implement the classifiers.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 5. Anomaly detection based on one-class intelligent techniques over a control level plant

In this work, the dataset created with data from normal operation corresponds to a state in which the proportional electrovalve is completely closed, and the dataset created with data from an anomalous operation corresponds to a state in which the electrovalve opens gradually. This valve opened from 10% to 90% with a 20% step value. For each operating condition, a dataset of 5400 samples was registered.

5.3. Soft Computing Techniques Used

Different techniques were applied with the aim of achieving the best classifier. Their performance was checked using a 5 nested k -fold cross-validation with $k = 10$. The techniques used are described briefly below.

5.3.1. Approximate Convex Hull

This one-class classification has rendered well in the anomaly detection task in many different fields [4, 11]. It offers successful results on different UCI learning machine repositories [4]. The main idea of this classification technique is to model the limits of an original dataset $S \subset \mathbb{R}^n$ using its convex hull. The convex hull $CH(S)$ of a finite set of points $S \subset \mathbb{R}^n$ is the minimal convex set containing S , and it is defined as the convex combination of points in S according to Equation 5.3 [11, 27].

$$CH(S) = \left\{ \sum_{i=1}^{|S|} \beta x_i \mid \forall i : \beta_i \geq 0 \wedge \sum_{i=1}^{|S|} \beta x_i = 1, x_i \in S \right\} \quad (5.3)$$

Also, the possibility of expanding or contracting the vertexes v of the convex hull from its centroid $c = (1/|S|) \sum_i x_i, \forall x_i \in S$, can be carried out by using the parameter $\lambda \in [0, +\infty)$ following the Equation 5.4.

$$v^\lambda : \{ \lambda v + (1 - \lambda)c \mid v \in CH(s) \} \quad (5.4)$$

Therefore, values of λ lower than 1 lead to convex hull contraction, and values greater than 1 expand convex hull. The proper value of λ depends on the shape of 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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

5.3 Soft Computing Techniques Used

dataset.

However, the process of obtaining a convex hull from a dataset with N samples and d variables, has a computational cost of $O(N^{(d/2)+1})$ [4]. Given the high computational cost of this process, an alternative method consists in making p random projections of the original data on $2D$ planes and determining their convex limits on that plane.

According to this approach, when the convex hull approximation is obtained from the training dataset, the following classification criteria for test data is used: if the data is out of at least one of the p projections, it is considered an anomaly. Figure 5.5 shows a $2D$ example where an anomaly point in \mathbb{R}^3 is out of one of the original data projections.




Figure 5.5: Anomaly point in \mathbb{R}^3

5.3.2. Artificial neural networks. Autoencoder

This technique is commonly applied to different tasks and it tends to obtain successful results [30]. Those tasks range from denoising data to anomaly detection, among others [14, 35].

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 5. Anomaly detection based on one-class intelligent techniques over a control level plant

The one-class classification using Autoencoders is based on the dimensional reduction of an initial dataset using an Artificial Neural Network (ANN). The most common supervised learning ANN is the Multilayer Perceptron (MLP), whose performance has proven to be robust [5, 32, 20].

The typical MLP configuration includes one input layer, one output layer and one or more hidden layers. These layers have neurons with weighted connections between contiguous layer neurons. The weighted links are self-tuned to reduce the error between the obtained output and the target output. Each layer has an activation function commonly assigned to all neurons from a layer. It can be linear, step, tan-sigmoid or log-sigmoid [6, 18].

The main idea of the Autoencoder is to train a neural network capable of reconstructing the input dataset $x_i \in \mathbb{R}^a$ into the output \hat{x}_i after a nonlinear dimensional reduction. Hence, the number of neurons of the input and output layers are the same. The main feature of this configuration lies in the fact that the hidden layer has at least one neuron less than the input one. This means that the vector $x_i \in \mathbb{R}^a$ is converted to a lower dimensional vector $v_i \in \mathbb{R}^b$, as shown in Equation 5.5 [30].

$$v_i = f_1(W_1x_i + b_1) \tag{5.5}$$

where:

- W_1 - Weight matrix between input and hidden layer.
- b_1 - Bias vector.

Thus, reducing the dimension of the input vector leads to the elimination of abnormal data. After the hidden layer, the information is decompressed and projected at the output, that must replicate the input pattern, according to Equation 5.6 [30].

$$\hat{x}_i = f_2(W_2v_i + b_2) \tag{5.6}$$

where:

Este documento incorpora firma electrónica, y es copia auténtica de un documento electrónico archivado por la ULL según la Ley 39/2015. <i>Su autenticidad puede ser contrastada en la siguiente dirección https://sede.ull.es/validacion/</i>	
Identificador del documento: 2307538	Código de verificación: Ejyc0z4z
Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

- W_2 - Weight matrix between hidden and output layer.
- b_2 - Bias vector.

Then, the reconstruction error is calculated as the difference between vectors x_i and \hat{x}_i . It demonstrates whether a test data is consistent with the model obtained with the training data. If the test data is not consistent with the model, the reconstruction error is high and the data is considered as an anomaly.

5.3.3. Support Vector Machine

The use of Support Vector Machine for classification has been applied in many different fields, such as image retrieval, document classification or anomaly detection [22].

This technique aims to map an initial dataset into a multidimensional space using a kernel function and then, it constructs an hyperplane that maximizes the distance between the mapped points and the origin [29]. The support vectors are known as the training instances located close to the hyperplane.

To achieve this objective, the expression shown in Equation 5.7 must be minimized [31] with respect to the Lagrange multipliers $\alpha_1, \dots, \alpha_n$ subject to Equation 5.8 and Equation 5.9.

$$0.5 \sum_{jk} \alpha_j \alpha_k K(x_j, x_k) \tag{5.7}$$

$$\sum_j \alpha_j = 1 \tag{5.8}$$

$$0 \leq \alpha_j \leq \frac{1}{\nu l} \tag{5.9}$$

where:

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 5. Anomaly detection based on one-class intelligent techniques over a control level plant

- α_j - Lagrange multipliers.
- $K(x_j, x_k)$ - Kernel function.
- ν - Parameter that relates the distance maximization and the number of points contained by the hyperplane.
- l - Number of points of the dataset.

Once the SVM classifier is implemented with the training data, it gives a score for each test data. This score represents the distance from the data to the decision hyperplane. If this distance is positive, the data is inside the target class, and it is considered as an anomaly otherwise.

5.4. Experiments and results

The three different techniques explained in previous section were applied to the dataset obtained during plant operation. This work focuses on detecting anomaly situations in an industrial plant by measuring different parameters. In this case, the normal operation is considered when the output electrovalve is completely closed. Then, to verify the one-class classification methods, all the cases where the electrovalve opened from 10% to 90% with a 20% step, are considered anomalies.

Regardless of the applied technique, the method was validated using a 10 *k* – fold cross-validation technique. This cross-validation was repeated 5 times. The performance of each classifier was checked using the Area Under Curve (AUC), in %. This commonly used indicator establishes a relation between false positives and true positives [2]. Furthermore, the standard deviation (SD) of the AUC obtained in each repetition is also registered.

The training process performed to obtain each classifier and the test process for the verification of the performance of each classifier, were implemented in a computer with an *Intel Core i7 – 8550U 1.80 GHz* processor.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

5.4.1. Approximate Convex Hull Classifier

The following parameters has been configured:

- Number of 2D projections: this value was set to 5, 10, 50, 100, 500 and 1000.
- Parameter λ : it was set to 0,9 (contraction), 1 (the convex hull remains without change) and 1,1 (expansion).

Given the fact that this method is based on geometric representation, the initial dataset was not normalized. The best results for each opening value percentage, in terms of AUC, SD and training time are shown in Table 5.4.1.

Valve open (%)	Number of projections	Lambda	AUC (%)	SD (%)	Training time (min)
10	1000	1,1	99,65	0,14	18,46
30	100	1,1	99,96	0,06	1,64
50	100	1,1	99,96	0,07	0,96
70	500	1,1	99,95	0,05	3,99
90	100	1,1	99,96	0,06	0,73

Table 5.1: Best results obtained with ACH Classifier

Figure 5.6 shows the average performance of this technique in terms of AUC and training time, depending on the selected parameter λ and the number of projections. In this case, it can be noticed that a λ value of 0.9 does not offer good results, and values of λ equal to or greater than 1 offer higher AUC. Furthermore, from this figure, we arrive at the conclusion that with $\lambda \geq 1$, the use of more than 50 projections does not lead to a significant improvement in the AUC.

5.4.2. Artificial Neural Network Autoencoder Classifier

To implement this technique, the Matlab function '*trainAutoencoder*' was used [25]. The performance of this technique was checked using different configurations, taking into account the following features:

- Number of neurons in the hidden layer: it was set from 1 to $n - 1$, being n the

Chapter 5. Anomaly detection based on one-class intelligent techniques over a control level plant




Figure 5.6: Comparative of ACH performance depending its configuration

number of inputs. In this case, the Autoencoder network was trained with 1, 2, 3 and 4 neurons in the hidden layer.

- Normalization: the input data to the network was normalized in a 0 to 1 interval, or normalized using the *Zscore* method [33] or it was not normalized.
- The decision criteria if a new piece of test data is out of the class was based on the reconstruction error. If this error is above a threshold, the test data is considered as an anomaly. To evaluate and select the proper threshold, the reconstruction error of the test data is compared with the error obtained with the training data. To do so, the percentile of the training data reconstruction error was assessed from 50 % to 100 %, selecting the percentile threshold that offered better results on the test data.
- The activation function of the hidden layer was set to log-sigmoid and the output activation function was set to linear.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

5.4 Experiments and results

The best AUC and SD of this technique for each opening valve percentage are shown in Table 5.4.2. A comparison of the number of neurons, the normalization type, and the results obtained in terms of average AUC and average training time is shown in Figure 5.7. This figure shows that the lowest computational cost corresponds to a normalization between 0 and 1. For that configuration, using 1 neuron in the hidden layer leads to a very low training time (0,43 min) and very successfully results with a 98.7% AUC average.

Valve open (%)	Norm. type	Neurons	Percentile (%)	AUC (%)	SD (%)	Training time (min)
10	Z score	3	99	99,48	0,23	10,70
30	Z score	4	99	99,51	0,17	10,22
50	Norm	3	99	99,50	0,24	1,25
70	Norm	3	99	99,50	0,22	0,53
90	Norm	4	99	99,50	0,24	1,49

Table 5.2: Best results obtained Autoencoder Classifier

5.4.3. SVM Classifier

The SVM classifier was obtained using the function '*fitsvm*' [23] provided by the software Matlab. The parameters taken into account to obtain the classifiers were the following:

- Kernel function: it was set as '*Gaussian*'.
- Outlier fraction: this parameter was tested in an interval from 0% to 10%.
- Normalization: the input data to the network was normalized in a 0 to 1 interval, or normalized using the *Zscore* method or it was not normalized.
- The criteria for deciding whether a new piece of test data is out of the class was based on the score obtained using the Matlab function '*predict*' [24]. If this score is negative, then the data is considered to be an outlier.

The best results for each opening valve percentage, in terms of AUC, SD and computational cost are shown in Table 5.4.3. In this case, the computational cost and AUC of the method does not depend on the outlier fraction or the normalization type.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 5. Anomaly detection based on one-class intelligent techniques over a control level plant

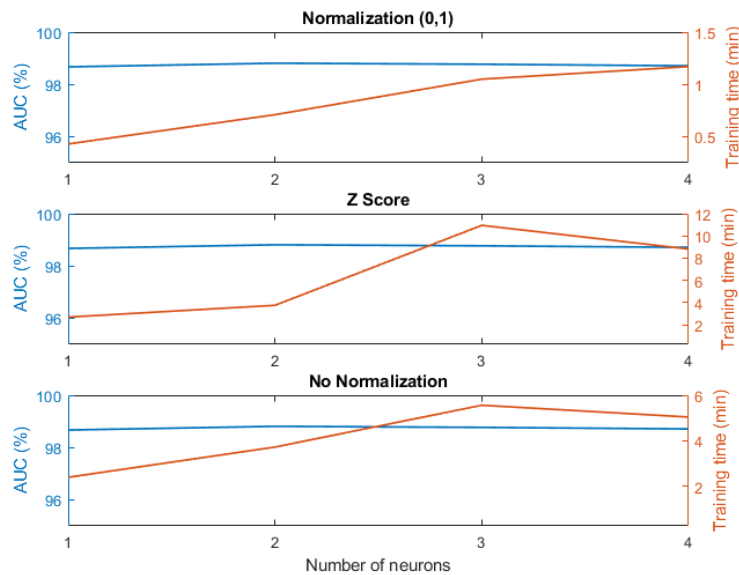


Figure 5.7: Comparative of Autoencoder performance depending its configuration

This fact is detailed in Figure 5.8, where the average variation depending on the outlier fraction and the normalization type is very low. The training time required to obtain the classifier has been in all cases close to 1 min.

5.5. Conclusions and future works

In this study, three different methods of one-class classification have been proposed for performing fault detection in tank level control. The correct operation of the plant was signalled by a completely closed output electrovalve, while the generated anomalies consisted of opening the electrovalve from 10 % to 90 % with a 20 % step.

Overall, the obtained results have been very successful for the three techniques. The ACH technique performed best in terms of AUC with at least 99.65 % for the entire operating range of the anomaly. However, due to the fact that the three techniques offer

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

5.5 Conclusions and future works

Valve open (%)	Norm. type	Outlier fract. (%)	Percentile (%)	AUC (%)	SD (%)	Training time (min)
10	Norm	4	2	99,85	0,43	1,03
30	No Norm	4	2	99,48	0,30	1,02
50	No Norm	2	4	99,48	0,22	1,03
70	Norm	5	9	99,49	0,21	1,04
90	No Norm	9	7	99,48	0,24	1,32

Table 5.3: Best results obtained with SVM Classifier

very similar results in terms of AUC, the selection criteria must take into consideration the computational cost of each one. Tables 5.5, 5.6 and 5.7 show the average results for the configuration of each technique, taking into account all the operating ranges of the anomaly. The classifier that had been chosen in this case was the one implemented with a one neuron Autoencoder and 0 to 1 normalization, due to its very low training time and great performance in terms of AUC.

Number of projections	$\lambda = 0.9$		$\lambda = 1$		$\lambda = 1.1$	
	AUC (%)	Training time (min)	AUC (%)	Training time (min)	AUC (%)	Training time (min)
5	94,30	0,09	93,68	0,05	92,08	0,06
10	88,60	0,18	96,29	0,11	96,31	0,10
50	84,18	0,47	98,78	0,49	99,32	0,53
100	82,05	1,23	98,74	1,11	99,60	1,15
500	76,37	5,92	98,44	5,62	99,77	5,80
1000	74,94	11,68	98,32	11,45	99,78	13,25

Table 5.4: Average results for ACH

Number of neurons	Norm		Z Score		No Norm	
	AUC (%)	Training time (min)	AUC (%)	Training time (min)	AUC (%)	Training time (min)
1	98,68	0,43	93,72	2,70	95,70	2,40
2	98,82	0,72	97,93	3,77	99,20	3,72
3	98,78	1,05	99,49	10,95	99,48	5,56
4	98,71	1,17	99,49	8,83	99,47	5,04

Table 5.5: Average results for Autoencoder

This work also shows the importance of the λ parameter in defining the decision

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 5. Anomaly detection based on one-class intelligent techniques over a control level plant

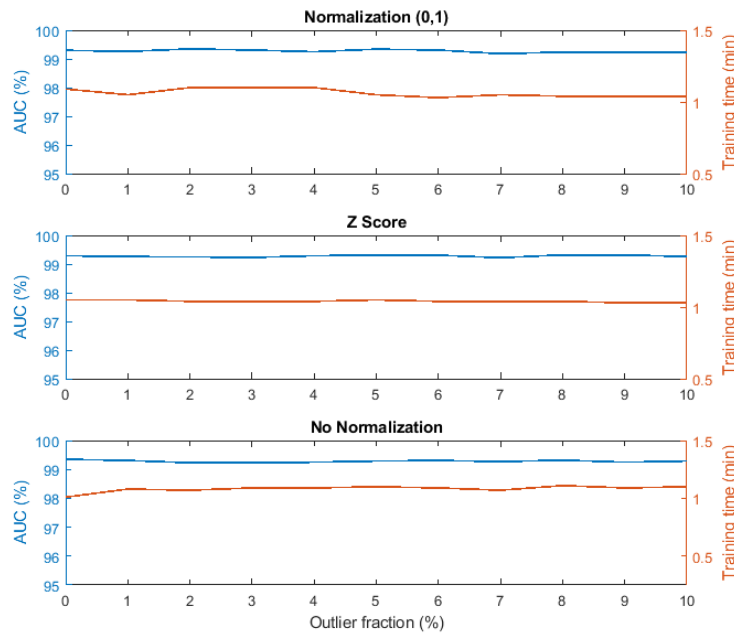


Figure 5.8: Comparative of SVM performance depending its configuration

convex hull of the ACH classifier. For this dataset, restrictive values of λ lead to worse results, while the use of values of λ higher than one offer very good results. Furthermore, the use of 50 projections is enough to achieve a good classifier with very low computational cost.

Regarding the Autoencoder technique, the use of a different number of neurons in the hidden layer does not have any significant impact on the AUC and STD. However, this number has influenced the training time significantly. It is important to highlight that if the reconstruction error of a test data is above the 99% of the training errors, it is identified as anomalous. This high value means that the training set is comprised of data that belongs to normal operation.

Finally, the SVM classifier offered successful results regardless the percentage of outlier fraction considered during the training phase and the normalization type.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

5.5 Conclusions and future works

The proposed method is applicable to a wide range of industrial practices. It can be used as a means of improving performance in terms of maintenance, product quality, efficiency, energy saving or system optimization.

In a future work we are going to consider more than one operating range as normal class. Also, the use of Dimensional Reduction Techniques for the decrease in the number of input variables could lead to a reduction in computational cost or even, to better results. If the one class methods are applied to a sensor, the possibility of using imputation techniques [19] when an inaccurate measured is detected, can be considered.

Given the fact that the system evolves during its use, the behaviour of the data obtained from correct operation may be subject to slight changes. These natural changes, that do not represent anomalies, could be detected as anomalies by the classifier. Hence, to avoid this situation, it would be interesting to include new normal data to the classifier and re-train it during plant operation.

Outlier percentage	Norm		Z Score		No Norm	
	AUC (%)	Training time (min)	AUC (%)	Training time (min)	AUC (%)	Training tim (min)
0	99,30	1,10	99,29	1,05	99,35	1,01
1	99,27	1,05	99,27	1,05	99,32	1,09
2	99,35	1,11	99,26	1,04	99,23	1,08
3	99,31	1,11	99,24	1,04	99,25	1,09
4	99,25	1,11	99,30	1,05	99,24	1,09
5	99,35	1,04	99,32	1,04	99,30	1,09
6	99,31	1,03	99,32	1,04	99,32	1,11
7	99,19	1,04	99,23	1,05	99,27	1,09
8	99,25	1,04	99,33	1,04	99,33	1,08
9	99,24	1,04	99,33	1,04	99,26	1,11
10	99,23	1,04	99,27	1,05	99,30	1,10

Table 5.6: Average results for SVM

Bibliography

- [1] B. Baruque, S. Porras, E. Jove, and J. L. Calvo-Rolle. Geothermal heat exchanger energy prediction based on time series and monitoring sensors optimi-

Chapter 5. Anomaly detection based on one-class intelligent techniques over a control level plant

- zation. *Energy*, 171:49 – 60, 2019. ISSN 0360-5442. doi: <https://doi.org/10.1016/j.energy.2018.12.207>. URL <http://www.sciencedirect.com/science/article/pii/S0360544218325817>.
- [2] A. P. Bradley. The use of the area under the roc curve in the evaluation of machine learning algorithms. *Pattern Recognition*, 30(7):1145 – 1159, 1997. ISSN 0031-3203. doi: [https://doi.org/10.1016/S0031-3203\(96\)00142-2](https://doi.org/10.1016/S0031-3203(96)00142-2).
- [3] J. L. Calvo-Rolle, O. Fontenla-Romero, B. Pérez-Sánchez, and B. Guijarro-Berdiñas. Adaptive inverse control using an online learning algorithm for neural networks. *Informatica*, 25(3):401–414, 2014.
- [4] P. Casale, O. Pujol, and P. Radeva. Approximate convex hulls family for one-class classification. In C. Sansone, J. Kittler, and F. Roli, editors, *Multiple Classifier Systems*, pages 106–115, Berlin, Heidelberg, 2011. Springer Berlin Heidelberg. ISBN 978-3-642-21557-5.
- [5] 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. Baroque, 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.
- [6] 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 remifentanil drug and emg signal. *Neural Computing and Applications*, Jul 2018. ISSN 1433-3058. doi: 10.1007/s00521-018-3605-z. URL <https://doi.org/10.1007/s00521-018-3605-z>.
- [7] V. Chandola, A. Banerjee, and V. Kumar. Anomaly detection: A survey. *ACM computing surveys (CSUR)*, 41(3):15, 2009.
- [8] L. H. Chiang, E. L. Russell, and R. D. Braatz. *Fault detection and diagnosis in industrial systems*. Springer Science & Business Media, 2000.
- [9] G. Cohen, H. Sax, A. Geissbuhler, et al. Novelty detection using one-class parzen density estimator. an application to surveillance of nosocomial infections. In *MIE*, pages 21–26, 2008.
- [10] M. P. de la Portilla, A. L. Piñeiro, J. A. S. Sánchez, and R. M. Herrera. Modelado dinámico y control de un dispositivo sumergido provisto de actuado-

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

5.5 Conclusions and future works

- res hidrostáticos. *Revista Iberoamericana de Automática e Informática industrial*, 15(1):12–23, 2017. ISSN 1697-7920. doi: 10.4995/riai.2017.8824. URL <https://polipapers.upv.es/index.php/RIAI/article/view/8824>.
- [11] D. Fernández-Francos, ó. Fontenla-Romero, and A. Alonso-Betanzos. One-class convex hull-based algorithm for classification in distributed environments. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, pages 1–11, 2018. ISSN 2168-2216. doi: 10.1109/TSMC.2017.2771341.
- [12] 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.
- [13] G. González, C. D. Angelo, D. Forchetti, and D. Aligia. Diagnóstico de fallas en el convertidor del rotor en generadores de inducción con rotor bobinado. *Revista Iberoamericana de Automática e Informática industrial*, 15(3):297–308, 2018. ISSN 1697-7920. doi: 10.4995/riai.2017.9042. URL <https://polipapers.upv.es/index.php/RIAI/article/view/9042>.
- [14] I. Goodfellow, Y. Bengio, A. Courville, and Y. Bengio. *Deep learning*, volume 1. MIT press Cambridge, 2016.
- [15] M. Hobday. Product complexity, innovation and industrial organisation. *Research policy*, 26(6):689–710, 1998.
- [16] V. Hodge and J. Austin. A survey of outlier detection methodologies. *Artificial intelligence review*, 22(2):85–126, 2004.
- [17] 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*, page e12395.
- [18] 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.
- [19] 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 *International Joint Conference SOCO'17-CISIS'17-ICEUTE'17 León, Spain, September 6–8, 2017, Proceeding*, pages 167–176. Springer, 2017.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 5. Anomaly detection based on one-class intelligent techniques over a control level plant

- [20] 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 *International Joint Conference SOCO'17-CISIS'17-ICEUTE'17 León, Spain, September 6–8, 2017, Proceeding*, pages 492–501. Springer, 2017.
- [21] 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. In F. Martínez Álvarez, A. Troncoso Lora, J. A. Sáez Muñoz, H. Quintián, and E. Corchado, editors, *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.
- [22] K.-L. Li, H.-K. Huang, S.-F. Tian, and W. Xu. Improving one-class svm for anomaly detection. In *Machine Learning and Cybernetics, 2003 International Conference on*, volume 5, pages 3077–3081. IEEE, 2003.
- [23] MathWorks. fitcsvm. <https://es.mathworks.com/help/stats/fitcsvm.html>, 01-29-2019.
- [24] MathWorks. predict. <https://es.mathworks.com/help/stats/classreg.learning.classif.compactclassificationsvm.predict.html>, 01-29-2019.
- [25] MathWorks. Autoencoder. <https://es.mathworks.com/help/deeplearning/ref/trainautoencoder.html>, 01-29-2019.
- [26] D. Miljković. Fault detection methods: A literature survey. In *MIPRO, 2011 proceedings of the 34th international convention*, pages 750–755. IEEE, 2011.
- [27] F. P. Preparata and M. I. Shamos. *Computational geometry: an introduction*. Springer Science & Business Media, 2012.
- [28] 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.
- [29] P. Reberstrost, M. Mohseni, and S. Lloyd. Quantum support vector machine for big data classification. *Phys. Rev. Lett.*, 113:130503, Sep 2014. doi: 10.1103/PhysRevLett.113.130503. URL <https://link.aps.org/doi/10.1103/PhysRevLett.113.130503>.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

5.5 Conclusions and future works

- [30] M. Sakurada and T. Yairi. Anomaly detection using autoencoders with nonlinear dimensionality reduction. In *Proceedings of the MLSDA 2014 2nd Workshop on Machine Learning for Sensory Data Analysis*, page 4. ACM, 2014.
- [31] B. Schölkopf, J. C. Platt, J. Shawe-Taylor, A. J. Smola, and R. C. Williamson. Estimating the support of a high-dimensional distribution. *Neural computation*, 13(7):1443–1471, 2001.
- [32] F. Segovia, J. M. Górriz, J. Ramírez, F. J. Martínez-Murcia, and M. García-Pérez. Using deep neural networks along with dimensionality reduction techniques to assist the diagnosis of neurodegenerative disorders. *Logic Journal of the IGPL*, 26(6):618–628, 2018. doi: 10.1093/jigpal/jzy026. URL <http://dx.doi.org/10.1093/jigpal/jzy026>.
- [33] L. A. Shalabi and Z. Shaaban. Normalization as a preprocessing engine for data mining and the approach of preference matrix. In *2006 International Conference on Dependability of Computer Systems*, pages 207–214, May 2006. doi: 10.1109/DEPCOS-RELCOMEX.2006.38.
- [34] D. M. J. Tax. One-class classification: concept-learning in the absence of counter-examples [ph. d. thesis]. *Delft University of Technology*, 2001.
- [35] P. Vincent, H. Larochelle, I. Lajoie, Y. Bengio, and P.-A. Manzagol. Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion. *Journal of Machine Learning Research*, 11(Dec):3371–3408, 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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 5. Anomaly detection based on one-class intelligent techniques over a control level
plant

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

CHAPTER 6



Detección de anomalías basada en técnicas inteligentes de una planta de obtención de material bicomponente empleado en la fabricación de palas de aerogenerador

This chapter corresponds to the third manuscript used to present this research work through the compendium of publications modality. With the aim of having a homogeneous format in the document, the original article format has been adapted. The main information of this contribution is presented below. It is important to note that the article has been accepted but it is still in print process.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 6. Detección de anomalías basada en técnicas inteligentes de una planta de obtención de material bicomponente empleado en la fabricación de palas de aerogenerador

General information:

Authors:

Esteban Jove ^{1,2}, José-Luis Casteleiro-Roca¹, Héctor Quintián¹, Juan Albino Méndez Pérez² y José Luis Calvo-Rolle¹.

Affiliations:

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.

Title: Detección de anomalías basada en técnicas inteligentes de una planta de obtención de material bicomponente empleado en la fabricación de palas de aerogenerador.

Journal: Revista Iberoamericana de Automática e Informática Industrial.

Volume: N/A.

Pages: N/A.

Publisher: Comité Español de la Automática.

Year: 2019.

DOI: N/A.

Impact factor ISI JCR 2017: 0,494.

Impact factor ISI JCR 2018: 1,313.

Impact factor ISI JCR 2017 (5 years): 0,505.

Impact factor ISI JCR 2018 (5 years): 0,850.

Category Automation & Control Systems 2017: 46/62 - Q4.

Category Automation & Control Systems 2018: 60/61 - Q3.

Category Robotics 2017: 26/26 - Q4.

Category Robotics 2018: 20/26 - Q4.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Abstract

Los avances tecnológicos en general, y en el ámbito de la industria en particular, conllevan el desarrollo y optimización de las actividades que en ella tienen lugar. Para alcanzar este objetivo, resulta de vital importancia detectar cualquier tipo de anomalía en su fase más incipiente, contribuyendo, entre otros, al ahorro energético y económico, y a una reducción del impacto ambiental. En un contexto en el que se fomenta la reducción de emisión de gases contaminantes, las energías alternativas, especialmente la energía eólica, juegan un papel crucial. En la fabricación de las palas de aerogenerador se recurre comúnmente a materiales de tipo bicomponente, obtenidos a través del mezclado de dos sustancias primarias. En la presente investigación se evalúan distintas técnicas inteligentes de clasificación *one-class* para detectar anomalías en un sistema de mezclado para la obtención de materiales bicomponente empleados en la elaboración de palas de aerogenerador. Para lograr los modelos inteligentes que permitan la detección de anomalías, se han usado datos reales extraídos de una planta de mezclado en operación durante su correcto funcionamiento. Los clasificadores obtenidos para cada técnica son validados a través de anomalías generadas de manera artificial, obteniéndose resultados altamente satisfactorios.

Palabras clave: Sistemas de energías renovables, Aerogeneradores, Detección de anomalías, Diagnóstico de sistemas, Redes neuronales

6.1. Introducción

Los avances tecnológicos en general, y en el ámbito de la industria en particular, conllevan el desarrollo y optimización de las diferentes actividades que en ella existen, para el deseado perfeccionamiento de los procesos en su conjunto [13]. Con el fin de alcanzar este objetivo, un aspecto de gran importancia es la posibilidad de detectar, sobre los diferentes sistemas que conforman la producción, cualquier tipo de anomalía en su fase más incipiente. Si se consigue, este hecho contribuirá, entre otros, al ahorro energético, económico, reducción de desecho de material y reducción del impacto ambiental [16]. Además, una detección precoz de una anomalía cobra mayor relevancia en procesos de alto coste y en los que la seguridad es un factor crítico [19].

En cualquier proceso, una anomalía puede ser causada por el mal funcionamiento

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 6. Detección de anomalías basada en técnicas inteligentes de una planta de obtención de material bicomponente empleado en la fabricación de palas de aerogenerador

de un actuador, una mala lectura de un sensor o por la variación en los parámetros de la planta en términos generales [6].

Desde un punto de vista genérico, se denominan anomalías a los datos que siguen un patrón diferente al esperado en una aplicación determinada [4].

Partiendo de esta definición, la detección de anomalías presenta una serie de retos y dificultades [4]:

- Existe la posibilidad de que el conjunto de datos obtenidos en un estado de funcionamiento anómalo del proceso sea lo suficientemente grande como para que estos no sean considerados como anomalías.
- El establecimiento de un criterio que delimite los datos correspondientes al funcionamiento normal del sistema puede resultar una tarea compleja.
- En muchas aplicaciones, el desgaste lento de los componentes debido a su uso sistemático, no implica una anomalía, siempre que éstos no superen unos límites técnicamente establecidos. Por ejemplo, un engranaje puede desgastarse debido a su uso y no por ello funcionar de manera anómala.
- Incluso aunque exista la posibilidad de registrar datos correspondientes a uno o varios tipos de anomalías concretas, esto no asegura que estén cubiertos todos los posibles tipos de anomalías que se puedan producir.
- Es posible que los datos contengan ruido que pueda acarrear una detección de anomalías errónea.

Dependiendo de la información que se tiene acerca de los datos, existen tres tipos de detección de anomalías [4, 14]:

- Tipo 1: para este caso, las técnicas empleadas en este tipo de detección se denominan semisupervisadas, puesto que los datos son únicamente etiquetados como buenos, dado que el conjunto de datos de partida contiene datos obtenidos en funcionamiento normal del proceso e incluso puede contener una cantidad poco significativa de anomalías. Para este tipo de detección de fallos se entrena un clasificador con los datos correspondientes al funcionamiento normal del sistema. Por tanto, se identifica una anomalía cuando se registra un dato que difiere del

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

6.1 Introducción

patrón de entrenamiento. Dado que la naturaleza de una anomalía es desconocida en gran parte de los casos prácticos, este tipo de detección, denominada *one-class*, sirve de utilidad en infinidad de aplicaciones. Este trabajo aborda la detección de anomalías en un conjunto de datos del que se dispone únicamente información correspondiente al correcto funcionamiento del sistema.

- Tipo 2: este tipo de detección de anomalías da por hecho que los datos obtenidos en un estado de funcionamiento anómalo del proceso están separados de los obtenidos en funcionamiento normal. Es por ello que, ante la aparición de una muestra distanciada del conjunto de datos mayoritario, ésta es considerada como una anomalía. La aplicación de este tipo de técnicas es adecuada cuando el tamaño del conjunto de datos es lo suficientemente significativo.
- Tipo 3: el conjunto de datos iniciales está dividido y etiquetado entre datos obtenidos en funcionamiento normal del proceso y anomalías. Es por ello que para llevar a cabo la clasificación se emplean técnicas supervisadas. El enfoque habitual en este tipo de casos consiste en implementar un modelo predictivo para cada uno de los grupos etiquetados. Con la llegada de un nuevo dato, se identifica a qué clase pertenece según lo determinen los modelos obtenidos. Además, la clase normal puede ser dividida a su vez en diferentes subclases.

Por otra parte, según el enfoque que se le dé a los datos de entrenamiento, existen básicamente tres tipos de métodos para abordar la detección de anomalías: los métodos de estimación de densidad, los métodos de establecimiento de límites y los métodos de reconstrucción [26]. Los primeros tratan de identificar desviaciones de los patrones en base a la distribución de los mismos. Los segundos tratan de establecer límites espaciales para separar un dato normal de una anomalía y los terceros tratan de reconstruir los patrones de entrada y detectar las desviaciones en función de dicha reconstrucción.

Las técnicas de detección de anomalías se emplean en multitud de aplicaciones, tales como la detección de fraude en tarjetas de crédito, detección de fallos en procesos industriales, intrusión en sistemas de seguridad o diagnóstico de pacientes en medicina, entre otras [4, 10].

Este trabajo aborda la detección de anomalías a partir de los datos registrados durante el correcto funcionamiento de una planta industrial destinada a obtener el material empleado en fabricación de palas de aerogeneradores. En un contexto global en el que, tanto el incremento del consumo de energía como, el empleo de fuentes de energías

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 6. Detección de anomalías basada en técnicas inteligentes de una planta de obtención de material bicomponente empleado en la fabricación de palas de aerogenerador

derivadas de combustibles fósiles, han provocado un aumento de la contaminación ambiental, con las consecuencias nocivas que ello implica [22]. Esto ha producido una expansión en el aprovechamiento de energías renovables no contaminantes, especialmente la energía eólica [7, 33]. Comúnmente, se emplea fibra de carbono como material base para la fabricación de las palas de aerogenerador. Este compuesto se obtiene mediante el mezclado de dos productos primarios, dando lugar a un compuesto final que recibe el nombre de bicomponente [31]. Este compuesto tiene unas características completamente diferentes a las de las sustancias previamente mezcladas, otorgando a las palas de aerogenerador las cualidades físicas apropiadas para su uso.

Con el fin de asegurar la detección de cualquier tipo de anomalía en la instalación, y favorecer así el buen funcionamiento de la misma, se evalúan distintas técnicas de clasificación *one-class*. Concretamente, se emplean técnicas de establecimiento de límites, tales como las Máquinas de Vectores Soporte [21] y Contornos Convexos Aproximados [2], así como técnicas de reconstrucción, como es el caso de los Autoencoders y del Análisis de Componentes Principales [20, 26].

Para evaluar y validar los métodos propuestos, se generan una serie de anomalías de manera artificial en cada una de las variables presentes en el proceso, obteniendo resultados satisfactorios en términos generales.

Este artículo está estructurado de la siguiente manera: tras la presente introducción, se describe el caso de estudio. Posteriormente se explican las técnicas empleadas para obtener el sistema de detección de anomalías. A continuación, se presentan los resultados obtenidos y finalmente, se exponen las conclusiones y los trabajos futuros.

6.2. Caso de estudio

Antes de abordar la detección de anomalías en el sistema de mezclado de bicomponentes, en la Sección 6.2.1 se hace una descripción previa del funcionamiento de la instalación y los componentes que la integran. La Sección 6.2.2 detalla la naturaleza del conjunto de datos del que se parte para realizar esta investigación.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

6.2.1. Sistema de mezclado

Como se ha mencionado en la Introducción, el objetivo del sistema es mezclar dos componentes primarios con la proporción adecuada. Concretamente, uno de los componentes es una resina epoxy, y el otro es un catalizador. El bicomponente obtenido en este proceso presenta, entre otras ventajas, una gran resistencia específica tanto a esfuerzos de tracción como de compresión y una excelente resistencia ante agentes químicos, motivos por los cuales se convierte en un material ideal para la construcción de las palas de aerogenerador.

Ambos componentes a mezclar están almacenados en sendos tanques separados y son impulsados mediante dos bombas independientes encargadas de suministrar el caudal necesario para obtener la proporción de mezcla requerida.

Cada una de las bombas es accionada a través de motores comandados por variadores de frecuencia que controlan sus respectivas velocidades. El fluido bombeado circula a través de tuberías que conducen a una válvula de mezclado encargada de proporcionar el bicomponente final usado para la fabricación de las palas de aerogenerador. En la figura 6.1 se muestra un esquema simplificado del sistema de mezclado en el que se aprecian los componentes de la instalación, así como los sensores presentes en ella.

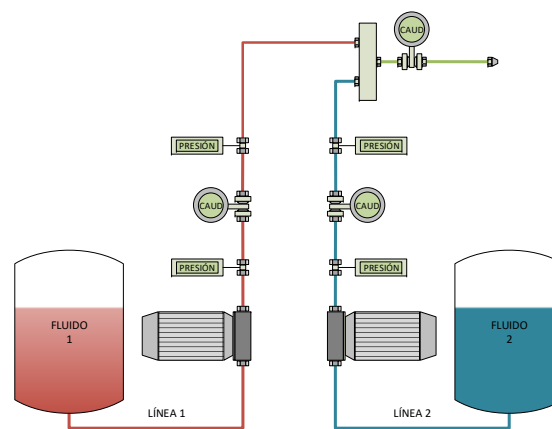


Figure 6.1: Diagrama del proceso

Una de las principales características del sistema radica en el hecho de que los

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 6. Detección de anomalías basada en técnicas inteligentes de una planta de obtención de material bicomponente empleado en la fabricación de palas de aerogenerador

componentes a mezclar son fluidos no newtonianos, es decir, sus propiedades mecánicas varían en función de los esfuerzos a los que se ven sometidos [8]. Un ejemplo de ello se puede observar en la figura 6.2, donde se representa la variación de la viscosidad en el fluido catalizador en función de los esfuerzos cortantes a los que se ve sometido. Además de las características no newtonianas de los fluidos con los que se trabaja, aspectos como, por ejemplo, el comportamiento no lineal de la bomba, aumentan la complejidad del sistema. En consecuencia, todo ello hace que la tarea de detectar una anomalía suponga un reto.




Figure 6.2: Variación de la viscosidad del catalizador con el esfuerzo cortante al que se ve sometido

6.2.2. Conjunto de datos

Durante el correcto funcionamiento del sistema se han registrado diferentes variables que conforman el conjunto de datos a partir del cual se pretende implementar el sistema de detección de anomalías. Las variables registradas son las siguientes:

- Consigna del caudal de salida: representa el caudal, en l/min de bicomponente deseado a la salida de la válvula de mezclado. Según la parte de la pala que esté siendo fabricada, el caudal a entregar varía.
- Caudales de los componentes 1 y 2: representan los caudales de salida medidos en cada una de las bombas, en l/min .

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

6.2 Caso de estudio

- Caudal de salida real: representa la suma de las variables descritas en el apartado anterior. Su valor varía en función de la consigna deseada para el caudal de salida (l/min).
- Velocidades de las bombas 1 y 2: representan las revoluciones por minuto a las que giran las bombas (rpm).
- Presión a la salida de las bombas 1 y 2: estas variables representan la presión medida, en bares, a la salida de cada una de las bombas que impulsan ambos fluidos (bar).
- Presión a la salida de los caudalímetros 1 y 2: son variables similares a las anteriores, pero en lugar de medirse a la salida de la bomba, se miden a la salida de los caudalímetros (bar).

En total, son 10 variables monitorizadas con una frecuencia de muestreo de 2 Hz. El conjunto de datos inicial se compone de 9511 muestras registradas durante el correcto funcionamiento de la instalación.

Se ha llevado a cabo un preprocesado inicial de los datos, que consiste en eliminar aquellas muestras, en las que al menos una de las variables no está disponible. Tras este paso, el conjunto final está compuesto por 8549 muestras. Dado que los datos nulos representan casos aberrantes, se evaluará el rendimiento de las técnicas *one-class* generando una serie de anomalías artificiales en un 5% de las muestras del conjunto preprocesado.

Para ello, se modifica en un 25% el valor leído en únicamente una de las variables por muestra. Se ha escogido este valor en base a la experiencia de los usuarios de la instalación, que han determinado éste, como un umbral lo suficientemente significativo como para considerar el dato como anomalía. En cada una de las muestras anómalas, la variable alterada es escogida de manera aleatoria. Se considera esta situación, en la que la anomalía ocurre únicamente en un punto de la instalación, como el peor de los escenarios. Dado que la detección se realiza sobre muestras puntuales, sin tener en cuenta los estados anteriores, se identificarían las anomalías en cualquiera de las partes del sistema antes de que el lazo de control tratase de compensarlas, evitando así el fenómeno conocido como "smearing effect" [29].

La figura 6.3 muestra en trazo continuo azul y en trazo discontinuo rojo las variables registradas y las alteradas artificialmente para evaluar el comportamiento de los

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 6. Detección de anomalías basada en técnicas inteligentes de una planta de obtención de material bicomponente empleado en la fabricación de palas de aerogenerador

clasificadores a la hora de detectar las anomalías, respectivamente.

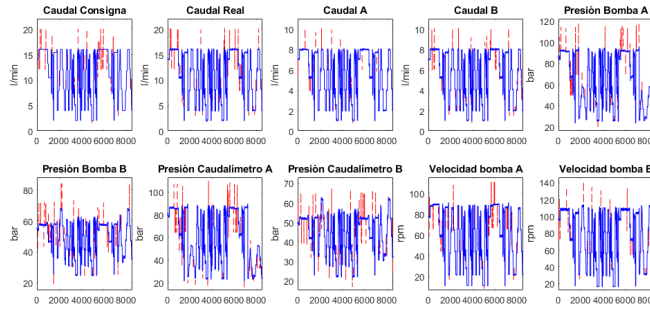


Figure 6.3: Variables originales y modificadas artificialmente

6.3. Técnicas empleadas

En esta sección se describirán las diferentes técnicas utilizadas para obtener el sistema de detección de anomalías.

6.3.1. Contornos Convexos Aproximados

Esta técnica de clasificación *one-class* (tipo 1) se ha revelado como una herramienta efectiva a la hora de detectar anomalías en diversas disciplinas [2, 9]. Además, ofrece resultados satisfactorios en relación con otras técnicas *one-class* aplicadas a conjuntos de datos de repositorios UCI (Universidad de California en Irvine) [3]. La idea principal de esta técnica de clasificación consiste en modelar el límite de un conjunto de datos $D \in R^n$ a partir su contorno convexo. El contorno convexo $CC(S)$ de un grupo finito de puntos $S \subseteq R^n$ es el mínimo conjunto convexo que contenga a S y se define como la combinación convexa de los puntos en S según la Ecuación 6.1.

$$CC(S) = \left\{ \sum_{i=1}^{|S|} \beta_i x_i \mid \forall i : \beta_i \geq 0 \wedge \sum_{i=1}^{|S|} \beta_i x_i = 1, x_i \in S \right\} \quad (6.1)$$

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

6.3 Técnicas empleadas

Dado que en esta técnica se delimita el conjunto de datos objetivo, es posible ampliar o reducir los vértices v desde el centroide $c = (1/|S|) \sum_i x_i, \forall x_i \in S$ a partir de un parámetro $\lambda \in [0, +\infty)$, de acuerdo con la Ecuación 6.2.

$$v^\lambda : [\lambda v + (1 - \lambda)c \mid v \in CC(s)] \quad (6.2)$$

De esta forma, un valor de λ menor que uno implica la contracción del contorno convexo, mientras que un valor mayor que uno provoca la expansión del mismo. Dependiendo de la naturaleza del conjunto de datos a tratar, puede resultar conveniente establecer unos límites más restrictivos ($\lambda < 1$) o unos límites más laxos ($\lambda > 1$).

Sin embargo, el proceso de obtención del contorno convexo dado un conjunto de datos con N muestras y d variables, tiene un coste computacional de $O(N^{(d/2)+1})$ [2]. Para evitar este inconveniente, se plantea una alternativa que consiste en realizar p proyecciones aleatorias de conjunto de datos original sobre planos $2D$ y de esta forma determinar su contorno convexo aproximado.

Según este procedimiento, una vez se ha determinado el contorno convexo aproximado con los datos de entrenamiento, el criterio para determinar la naturaleza de los datos de test es el siguiente: si el dato está fuera en al menos una de las p proyecciones, se considera una anomalía. Un ejemplo simplificado se puede observar en la figura 6.4, donde una anomalía en un conjunto de datos en R^3 se encuentra fuera en una de las proyecciones $2D$.

6.3.2. Autoencoders

Esta técnica perteneciente al tipo 1 se ha empleado de manera frecuente [20] en diferentes tareas, tales como reducción de ruido en datos, detección de anomalías o aprendizaje profundo [11, 27].

La clasificación *one-class* mediante Autoencoders se basa en la reducción dimensional no lineal del conjunto de datos mediante el uso de redes neuronales artificiales. Concretamente, la red neuronal artificial empleada en este tipo de tareas es el Perceptron Multicapa [15, 23], cuyo comportamiento ha demostrado ser muy robusto [32].

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 6. Detección de anomalías basada en técnicas inteligentes de una planta de obtención de material bicomponente empleado en la fabricación de palas de aerogenerador

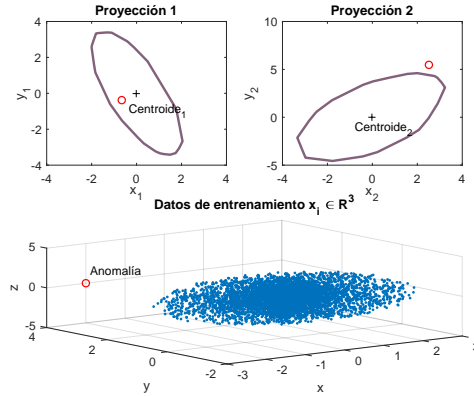


Figure 6.4: Anomalía en R^3

La configuración típica del Perceptron Multicapa presenta una capa de entrada, una de salida y una o más capas intermedias. Cada una de las capas está compuesta por neuronas, que a su vez presentan conexiones ponderadas con las neuronas de capas contiguas. Los pesos de las conexiones se autoajustan durante el proceso de entrenamiento de la red para reducir el error resultante de restar la salida obtenida y la deseada. Cada neurona cuenta con una función de activación y comúnmente se le asigna la misma a todas las neuronas de una capa. Esta función puede ser lineal, tangencial-sigmoidal o logarítmica-sigmoidal.

La principal idea del Autoencoder es la de entrenar una red neuronal capaz de reconstruir un conjunto de datos de entrada $x_i \in R^a$ en la salida \hat{x}_i , habiéndose producido una reducción dimensional en la capa intermedia. Por tanto, el número de neuronas de la capa de entrada es el mismo que el de neuronas a la salida, mientras que la capa intermedia debe tener al menos una neurona menos que éstas.

La red se configura de manera que el vector de entrada $x_i \in R^a$ se convierta en un vector de dimensión menor $v_i \in R^b$, de acuerdo con la Ecuación 6.3. Esta reducción dimensional en la capa intermedia tiene como objetivo filtrar aquellos datos que la red interprete como espurios, es decir, las anomalías.

$$v_i = f_1(W_1x_i + b_1) \quad (6.3)$$

6.3 Técnicas empleadas

Donde:

- f_1 - Función de activación de la capa de entrada.
- W_1 - Matriz de pesos entre la capa de entrada y la capa intermedia.
- b_1 - Vector bias.

Una vez realizada la reducción dimensional se produce la descompresión y se proyectan los datos en la salida, que debe replicar el patrón de entrada de acuerdo con la Ecuación 6.4.

$$\hat{x}_i = f_2(W_2v_i + b_2) \quad (6.4)$$

Donde:

- f_2 - Función de activación de la capa intermedia.
- W_2 - Matriz de pesos entre la capa de intermedia y la capa de salida.
- b_2 - Vector bias.

Una vez entrenada la red, el error de reconstrucción de un dato de test se calcula como la diferencia entre los vectores x_i y \hat{x}_i . Este parámetro se puede emplear para determinar si un dato de test tiene una naturaleza anómala o no: si dicho dato no es consistente con el modelo entrenado, el error presenta un valor elevado.

6.3.3. Máquinas de Vector Soporte

El uso de Máquinas de Vector Soporte (SVM, por sus siglas en inglés) para clasificación se ha implementado en gran cantidad de disciplinas, tales como reconstrucción de imágenes, clasificación de documentos o detección de anomalías [18, 5].

La técnica SVM empleada para *one-class* es considerada de tipo 1, y tiene como objetivo, mapear el conjunto de datos a través de una función denominada *kernel* en un

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 6. Detección de anomalías basada en técnicas inteligentes de una planta de obtención de material bicomponente empleado en la fabricación de palas de aerogenerador

espacio multidimensional, para luego construir un hiperplano que maximice la distancia entre los puntos mapeados y el origen [28].

Se desea minimizar la expresión mostrada en la Ecuación 6.5 [21, 12] con respecto a los multiplicadores de Lagrange $\alpha_1, \dots, \alpha_n$ sujetos a las restricciones de la Ecuación 6.6 y Ecuación 6.7.

$$0.5 \sum_{jk} \alpha_j \alpha_k K(x_j, x_k) \quad (6.5)$$

$$\sum_j \alpha_j = 1 \quad (6.6)$$

$$0 \leq \alpha_j \leq \frac{1}{\nu l} \quad (6.7)$$

Donde:

- α_j - Multiplicadores de Lagrange.
- $K(x_j, x_k)$ - Función *kernel*.
- ν - Parámetro de aprendizaje $\in (0, 1]$.
- l - Número de puntos del conjunto de datos.

Valores bajos de ν implican un menor número de vectores soporte y, por tanto, un hiperplano de decisión más suave. Por otra parte, valores elevados provocan un hiperplano más curvo y ajustado al conjunto de datos, con el riesgo de producir sobreentrenamiento.

Una vez se ha confeccionado el clasificador SVM con los datos de entrenamiento, éste ofrece una puntuación ante cada dato de test. Esta puntuación se corresponde con la distancia al hiperplano de decisión. Si la distancia es positiva, el dato se encuentra dentro de la clase objetivo, mientras que si es negativa, se identifica una anomalía.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

6.3.4. Análisis de Componentes Principales

La técnica de Análisis de Componentes Principales (PCA, por sus siglas en inglés) se ha empleado tanto para tareas de reducción dimensional como para clasificación [6, 26, 30].

Su aplicación en clasificación *one-class* (Tipo 1) trata de mapear los datos de entrada en un subespacio lineal definido por los autovectores de la matriz de covarianzas. Si el conjunto de datos es de dimensión d y se usan n autovectores, éstos se almacenan en una matriz W de dimensiones $d \times n$ [25]. El parámetro n , conocido como el número de componentes, ha de ser menor o igual que la dimensión d del conjunto de datos inicial.

El criterio para comprobar si un nuevo dato pertenece a la clase objetivo está basado en el error de reconstrucción. Éste se computa como la diferencia entre el punto original x y su proyección en el subespacio x_{proy} . El procedimiento para obtener la proyección y el error de reconstrucción se reflejan en las ecuaciones 6.8 y 6.9, respectivamente [25].

$$x_{proy} = W \cdot (W^T \cdot W)^{-1} \cdot W^T \cdot x \quad (6.8)$$

$$e(x) = \|x - x_{proy}\|^2 \quad (6.9)$$

El uso de esta técnica da lugar a buenos resultados cuando el subespacio es claramente lineal [26]. Además, dado que el PCA únicamente utiliza la varianza de los datos de la clase objetivo, es necesario eliminar las muestras correspondientes al funcionamiento anómalo del proceso durante el entrenamiento [26].

6.4. Experimentos y resultados

Tal y como se comentó con anterioridad, las cuatro técnicas explicadas se aplican sobre el conjunto de datos obtenido durante el funcionamiento normal de la planta. En este trabajo se aborda la detección de anomalías provocadas de manera artificial en cada una de las variables de manera individual. En concreto, un 5% de las muestras

Chapter 6. Detección de anomalías basada en técnicas inteligentes de una planta de obtención de material bicomponente empleado en la fabricación de palas de aerogenerador

son transformadas en anomalías. La transformación de una muestra consiste en variar en un $\pm 25\%$ una sola de las variables elegidas aleatoriamente.

Independientemente de la técnica aplicada, ésta ha sido validada utilizando una validación cruzada k -fold con un valor $k = 10$. A su vez, se ha repetido dos veces esta validación, con el objetivo de evaluar, para una configuración determinada, la desviación entre los resultados de cada una de las iteraciones [17]. El comportamiento de los clasificadores es evaluado a través del parámetro Área Bajo la Curva (%) (AUC por sus siglas en inglés). Este parámetro, que compara el ratio de verdaderos positivos y falsos positivos, ha demostrado ser un indicador representativo en este tipo de tareas [1]. Además, se evalúa la Desviación Típica (DT) del AUC obtenido en las distintas repeticiones, así como el tiempo de entrenamiento t_e y el tiempo de cómputo t_{comp} , es decir, el tiempo que necesita el clasificador para detectar la anomalía.

Los procesos de entrenamiento y comprobación de los clasificadores obtenidos se han llevado a cabo en un computador equipado con un procesador *Intel Core i7-8550U 1.80 GHz* y 8 GB de memoria RAM.

6.4.1. Clasificador mediante Contornos Convexos Aproximados

Este método fue implementado a través de Matlab, calculando los contornos convexos de cada proyección a través de la función '*convhull*'. Los parámetros definidos para determinar la configuración de esta técnica son los siguientes:

- Número de proyecciones $2D$: se ha comprobado los valores: 5, 10, 50, 100, 500, 1000, 5000 y 10000.
- Parámetro λ : se ha ajustado a 0,9 (contracción de los contornos convexos), 1 (el contorno convexo no presenta modificación) y 1,1 (expansión de los contornos convexos).

Debido a que este método realiza una clasificación en función de la posición geométrica de cada uno de los puntos, no se ha optado por realizar una normalización de los datos. Los resultados, en términos de AUC, DT, tiempo de entrenamiento y tiempo de cómputo, según el número de proyecciones y el parámetro λ se representan en la tabla 6.1.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

6.4 Experimentos y resultados

Se puede apreciar a partir de la tabla que un valor de $\lambda = 0.9$ no ofrece buenos resultados. Por otra parte, se observa cómo un aumento en el número de proyecciones implica una mejora del AUC, así como un incremento significativo del tiempo de entrenamiento y de cómputo. A pesar de obtener el mayor AUC con 10000 proyecciones y $\lambda = 1$, el clasificador con 5000 proyecciones ofrece prácticamente el mismo resultado en prácticamente una tercera parte de tiempo de entrenamiento.

λ	Pro.	AUC (%)	DT (%)	$t_e(min)$	$t_{comp}(ms)$
0,9	5	62,90	0,74	0,01	0,15
	10	64,41	0,73	0,01	0,29
	50	65,03	0,72	0,04	2,19
	100	65,38	0,90	0,08	2,44
	500	65,53	0,81	0,41	15,67
	1k	65,49	0,65	0,83	44,89
	5k	65,08	1,08	4,27	235,52
	10k	64,91	0,84	10,78	552,68
1	5	85,57	0,13	0,01	0,30
	10	89,30	0,15	0,01	0,55
	50	94,79	0,21	0,05	2,27
	100	95,58	0,22	0,09	5,17
	500	96,56	0,33	0,44	13,04
	1k	96,95	0,40	0,93	42,17
	5k	98,14	0,29	5,84	249,63
	10k	98,15	0,36	14,97	525,54
1,1	5	80,97	0,04	0,01	0,26
	10	86,00	0,05	0,01	0,35
	50	92,38	0,07	0,05	2,03
	100	93,06	0,06	0,08	4,65
	500	95,00	0,09	0,48	29,20
	1k	95,43	0,08	0,96	53,02
	5k	97,12	0,13	6,29	253,50
	10k	97,78	0,13	17,43	546,60

Table 6.1: Resultados obtenidos con Contornos Convexos Aproximados

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 6. Detección de anomalías basada en técnicas inteligentes de una planta de obtención de material bicomponente empleado en la fabricación de palas de aerogenerador

6.4.2. Clasificador mediante Autoencoder

Para llevar a cabo esta técnica, se ha empleado la función '*train.Autoencoder*' del software *Matlab*. El comportamiento de esta técnica se ha evaluado modificando los siguientes parámetros:

- Número de neuronas en la capa intermedia: dado que valor ha de ser menor que el número de variables, de cara a comprobar la influencia que tiene este parámetro, se ha evaluado un número de neuronas de 1, 3, 5, 7 y 9.
- Normalización: con el objetivo de comprobar qué configuración ofrece mejores resultados en términos de AUC y coste computacional, el conjunto de datos se normalizó en un intervalo de 0 a 1, utilizando el método *Z - score* [24] o simplemente no fueron normalizados.
- El criterio empleado para determinar si un dato se encuentra fuera de la clase objetivo y, por tanto, es identificado como una anomalía, se basa en el error de reconstrucción. Si el error de reconstrucción del dato de test sobrepasa un determinado umbral, éste se considera anomalía. Para evaluar el umbral óptimo, se compara el error de reconstrucción del dato de test con el obtenido por los datos de entrenamiento. De manera inmediata, se puede optar por el siguiente criterio: si el error de test es mayor que el de entrenamiento, se identifica la anomalía. Sin embargo, este criterio tiene un inconveniente, ya que puede que existan datos de entrenamiento puntuales que ofrezcan un error elevado, lo que acarrearía que datos de test obtenidos en un estado de funcionamiento anómalo del proceso no fuesen identificados como tal. Por ello, se evalúa como límite el percentil del error de reconstrucción de los datos de entrenamiento desde un 75 % a un 100 %. Se selecciona entonces como valor umbral del clasificador el percentil que mejor resultados ofrezca sobre los datos de test.
- La función de activación de la capa intermedia se corresponde con una logarítmica-sigmoidal, mientras que la capa de salida tiene una función de activación lineal.

Los resultados en términos de AUC, DT, tiempo de entrenamiento y tiempo de cómputo, en función del tipo de normalización y del número de neuronas se muestran en la tabla 6.2.

En este caso se puede observar la gran influencia que tiene sobre los resultados el tipo

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

6.4 Experimentos y resultados

de normalización aplicada. La normalización entre 0 y 1 de los datos de entrenamiento implica unos valores de AUC y tiempos de entrenamiento muy bajos. En cambio, la no normalización de los datos acarrea mejores resultados en términos de AUC (hasta 95,81 % para nueve neuronas) y tiempos de entrenamiento muy elevados con respecto al resto de configuraciones y técnicas.

La normalización mediante el método $Z - Score$ ofrece valores de AUC aceptables (91,45 % para nueve neuronas) y tiempos de entrenamiento relativamente elevados en comparación con el método de Contornos Convexos Aproximados. En términos generales, el aumento del número de neuronas en la capa oculta implica un mayor tiempo de entrenamiento y una mejora en el parámetro AUC. Por otra parte, el tiempo de cómputo constante, es decir, es independiente del número de neuronas o del tipo de normalización.

El mejor clasificador para esta técnica se obtiene con una configuración de 9 neuronas sin llevar a cabo normalización.

Norm.	Neur.	AUC (%)	DT (%)	$t_e(min)$	$t_{comp}(ms)$
-	1	62,89	0,43	110,53	0,01
	3	93,29	0,42	192,01	0,01
	5	95,01	1,23	203,26	0,01
	7	95,42	0,40	206,35	0,01
	9	95,81	0,34	230,33	0,01
0-1	1	51,31	1,52	0,26	0,01
	3	50,66	0,19	0,80	0,01
	5	50,67	0,46	0,74	0,01
	7	53,65	0,80	0,45	0,01
	9	54,07	0,70	0,35	0,01
ZS	1	66,73	0,47	1,00	0,01
	3	89,92	0,58	8,89	0,01
	5	90,84	0,34	6,62	0,01
	7	91,06	0,55	7,14	0,01
	9	91,45	0,43	9,74	0,01

Table 6.2: Resultados obtenidos con Autoencoder

En la figura 6.5, se pueden observar, a modo de ejemplo, los errores de reconstrucción obtenidos para esta configuración. Como se puede apreciar, el error de reconstrucción para los datos de comprobación anómalos, es significativamente mayor que el obtenido

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 6. Detección de anomalías basada en técnicas inteligentes de una planta de obtención de material bicomponente empleado en la fabricación de palas de aerogenerador

para los datos de validos, tanto de entrenamiento como de comprobación.




Figure 6.5: Error de reconstrucción obtenido con 9 neuronas y los datos sin normalizar

6.4.3. Clasificador SVM

El clasificador SVM se obtuvo a través del empleo de la función *'fitcsvm'* del software *Matlab*. Los parámetros tenidos en cuenta para obtener el clasificador fueron los enumerados a continuación:

- Función Kernel: se configura como Gaussiana.
- Fracción de anomalías (Fr_a) de los datos de entrenamiento: se evalúa la influencia que tiene este parámetro asignando valores de entre un 0% y 5%, en incrementos de 1%.
- Normalización: el conjunto de datos se normalizó en un intervalo de 0 a 1, utilizando el método *Z - Score* o simplemente no fueron normalizados.
- El criterio de decisión sobre si un dato es de naturaleza anómala, consiste en la distancia de dicho dato al hiperplano generado por la SVM. Si la distancia es negativa, el dato es identificado como anomalía.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

6.4 Experimentos y resultados

Los valores de AUC, DT, tiempo de entrenamiento y tiempo de cómputo, en función del tipo de normalización y la fracción de anomalías se muestran en la tabla 6.3.

En este caso se aprecia cómo los mejores resultados se obtienen mediante una normalización entre 0 y 1, con un 95.55% de AUC para una fracción de anomalías de 5%.

Sin embargo, el tipo de normalización aplicada o la fracción de anomalías no muestra una variación significativa en cuanto al tiempo de cómputo, tiempo de entrenamiento y el AUC obtenido.

Norm.	Fr_a	AUC (%)	DT (%)	$t_e(min)$	$t_{comp}(ms)$
-	0	94,76	0,80	2,45	0,08
	1	95,05	0,83	2,49	0,09
	2	95,07	1,21	2,35	0,10
	3	95,29	1,32	2,36	0,08
	4	94,92	0,95	2,33	0,08
	5	94,88	1,31	2,29	0,08
0-1	0	94,87	0,55	2,33	0,08
	1	95,08	0,71	2,35	0,08
	2	95,02	1,18	2,35	0,08
	3	94,87	0,87	2,38	0,08
	4	94,74	0,98	2,34	0,08
	5	95,55	0,84	2,60	0,08
ZS	0	95,06	0,74	2,34	0,08
	1	95,07	0,72	2,35	0,09
	2	95,24	0,98	2,32	0,11
	3	94,94	0,83	2,28	0,10
	4	95,09	1,09	2,34	0,08
	5	95,18	0,84	2,32	0,08

Table 6.3: Resultados obtenidos con SVM

6.4.4. Clasificador PCA

Para obtener el clasificador mediante PCA, se usó la función *pca.dd* de la *toolbox dd.tool* [25]. Los parámetros ajustados para dicha función han sido los siguientes:

Chapter 6. Detección de anomalías basada en técnicas inteligentes de una planta de obtención de material bicomponente empleado en la fabricación de palas de aerogenerador

- Fracción de anomalías de los datos de entrenamiento: se evalúa la influencia de este parámetro en un intervalo entre 0% y 5% en incrementos de 1%.
- Número de componentes: se comprueba el funcionamiento del clasificador para un número de componentes desde 1 hasta 10, que es el número máximo de variables de los datos de entrada.
- Normalización: el conjunto de datos se normalizó en un intervalo de 0 a 1, utilizando el método *Z – Score* o simplemente no fueron normalizados.
- El criterio de decisión para determinar la naturaleza anómala de los datos de test está basado en la distancia entre el dato original y el proyectado, y se autoajusta automáticamente con la función *pca.dd*.

Esta técnica ofrece los valores AUC, DT, t_e y t_{comp} , representados en la tabla 6.4.

Norm.	Comp.	AUC (%)	DT (%)	$t_e(min)$	$t_{comp}(\mu s)$
-	3	91,40	0,12	0,03	3,26
	4	92,41	0,34	0,03	3,40
	5	95,16	0,42	0,05	6,01
	6	96,10	0,39	0,03	3,01
	7	96,76	0,37	0,03	4,05
	8	77,34	0,94	0,05	5,60
0-1	3	94,57	0,35	0,04	4,56
	4	97,50	0,37	0,06	6,84
	5	97,29	0,50	0,03	3,72
	6	93,26	0,98	0,05	6,06
	7	88,74	1,12	0,03	3,83
	8	87,53	0,35	0,06	6,46
ZS	3	94,24	0,24	0,03	2,98
	4	97,49	0,48	0,05	6,58
	5	97,25	0,33	0,03	3,06
	6	93,42	0,56	0,05	6,50
	7	92,18	1,62	0,03	3,08
	8	87,67	0,37	0,06	6,71

Table 6.4: Resultados obtenidos con PCA

De esta tabla, se han obviado por motivos de espacio los resultados correspondientes a un número de componentes de 1, 2, 9 y 10 debido a los bajos resultados que ofrecían.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

6.5 Conclusiones y trabajos futuros

Tampoco se presentan los resultados en función de la fracción de anomalías de los datos de entrenamiento, ya que no se presentaban variaciones significativas en los mismos.

El mejor clasificador en términos de AUC se obtiene con una normalización entre 0 y 1 y 4 componentes, alcanzando un con un 97,50% de AUC. A partir de la tabla 6.4, se puede apreciar cómo el tipo de normalización no tiene especial influencia en el AUC obtenido. Tampoco influye significativamente en el tiempo de cómputo y tiempo de entrenamiento.

6.5. Conclusiones y trabajos futuros

En este artículo, se han propuesto y evaluado cuatro técnicas distintas para llevar a cabo la detección de anomalías en una planta de mezclado de bicomponentes empleados en la fabricación de palas de aerogeneradores. A partir de los datos correspondientes al correcto funcionamiento, se han implementado distintos clasificadores *one-class* con el objetivo de detectar las anomalías generadas artificialmente variando los parámetros de la planta.

Los resultados alcanzados en términos de AUC y DT han sido muy satisfactorios en términos generales para las cuatro técnicas, ofreciendo el mejor AUC la técnica de Contornos Convexos Aproximados, con un 98,15% y una DT de 0,36%. Sin embargo, resulta conveniente evaluar los resultados también desde un punto de vista computacional, prestando atención a los tiempos de cómputo y de entrenamiento de cada una de las técnicas empleadas.

En la primera de las técnicas, Contornos Convexos Aproximados, el aumento en el número de proyecciones aumenta las prestaciones del AUC en detrimento del tiempo de cómputo y entrenamiento. Es por este motivo que, a pesar de obtenerse mediante esta técnica el mejor de los resultados en términos de AUC, no se elige este clasificador para la aplicación que nos ocupa.

El clasificador mediante Análisis de Componentes Principales con 4 componentes y los datos normalizados obtiene unos resultados ligeramente inferiores al mejor clasificador obtenido con Contornos Convexos Aproximados (97,50%). Sin embargo, los tiempos de cómputo y entrenamiento son extremadamente más pequeños (6,84 μ s y 0,06 minutos respectivamente). Por tanto, se elige éste como el mejor clasificador 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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 6. Detección de anomalías basada en técnicas inteligentes de una planta de obtención de material bicomponente empleado en la fabricación de palas de aerogenerador

todos los considerados.

Con respecto al clasificador obtenido mediante Autoencoder, se puede apreciar que el tiempo de entrenamiento se reduce significativamente cuando se aplica la normalización entre 0 y 1, sin embargo los resultados obtenidos en esta configuración no son satisfactorios.

Mediante el resto de configuraciones no se obtienen resultados tan buenos como los obtenidos mediante la técnica de Contornos Convexos Aproximados, especialmente desde un punto de vista de tiempo de entrenamiento. Además, se ha demostrado para este caso, que el número de neuronas en la capa oculta tiene una influencia significativa en el coste computacional y el valor de AUC obtenido.

El clasificador obtenido a través de las SVM ofrece buenos resultados en todas sus configuraciones, sin presentarse una diferencia notable entre ellas. Sin embargo, presenta un tiempo de entrenamiento más elevado comparativamente con la técnica PCA, la cual se revela como la más rápida de las cuatro.

Para el clasificador seleccionado, se calcula un tiempo de latencia de 500,006 ms, que es el resultado de sumar el periodo de muestreo necesario para adquirir un nuevo dato (500 ms) y el tiempo de cómputo del clasificador escogido (6 μ s).

Con el método propuesto, es posible detectar de manera satisfactoria las anomalías producidas, en la totalidad de los componentes presentes en el sistema de mezclado de bicomponentes empleados en la fabricación de palas de aerogenerador.

Este clasificador se presenta como una herramienta valiosa a la hora de realizar la detección de un funcionamiento anómalo en la planta industrial, lo que permite tomar decisiones y favorecer su correcto funcionamiento, con las ventajas que ello implica, en materia de ahorro de energía, de material y mantenimiento, entre otros.

Como trabajos futuros, se podría considerar la realización de un clasificador independiente para cada una de las señales monitorizadas.

Como paso previo a la implementación de cada clasificador, posiblemente sería viable emplear Técnicas de Reducción Dimensional para disminuir el número de variables de entrada y así, reducir el coste computacional del mismo. Además, se plantea la posibilidad de emplear otras técnicas, tales como Estimación de Densidad Parzen (PDE,

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

por sus siglas en inglés), *k-centros* o *k-medias*.

Además, debido a que el sistema está evolucionando durante su uso, es probable que el comportamiento de los datos vaya cambiando durante su correcto funcionamiento. Este cambio puede no implicar una anomalía, aunque así lo determinase el clasificador implementado en este trabajo. Una alternativa para evitar esta circunstancia consistiría en reentrenar el clasificador cada cierto tiempo de funcionamiento.

Bibliography

- [1] A. P. Bradley. The use of the area under the roc curve in the evaluation of machine learning algorithms. *Pattern Recognition*, 30(7):1145 – 1159, 1997. ISSN 0031-3203. doi: [https://doi.org/10.1016/S0031-3203\(96\)00142-2](https://doi.org/10.1016/S0031-3203(96)00142-2).
- [2] P. Casale, O. Pujol, and P. Radeva. Approximate convex hulls family for one-class classification. In C. Sansone, J. Kittler, and F. Roli, editors, *Multiple Classifier Systems*, pages 106–115, Berlin, Heidelberg, 2011. Springer Berlin Heidelberg.
- [3] P. Casale, O. Pujol, and P. Radeva. Approximate polytope ensemble for one-class classification. *Pattern Recognition*, 47(2):854 – 864, 2014. ISSN 0031-3203. doi: <https://doi.org/10.1016/j.patcog.2013.08.007>.
- [4] V. Chandola, A. Banerjee, and V. Kumar. Anomaly detection: A survey. *ACM computing surveys (CSUR)*, 41(3):15, 2009.
- [5] Y. Chen, X. S. Zhou, and T. S. Huang. One-class svm for learning in image retrieval. In *Image Processing, 2001. Proceedings. 2001 International Conference on*, volume 1, pages 34–37. IEEE, 2001.
- [6] L. H. Chiang, E. L. Russell, and R. D. Braatz. *Fault detection and diagnosis in industrial systems*. Springer Science & Business Media, 2000.
- [7] M. P. de la Portilla, A. L. Piñeiro, J. A. S. Sánchez, and R. M. Herrera. Modelado dinámico y control de un dispositivo sumergido provisto de actuadores hidrostáticos. *Revista Iberoamericana de Automática e Informática industrial*, 15(1):12–23, 2017. ISSN 1697-7920. doi: 10.4995/riai.2017.8824.
- [8] H. Fan, C. Wong, and M.-F. Yuen. Prediction of material properties of epoxy materials using molecular dynamic simulation. In *Thermal, Mechanical and Multiphysics Simulation and Experiments in Micro-Electronics and Micro-Systems*,

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 6. Detección de anomalías basada en técnicas inteligentes de una planta de obtención de material bicomponente empleado en la fabricación de palas de aerogenerador

2006. *EuroSime 2006. 7th International Conference on*, pages 1–4, April 2006.
doi: 10.1109/ESIME.2006.1644033.

- [9] D. Fernández-Francos, O. Fontenla-Romero, and A. Alonso-Betanzos. One-class convex hull-based algorithm for classification in distributed environments. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, pages 1–11, 2018. ISSN 2168-2216. doi: 10.1109/TSMC.2017.2771341.
- [10] G. González, C. D. Angelo, D. Forchetti, and D. Aligia. Diagnóstico de fallas en el convertidor del rotor en generadores de inducción con rotor bobinado. *Revista Iberoamericana de Automática e Informática industrial*, 15(3):297–308, 2018. ISSN 1697-7920. doi: 10.4995/riai.2017.9042.
- [11] I. Goodfellow, Y. Bengio, A. Courville, and Y. Bengio. *Deep learning*, volume 1. MIT press Cambridge, 2016.
- [12] K. A. Heller, K. M. Svore, A. D. Keromytis, and S. J. Stolfo. One class support vector machines for detecting anomalous windows registry accesses. In *Proc. of the workshop on Data Mining for Computer Security*, volume 9, 2003.
- [13] M. Hobday. Product complexity, innovation and industrial organisation. *Research policy*, 26(6):689–710, 1998.
- [14] V. Hodge and J. Austin. A survey of outlier detection methodologies. *Artificial intelligence review*, 22(2):85–126, 2004.
- [15] B. Hwang and S. Cho. Characteristics of auto-associative mlp as a novelty detector. In *Neural Networks, 1999. IJCNN'99. International Joint Conference on*, volume 5, pages 3086–3091. IEEE, 1999.
- [16] 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, 2018. Springer International Publishing.
- [17] D. Krstajic, L. J. Buturovic, D. E. Leahy, and S. Thomas. Cross-validation pitfalls when selecting and assessing regression and classification models. *Journal of Cheminformatics*, 6(1):10, Mar 2014. ISSN 1758-2946. doi: 10.1186/1758-2946-6-10. URL <https://doi.org/10.1186/1758-2946-6-10>.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

6.5 Conclusiones y trabajos futuros

- [18] K.-L. Li, H.-K. Huang, S.-F. Tian, and W. Xu. Improving one-class svm for anomaly detection. In *Machine Learning and Cybernetics, 2003 International Conference on*, volume 5, pages 3077–3081. IEEE, 2003.
- [19] D. Miljković. Fault detection methods: A literature survey. In *MIPRO, 2011 proceedings of the 34th international convention*, pages 750–755. IEEE, 2011.
- [20] M. Sakurada and T. Yairi. Anomaly detection using autoencoders with nonlinear dimensionality reduction. In *Proceedings of the MLSDA 2014 2nd Workshop on Machine Learning for Sensory Data Analysis*, page 4. ACM, 2014.
- [21] B. Schölkopf, J. C. Platt, J. Shawe-Taylor, A. J. Smola, and R. C. Williamson. Estimating the support of a high-dimensional distribution. *Neural computation*, 13(7):1443–1471, 2001.
- [22] J. Schwartz. Air pollution and daily mortality: A review and meta analysis. *Environmental Research*, 64(1):36 – 52, 1994. ISSN 0013-9351. doi: <http://dx.doi.org/10.1006/enrs.1994.1005>.
- [23] F. Segovia, J. M. Górriz, J. Ramírez, F. J. Martínez-Murcia, and M. García-Pérez. Using deep neural networks along with dimensionality reduction techniques to assist the diagnosis of neurodegenerative disorders. *Logic Journal of the IGPL*, 26(6):618–628, 2018. doi: 10.1093/jigpal/jzy026. URL <http://dx.doi.org/10.1093/jigpal/jzy026>.
- [24] L. A. Shalabi and Z. Shaaban. Normalization as a preprocessing engine for data mining and the approach of preference matrix. In *2006 International Conference on Dependability of Computer Systems*, pages 207–214, May 2006. doi: 10.1109/DEPCOS-RELCOMEX.2006.38.
- [25] D. Tax. Ddttools, the data description toolbox for matlab, Jan 2018. version 2.1.3.
- [26] D. M. J. Tax. One-class classification: concept-learning in the absence of counter-examples [ph. d. thesis]. *Delft University of Technology*, 2001.
- [27] P. Vincent, H. Larochelle, I. Lajoie, Y. Bengio, and P.-A. Manzagol. Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion. *Journal of Machine Learning Research*, 11(Dec):3371–3408, 2010.
- [28] X. Wei, G. Huang, and Y. Li. Mahalanobis ellipsoidal learning machine for one class classification. In *2007 International Conference on Machine Learning 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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 6. Detección de anomalías basada en técnicas inteligentes de una planta de obtención de material bicomponente empleado en la fabricación de palas de aerogenerador

- Cybernetics*, volume 6, pages 3528–3533, Aug 2007. doi: 10.1109/ICMLC.2007.4370758.
- [29] J. A. Westerhuis, S. P. Gurden, and A. K. Smilde. Generalized contribution plots in multivariate statistical process monitoring. *Chemometrics and intelligent laboratory systems*, 51(1):95–114, 2000.
- [30] J. Wu and X. Zhang. A pca classifier and its application in vehicle detection. In *IJCNN'01. International Joint Conference on Neural Networks. Proceedings (Cat. No. 01CH37222)*, volume 1, pages 600–604. IEEE, 2001.
- [31] W.-B. Young and W.-H. Wu. Optimization of the skin thickness distribution in the composite wind turbine blade. In *Fluid Power and Mechatronics (FPM), 2011 International Conference on*, pages 62–66, Aug 2011. doi: 10.1109/FPM.2011.6045730.
- [32] Z. Zeng and J. Wang. *Advances in neural network research and applications*. Springer Publishing Company, Incorporated, 1st edition, 2010. ISBN 3642129897, 9783642129896.
- [33] Y. Zuo and H. Liu. Evaluation on comprehensive benefit of wind power generation and utilization of wind energy. In *Software Engineering and Service Science (ICSESS), 2012 IEEE 3rd International Conference on*, pages 635–638, June 2012. doi: 10.1109/ICSESS.2012.6269547.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

CHAPTER 7



Conclusions

The general conclusions drawn from this research are summarized next:

- Two different procedures were successfully developed and tested to achieve the anomaly detection in industrial systems, whose main features were discussed. The methods were applied to two industrial applications with satisfactory results: a bicomponent mixing machine and a tank-system level control.
- The hybrid intelligent model approach has proved to offer high performance as a method to supervise the occurrence of anomalies in industrial plants. This means that, it is crucial to take into account the user expertise. Thus, the system performs well when the criteria selected is based on a deep system knowledge on the sensors, actuators, noise characteristics, etc.
- As an alternative, an anomaly detection system based on on-class classifiers was successfully designed. The use of one-class techniques offers the possibility of achieving the anomaly detection without prior expert knowledge about the system. This is presented as an important development when the anomaly problem is addressed in extremely complex systems, or systems where having an expert user is not feasible.
- According to the performance analysis, both proposals are versatile and demonstrated a high potential for anomaly detection in different applications. In addition to the industrial systems presented in this work, the proposed methodology was assessed on other application fields (anesthesia drug infusion, energy systems ...) with satisfactory results.

Specific conclusions arising from the published work of this research are:

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 7. Conclusions

- Chapter 4. This work achieves a virtual sensor for anomaly detection, isolation and data recovery in a bicomponent mixing machine. The virtual sensor uses a hybrid intelligent model to predict the signal value in a specific sensor. All models are capable of predicting the readings of one sensor with a maximum error of $0.1894e-3$. The best performance is achieved when the dataset is grouped in 7 clusters, with a mean error of $0.1314e-3$.
- Chapter 5. Three different one-class classification methods are proposed for performing fault detection in laboratory plant used to control the water level in a tank. A detailed analysis of each method performance is exposed in terms of AUC, training time, and hyperparameters influence. The classifier with the highest AUC (99,78 %) is obtained with ACH with 1000 projections and $\lambda = 1$.
- Chapter 6. In this article, the anomaly detection in a bicomponent mixing system is achieved using four one-class classification methods, whose performance are evaluated. To evaluate the detection system, an artificial anomaly generator was used. For all the techniques, the detection was successful. In terms of AUC, the highest detection score obtained was 98,15 %, obtained with ACH with 10000 projections and $\lambda = 1$.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

CHAPTER 8



Future works

A wide variety of future works can be derived from the achievements of the present research. The generic proposed future works regarding the anomaly detection are the following:

- Apply both approaches developed in this work to system diagnosis, trying to identify the source of the anomaly. This could be done by implementing local anomaly detection systems distributed along the facility.
- The previous future work could be the first step to implement fault tolerant systems. This means that the system could generate control actions with low dependency of faults presence.
- In addition to more industrial plants, a future research line would consist on validate the implemented methods over different applications, such as medicine or fraud detection.

More specifically, according to the approaches proposed, two main research lines that will continue the present work are detailed below:

- Anomaly detection using virtual sensor.
 - Make use of alternative methods that contribute to improve the anomaly detection performance. This review would affect the clustering (DBSCAN, EM-GMM, AHC, etc.) and regression (time delay neural networks, convolutional neural networks, decision trees, etc.) stages. Even it would be interesting to improve the current used methods.
 - Improve the system reliability by developing new methods capable of obtaining more knowledge extraction from data.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 8. Future works

- Develop a distributed topology over a industrial system to identify the source of the anomaly. If one virtual sensor is placed in every measure point, the fault detection could be located.
 - Since the systems behaviour would evolve slightly due to the use, it could be interesting to implement an adaptive model according to the system changes.
 - Use dimensional reduction techniques to reduce the training times in applications where the model must be updated in short periods of time.
- Anomaly detection using one-class techniques.
- Explore the possibility of using alternative methods to obtain better one-class classifiers, such as k-Nearest Neighbor, Parzen Density Estimator or Gaussian Models.
 - Implement hybrid one-class classifiers combining clustering and one-class techniques. This may help to improve the classifier performance in complex systems with different operating points.
 - Retrain the classifier after a certain time to incorporate system deviations resulting from aging.
 - Improve the performance of ACH technique when the target set presents non-convex shapes. One way to face this issue would be the application of clustering algorithms to divide the non-convex set into convex groups.
 - Explore the possibility of reducing training times by apply dimensional reduction techniques.
 - Add the possibility of recovering data in case of punctual anomalies. This could be done by applying virtual sensors or imputation techniques.
 - Since only data from target set is available without further prior knowledge about the system, a preprocessing stage to reduce the noise could increase the classifier performance.
 - Due to the same reason stated above, the development of anomaly generation techniques could be a very useful tool to validate the one-class classifiers.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

CHAPTER 9



Publications

This chapter summarizes the different works published by the doctoral student, as an indicator of his research activity quality. All the listed works are presented in chronological order.

■ Awards:

1. Best Data fusion Paper Award of PAAMS, DCAI, ISAmI, PACBB, MIS4TEL, BLOCKCHAIN, DECON international conferences in 2019 edition. Paper title: A Global Classifier Implementation for Detecting Anomalies by Using One-Class Techniques over a Laboratory Plant [30].

■ Research articles published in JCR indexed journals:

1. Power cell SOC modelling for intelligent virtual sensor implementation [8].
2. P1034 Frequency domain analysis of surface ECG enables distinction of patients with brugada syndrome [12].
3. Hybrid model for the ANI index prediction using Remifentanil drug and EMG signal [10].
4. Hybrid intelligent system to predict the individual academic performance of engineering students [24].
5. Modelling the hypnotic patient response in general anaesthesia using intelligent models [22].
6. A fault detection system based on unsupervised techniques for industrial control loops [29].
7. Short-term energy demand forecast in hotels using hybrid intelligent modeling [11].
8. A Fault Detection System for a Geothermal Heat Exchanger Sensor Based on Intelligent Techniques [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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 9. Publications

9. Geothermal heat exchanger energy prediction based on time series and monitoring sensors optimization [7].
 10. Virtual sensor for fault detection, isolation and data recovery for bicomponent mixing machine monitoring [27].
 11. Anomaly detection based on one-class intelligent techniques over a control level plant [26].
 12. Detección de anomalías basada en técnicas inteligentes de una planta de obtención de material bicomponente empleado en la fabricación de palas de aerogenerador [28].
 13. Bioinspired Hybrid Model to Predict the Hydrogen Inlet Fuel Cell Flow Change of an Energy Storage System [4].
- International conferences
1. Modeling of bicomponent mixing system used in the manufacture of wind generator blades [16].
 2. Bioclimatic House Heat Exchanger Behavior Prediction with Time Series Modeling [5].
 3. Attempts prediction by missing data imputation in engineering degree [18].
 4. An intelligent model to predict ANI in patients undergoing general anesthesia [19].
 5. A machine learning based system for analgesic drug delivery [13].
 6. PID-ITS: an intelligent tutoring system for PID tuning learning process [17].
 7. A new approach for system malfunctioning over an industrial system control loop based on unsupervised techniques [20].
 8. Sensor Fault Detection and Recovery Methodology for a Geothermal Heat Exchanger [1].
 9. Prediction of the Energy Demand of a Hotel Using an Artificial Intelligence-Based Model [9].
 10. Remifentanyl Dose Prediction for Patients During General Anesthesia [23].
 11. Inferring Knowledge from Clinical Data for Anesthesia Automation [14].
 12. Anomaly Detection on Patients Undergoing General Anesthesia [32].
 13. Outlier Generation and Anomaly Detection Based on Intelligent One-Class Techniques over a Bicomponent Mixing System [31].

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

14. A Global Classifier Implementation for Detecting Anomalies by Using One-Class Techniques over a Laboratory Plant [30].
 15. Anomaly Detection Over an Ultrasonic Sensor in an Industrial Plant [25]
 16. Study of Data Pre-processing for Short-Term Prediction of Heat Exchanger Behaviour Using Time Series [6].
 17. Prediction of Student Performance Through an Intelligent Hybrid Model [3].
- Spanish national conferences:
 1. Sistema híbrido para la predicción del funcionamiento de una celda de combustible basada en hidrógeno, empleada en el almacenamiento de energía [33].
 2. Diseño de un gemelo digital para el gestor de operaciones de una lavandería industrial [15].
 - Books
 1. Estudio y análisis de métodos y técnicas de control de temperatura [21]
 2. Estudio de sistemas de control con equipos industriales comerciales: análisis y estudio [35]
 - Chapters
 1. An energy storage system: experimental proposal for the efficiency improvement of the electrical network management [34]

Bibliography

- [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 *International Conference on Hybrid Artificial Intelligence Systems*, pages 171–184. Springer, 2018.
- [2] H. Aláiz-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):2740, 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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 9. Publications

- [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 *International Conference on Hybrid Artificial Intelligence Systems*, pages 710–721. Springer, 2019.
- [4] H. Alaiz-Moretón, E. Jove, J.-L. Casteleiro-Roca, H. Quintián, H. López García, J. A. Benítez-Andrades, P. Novais, and J. L. Calvo-Rolle. Bioinspired hybrid model to predict the hydrogen inlet fuel cell flow change of an energy storage system. *Processes*, 7(11), 2019.
- [5] 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 series modeling. In *International Joint Conference SOCO'17-CISIS'17-ICEUTE'17 León, Spain, September 6–8, 2017, Proceeding*, pages 112–124. Springer, 2017.
- [6] B. Baruque, E. Jove, S. Porras, and J. L. Calvo-Rolle. Study of data pre-processing for short-term prediction of heat exchanger behaviour using time series. In *International Conference on Hybrid Artificial Intelligence Systems*, pages 38–49. Springer, 2019.
- [7] B. Baruque, S. Porras, E. Jove, and J. L. Calvo-Rolle. Geothermal heat exchanger energy prediction based on time series and monitoring sensors optimization. *Energy*, 171:49–60, 2019.
- [8] 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.
- [9] 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 *International Conference on Hybrid Artificial Intelligence Systems*, pages 586–596. Springer, 2018.
- [10] J.-L. Casteleiro-Roca, E. Jove, J. M. Gonzalez-Cava, J. A. M. Pérez, J. L. Calvo-Rolle, and F. B. Alvarez. Hybrid model for the ani index prediction using remifentanyl drug and emg signal. *Neural Computing and Applications*, pages 1–10, 2018.
- [11] 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):2485, 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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

- [12] D. García Iglesias, E. Jove Perez, P. Penyafiel Verdu, I. Valverde, M. Gonzalez Vas-serot, J. Rubin Lopez, D. Perez Diez, A. Garcia Alberola, C. Moris De La Tassa, J. Calvo Rolle, et al. P1034 frequency domain analysis of surface ecg enables distin-ction of patients with brugada syndrome. *EP Europace*, 19(suppl.3):iii222–iii223, 2017.
- [13] J. M. Gonzalez-Cava, R. Arnay, J. A. M. 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 *International Joint Conferen-ce SOCO'17-CISIS'17-ICEUTE'17 León, Spain, September 6–8, 2017, Proceeding*, pages 461–470. Springer, 2017.
- [14] J. M. Gonzalez-Cava, I. Castilla-Rodríguez, J. A. Reboso, A. León, M. Martín, E. Jove-Pérez, J. L. Calvo-Rolle, and J. A. Méndez-Pérez. Inferring knowledge from clinical data for anesthesia automation. In *International Conference on Hybrid Artificial Intelligence Systems*, pages 480–491. Springer, 2019.
- [15] G. González Rodríguez, J. M. González-Cava, E. Jove, J. L. Calvo-Rolle, and J. A. Méndez Pérez. Diseño de un gemelo digital para el gestor de operaciones de una lavandería industrial. In *XL Jornadas de Automática*, pages 499–505. Universidade da Coruña, Servizo de Publicacións, 2019.
- [16] 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 *International Conference on Intelligent Data Engineering and Automated Learning*, pages 275–285. Springer, 2014.
- [17] 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 *International Joint Conference SOCO'17-CISIS'17-ICEUTE'17 León, Spain, September 6–8, 2017, Proceeding*, pages 726–735. Springer, 2017.
- [18] 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 *International Joint Conference SOCO'17-CISIS'17-ICEUTE'17 León, Spain, September 6–8, 2017, Proceeding*, pages 167–176. Springer, 2017.
- [19] 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 under-

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 9. Publications

- going general anesthesia. In *International Joint Conference SOCO'17-CISIS'17-ICEUTE'17 León, Spain, September 6–8, 2017, Proceeding*, pages 492–501. Springer, 2017.
- [20] 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 *The 13th International Conference on Soft Computing Models in Industrial and Environmental Applications*, pages 415–425. Springer, 2018.
- [21] 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.
- [22] 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.
- [23] 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. Rebozo. Remifentanil dose prediction for patients during general anesthesia. In *International Conference on Hybrid Artificial Intelligence Systems*, pages 537–546. Springer, 2018.
- [24] E. Jove, J. A. V. López, I. Fernández-Ibáñez, J. L. Casteleiro-Roca, and J. L. Calvo-Rolle. Hybrid intelligent system topredict the individual academic performance of engineering students. *The International journal of engineering education*, 34(3): 895–904, 2018.
- [25] 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 *International Conference on Hybrid Artificial Intelligence Systems*, pages 492–503. Springer, 2019.
- [26] E. Jove, J.-L. Casteleiro-Roca, D. S. Quintián, Héctor, J. A. Méndez-Pérez, and J. L. Calvo-Rolle. Anomaly detection based on one-class intelligent techniques over a control level plant. *International Journal of the IGPL*, 2019.
- [27] E. Jove, J.-L. Casteleiro-Roca, H. Quintián, J. A. Méndez-Pérez, and J. L. Calvo-Rolle. Virtual sensor for fault detection, isolation and data recovery for bicomponent mixing machine monitoring. *Informatica*, 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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

- [28] 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*, 2019.
- [29] 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*, page e12395, 2019.
- [30] 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 *International Symposium on Distributed Computing and Artificial Intelligence*, pages 149–160. Springer, 2019.
- [31] 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 *International Workshop on Soft Computing Models in Industrial and Environmental Applications*, pages 399–410. Springer, 2019.
- [32] 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. In *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. Springer, 2019.
- [33] J. A. Montero-Sousa, E. Jove, J.-L. Casteleiro-Roca, H. Quintián, J. L. Calvo-Rolle, H. Aláiz-Moretón, and T. González-Ayuso. 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*, pages 200–210. Universidade da Coruña, Servizo de Publicacións, 2019.
- [34] 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.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Chapter 9. Publications

- [35] 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.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Articles proofs

The acceptance letter of journal articles in chapter 4 and 5, as well as the paper proof of chapter 6, are presented in next pages.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Vilnius University
Institute of Data Science and Digital Technologies

Lithuanian Academy of Sciences

INFORMATICA

International Journal

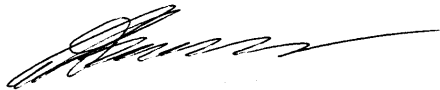
Editor-in-Chief
Prof. G. Dzemyda
Institute of Data Science and Digital Technologies
Vilnius University
Akademijos St. 4
08663 Vilnius, Lithuania
Phone: (+370 5) 2729 207, Fax: (+370 5) 2729 209
E-mail: gintautas.dzemyda@mii.vu.lt
<http://www.mii.lt/Informatica/>

November 6, 2019

Dear Esteban Jove,

With this letter we certify that the paper with the title „**Virtual sensor for fault detection, isolation and data recovery for bicomponent mixing machine monitoring**” of the authors **E. Jove, J. Cateleiro-Roca, H. Quintián, J. Méndez-Pérez, J. Calvo-Rolle** has been accepted for publication in the journal "Informatica", ISSN 0868-4952.

Prof. Gintautas Dzemyda,
Editor-in-Chief of INFORMATICA



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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

142

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

OUP UNCORRECTED PROOF – FIRST PROOF, 10/11/2019, SPi

Anomaly Detection Based on One-Class Intelligent Techniques Over a Control Level Plant

ESTEBAN JOVE*, *Department of Industrial Engineering, University of A Coruña (UDC), Avda. 19 de febrero s/n, 15405, Ferrol, A Coruña, Spain.* AQ1
, *Department of Computer Science and System Engineering, University of La Laguna (ULL), Avda. Astrof. Francisco Sánchez s/n, 38200, S/C de Tenerife, Spain.*

JOSÉ-LUIS CASTELEIRO-ROCA, *Department of Industrial Engineering, University of A Coruña (UDC), Avda. 19 de febrero s/n, 15405, Ferrol, A Coruña, Spain.*

HÉCTOR QUINTIÁN, *Department of Industrial Engineering, University of A Coruña (UDC), Avda. 19 de febrero s/n, 15405, Ferrol, A Coruña, Spain.*

DRAGAN SIMIĆ, *Faculty of Technical Sciences, University of Novi Sad, Trg Dositeja Obradovića 6, 106314, Novi Sad, Serbia.*

JUAN-ALBINO MÉNDEZ-PÉREZ, *Department of Computer Science and System Engineering, University of La Laguna (ULL), Avda. Astrof. Francisco Sánchez s/n, 38200, S/C de Tenerife, Spain.*

JOSÉ LUIS CALVO-ROLLE, *Department of Industrial Engineering, University of A Coruña (UDC), Avda. 19 de febrero s/n, 15405, Ferrol, A Coruña, Spain.*

Abstract

A large part of technological advances, especially in the field of industry, have been focused on the optimization of productive processes. However, the detection of anomalies has turned out to be a great challenge in fields like industry, medicine or stock markets. The present work addresses anomaly detection on a control level plant. We propose the application of different intelligent techniques, which allow to obtain one-class classifiers using real data taken from the correct plant operation. The performance of each classifier is assessed and validated with real created faults, achieving successful overall results.

Keywords: Fault detection, one-class, ACH, autoencoder, SVM.

*E-mail: esteban.jove@udc.es

© The Author(s) 2019. Published by Oxford University Press. All rights reserved.
For permissions, please e-mail: journals.permission@oup.com.
doi:10.1093/jigpal/jzz057

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

Este artículo ha sido aceptado para su publicación en un futuro número de RIAI. Su contenido es definitivo y únicamente cambiará en la versión final la información relativa al volumen, número y número de páginas.



Revista Iberoamericana de Automática e Informática Industrial

Revista Iberoamericana de Automática e Informática Industrial 00 (2019) 1–10



Detección de anomalías basada en técnicas inteligentes de una planta de obtención de material bicomponente empleado en la fabricación de palas de aerogenerador

Esteban Jove^{a,b}, José-Luis Casteleiro-Roca^{a,*}, Héctor Quintián^a, Juan Albino Méndez-Pérez^b, Jose Luis Calvo-Rolle^a

^aDepartamento de Ingeniería Industrial, Univesidade da Coruña,

^bDepartamento de Ingeniería Informática y de Sistemas, Universidad de La Laguna

Resumen

Los avances tecnológicos en general, y en el ámbito de la industria en particular, conllevan el desarrollo y optimización de las actividades que en ella tienen lugar. Para alcanzar este objetivo, resulta de vital importancia detectar cualquier tipo de anomalía en su fase más incipiente, contribuyendo, entre otros, al ahorro energético y económico, y a una reducción del impacto ambiental. En un contexto en el que se fomenta la reducción de emisión de gases contaminantes, las energías alternativas, especialmente la energía eólica, juegan un papel crucial. En la fabricación de las palas de aerogenerador se recurre comúnmente a materiales de tipo bicomponente, obtenidos a través del mezclado de dos sustancias primarias. En la presente investigación se evalúan distintas técnicas inteligentes de clasificación *one-class* para detectar anomalías en un sistema de mezclado para la obtención de materiales bicomponente empleados en la elaboración de palas de aerogenerador. Para lograr los modelos inteligentes que permitan la detección de anomalías, se han usado datos reales extraídos de una planta de mezclado en operación durante su correcto funcionamiento. Los clasificadores obtenidos para cada técnica son validados a través de anomalías generadas de manera artificial, obteniéndose resultados altamente satisfactorios.

Palabras Clave: Sistemas de energías renovables, Aerogeneradores, Detección de anomalías, Diagnóstico de sistemas, Redes neuronales

Anomaly detection based on intelligent techniques over a bicomponent production plant used on wind generator blades manufacturing

Abstract

Technological advances, especially in the industrial field, have led to the development and optimization of the activities that takes place on it. To achieve this goal, an early detection of any kind of anomaly is very important. This can contribute to energy and economic savings and an environmental impact reduction. In a context where the reduction of pollution gasses emission is promoted, the use of alternative energies, specially the wind energy, plays a key role. The wind generator blades are usually manufactured from bicomponent material, obtained from the mixture of two different primary components. The present research assesses different *one-class* intelligent techniques to perform anomaly detection on a bicomponent mixing system used on the wind generator manufacturing. To perform the anomaly detection, the intelligent models were obtained from real dataset recorded during the right operation of a bicomponent mixing plant. The classifiers for each technique were validated using artificial outliers, achieving very good results.

Keywords:

Renewable energy systems, Windmills, Fault detection, System diagnosis, Neural networks

*Autor para correspondencia: jose.luis.casteleiro@udc.es

To cite this article: Esteban Jove, José-Luis Casteleiro-Roca, Héctor Quintián, Juan Albino Méndez-Pérez, José Luis Calvo-Rolle. 2018. Anomaly detection based on intelligent techniques over a bicomponent production plant used on wind generator blades manufacturing. Revista Iberoamericana de Automática e Informática Industrial 00, 1-5. <https://doi.org/10.4995/riai.2019.11055>
Attribution-NonCommercial-NoDerivatives 4.0 International (CC BY-NC-ND 4.0)

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

References

- [1] B. Baruque, S. Porras, E. Jove, and J. L. Calvo-Rolle. Geothermal heat exchanger energy prediction based on time series and monitoring sensors optimization. *Energy*, 171:49 – 60, 2019. ISSN 0360-5442. doi: <https://doi.org/10.1016/j.energy.2018.12.207>. URL <http://www.sciencedirect.com/science/article/pii/S0360544218325817>.
- [2] C. M. Bishop. Novelty detection and neural network validation. *IEE Proceedings-Vision, Image and Signal processing*, 141(4):217–222, 1994.
- [3] C. M. Bishop. *Pattern Recognition and Machine Learning (Information Science and Statistics)*. Springer-Verlag New York, Inc., Secaucus, NJ, USA, 2006. ISBN 0387310738.
- [4] A. P. Bradley. The use of the area under the roc curve in the evaluation of machine learning algorithms. *Pattern Recognition*, 30(7):1145 – 1159, 1997. ISSN 0031-3203. doi: [https://doi.org/10.1016/S0031-3203\(96\)00142-2](https://doi.org/10.1016/S0031-3203(96)00142-2).
- [5] J. L. Calvo-Rolle, O. Fontenla-Romero, B. Pérez-Sánchez, and B. Guijarro-Berdiñas. Adaptive inverse control using an online learning algorithm for neural networks. *Informatica*, 25(3):401–414, 2014.
- [6] J. Carvajal-Godinez, J. Guo, and E. Gill. Agent-based algorithm for fault detection and recovery of gyroscope’s drift in small satellite missions. *Acta Astronautica*, 139:181–188, 2017.
- [7] P. Casale, O. Pujol, and P. Radeva. Approximate convex hulls family for one-class classification. In C. Sansone, J. Kittler, and F. Roli, editors, *Multiple Classifier Systems*, pages 106–115, Berlin, Heidelberg, 2011. Springer Berlin Heidelberg. ISBN 978-3-642-21557-5.
- [8] P. Casale, O. Pujol, and P. Radeva. Approximate polytope ensemble for one-class classification. *Pattern Recognition*, 47(2):854–864, 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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

- [9] 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.
- [10] 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, 2017.
- [11] 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 remifentanil drug and emg signal. *Neural Computing and Applications*, Jul 2018. ISSN 1433-3058. doi: 10.1007/s00521-018-3605-z. URL <https://doi.org/10.1007/s00521-018-3605-z>.
- [12] V. Chandola, A. Banerjee, and V. Kumar. Anomaly detection: A survey. *ACM computing surveys (CSUR)*, 41(3):15, 2009.
- [13] Y. Chen, X. S. Zhou, and T. S. Huang. One-class svm for learning in image retrieval. In *Image Processing, 2001. Proceedings. 2001 International Conference on*, volume 1, pages 34–37. IEEE, 2001.
- [14] Y. Chen, X. S. Zhou, and T. S. Huang. One-class svm for learning in image retrieval. In *ICIP (1)*, pages 34–37. Citeseer, 2001.
- [15] L. H. Chiang, E. L. Russell, and R. D. Braatz. *Fault detection and diagnosis in industrial systems*. Springer Science & Business Media, 2000.
- [16] B. Chidlovskii and M. Hovelynck. Multi-modality classification for one-class classification in social networks, Feb. 26 2013. US Patent 8,386,574.
- [17] T. J. Cleophas, A. H. Zwinderman, and H. I. Cleophas-Allers. *Machine learning in medicine*. Springer, 2013.
- [18] G. Cohen, H. Sax, A. Geissbuhler, et al. Novelty detection using one-class parzen density estimator. an application to surveillance of nosocomial infections. In *MIE*, pages 21–26, 2008.
- [19] 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.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

- [20] M. P. de la Portilla, A. L. Piñeiro, J. A. S. Sánchez, and R. M. Herrera. Modelado dinámico y control de un dispositivo sumergido provisto de actuadores hidrostáticos. *Revista Iberoamericana de Automática e Informática industrial*, 15(1):12–23, 2017. ISSN 1697-7920. doi: 10.4995/riai.2017.8824.
- [21] E. Eskin, A. Arnold, M. Prerau, L. Portnoy, and S. Stolfo. A geometric framework for unsupervised anomaly detection. In *Applications of data mining in computer security*, pages 77–101. Springer, 2002.
- [22] H. Fan, C. Wong, and M.-F. Yuen. Prediction of material properties of epoxy materials using molecular dynamic simulation. In *Thermal, Mechanical and Multiphysics Simulation and Experiments in Micro-Electronics and Micro-Systems, 2006. EuroSime 2006. 7th International Conference on*, pages 1–4, April 2006. doi: 10.1109/ESIME.2006.1644033.
- [23] T. Fawcett. An introduction to roc analysis. *Pattern recognition letters*, 27(8): 861–874, 2006.
- [24] C.-W. Fei and G.-C. Bai. Distributed collaborative probabilistic design for turbine blade-tip radial running clearance using support vector machine of regression. *Mechanical Systems and Signal Processing*, 49(1):196 – 208, 2014. ISSN 0888-3270. doi: <https://doi.org/10.1016/j.ymssp.2014.04.013>. URL <http://www.sciencedirect.com/science/article/pii/S0888327014001198>.
- [25] D. Fernández-Francos, ó. Fontenla-Romero, and A. Alonso-Betanzos. One-class convex hull-based algorithm for classification in distributed environments. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, pages 1–11, 2018. ISSN 2168-2216. doi: 10.1109/TSMC.2017.2771341.
- [26] A. B. Gardner, A. M. Krieger, G. Vachtsevanos, and B. Litt. One-class novelty detection for seizure analysis from intracranial eeg. *Journal of Machine Learning Research*, 7(Jun):1025–1044, 2006.
- [27] L. Garg, S. McClean, B. Meenan, and P. Millard. Phase-type survival trees and mixed distribution survival trees for clustering patients’ hospital length of stay. *Informatica*, 22(1):57–72, jan 2011. ISSN 0868-4952.
- [28] G. González, C. D. Angelo, D. Forchetti, and D. Aligia. Diagnóstico de fallas en el convertidor del rotor en generadores de inducción con rotor bobinado. *Revista Iberoamericana de Automática e Informática industrial*, 15(3):297–308, 2018. ISSN 1697-7920. doi: 10.4995/riai.2017.9042.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

- [29] S. González, J. Sedano, J. R. Villar, E. Corchado, Á. Herrero, and B. Baruaque. Features and models for human activity recognition. *Neurocomputing*, 167:52–60, 2015. doi: 10.1016/j.neucom.2015.01.082. URL <https://doi.org/10.1016/j.neucom.2015.01.082>.
- [30] J. M. Gonzalez-Cava, J. A. Rebozo, 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] I. Goodfellow, Y. Bengio, A. Courville, and Y. Bengio. *Deep learning*, volume 1. MIT press Cambridge, 2016.
- [32] Y. Guo, X. Li, G. Bai, and J. Ma. Time series prediction method based on LS-SVR with modified gaussian RBF. In T. Huang, Z. Zeng, C. Li, and C. Leung, editors, *Neural Information Processing*, volume 7664 of *Lecture Notes in Computer Science*, pages 9–17. Springer Berlin Heidelberg, 2012. ISBN 978-3-642-34480-0. doi: 10.1007/978-3-642-34481-7{_}2.
- [33] K. Hemalatha and K. U. Rani. Advancements in multi-layer perceptron training to improve classification accuracy. *International Journal on Recent and Innovation Trends in Computing and Communication*, 5(6):353–357, 2017.
- [34] G. Heredia and A. Ollero. Virtual sensor for failure detection, identification and recovery in the transition phase of a morphing aircraft. *Sensors*, 10(3):2188–2201, 2010.
- [35] M. Hobday. Product complexity, innovation and industrial organisation. *Research policy*, 26(6):689–710, 1998.
- [36] V. Hodge and J. Austin. A survey of outlier detection methodologies. *Artificial intelligence review*, 22(2):85–126, 2004.
- [37] J. Hu, J. Hu, H. Lin, X. Li, C. Jiang, X. Qiu, and W. Li. State-of-charge estimation for battery management system using optimized support vector machine for regression. *Journal of Power Sources*, 269(Supplement C):682 – 693, 2014. ISSN 0378-7753. doi: <https://doi.org/10.1016/j.jpowsour.2014.07.016>. URL <http://www.sciencedirect.com/science/article/pii/S0378775314010593>.
- [38] B. Hwang and S. Cho. Characteristics of auto-associative mlp as a novelty detector. In *Neural Networks, 1999. IJCNN'99. International Joint Conference on*, volume 5, pages 3086–3091. IEEE, 1999.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

- [39] I. Hwang, S. Kim, Y. Kim, and C. E. Seah. A survey of fault detection, isolation, and reconfiguration methods. *IEEE Transactions on Control Systems Technology*, 18(3):636–653, 2010.
- [40] A. K. Jain. Data clustering: 50 years beyond k-means. *Pattern Recognition Letters*, 31(8):651–666, 2010. doi: 10.1016/j.patrec.2009.09.011. URL <https://doi.org/10.1016/j.patrec.2009.09.011>.
- [41] A. K. Jain, J. Mao, and K. M. Mohiuddin. Artificial neural networks: A tutorial. *Computer*, 29(3):31–44, 1996.
- [42] 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.
- [43] 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 *International Joint Conference SOCO'17-CISIS'17-ICEUTE'17 León, Spain, September 6–8, 2017, Proceeding*, pages 167–176. Springer, 2017.
- [44] 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 *International Joint Conference SOCO'17-CISIS'17-ICEUTE'17 León, Spain, September 6–8, 2017, Proceeding*, pages 492–501. Springer, 2017.
- [45] 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, 2018. Springer International Publishing.
- [46] 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. In F. Martínez Álvarez, A. Troncoso Lora, J. A. Sáez Muñoz, H. Quintián, and E. Corchado, editors, *International Joint Conference: 12th International Conference on Computational Intelligence in Security for Information*

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

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.

- [47] S. Kaski, J. Sinkkonen, and A. Klami. Discriminative clustering. *Neurocomputing*, 69(13):18–41, 2005. ISSN 0925-2312. doi: <http://dx.doi.org/10.1016/j.neucom.2005.02.012>.
- [48] S. S. Khan and M. G. Madden. A survey of recent trends in one class classification. In *Irish conference on artificial intelligence and cognitive science*, pages 188–197. Springer, 2009.
- [49] D. Krstajic, L. J. Buturovic, D. E. Leahy, and S. Thomas. Cross-validation pitfalls when selecting and assessing regression and classification models. *Journal of Cheminformatics*, 6(1):10, Mar 2014. ISSN 1758-2946. doi: 10.1186/1758-2946-6-10. URL <https://doi.org/10.1186/1758-2946-6-10>.
- [50] C. Kruegel and G. Vigna. Anomaly detection of web-based attacks. In *Proceedings of the 10th ACM conference on Computer and communications security*, pages 251–261. ACM, 2003.
- [51] K.-L. Li, H.-K. Huang, S.-F. Tian, and W. Xu. Improving one-class svm for anomaly detection. In *Machine Learning and Cybernetics, 2003 International Conference on*, volume 5, pages 3077–3081. IEEE, 2003.
- [52] A. Likas, N. Vlassis, and J. J. Verbeek. The global k-means clustering algorithm. *Pattern recognition*, 36(2):451–461, 2003.
- [53] A. Maas, Q. V. Le, T. M. O’neil, O. Vinyals, P. Nguyen, and A. Y. Ng. Recurrent neural networks for noise reduction in robust asr. 2012.
- [54] L. M. Manevitz and M. Yousef. One-class svms for document classification. *Journal of machine Learning research*, 2(Dec):139–154, 2001.
- [55] L. Martí, N. Sanchez-Pi, J. Molina, and A. Garcia. Anomaly detection based on sensor data in petroleum industry applications. *Sensors*, 15(2):2774–2797, 2015.
- [56] MathWorks. `fitcsvm`. <https://es.mathworks.com/help/stats/fitcsvm.html>, 01-29-2019.
- [57] MathWorks. `predict`. <https://es.mathworks.com/help/stats/classreg.learning.classif.compactclassificationsvm.predict.html>, 01-29-2019.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

- [58] MathWorks. Autoencoder. <https://es.mathworks.com/help/deeplearning/ref/trainautoencoder.html>, 01-29-2019.
- [59] O. Mazhelis. One-class classifiers: a review and analysis of suitability in the context of mobile-masquerader detection. *South African Computer Journal*, 2006 (36):29–48, 2006.
- [60] W. S. McCulloch and W. Pitts. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4):115–133, 1943.
- [61] D. Miljković. Fault detection methods: A literature survey. In *MIPRO, 2011 proceedings of the 34th international convention*, pages 750–755. IEEE, 2011.
- [62] S. R. Naidu, E. Zafiriou, and T. J. McAvoy. Use of neural networks for sensor failure detection in a control system. *IEEE Control Systems Magazine*, 10(3): 49–55, 1990.
- [63] A. Ng et al. Sparse autoencoder. *CS294A Lecture notes*, 72(2011):1–19, 2011.
- [64] T. Nicholson. *Optimization in Industry: Volume 1, Optimization Techniques*. Routledge, 2017.
- [65] N. Pal and J. Biswas. Cluster validation using graph theoretic concepts. *Pattern Recognition*, 30(6):847–857, 1997. ISSN 0031-3203. doi: [http://dx.doi.org/10.1016/S0031-3203\(96\)00127-6](http://dx.doi.org/10.1016/S0031-3203(96)00127-6).
- [66] I. Parmee and P. Hajela. *Optimization in industry*. Springer Science & Business Media, 2012.
- [67] Y. Pei and O. Zaïane. A synthetic data generator for clustering and outlier analysis. 2006.
- [68] C. Pinzón, J. F. de Paz, J. Bajo, Á. Herrero, and E. Corchado. AIIDA-SQL: an adaptive intelligent intrusion detector agent for detecting SQL injection attacks. In *10th International Conference on Hybrid Intelligent Systems (HIS 2010), Atlanta, GA, USA, August 23-25, 2010*, pages 73–78, 2010. doi: 10.1109/HIS.2010.5600026. URL <https://doi.org/10.1109/HIS.2010.5600026>.
- [69] F. P. Preparata and M. I. Shamos. *Computational geometry: an introduction*. Springer Science & Business Media, 2012.
- [70] Z. Qi, Y. Tian, and Y. Shi. Robust twin support vector machine for pattern classification. *Pattern Recognition*, 46(1):305 – 316, 2013. ISSN 0031-3203. doi: <https://doi.org/10.1016/j.patcog.2012.06.019>. URL <http://www.sciencedirect.com/science/article/pii/S0031320312002890>.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

- [71] A. Qin and P. Suganthan. Enhanced neural gas network for prototype-based clustering. *Pattern Recogn.*, 38(8):1275–1288, aug 2005. ISSN 0031-3203. doi: 10.1016/j.patcog.2004.12.007.
- [72] 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.
- [73] P. Reberntrost, M. Mohseni, and S. Lloyd. Quantum support vector machine for big data classification. *Phys. Rev. Lett.*, 113:130503, Sep 2014. doi: 10.1103/PhysRevLett.113.130503. URL <https://link.aps.org/doi/10.1103/PhysRevLett.113.130503>.
- [74] M. Ringnér. What is principal component analysis? *Nature biotechnology*, 26(3):303, 2008.
- [75] G. Ritter and M. T. Gallegos. Outliers in statistical pattern recognition and an application to automatic chromosome classification. *Pattern Recognition Letters*, 18(6):525–539, 1997.
- [76] M. Sakurada and T. Yairi. Anomaly detection using autoencoders with nonlinear dimensionality reduction. In *Proceedings of the MLSDA 2014 2nd Workshop on Machine Learning for Sensory Data Analysis*, page 4. ACM, 2014.
- [77] R. Sánchez, Á. Herrero, and E. Corchado. Visualization and clustering for SNMP intrusion detection. *Cybernetics and Systems*, 44(6-7):505–532, 2013. doi: 10.1080/01969722.2013.803903. URL <https://doi.org/10.1080/01969722.2013.803903>.
- [78] B. Schölkopf, J. C. Platt, J. Shawe-Taylor, A. J. Smola, and R. C. Williamson. Estimating the support of a high-dimensional distribution. *Neural computation*, 13(7):1443–1471, 2001.
- [79] J. Schwartz. Air pollution and daily mortality: A review and meta analysis. *Environmental Research*, 64(1):36 – 52, 1994. ISSN 0013-9351. doi: <http://dx.doi.org/10.1006/enrs.1994.1005>.
- [80] F. Segovia, J. M. Górriz, J. Ramírez, F. J. Martínez-Murcia, and M. García-Pérez. Using deep neural networks along with dimensionality reduction techniques to assist the diagnosis of neurodegenerative disorders. *Logic Journal of the IGPL*, 26(6):618–628, 2018. doi: 10.1093/jigpal/jzy026. URL <http://dx.doi.org/10.1093/jigpal/jzy026>.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

- [81] L. A. Shalabi and Z. Shaaban. Normalization as a preprocessing engine for data mining and the approach of preference matrix. In *2006 International Conference on Dependability of Computer Systems*, pages 207–214, May 2006. doi: 10.1109/DEPCOS-RELCOMEX.2006.38.
- [82] A. B. Sharma, L. Golubchik, and R. Govindan. Sensor faults: Detection methods and prevalence in real-world datasets. *ACM Transactions on Sensor Networks (TOSN)*, 6(3):23, 2010.
- [83] H. Shen, Z.-G. Wu, and J. H. Park. Reliable mixed passive h-infinite filtering for semi-markov jump systems with randomly occurring uncertainties and sensor failures. *International Journal of Robust and Nonlinear Control*, 25(17):3231–3251, 2015.
- [84] I. Steinwart and A. Christmann. *Support vector machines*. Springer Publishing Company, Incorporated, 1st edition, 2008. ISBN 0387772413.
- [85] 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.
- [86] D. Tax. Ddtools, the data description toolbox for matlab, Jan 2018. version 2.1.3.
- [87] D. M. J. Tax. One-class classification: concept-learning in the absence of counter-examples [ph. d. thesis]. *Delft University of Technology*, 2001.
- [88] P. Vincent, H. Larochelle, I. Lajoie, Y. Bengio, and P.-A. Manzagol. Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion. *Journal of Machine Learning Research*, 11(Dec):3371–3408, 2010.
- [89] C.-K. Wang, Y. Ting, Y.-H. Liu, and G. Hariyanto. A novel approach to generate artificial outliers for support vector data description. In *Industrial Electronics, 2009. ISIE 2009. IEEE International Symposium on*, pages 2202–2207. IEEE, 2009.
- [90] L. Wang and J. Wu. Neural network ensemble model using PPR and LS-SVR for stock market forecasting. In D.-S. Huang, Y. Gan, V. Bevilacqua, and J. Figueroa, editors, *Advanced Intelligent Computing*, volume 6838 of *Lecture Notes in Computer Science*, pages 1–8. Springer Berlin Heidelberg, 2012. ISBN 978-3-642-24727-9. doi: 10.1007/978-3-642-24728-6{_}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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

- [91] R. Wang, A. Wang, and Q. Song. Research on the alkalinity of sintering process based on LS-SVM algorithms. In D. Jin and S. Lin, editors, *Advances in Computer Science and Information Engineering*, volume 168 of *Advances in Intelligent and Soft Computing*, pages 449–454. Springer Berlin Heidelberg, 2012. ISBN 978-3-642-30125-4. doi: 10.1007/978-3-642-30126-1{_}71.
- [92] S. Wang and J. Cui. Sensor-fault detection, diagnosis and estimation for centrifugal chiller systems using principal-component analysis method. *Applied Energy*, 82(3):197–213, 2005.
- [93] P. Wasserman. *Advanced methods in neural computing*. John Wiley & Sons, Inc., New York, NY, USA, 1st edition, 1993. ISBN 0442004613.
- [94] J. A. Westerhuis, S. P. Gurden, and A. K. Smilde. Generalized contribution plots in multivariate statistical process monitoring. *Chemometrics and intelligent laboratory systems*, 51(1):95–114, 2000.
- [95] D. K. Wornyo and X.-J. Shen. Coupled least squares support vector ensemble machines. *Information*, 10(6):195, 2019.
- [96] J. Wu and X. Zhang. A pca classifier and its application in vehicle detection. In *IJCNN'01. International Joint Conference on Neural Networks. Proceedings (Cat. No. 01CH37222)*, volume 1, pages 600–604. IEEE, 2001.
- [97] J. Ye and T. Xiong. Svm versus least squares SVM. *Journal of Machine Learning Research - Proceedings Track*, 2:644–651, 2007.
- [98] W.-B. Young and W.-H. Wu. Optimization of the skin thickness distribution in the composite wind turbine blade. In *Fluid Power and Mechatronics (FPM), 2011 International Conference on*, pages 62–66, Aug 2011. doi: 10.1109/FPM.2011.6045730.
- [99] M. Zeng, Y. Yang, S. Luo, and J. Cheng. One-class classification based on the convex hull for bearing fault detection. *Mechanical Systems and Signal Processing*, 81:274–293, 2016.
- [100] Z. Zeng and J. Wang. *Advances in neural network research and applications*. Springer Publishing Company, Incorporated, 1st edition, 2010. ISBN 3642129897, 9783642129896.
- [101] Y. Zuo and H. Liu. Evaluation on comprehensive benefit of wind power generation and utilization of wind energy. In *Software Engineering and Service Science*

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11

(ICSESS), 2012 IEEE 3rd International Conference on, pages 635–638, June
2012. doi: 10.1109/ICSESS.2012.6269547.

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: 2307538 Código de verificación: Ejyc0z4z

Firmado por: ESTEBAN JOVE PEREZ UNIVERSIDAD DE LA LAGUNA	Fecha: 29/11/2019 17:07:56
JOSÉ LUIS CALVO ROLLE UNIVERSIDAD DE LA LAGUNA	29/11/2019 17:18:16
Juan Albino Méndez Pérez UNIVERSIDAD DE LA LAGUNA	29/11/2019 19:01:11