



Universidad de Córdoba
Escuela Politécnica Superior
Departamento de Informática y Análisis Numérico

TESIS DOCTORAL

**MODELOS Y ALGORITMOS PARA EL
MANTENIMIENTO PREDICTIVO EN
PLANTAS SOLARES**

Autor: D. Fernando Agustín Olivencia Polo (z42olpof@uco.es)

CÓRDOBA, NOVIEMBRE 2015

TITULO: *Modelos y algoritmos para el mantenimiento predictivo en plantas solares*

AUTOR: *Fernando Agustín Olivencia Polo*

© Edita: UCOPress. 2016
Campus de Rabanales
Ctra. Nacional IV, Km. 396 A
14071 Córdoba

www.uco.es/publicaciones
publicaciones@uco.es

MODELOS Y ALGORITMOS PARA EL MANTENIMIENTO PREDICTIVO EN PLANTAS SOLARES

Por

Fernando Agustín Olivencia Polo

A complex, multi-looped handwritten signature in blue ink, consisting of several overlapping circles and lines.

*Fdo. D. Gonzalo Cerruela
García*
*Profesor Titular de Universidad
Universidad de Córdoba*

A handwritten signature in blue ink, featuring a large, sweeping loop on the left side and a vertical line intersecting it.

Fdo. D. Juan F. Gómez
*Profesor Asociado de Universidad
Universidad de Sevilla*

*Trabajo presentado para optar al grado de
Doctor Ingeniero de Telecomunicación*



**TÍTULO DE LA TESIS: MODELOS Y ALGORITMOS PARA EL
MANTENIMIENTO PREDICTIVO EN PLANTAS
SOLARES**

DOCTORANDO/A: FERNANDO AGUSTÍN OLIVENCIA POLO

INFORME RAZONADO DE LOS DIRECTORES DE LA TESIS

(Se hará mención a la evolución y desarrollo de la tesis, así como a trabajos y publicaciones derivados de la misma).

Los resultados obtenidos en la investigación llevada a cabo en esta Tesis Doctoral han supuesto un avance en el modelado de la generación eléctrica mediante energía solar fotovoltaica, así como en el desarrollo de algoritmos y técnicas para la detección de diversos modos de fallo en plantas solares fotovoltaicas.

Esta investigación centrada en el mantenimiento predictivo de plantas solares fotovoltaicas tiene su origen en la actividad profesional que el doctorando desarrolla para el grupo empresarial Magtel, promotor de varias instalaciones fotovoltaicas de diversa naturaleza (estructura fija y móvil) y tamaño (100 KWp-10 MWp), así como mantenedor a nivel nacional de más de 50 MWp de instalaciones de este tipo.

La propuesta de esta Tesis Doctoral, basada en el uso de técnicas de minería y análisis de datos, principalmente del tipo estadístico paramétrico y redes neuronales, ha abierto un campo de investigación de elevado interés a nivel internacional para la extensión del ciclo de vida de las plantas solares fotovoltaicas y la reducción de los costes de explotación de las mismas, mediante la adecuada implementación de un programa de mantenimiento predictivo

La formación investigadora en el periodo 2004-2016 de D. Fernando Agustín Olivencia Polo ha estado marcada por una clara vocación, dedicación y esfuerzo que han conducido a que obtuviera la máxima calificación en el Trabajo de Investigación del Programa de Doctorado “Ingeniería y Tecnología”, y los resultados de su investigación hayan sido refrendados por prestigiosas publicaciones en las Actas de Congresos de carácter internacional, y en revistas especializadas, que se encuentran tabuladas por el Journal Citation Report en los primeros cuartiles de diferentes áreas de investigación.

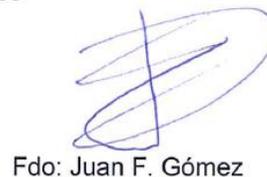
Teniendo en cuenta la formación adquirida, el trabajo investigador realizado, los resultados obtenidos y los que en un futuro se espera se deriven, así como la profesionalidad, extensión y estilo de la Memoria de Tesis Doctoral, los directores de este trabajo autorizan su presentación.

Córdoba, 27 de Noviembre de 2015

Firma de los directores



Fdo: Gonzalo Cerruela García



Fdo: Juan F. Gómez



**TÍTULO DE LA TESIS: MODELOS Y ALGORITMOS PARA EL
MANTENIMIENTO PREDICTIVO EN PLANTAS
SOLARES**

DOCTORANDO/A: FERNANDO AGUSTÍN OLIVENCIA POLO

ESCRITO RAZONADO DEL RESPONSABLE DE LA LÍNEA DE INVESTIGACIÓN

(Ratificando el informe favorable del director. Sólo cuando el director no pertenezca a la Universidad de Córdoba).

El doctorando D. Fernando Agustín Olivencia Polo lleva realizando tareas investigadoras en la línea de Inteligencia Ambiental y Tratamiento de la Información desde el año 2004. En estos años en los que ha superado brillantemente su formación, y ha obtenido unas excelentes calificaciones en los Trabajos Fin de Carrera de Ingeniero de Telecomunicación, Ingeniero de Telecomunicación y en el Trabajo de Investigación del Programa de Doctorado “Ingeniería y Tecnología”, al mismo tiempo ha demostrado una vocación y capacidad investigadora digna de resaltar.

Los resultados de la investigación presentados en la Tesis Doctoral que lleva por título: “Modelos y Algoritmos para el Mantenimiento Predictivo en Plantas Solares” ponen de manifiesto la apreciación que el responsable de la línea ha expuesto del doctorado. En esta Tesis Doctoral, refrendada por sus dos Directores, se han propuesto, estudiado, investigado y resuelto nuevos modelos para estimar la producción de plantas solares fotovoltaicas y la predicción de varios modos de fallo de las mismas, que han permitido afianzar la línea de investigación, que han abierto nuevas tendencias investigadoras a nivel internacional, y que han demostrado que los modelos y algoritmos propuestos y desarrollados por el doctorando son robustos, eficaces, simples y muy apropiados para el mantenimiento predictivo de plantas solares fotovoltaicas, siendo extrapolables a otras tecnologías renovables.

Los resultados de la investigación llevada a cabo para el desarrollo de esta Tesis Doctoral han sido publicados en revistas de alto índice de impacto y de reconocido prestigio internacional dentro de diferentes áreas de conocimiento, tanto relacionadas con la ciencia de la computación y las energías renovables.

Por todo ello, considero que la investigación desarrollada por D. Fernando Agustín Olivencia Polo, y recogida en la Memoria de la Tesis Doctoral, reúne todos los requisitos necesarios en cuanto a innovación, originalidad y calidad científica, que ponen de manifiesto el alto grado de formación científica y profesional del doctorando; y se autoriza la presentación de la tesis doctoral.

Córdoba, 27 de Noviembre de 2015

Firma del responsable de línea de investigación


Fdo.: Miguel Ángel Gómez Nieto

AGRADECIMIENTOS

A mi familia: a los que están aquí, y a los que desde hace tiempo ya no se encuentran entre nosotros, por su apoyo incondicional y creer en que llegaría este día.

A mis compañeros de la Universidad de Córdoba y Universidad de Sevilla, por su soporte, inestimable ayuda y colaboración.

A Magtel, por permitirme compaginar mi actividad profesional con mi trayectoria investigadora.

Gracias.

ÍNDICE DE CONTENIDOS

ÍNDICE DE TABLAS	1
ÍNDICE DE FIGURAS	3
PARTE I	5
1 INTRODUCCIÓN	7
1.1 MOTIVACIÓN DEL TRABAJO DE INVESTIGACIÓN	8
1.2 OBJETIVOS DE LA INVESTIGACIÓN	10
1.3 BIBLIOGRAFÍA	10
2 METODOLOGÍA	13
3 ANTECEDENTES Y FUNDAMENTOS TEÓRICOS	17
3.1 ENERGÍA SOLAR FOTOVOLTAICA.....	18
3.2 PROCESO DE MANTENIMIENTO	30
3.2.1 Estándares de Referencia	32
3.2.2 Marcos de Referencia.....	37
3.2.3 Reliability Centered Maintenance	39
3.3 SISTEMAS MULTIAGENTE	42
3.4 MAXIMUM LIKELIHOOD ESTIMATION	45
3.5 REDES NEURONALES	48
3.6 BIBLIOGRAFÍA	51

4	SISTEMA PARA EL CONTROL Y ADQUISICIÓN DE DATOS EN FUENTES DE ENERGÍA RENOVABLE ..	66
4.1	INTRODUCCIÓN.....	67
4.2	SISTEMA DE SUPERVISIÓN, CONTROL Y ADQUISICIÓN DE DATOS (SCADA).....	69
4.3	MÉTODO DE DETECCIÓN DE FALLOS	75
4.4	AUTOMATIZACIÓN DEL PROCESO DE DETECCIÓN DE FALLOS.....	79
4.5	CONCLUSIONES.....	82
4.6	BIBLIOGRAFÍA.....	83
5	MODELADO ESTADÍSTICO PARAMÉTRICO DE LA PRODUCCIÓN	89
5.1	INTRODUCCIÓN.....	89
5.2	ESTADO DEL ARTE DE LOS MODELOS DE PREDICCIÓN DE LA PRODUCCIÓN DE PLANTAS SOLARES FOTOVOLTAICAS.....	93
5.3	DETECCIÓN DE FALLOS EN PLANTAS SOLARES FOTOVOLTAICAS MEDIANTE EL MODELADO ESTADÍSTICO DE LA PRODUCCION	97
5.4	CONCLUSIONES.....	105
5.5	BIBLIOGRAFÍA.....	106
6	APLICACIÓN DE REDES NEURONALES A LA DETECCIÓN DE FALLOS EN PLANTAS SOLARES FOTOVOLTAICAS	115
6.1	INTRODUCCIÓN.....	115
6.2	SELECCIÓN DEL MODELO	118
6.3	CASO PRÁCTICO.....	129
6.4	CONCLUSIONES.....	150
6.5	BIBLIOGRAFÍA.....	151

7	CONCLUSIONES	163
7.1	CUMPLIMIENTO DE OBJETIVOS	163
7.1.1	O1. Diseño de un Sistema de Supervisión, Control y Adquisición de Datos	164
7.1.2	O2. Modelado de la Producción	164
7.1.3	O3. Detección de Errores de Configuración de Elementos Activos	166
7.1.4	O4. Detección de Fallos no Asociados Directamente a Alarmas Generadas por los Propios Equipos	166
7.1.5	O5. Identificación de Modos de Fallo Susceptibles de ser Tratados mediante un Mantenimiento Predictivo	167
7.2	LÍNEAS FUTURAS DE INVESTIGACIÓN	168
7.2.1	LF1. Mejora de la Exactitud de los Modelos de Predicción	168
7.2.2	LF2. Aplicación del Conocimiento Generado a otras Tecnologías Renovables	169
7.3	BIBLIOGRAFÍA	171

ÍNDICE DE TABLAS

Tabla 1.	Coefficientes de regresión lineal (A57 vs. A42)	78
Tabla 2.	Coefficientes ajuste MLE distribución Weibull	100
Tabla 3.	Configuración típica de estructura de producción por centro de transformación de la planta	131
Tabla 4.	Variables de trabajo caso A	136
Tabla 5.	Resultados test caso A.....	138
Tabla 6.	Detección de evento de identificación de fallo de aislamiento	140
Tabla 7.	Variables de trabajo caso B	143
Tabla 8.	Modelo de Weibull semiparamétrico para reorganización de datos de supervivencia.....	147
Tabla 9.	Reorganización de datos de supervivencia para entrenamiento de red	147
Tabla 10.	Resultados test caso B.....	148
Tabla 11.	Resultados test caso B con Ravdin y Clark.....	148

ÍNDICE DE FIGURAS

Figura 1. Metodología de trabajo.....	15
Figura 2. Fuentes de energía primaria 2013 (© IEA).....	18
Figura 3. Fuentes de energía primaria 2013 (© IEA).....	20
Figura 4. Crecimiento interanual por tecnología renovable (©IEA).....	21
Figura 5. Uso OECD de las fuentes primarias renovables 1990-2013 (©IEA)	21
Figura 6. Uso mundial de las fuentes primarias renovables 2013 (©IEA).....	22
Figura 7. Contribución en la generación de electricidad mundial 2013 (©IEA)	22
Figura 8. Contribución en la generación de electricidad española 2014 (©REE).....	23
Figura 9. Distribución de la potencia instalada en España, 2014 (©REE)	24
Figura 10. Estándares y Mejores Prácticas Gestión en la Empresa	32
Figura 11. Estructura del marco de gestión.....	34
Figura 12. Evolución histórica de marcos de referencia.....	37
Figura 13. Principales elementos de análisis para un mantenimiento centrado en la fiabilidad	40
Figura 14. Metodología RCM.....	41
Figura 15. Hitos en la evolución de las redes neuronales	50
Figura 16. Planta solar El Molino Energía (Córdoba).....	68
Figura 17. Arquitectura física del sistema de control.....	69
Figura 18. Arquitectura del sistema SCADA	71
Figura 19. Diagrama de colaboración multiagente	75
Figura 20. Producción normalizada de energía en 5 inversores de la planta Molino Energía entre enero y agosto de 2009	77
Figura 21. Matriz de correlación de la producción de 56 inversores Molino Energía.....	78
Figura 22. Regresión lineal de la producción en el A57 frente a la producción del inversor A42.....	79

Figura 23. Proceso para la detección automática de fallos de producción	81
Figura 24. Arquitectura lógica del SCADA.....	97
Figura 25. Distribuciones de Weibull obtenidas por ajuste MLE.....	99
Figura 26. Comparativa producción real (rojo) frente a estimación (negro): (a) octubre 2011; (b) julio 2009.....	101
Figura 27. Comparativa producción real (rojo) frente a estimación (negro) con modelos cruzados: (a) julio 2009; (b) octubre 2011.....	102
Figura 28. Análisis temporal de la ratio producción estimada / real.....	104
Figura 29. Escenario de detección de fallo (real: roja discontinua).....	105
Figura 30. Lógica de decisión para la selección del modelo	134
Figura 31. Arquitectura red neuronal Caso A).....	137
Figura 32. Predicciones red neuronal caso A)	139
Figura 33. Comparación producción real frente a predicción	140
Figura 34. Comparación producción real frente a predicción en otras plantas de Zamora y Toledo.....	142
Figura 35. Predicciones red neuronal caso B.....	149
Figura 36. Planta termosolar La Africana Energía	170



PARTE I

1 INTRODUCCIÓN

El uso de la tecnología solar fotovoltaica se ha incrementado en la última década debido a la caída de los costes de producción, la concienciación por el desarrollo sostenible y los incentivos facilitados por numerosos países, entre ellos España [1-3].

A pesar de la citada disminución de los costes de la tecnología [4], la explotación de instalaciones de este tipo sigue requiriendo de algún tipo de incentivación para que el caso de negocio sea viable. De hecho, los cambios regulatorios acaecidos a este respecto [5] han afectado seriamente la rentabilidad de parques solares fotovoltaicos ya en operación.

Si el lado de los ingresos de las explotaciones se ha visto reducido por las modificaciones producidas en el ámbito regulatorio, la única variable disponible sobre la que actuar para conseguir rentabilizar las inversiones es el gasto de mantenimiento, por lo que la optimización de la gestión del mantenimiento de este tipo de instalaciones, generalmente desatendidas, es un elemento crucial para su rentabilidad y la viabilidad económica de las inversiones efectuadas.

La incorporación de la gestión del mantenimiento en el esquema general de la organización se viene produciendo de forma continua desde hace cuatro décadas [6]. Desarrollar un modelo para la gestión del mantenimiento eficiente, embebido en el sistema de información de la gestión de la organización, se ha convertido en un

tópico de investigación y un aspecto fundamental para alcanzar los objetivos organizacionales [7].

Esta tesis doctoral tiene como objetivo principal establecer un marco de trabajo para el desarrollo de algoritmos aplicables al mantenimiento predictivo de diferentes modos de fallo de los componentes que conforman un parque solar fotovoltaico, dentro del alcance de un sistema de gestión del mantenimiento.

La metodología parte del análisis de series temporales asociadas a las condiciones ambientales y de operación del proceso, el estudio de los posibles modos de fallo relacionados con dichos factores y la evaluación del impacto en la degradación de la función de utilidad del sistema.

Los algoritmos generados se integran en el sistema de información de la planta conforme a un marco de referencia para la gestión del mantenimiento (MGM) basado en estándares industriales y de comunicaciones, especialmente en la especificación de la gestión de activos ISO 55000:2014 [8], en el estándar de gestión de la calidad ISO 9001:2008 [9] y el estándar abierto de intercambio de información OpenO&M [10].

1.1 MOTIVACIÓN DEL TRABAJO DE INVESTIGACIÓN

El autor de la tesis desarrolla su carrera profesional en el grupo empresarial Magtel [11], entre cuyas líneas de negocio se encuentra la promoción de parques de generación de energía eléctrica mediante

diferentes fuentes renovables (fotovoltaica, termosolar, eólica y biomasa).

En el año 2008 comenzó la explotación de varios parques solares fotovoltaicos promovidos por la empresa, entre los que destacan las plantas denominadas “El Molino”, de 6.1 MWp con seguidores solares a 2 ejes, y “La Castilleja”, de 10 MWp con estructura fija, así como numerosas cubiertas con un máximo de 20 KWp.

Estas plantas disponían de un incentivo a la generación eléctrica consistente en la garantía de la comercialización de la producción completa con un precio igual a 5 veces el precio de referencia del mercado eléctrico. Sin embargo, en los últimos años se han establecido dentro del marco jurídico español tanto restricciones a la producción, como una reducción del precio de compra garantizado.

Ambas medidas impactan de forma considerable a los ingresos previstos en el plan de negocio original de los inversores, por lo que se torna especialmente importante optimizar el capítulo de gastos de explotación de la planta para paliar en la medida de lo posible este efecto adverso en la rentabilidad.

La línea de investigación seleccionada por el autor dentro de sus estudios de doctorado está centrada el análisis, modelado y simulación de sistemas, por lo que la citada problemática constituía un bonito reto tanto académico como profesional.

1.2 OBJETIVOS DE LA INVESTIGACIÓN

Se establecieron los siguientes objetivos para el trabajo de investigación:

- **O1.** Diseño de un sistema de supervisión, control y adquisición de datos para la explotación de los parques solares fotovoltaicos adaptado a los requerimientos de la línea de investigación (capítulo 4)
- **O2.** Modelado de la producción de un sistema de generación solar fotovoltaico conectado a red (capítulos 4, 5, 6)
- **O3.** Detección de errores de configuración en elementos activos de parques solares fotovoltaicos en explotación (capítulo 4)
- **O4.** Detección de fallos no asociados directamente a alarmas generadas por los propios equipos (capítulos 4, 5, 6)
- **O5.** Identificación de modos de fallo susceptibles de ser tratados mediante un mantenimiento predictivo, así como su detección (capítulo 6).

1.3 BIBLIOGRAFÍA

- [1] REN21. "Renewables Global Status Report,"
<http://www.ren21.net/AboutREN21.aspx>.

- [2] APPA. "Asociación de Empresas de Energías Renovables," <http://www.appa.es/09fotovoltaica/09situacion.php>.
- [3] I. E. Agency, Renewables Information 2014, 2014.
- [4] I. E. Agency, "Technology Roadmap: Solar Photovoltaic Energy - 2014 edition," 2014.
- [5] REAL DECRETO 1578/2008, 2008.
- [6] L. M. Pintelon, and L. Gelders, "Maintenance management decision making," *European Journal of Operational Research*, vol. 58, no. 3, pp. 301-317, 1992.
- [7] S. Vanneste, and L. Van Wassenhove, "An integrated and structured approach to improve maintenance," *European Journal of Operational Research*, vol. 82, no. 2, pp. 241-257, 1995.
- [8] ISO. "ISO 55000:2014 Asset management -- Overview, principles and terminology," http://www.iso.org/iso/catalogue_detail?csnumber=55088.
- [9] ISO. "ISO 9000:2008 Quality management," http://www.iso.org/iso/iso_9000.
- [10] OpenO&M. "OpenO&M," <http://www.openoandm.org>.
- [11] Magtel. "Grupo Magtel," <http://www.magtel.es>.

2 METODOLOGÍA

Esta tesis doctoral es el resultado tanto de un desarrollo teórico como práctico, llevados a cabo ambos según lo descrito en un programa de trabajo, haciendo uso siempre de varias fuentes de investigación que respaldan los avances. En este sentido, las publicaciones desarrolladas a la par, han tenido la función de servir como hoja de ruta y de validación de cada etapa de la investigación.

Es importante mencionar que además de las tradicionales fuentes bibliográficas, se ha contado con el apoyo del conocimiento de los integrantes de los departamentos de Informática y Análisis Numérico de la Universidad de Córdoba y de Organización Industrial y Gestión de Empresas de la Universidad de Sevilla. Estos grupos, al ser integrados por profesionales de distintas especialidades, han conformado un elemento clave para el desarrollo de este trabajo de investigación.

A continuación se relacionan las principales fuentes de investigación utilizadas en el presente trabajo:

- Fuentes bibliográficas
- Bases de datos y revistas electrónicas
- Entrevistas con expertos tanto del área académica como empresarial
- Asistencia a congresos y eventos especializados

- Intercambio de información con doctorandos de otras universidades trabajando en temas relacionados
- Asistencia a cursos de capacitación sobre temas específicos
- Consulta de información a proveedores de diversos productos
- Retroalimentación por parte de revisores de revistas científicas
- Realización de pruebas (software)
- Análisis crítico, comparativo y propositivo

El proceso seguido para el desarrollo de la tesis ha constado, como se comentó anteriormente, de dos partes: una primera parte teórica que involucra el estado del arte de las metodologías, conceptos y disciplinas relacionadas con el proyecto, y una segunda parte, de naturaleza más práctica, donde se desarrollan los diferentes algoritmos y modelos para estimar la producción de una planta solar fotovoltaica y detectar, así como pronosticar la aparición de fallos en las instalaciones y equipos.

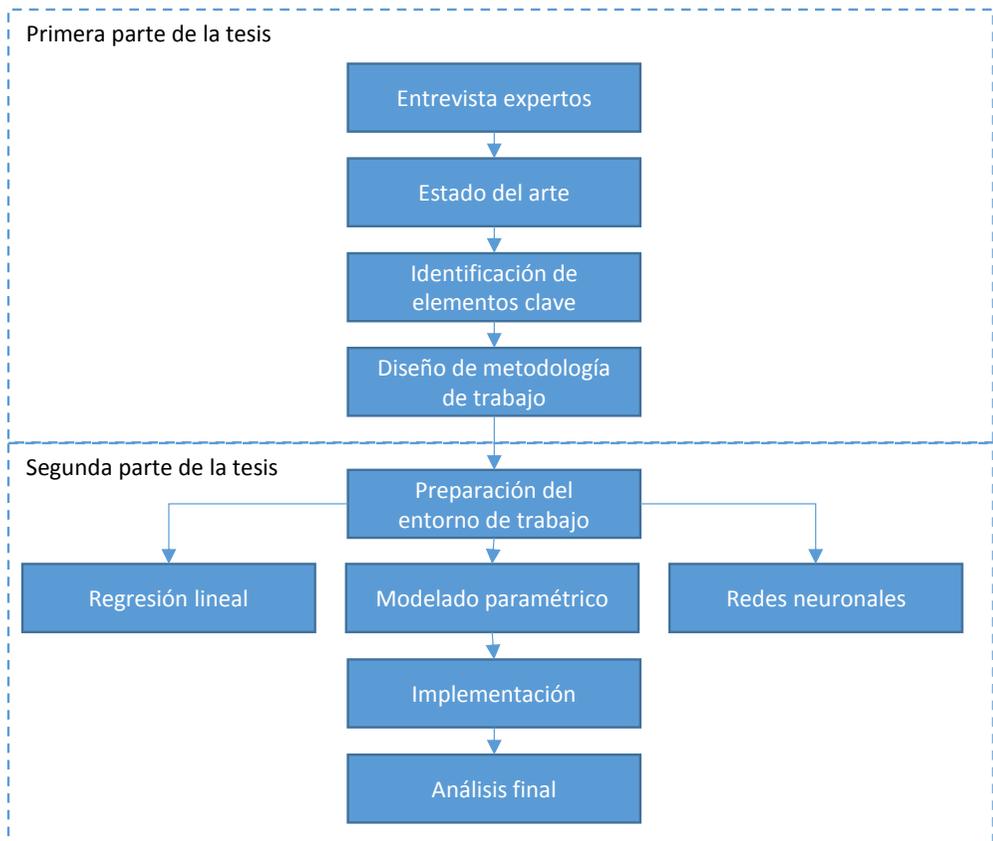


Figura 1. Metodología de trabajo

3 ANTECEDENTES Y FUNDAMENTOS TEÓRICOS

En este capítulo se introducen la metodología, antecedentes, teoría y herramientas que se han considerado para la realización de este trabajo de investigación. Concretamente, se tratan los siguientes puntos:

- Energía solar fotovoltaica
- Procesos de mantenimiento
- Sistemas Multiagente
- Maximum Likelihood Estimation
- Redes neuronales

En primer lugar se presenta de forma breve el escenario actual de generación de energía eléctrica mediante la tecnología solar fotovoltaica, así como los antecedentes y estado del arte en el modelado de la predicción y detección de fallos en el ámbito de la energía solar fotovoltaica.

A continuación se describen las mejores prácticas en lo que respecta a la gestión del mantenimiento, disciplina que permite la extensión de la vida útil de los equipos de producción y la optimización del coste del ciclo de vida de los mismos.

Seguidamente, se exponen los principales conceptos de los sistemas multiagente, que ha sido la arquitectura seleccionada para la

mejora del entorno de trabajo donde se desarrolla esta línea de investigación.

Finalmente, se presentan los fundamentos teóricos de las técnicas seleccionadas para el modelado de la producción y la detección de fallos en las plantas solares fotovoltaicas.

3.1 ENERGÍA SOLAR FOTOVOLTAICA

La generación de electricidad mediante fuentes renovables ha experimentado un crecimiento sostenido en las últimas dos décadas, motivado por la concienciación global con respecto al cambio climático, por el alto precio de los combustibles fósiles y las iniciativas e incentivos gubernamentales a nivel mundial.

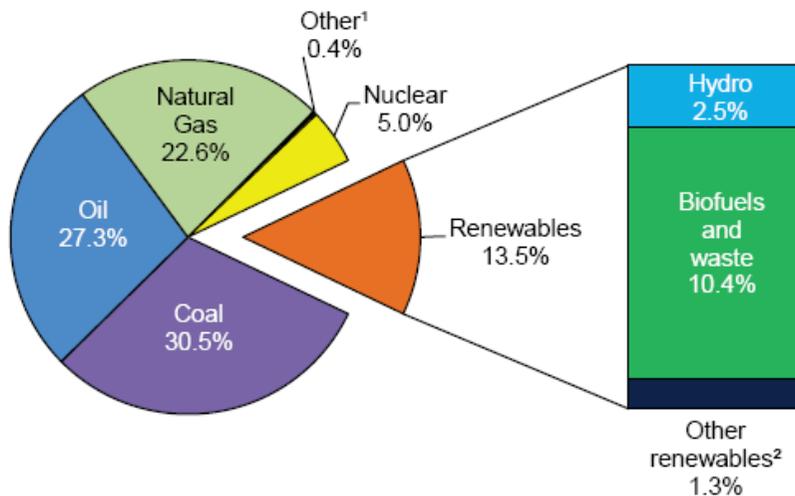


Figura 2. Fuentes de energía primaria 2013 (© IEA)

En 2013, la energía total primaria a nivel mundial (TPES) fue de 13.555 millones de toneladas equivalentes de petróleo (Mtoe), de las cuales 1.829 Mtoe (13,5%), procedieron de fuentes renovables [1] (ver Figura 2). La mayor parte de del uso de las fuentes renovables (73,4%) corresponde a aplicaciones domésticas (calefacción y cocina) de biocombustibles sólidos. La segunda mayor fuente renovable es la energía hidroeléctrica (17,8%). A continuación, la energía geotérmica, los biocombustibles líquidos, la energía solar, la eólica y la mareomotriz comparten la cuota restante (8,8%), como se puede observar en la Figura 3.

Desde el año 1990, el uso de fuentes de energía renovable ha crecido a un ritmo medio anual del 2,2%, que es significativamente mayor que el crecimiento de consumo de energía global en ese mismo periodo (1,9% anual).

Esta contribución se ha debido principalmente a la energía solar fotovoltaica y a la energía eólica, con tasas de crecimiento del 46,6% y 24,8%, respectivamente. No obstante, partían de una base instalada muy pequeña y por tanto su contribución absoluta es aún reducida.

Mientras que aproximadamente la mitad de las fuentes primarias de energías renovables se utilizan en los países de la OECD para la generación de energía eléctrica (ver Figura 5), a nivel mundial este efecto queda enmascarado por el amplio uso de biocombustibles en países en vías de desarrollo (ver Figura 6). Asimismo, dentro de las

fuentes de energía utilizadas en la generación de energía eléctrica, las energías renovables contribuyen con un 21,7% (ver Figura 7).

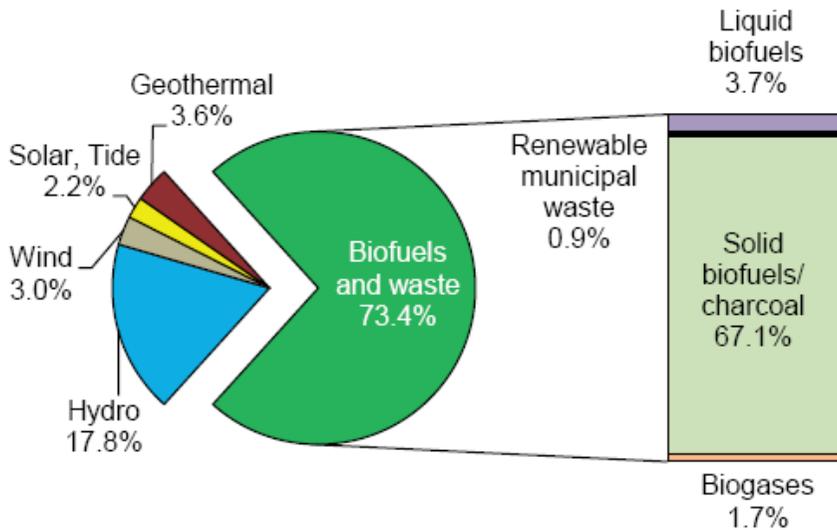


Figura 3. Fuentes de energía primaria 2013 (© IEA)

Según el informe de tendencias en las aplicaciones de la energía solar fotovoltaica de la Agencia Internacional de la Energía [2], en el año 2013, los países miembros de la IEA PVPS instalaron 35 de los 39 GW instalados a nivel global, frente a los 25 GW desplegados en 2012, totalizando a finales del año 2013, 137 GW.

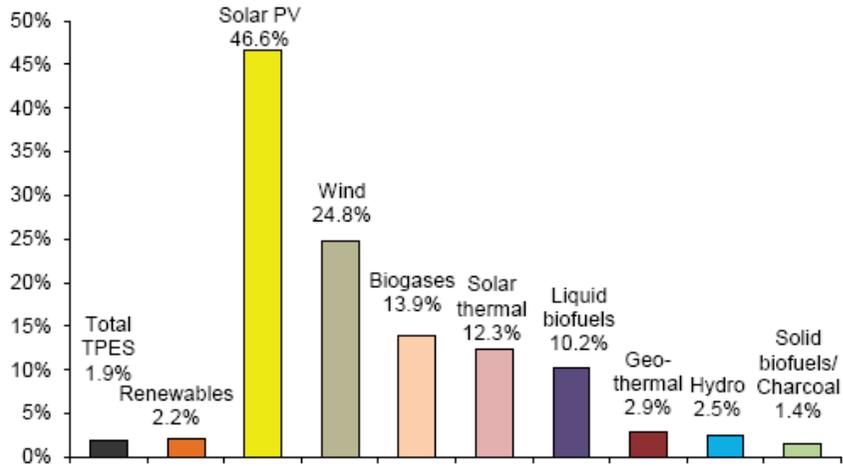


Figura 4. Crecimiento interanual por tecnología renovable (©IEA)

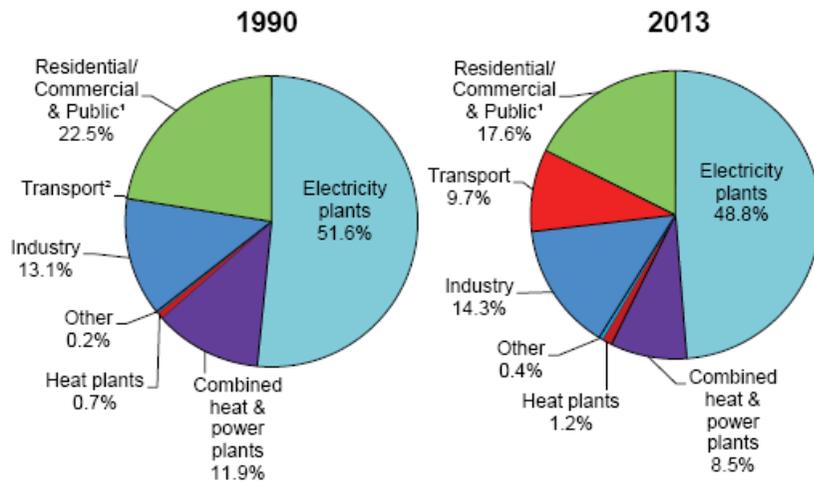


Figura 5. Uso OECD de las fuentes primarias renovables 1990-2013 (©IEA)

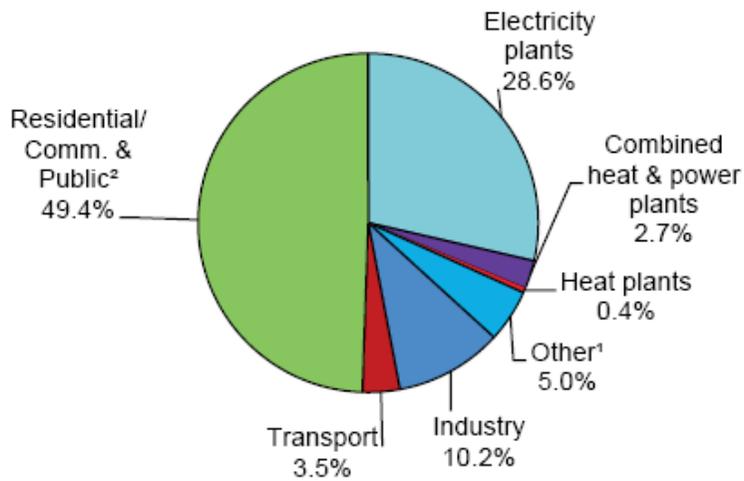


Figura 6. Uso mundial de las fuentes primarias renovables 2013 (©IEA)

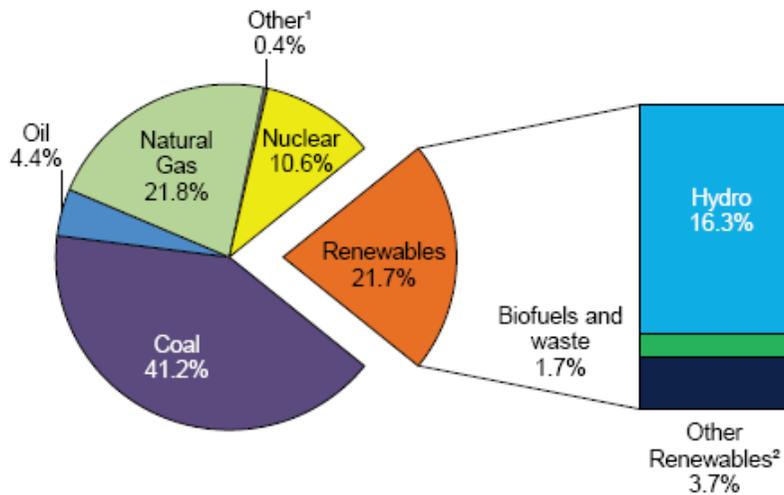


Figura 7. Contribución en la generación de electricidad mundial 2013 (©IEA)

En España, en el año 2014 [3], las energías renovables han mantenido un papel destacado en la producción global de energía del sistema peninsular cubriendo el 42,8 % de la producción total (un 42,2 % en 2013). Dentro de estas energías destaca el importante papel de la generación eólica, con una contribución a la producción anual peninsular del 20,3 % (ver Figura 8), lo que coloca a esta tecnología en el segundo lugar en cuanto a la participación de los distintos tipos de energía en la cobertura de la demanda peninsular, tan sólo detrás de la nuclear.

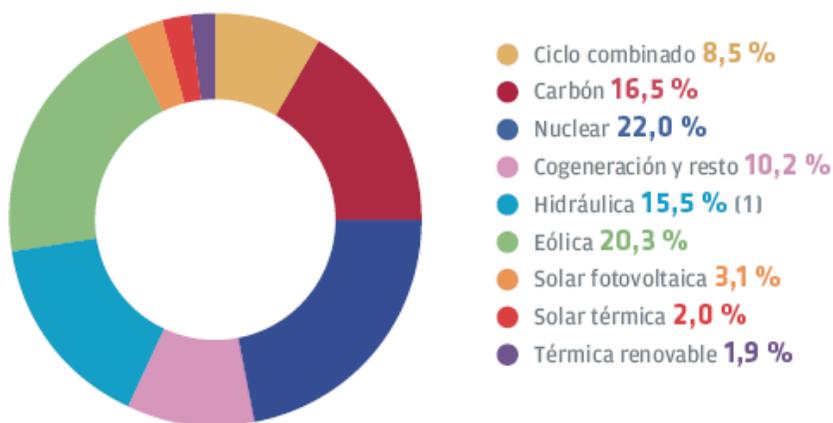


Figura 8. Contribución en la generación de electricidad española 2014 (©REE)

La energía solar fotovoltaica contribuye, sin embargo, al 3,1% de la demanda energética española neta (total de 258.177 GWh), con una potencia instalada que representa el 4,3% del total (102.262 MW).

La energía solar fotovoltaica [4], conjuntamente con la solar termo-eléctrica, tienen el mayor potencial de todas las fuentes renovables, puesto que la energía solar es prácticamente un recurso ilimitado (al menos, a muy largo plazo), y se encuentra disponible en cualquier parte.

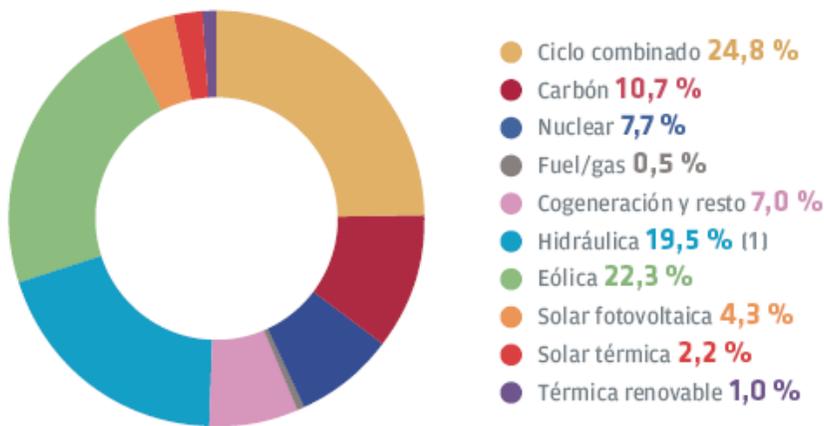


Figura 9. Distribución de la potencia instalada en España, 2014 (©REE)

Sin embargo, a pesar de los avances tecnológicos y los incentivos gubernamentales, el coste de la energía producida por los sistemas fotovoltaicos conectados a red es todavía relativamente alto y no puede competir aún en los mercados eléctricos. Este hecho motiva el desarrollo de nuevas líneas de investigación para optimizar el ciclo de vida completo de este tipo de sistemas, y es precisamente aquí donde se enmarca la presente tesis doctoral.

Desde el tercer siglo antes de Cristo, la humanidad ha sido consciente de la energía solar cuando se empezaron a utilizar lentes de aumento para encender antorchas. El efecto fotovoltaico fue descubierto por el científico francés Edmond Becquerel en 1839, pero sólo pudo ser explicado por Albert Einstein en 1905 [5], lo que le supuso la consecución del premio Nobel en 1921. A partir de ahí, fue en 1954 cuando varios científicos en los laboratorios Bell desarrollaron la primer célula fotovoltaica.

El primer uso de la energía solar fotovoltaica fue en aplicaciones espaciales para dotar de energía a los satélites artificiales. Las aplicaciones terrestres no se desarrollaron, sin embargo hasta la década de los 70.

Actualmente la energía solar fotovoltaica está presente en numerosas aplicaciones de consumo (calculadoras y otros dispositivos electrónicos) en el rango de los mW, para uso doméstico (KW) e incluso en plantas solares con potencias instaladas del orden de decenas de MWp.

La mayor parte (90%) de las células fotovoltaicas se fabrican a partir de obleas de silicio monocristalino, aunque también se fabrican con tecnología policristalina y de capa fina.

Las tecnologías de concentración tratan de reducir la cantidad de semiconductor necesario, empleando células de reducido tamaño y lentes fabricadas con polímeros de bajo coste para concentrar la radiación solar, por lo que se requiere el uso de sistemas de

seguimiento solar, haciéndolas por tanto adecuadas en plantas de medio o gran tamaño (MW) donde la componente directa de la radiación solar sea importante.

Las aplicaciones terrestres de la energía solar fotovoltaica se pueden clasificar en seis áreas [2]:

- Sistemas pico fotovoltaicos
- Sistemas aislados residenciales
- Sistemas aislados no residenciales
- Sistemas híbridos
- Sistemas conectados a red distribuidos
- Sistemas conectados a red centralizados

Los sistemas pico fotovoltaicos han experimentado un desarrollo significativo en los últimos años, combinando el uso de fuentes de luz muy eficientes conjuntamente con complejos controladores de carga y baterías. Con un pequeño panel fotovoltaico con una capacidad de generación de varios vatios es posible proporcionar servicios como iluminación, carga de dispositivos móviles, y alimentación a radios y pequeños ordenadores. Actualmente se comercializan kits escalables de este tipo utilizados en aplicaciones no conectadas a la red eléctrica, principalmente en países en vías de desarrollo.

Los sistemas aislados residenciales proporcionan energía eléctrica a unidades domiciliarias que no se encuentran conectadas a la red eléctrica. En este tipo de sistemas son típicas las potencias pico

de 5 KW y suponen una alternativa económica a la extensión de la red de distribución eléctrica en distancias superiores a los 2 Km desde los centros existentes.

Por otro lado, los sistemas aislados no residenciales fueron la primera aplicación comercial de la energía fotovoltaica en el ámbito terrestre. Proporcionan energía para un amplio rango de aplicaciones como el bombeo de agua, las comunicaciones y las ayudas a la navegación. El coste de la energía fotovoltaica en estas aplicaciones es muy competitiva frente a otras alternativas debido a que con consumos muy pequeños se proporciona un gran valor.

En el caso de los sistemas híbridos se combinan las ventajas de un sistema fotovoltaico con un generador diésel. De esta forma se permite optimizar el coste de la energía y ofrecer un servicio en alta disponibilidad. Este tipo de sistemas se está desplegando especialmente en el ámbito de las telecomunicaciones y para el consumo en pequeños municipios rurales.

Los sistemas conectados a red se despliegan para proporcionar energía adicional a un cliente conectado a la red eléctrica e incluso, si es el caso, inyectar el exceso de la energía generada a red. En este tipo de aplicaciones se pueden encontrar sistemas de hasta 1 MW.

Finalmente, con respecto a los sistemas conectados a red centralizados, su función es la generación de energía para inyectar a la red eléctrica.

Presentadas las principales magnitudes e indicadores de la energía solar fotovoltaica y justificada su importante contribución al sector de la energía, se resume el estado del arte en el modelado de la predicción, así como en la detección de fallos en sistemas fotovoltaicos.

Aunque se han desarrollado modelos físicos para los diferentes componentes de una instalación solar fotovoltaica, naturaleza aleatoria de las condiciones climatológicas y de operación hace que una caracterización práctica de los mismos sea muy compleja. No es posible obtener analíticamente una función de transferencia para una predicción ajustada de la producción. Es más, considerar la degradación temporal de los componentes, la deposición de polvo en los módulos y/o el mantenimiento aplicado dificultan aún más esta posibilidad.

Por ese motivo, los investigadores han desarrollado diferentes propuestas para abordar esta problemática [6]. En la referencia [7] se propone un modelo para estimar la producción de energía como una función de la irradiancia y la temperatura ambiente, considerando que los módulos están trabajando en su punto de operación de máxima potencia [8], y unas aproximaciones de las pérdidas del sistema.

La eficiencia de un generador fotovoltaico trabajando en condiciones de máxima potencia se puede caracterizar por un modelo paramétrico de la irradiancia y de la temperatura del dispositivo. Esta

aproximación se basa en los trabajos [9,10] donde se demuestra su aplicación tanto en módulos convencionales como de capa fina.

Otros modelos físicos se basan en el conocido modelo del doble diodo [11], aplicado en diferentes líneas de investigación [12-16]. Este modelo es extendido con la aplicación de una red neuronal de tres capas en [17].

El empleo de sistemas inteligentes en la simulación del comportamiento de los paneles fotovoltaicos se desarrolla en [18,19], empleando redes neuronales [20], lógica difusa [21] e incluso sistemas híbridos [22]. Sin embargo, es difícil obtener un modelo que contemple todos los elementos de una instalación solar fotovoltaica.

En la parte II de esta tesis doctoral, dentro de cada uno de los capítulos, se desarrolla de forma más completa el estado del arte de cada una de las líneas de investigación acometidas.

3.2 PROCESO DE MANTENIMIENTO

En los entornos de fuerte competencia en los que desarrolla la actividad empresarial, la complejidad de los activos y la tendencia creciente a minimizar los inventarios han obligado a las organizaciones a optimizar el funcionamiento de los equipos, llenando de retos la operación de todas las funciones empresariales.

Una de las funciones más relevantes, puesto que de ella depende en gran medida el funcionamiento continuo de los activos de la organización, es la función de mantenimiento. Según AENOR [23] esta función puede definirse como la combinación de todas las acciones técnicas, administrativas y de gestión a lo largo del ciclo de vida de un elemento, destinadas a conservarlo o devolverlo a un estado en el cual pueda desarrollar la función requerida.

De esta forma, el mantenimiento se ha convertido en un factor clave en la productividad y competitividad de una empresa [24]. Una vez reconocido el valor del mantenimiento, se han seguido diferentes estrategias con el paso del tiempo para optimizar el resultado de su aplicación: desde la reparación de los fallos en los activos por parte de los propios operadores en un entorno donde los únicos indicadores registrados eran la contabilización de las averías, hasta el empleo de las tecnologías de la información y las comunicaciones (e-maintenance).

En esta evolución por la optimización del mantenimiento, con independencia de las teorías, conceptos, técnicas y metodologías

empleadas, prima la gestión del mantenimiento. Sobre esta base han surgido numerosos marcos o modelos que tratan de englobar las mejores prácticas de gestión y operación del mantenimiento con varios objetivos que van desde la optimización general de las operaciones, el desarrollo de un sistema de documentación y organización de las actividades, la creación de un sistema informático o de un sistema de evaluación, o una combinación de estos factores.

Para desarrollar una correcta gestión del mantenimiento es fundamental gestionar los activos de forma adecuada. La gestión de activos, como destaca Woodhouse [25], tiene su primera formalización en el estándar británico PAS-55:2008. Este estándar ha evolucionado y se ha convertido en un estándar internacional: ISO 55.000-2014 [26].

La gestión del mantenimiento, como proceso dentro de la organización, puede ser especificada con el uso de los lenguajes gráficos especializados para el modelado de procesos y sistemas: SysML [27], BPMN [28] y UML [29], reconocidos internacionalmente por el OMG (Object Management Group). Conviene destacar que a partir de las especificaciones realizadas en este tipo de lenguajes gráficos es posible generar de forma automática aplicaciones informáticas que automaticen el proceso.

Actualmente, no se concibe el proceso de mantenimiento sin el apoyo de las tecnologías de la información y de las comunicaciones y de los estándares de gestión de la calidad. En el apartado 3.2.1 se presentan los principales estándares de referencia en procesos,

calidad y tecnologías de la información aplicables a la gestión del mantenimiento.

A continuación, en el apartado 3.2.2 se relacionan los principales marcos de referencia para la gestión del mantenimiento. Finalmente, en el apartado 3.2.3 se describe la metodología RCM (Reliability Centered Maintenance), utilizada en esta tesis doctoral para analizar los modos de fallo de la planta solar fotovoltaica.

3.2.1 Estándares de Referencia

En la Figura 10 se presentan los estándares de referencia y buenas prácticas en el ámbito de la empresa y de las tecnologías de la información, según Gartner:

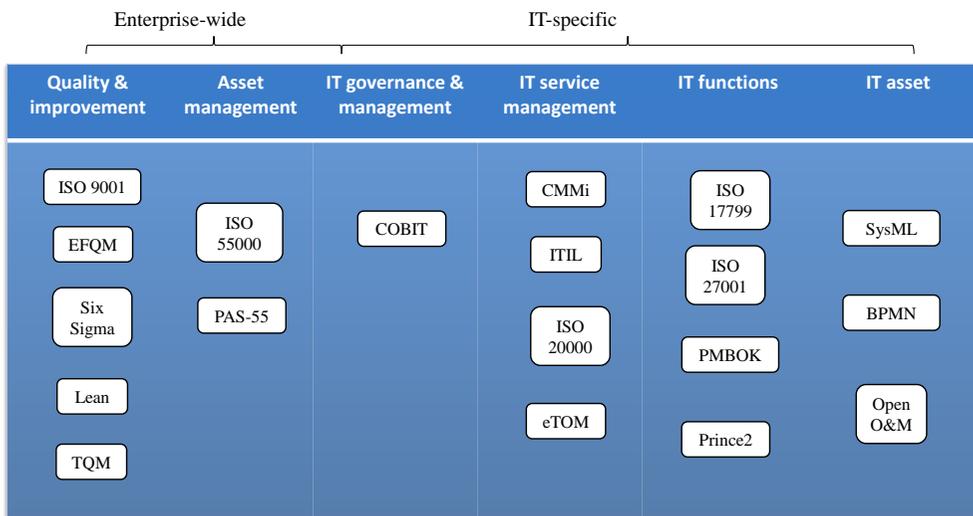


Figura 10. Estándares y Mejores Prácticas Gestión en la Empresa

No obstante, como expone Ishikawa [30], ningún conjunto general de procesos funciona en todo tipo de condiciones, por lo que los estándares no deben ser rígidos, deben cambiar.

Las organizaciones dependen de forma creciente de las tecnologías de la información, y son fuente de ventajas competitivas, aunque siempre evitando que los procesos sean esclavos de los sistemas. De igual forma debe suceder con los estándares de gestión [31]: los sistemas de información deben estar alineados con los objetivos del negocio para mejorar la productividad.

La metodología de trabajo seguida en esta tesis doctoral se apoyará en los estándares de referencia en gestión para los procesos de mantenimiento, y en los estándares de las tecnologías de la información en su implementación.

Comenzamos describiendo lo que se entiende por proceso. Según Davenport [32], un proceso es un conjunto de tareas lógicamente relacionadas que se ejecutan para alcanzar un determinado resultado de negocio. Por otro lado, Pall [33], define un proceso como la organización lógica de personas, materiales, energía, equipos y procedimientos en actividades, diseñada para producir un resultado final especificado. Existe, por tanto, una doble visión de cada proceso, estratégica, por su contribución al resultado del negocio, y una visión operativa.

Nuestro enfoque para la reingeniería del proceso de mantenimiento se centrará en ambas dimensiones, empleando una

metodología de trabajo metódica, integrada y basada en procesos [34], haciendo especial énfasis en alcanzar la calidad del servicio requerida por el cliente [35]. Por tanto, usaremos una metodología orientada al cliente, procesos, tecnologías y conocimiento, para la entrega de servicios de forma fiable, con la máxima calidad y eficiencia, durante el mayor periodo de disponibilidad posible.

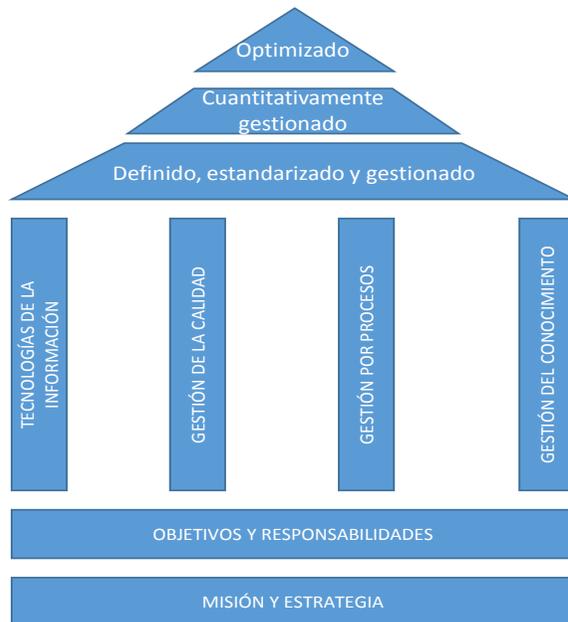


Figura 11. Estructura del marco de gestión

Para ello, tendremos como marco de referencia las mejores prácticas y estándares:

- **ISO 9001** [36]. Se trata de un conjunto de normas para la gestión continua de la calidad.

- **ISO 55000** [26]. Proporciona una introducción a la gestión de activos, sus principios y la terminología, así como los beneficios esperados de la misma.
- **EFQM** [37]. Es el modelo europeo de excelencia de la European Foundation for Quality Management. Se constituyó con el objetivo de mejorar la competitividad global de las empresas europeas.
- **TPM** (Total Productive Maintenance) [38], del Instituto Japonés de Mantenimiento de Planta. Se trata de un programa de mantenimiento centrado en el equipamiento para reducir las faltas de calidad, averías y accidentes, así como aumentar la productividad y motivación.
- **ITIL** (Information Technology Infrastructure Library) [39]. Se trata de las mejores prácticas en la entrega de servicios de tecnologías de la información, desarrolladas originalmente por la Oficina de Comercio del Gobierno Británico y que cada vez más están siendo adoptadas a nivel mundial tanto en el sector público como privado.
- **CMMI** (Capability Maturity Model Integration). Desarrollado por el centro de investigación SEI (Software Engineering Institute) es un marco para la mejora y evaluación del grado de madurez de los procesos de la organización [40].
- **COBIT** (Control Objectives for Information and related Technology) [41], desarrollado por ISACA (Information

Systems Audit and Control Association) e ITGI (IT Governance Institute), se trata de un modelo para la administración de las tecnologías de la información alineado con los objetivos del negocio mediante la especificación de un conjunto de controles generalmente aceptados.

- **Six Sigma** [42]. Promovido por el Six Sigma Research Institute, es un marco de gestión basado en métodos estadísticos focalizado en la mejora de procesos desde un punto de vista predictivo, orientado a la eliminación de las causas que originan los fallos.
- **Lean** [43]. Desarrollado en sus orígenes por Toyota, esta metodología comparte el mismo objetivo que Six Sigma, eliminar ineficiencias, pero sigue una aproximación diferente. Mientras que Six Sigma hace foco en eliminar las potenciales causas de ineficiencias, la metodología Lean contempla que el origen estas ineficiencias está en la ejecución de actividades que no aportan valor al proceso. De hecho, ambos enfoques son compatibles por lo que se ha generado una nueva metodología: Lean-Six Sigma [44].
- **OpenO&M** [45]. Se trata de una iniciativa de múltiples organizaciones pertenecientes a diferentes sectores industriales para proporcionar un conjunto de estándares

para el intercambio de datos generados en los procesos de operación y mantenimiento.

Para el desarrollo de esta línea de investigación se establece un marco de gestión del mantenimiento estructurado, basado en actividades, integrado y con el objetivo de garantizar la calidad del servicio, de forma que facilite la toma de decisiones y encontrar los puntos de mejora más rápida y fácilmente.

3.2.2 Marcos de Referencia

Hasta la fecha, se han desarrollado múltiples marcos para la gestión del mantenimiento [46,47], intentando combinar buenas prácticas para alinear la contribución del mantenimiento a los objetivos del negocio. A continuación se ilustra su evolución histórica [48].

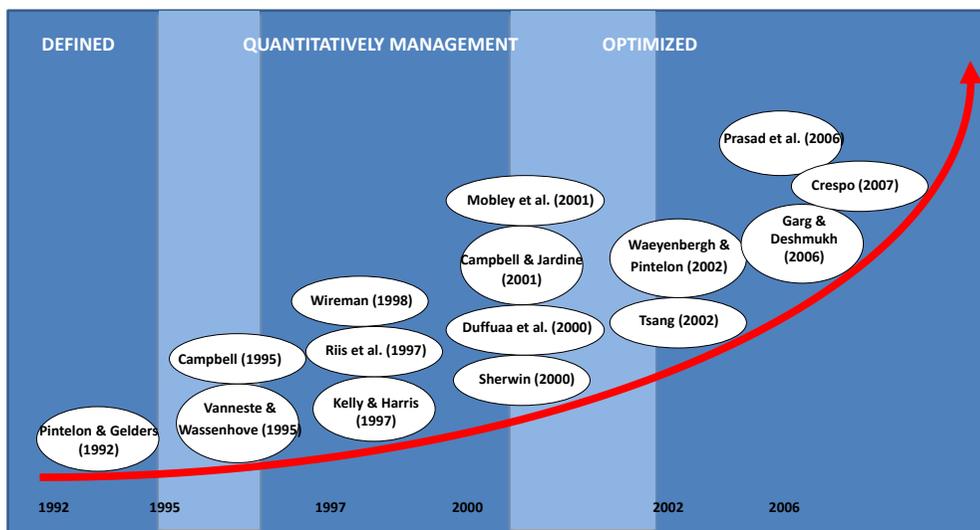


Figura 12. Evolución histórica de marcos de referencia

Los primeros esfuerzos que sirvieron de base a los posteriores autores para desarrollar la gestión del mantenimiento moderna estuvieron enfocados en los aspectos estratégicos y operativos, fueron realizados por Pintelon [49], Vanneste [50] y Wireman [51].

La evolución de los marcos de referencia es paralela a la evolución de los marcos de gestión empresarial. En primer lugar se incorporaron los aspectos de estrategia, incluyendo objetivos, misión, organización y responsabilidades.

A continuación, los técnicos y operativos, incorporando herramientas para la optimización de las funciones del mantenimiento. Así, se pueden considerar tres generaciones en la gestión del mantenimiento correspondientes a la evolución del grado de madurez de la organización (CMMI) y a la aplicación de las tecnologías de la información y de las comunicaciones:

- **Mantenimiento definido.** El proceso de mantenimiento se gestiona, existiendo una planificación y ejecución alineadas con las directrices de la empresa, así como una revisión del mismo. En esta etapa el mantenimiento ya ha sido identificado como un punto clave y se encuentra integrado en la política de procesos de la organización. Se emplean las tecnologías de la información para la automatización y gestión administrativa.

- **Mantenimiento cuantitativamente gestionado.** En esta etapa se extiende el alcance de las tecnologías de la información a los aspectos técnicos-operativos, lo que permite comenzar a realizar análisis estadísticos y revisar el proceso desde un punto de vista cuantitativo.
- **Mantenimiento optimizado.** La gestión del proceso está enfocada a la mejora continua del mismo.

3.2.3 Reliability Centered Maintenance

Como herramienta cuyo uso conviene destacar dentro de esta línea de investigación, se encuentra la técnica RCM (Reliability Centered Maintenance) [52], originaria de la industria aeronáutica, que contribuye a una planificación eficaz del mantenimiento con el objetivo de aumentar la disponibilidad y disminuir los costes de mantenimiento de la planta. Para ello se centra en el análisis de los activos y elementos susceptibles de fallo, lo que aporta los siguientes resultados:

- Mejora la comprensión del funcionamiento de los equipos y sistemas.
- Analiza todas las posibilidades de fallo de un sistema y desarrolla mecanismos que tratan de evitarlos, ya sean producidos por causas intrínsecas al propio equipo o por actos personales.
- Determina una serie de acciones que permiten garantizar una alta disponibilidad de la planta.

El mantenimiento centrado en fiabilidad se basa en el análisis de fallos, tanto aquellos que ya han ocurrido, como los que se están tratando de evitar con determinadas acciones preventivas y aquellos que tienen cierta probabilidad de ocurrir y pueden tener consecuencias graves. Durante ese análisis de fallos debemos contestar a seis preguntas claves:



Figura 13. Principales elementos de análisis para un mantenimiento centrado en la fiabilidad

La metodología en la que se basa RCM, sintetizada en la Figura 14, supone completar una serie de fases para cada uno de los activos, donde se realiza una recopilación previa de datos que incluye una identificación e inventario exhaustivo de todos los elementos lo componen; un estudio detallado del funcionamiento del activo relacionando todas las funciones que desarrolla; la determinación de los fallos funcionales y técnicos; la determinación de los modos de fallo o causas de cada uno de los fallos; el estudio de las consecuencias de cada uno de los modos de fallo; la determinación de las medidas preventivas que eviten o atenúen los efectos del fallo; la agrupación y

clasificación de las medidas identificadas y seleccionadas; y finalmente, la puesta en marcha de las mismas.

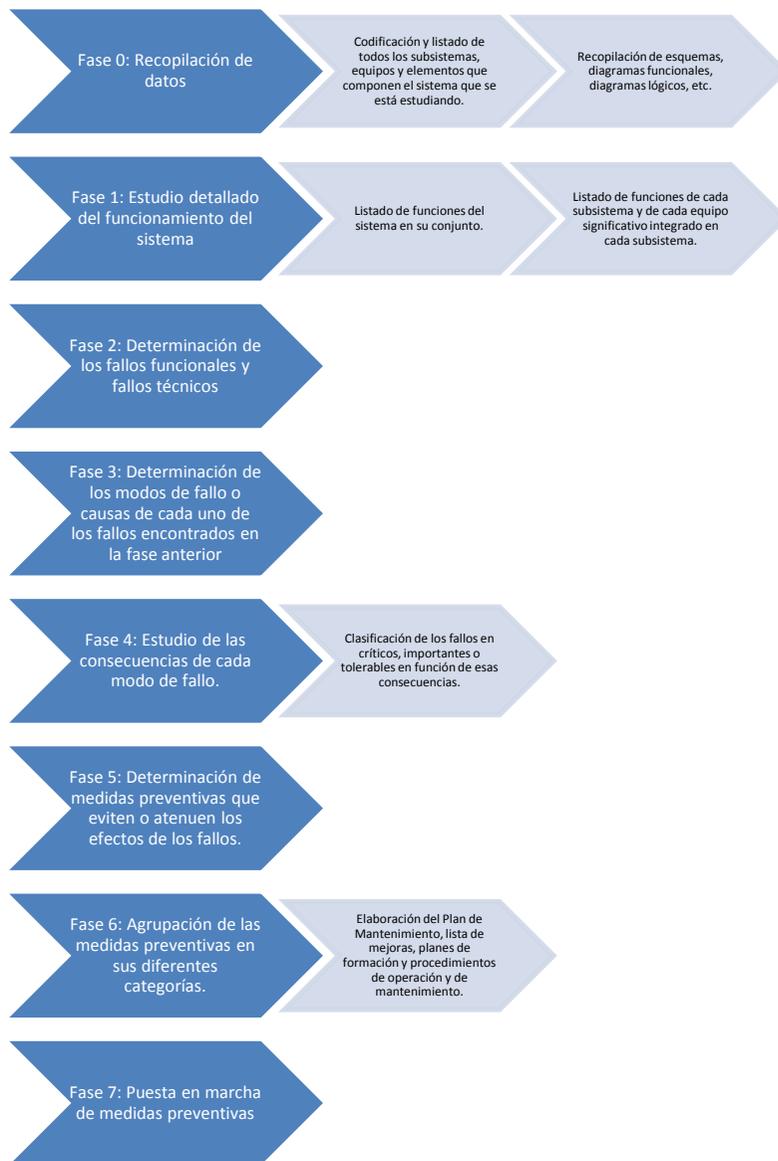


Figura 14. Metodología RCM

3.3 SISTEMAS MULTIAGENTE

Según Woolridge [53], un agente es un sistema informático situado en un entorno donde es capaz de actuar de forma autónoma para alcanzar sus objetivos delegados. Un sistema multiagente está formado por varios agentes que interactúan, cooperan, se coordinan y negocian.

La disciplina de los sistemas multiagente [54] trata del diseño de agentes (nivel micro) y el diseño de la sociedad de agentes (nivel macro). Para ello, se apoya en las siguientes especialidades del conocimiento:

- Ingeniería del software
- Economía
- Ciencias sociales
- Sistemas distribuidos
- Inteligencia artificial

Un agente consta de sensores (percepción del mundo), lógica de deliberación (basada en objetivos y percepciones que conducen a una acción) y actuadores (para producir un efecto en el entorno). Los agentes deben ser tolerantes al fallo porque no tienen un control completo de su entorno, pudiendo estos últimos ser clasificados en:

- Accesibles e inaccesibles, en función de la disponibilidad de la información.
- Estáticos y dinámicos, dependiendo de si son capaces de cambiar sin el control del agente.

- Deterministas y no deterministas, en función de si existe incertidumbre en el efecto de las acciones.
- Episódicos y no-episódicos si la historia pasada afecta a decisiones futuras.
- Discretos y continuos, si existe o no un número finito de acciones / percepciones.

Los principales retos que supone la programación de agentes son el carácter reactivo de los mismos, la toma de decisiones a largo plazo y el que se trata, a menudo, de sistemas de tiempo real.

Los agentes deben ser reactivos, en el sentido de que deben responder en tiempo y forma a sus percepciones del entorno; proactivos, ya que tienen que tomar la iniciativa para alcanzar sus metas; y sociales, puesto que interactúan con otros agentes o seres humanos para este fin. Por tanto, los agentes deben ser flexibles y alcanzar un compromiso entre su reactividad y proactividad.

Los agentes se diferencian de los objetos de un lenguaje orientado a objetos en que los agentes solicitan acciones y pueden rechazar las peticiones, son autónomos y flexibles, y deben estar activos de forma concurrente.

Frente a los sistemas expertos, estos últimos no están situados en un entorno, no presentan comportamientos reactivos/proactivos y no tienen capacidad social.

Para la descripción de agente se usan estados mentales: creencias, deseos e intenciones. Este tipo de especificaciones resulta

de utilidad en sistemas complejos donde se tiene desconocimiento de parte del entorno y no resulta útil si el escenario es simple y permite una descripción funcional sencilla.

La gestión de la complejidad en los sistemas multiagente se consigue mediante un mecanismo de abstracción, en el que intervienen:

- **Conjunto de estados del entorno:** E
- **Conjunto de posibles acciones del agente:** Ac
- **Carreras.** Secuencia de estados del entorno y acciones del agente
- **Función de transformación de estado** fs. Hace corresponder una carrera que finaliza con una determinada acción del agente, con un nuevo estado del entorno, de forma no determinista.
- **Entorno** (E, Estado Inicial, fs)
- **Agente** Ag. Hace corresponder una carrera que finaliza con un determinado estado del entorno, con una determinada acción. El agente puede mantener el estado o ser puramente reactivo.

Para especificar las tareas de los agentes se emplean las funciones de utilidad, que proporcionan un valor a los estados del entorno (utilidad a corto plazo) y/o a las carreras (utilidad a largo plazo). El agente óptimo es aquel que maximiza la utilidad esperada.

A menudo es difícil razonar en términos de utilidad, por lo que se suelen utilizar los denominados predicados de especificación de tareas, que mapean una carrera con un 1 o un 0.

Dos tipos comunes de especificaciones de tareas son el alcanzar uno o varios de los estados objetivos en cada carrera o el mantenerse fuera de otros estados especificados.

La programación de agentes se realiza mediante los lenguajes de programación orientados a agentes [55-60], siguiendo, fundamentalmente, dos estrategias: razonamiento simbólico, donde se trata de deducir de forma lógica una acción a realizar (o que no se pueda deducir el no ejecutar una acción), y razonamiento práctico basado en la acción y no en las creencias.

La incorporación de la tecnología de sistemas multiagente en el entorno de trabajo permite desacoplar las actualizaciones del modelo de predicción de la ejecución de los algoritmos de modelado de la producción y detección de fallos, garantizando la ininterrumpibilidad del servicio en tiempo real.

3.4 MAXIMUM LIKELIHOOD ESTIMATION

Maximum Likelihood Estimation (MLE) [61, 62] es un método para la estimación de los valores de los parámetros de una función de distribución estadística f de una variable aleatoria X que maximizan la probabilidad de obtener una determinada muestra $[x_1, x_2, \dots, x_N]$ de la distribución. Se define a partir de la función de densidad de probabilidad conjunta de una muestra formada por elementos

independientes e igualmente distribuidos, como el producto de las probabilidades condicionales de obtener los componentes de la muestra para un vector de parámetros θ (1).

$$L(\theta; x_1, x_2, \dots, x_N) = f(x_1, x_2, \dots, x_N | \theta) = \prod_{i=1}^N f(x_i | \theta) \quad (1)$$

La función MLE es difícil de manejar debido a que está compuesta de la función densidad de distribución conjunta para todos los datos observados, por lo que para simplificar el cálculo se suele tomar el logaritmo de la misma, obteniendo la función denominada log-likelihood L .

$$\ln L(\theta; x_1, x_2, \dots, x_N) = \sum_{i=1}^N \ln f(x_i | \theta) \quad (2)$$

Cabe destacar que el estimador MLE coincide con el estimador más probable Bayesiano (MAP: Maximum a Posteriori) en el caso de que la distribución a priori de los parámetros sea uniforme, teniendo una serie de propiedades matemáticas muy interesantes en el límite cuando el tamaño de la muestra tiende a infinito:

- **Consistencia.** La secuencia de estimadores converge en probabilidad al valor estimado.
- **Normalidad asintótica.** La distribución de los estimadores tiene a una distribución normal gaussiana con media θ y covarianza igual a la inversa de la matriz de información de Fisher (7).

- **Eficiencia.** Ningún estimador no consistente tiene asintóticamente menor error cuadrático medio.

Como ejemplo, para el caso de una función densidad de probabilidad de tipo Weibull (3), la función log-likelihood L tiene la forma de la expresión (4).

$$f(x) = \frac{\beta}{\eta} \cdot \left(\frac{x}{\eta}\right)^{\beta-1} \cdot e^{-\left(\frac{x}{\eta}\right)^\beta} \quad (3)$$

$$L = \eta^{-n} \cdot \beta \cdot \prod_{i=1}^N \left(\frac{x_i}{\eta}\right)^{\beta-1} \cdot e^{-\left(\frac{x_i}{\eta}\right)^\beta} \quad (4)$$

En este caso es posible resolver de forma analítica los valores de η y β que maximizan la probabilidad de obtener la muestra $[x_1, x_2, \dots, x_N]$.

$$\hat{\eta} = \left(\frac{N}{\sum_{i=1}^N x_i^\beta} \right) \quad (5)$$

$$\hat{\beta} = \frac{N \cdot \sum_{i=1}^N x_i^\beta}{N \cdot \sum_{i=1}^N x_i^\beta \cdot \ln(x_i) - \sum_{i=1}^N x_i^\beta \sum_{i=1}^N \ln(x_i)} \quad (6)$$

Para estimar la bondad del ajuste se puede emplear la matriz de Fisher [45]:

$$\Sigma = \begin{bmatrix} var(\eta) & cov(\eta, \beta) \\ cov(\eta, \beta) & var(\beta) \end{bmatrix} = \begin{bmatrix} -\frac{\partial^2 \ln L}{\partial \alpha^2} & -\frac{\partial^2 \ln L}{\partial \alpha \partial \beta} \\ -\frac{\partial^2 \ln L}{\partial \alpha \partial \beta} & -\frac{\partial^2 \ln L}{\partial \beta^2} \end{bmatrix} \quad (7)$$

En otros casos, sin embargo, hay que utilizar métodos numéricos para la optimización de la función [63,64].

3.5 REDES NEURONALES

Las redes neuronales son un intento del ser humano por desarrollar la llamada inteligencia artificial [65]. El hombre, en su evolución, ha perseguido de forma continua la mejora de su calidad de vida y para ello ha construido máquinas que le ayuden tanto en sus quehaceres diarios como en la realización de cálculos complejos.

Fue en el año 1948 cuando se construyó la primera computadora electrónica, el ENIAC [66]. A partir de ahí el desarrollo ha sido espectacular ya que con el uso de estos equipos se ha entrado en una espiral de innovación. Estos equipos resultan de gran ayuda para el diseño de nuevos productos y la mejora de los existentes.

Sin embargo, las arquitecturas de computación tradicionales no permiten la resolución de problemas relacionados con la capacidad de aprendizaje y razonamiento inteligente del ser humano, como por ejemplo el reconocimiento facial. Este reto da origen a la denominada inteligencia artificial [67].

Una de las líneas de investigación en este campo son las redes neuronales que constituyen un modelo matemático que pretende reproducir el comportamiento del elemento más simple de nuestro cerebro: la neurona. El procesamiento de la información se realiza a través de transmisores electroquímicos entre neuronas, en las denominadas sinapsis. El modelo matemático de las redes neuronales se desarrolla en la parte II de esta tesis doctoral.

Existe un consenso amplio en la comunidad científica en que en 1943, McCulloch y Pitts [68] dieron a conocer las bases de la computación neuronal, aunque las primeras teorías respecto al pensamiento y a la inteligencia del ser humano proceden de filósofos como Platón (siglo V a.C) y Aristóteles (siglo IV a.C). Sus ideas fueron desarrolladas por Descartes (siglo XVI) y diversos filósofos empiristas del siglo XVIII.

El trabajo de McCulloch y Pitts supuso la base para el desarrollo de los ordenadores digitales, la inteligencia artificial [69] y los perceptrones [70].

En 1949 Hebb [71] trató de explicar los procesos de aprendizaje del ser humano, estableciendo una relación entre aprendizaje y red neuronal y sentando las bases de la teoría de las redes neuronales. Posteriormente, en 1950, Lashley [72] confirmó la propagación de la información a través del sistema nervioso.

Rosenblatt [70] concibió en 1957 el denominado perceptrón, de amplia aplicación posterior en el reconocimiento de patrones. Sin embargo la primera red neuronal empleada en la resolución de un problema (eliminación del eco en líneas telefónicas) fue la red Adaline [73] de Widrow y Hoff, en 1960.

El concepto de memoria asociativa fue concebido por Steinbeck en 1961, y en 1967 Grossberg desarrolló la denominada red avalancha para el reconocimiento entre otros, de patrones del habla.

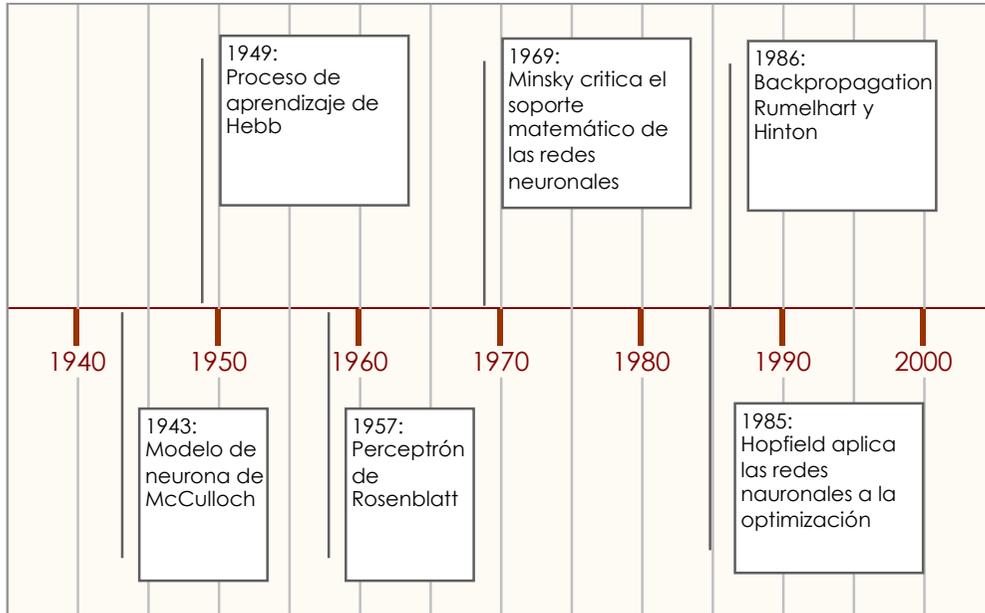


Figura 15. Hitos en la evolución de las redes neuronales

A pesar de todos estos avances, no existía aún una base matemática para el soporte de las redes neuronales, por lo que surgieron numerosas críticas a su uso, entre ellas, la de Minsky [74], y se produjo un estancamiento de su estudio hasta los años 80.

No obstante, contribuyeron al relanzamiento del uso de las redes neuronales los trabajos de Anderson [75] con su asociador lineal y BSB (Brain State in Box), el algoritmo de propagación de errores hacia atrás y la teoría de la resonancia adaptada que distingue entre memoria a corto y a largo plazo en el modelo [76].

En 1980 Fukushima [77] desarrolló una red neuronal para el reconocimiento de patrones visuales y Hopfield [78], en 1985, destacó el uso de la computación neuronal en problemas de optimización.

El algoritmo de aprendizaje más conocido, backpropagation, fue desarrollado por Rumelhart y Hinton [79] en 1986 y permite el entrenamiento de redes neuronales con patrones (experiencia) y es utilizado para el cálculo de modelos predictivos [80]. La descripción completa de este algoritmo, así como una exposición de las aplicaciones de las redes neuronales y otras técnicas de inteligencia artificial a las energías renovables se realiza en la parte II de esta tesis doctoral.

3.6 BIBLIOGRAFÍA

- [1] I. E. Agency, "Renewables Information 2015," International Energy Agency 2015.
- [2] I. I. E. Agency, "Trends 2014 in Photovoltaic Applications," IEA International Energy Agency 2014.
- [3] R. E. d. España, "El Sistema Eléctrico Español 2014," Red Eléctrica de España 2015.
- [4] E. E. P. I. Association, "Global Market Outlook For Photovoltaics 2014-2018," EPIA European Photovoltaic Industry Association 2014.

- [5] A. Einstein, "On a heuristic point of view about the creation and conversion of light," *Annalen der Physik*, vol. 17, pp. 132-148, 1905.
- [6] A. Orioli, and A. Di Gangi, "A procedure to calculate the five-parameter model of crystalline silicon photovoltaic modules on the basis of the tabular performance data," *Applied Energy*, vol. 102, no. 0, pp. 1160-1177, 2013.
- [7] A. Drews et al., "Monitoring and remote failure detection of grid-connected PV systems based on satellite observations," *Solar Energy*, vol. 81, no. 4, pp. 548-564, 2007.
- [8] J. M. Blanes et al., "In-Site Real-Time Photovoltaic I-V Curves and Maximum Power Point Estimator," *Power Electronics, IEEE Transactions on*, vol. 28, no. 3, pp. 1234-1240, 2013.
- [9] J. F. Randall, and J. Jacot, "Is AM1.5 applicable in practice? Modelling eight photovoltaic materials with respect to light intensity and two spectra," *Renewable Energy*, vol. 28, no. 12, pp. 1851-1864, 2003.
- [10] S. R. Williams et al., "Modelling long-term module performance based on realistic reporting conditions with consideration to spectral effects," in *Photovoltaic Energy Conversion*, 2003. *Proceedings of 3rd World Conference on*, 2003, pp. 1908-1911 Vol.2.
- [11] I. Caluianu et al., "Photovoltaic energy generation under partially shading conditions," in *Advanced Electromechanical Motion*

- Systems & Electric Drives Joint Symposium, 2009. ELECTROMOTION 2009. 8th International Symposium on, 2009, pp. 1-6.
- [12] K. F. Teng, and P. Wu, "PV module characterization using Q-R decomposition based on the least square method," *Industrial Electronics, IEEE Transactions on*, vol. 36, no. 1, pp. 71-75, 1989.
- [13] K. Araki, and M. Yamaguchi, "Novel equivalent circuit model and statistical analysis in parameters identification," *Solar Energy Materials and Solar Cells*, vol. 75, no. 3-4, pp. 457-466, 2003.
- [14] J. Merten et al., "Improved equivalent circuit and analytical model for amorphous silicon solar cells and modules," *Electron Devices, IEEE Transactions on*, vol. 45, no. 2, pp. 423-429, 1998.
- [15] J. Merten et al., "The role of the buffer layer in the light of a new equivalent circuit for amorphous silicon solar cells," *Solar Energy Materials and Solar Cells*, vol. 57, no. 2, pp. 153-165, 1999.
- [16] T. Ikegami et al., "Estimation of equivalent circuit parameters of PV module and its application to optimal operation of PV system," *Solar Energy Materials and Solar Cells*, vol. 67, no. 1-4, pp. 389-395, 2001.
- [17] E. Karatepe, M. Boztepe, and M. Çolak, "Development of a suitable model for characterizing photovoltaic arrays with

- shaded solar cells,” *Solar Energy*, vol. 81, no. 8, pp. 977-992, 2007.
- [18] S. K. H. Chow, E. W. M. Lee, and D. H. W. Li, “Short-term prediction of photovoltaic energy generation by intelligent approach,” *Energy and Buildings*, vol. 55, no. 0, pp. 660-667, 2012.
- [19] G. Capizzi, C. Napoli, and F. Bonanno, “Innovative Second-Generation Wavelets Construction With Recurrent Neural Networks for Solar Radiation Forecasting,” *Neural Networks and Learning Systems, IEEE Transactions on*, vol. 23, no. 11, pp. 1805-1815, 2012.
- [20] A. Al-Amoudi, and L. Zhang, “Application of radial basis function networks for solar-array modelling and maximum power-point prediction,” *Generation, Transmission and Distribution, IEEE Proceedings-*, vol. 147, no. 5, pp. 310-316, 2000.
- [21] M. T. Elhagry et al., “Fuzzy modeling of photovoltaic panel equivalent circuit,” in *Circuits and Systems, 1997. Proceedings of the 40th Midwest Symposium on*, 1997, pp. 60-63 vol.1.
- [22] M. AbdulHadi, A. M. Al-Ibrahim, and G. S. Virk, “Neuro-fuzzy-based solar cell model,” *Energy Conversion, IEEE Transactions on*, vol. 19, no. 3, pp. 619-624, 2004.
- [23] N. EN-UNE, "13306. 2002," *Mantenimiento–Terminología del mantenimiento*.

- [24] M. L. Campos and A. C. Márquez, "UN MODELO DE REFERENCIA PARA LA GESTIÓN DEL MANTENIMIENTO."
- [25] J. Woodhouse, "PAS 55: specification for the optimized management of physical infrastructure assets," The Institute of Asset Management, Bristol, UK, 2004.
- [26] ISO. (2014). ISO 55000:2014 Asset management -- Overview, principles and terminology. Available: http://www.iso.org/iso/catalogue_detail?csnumber=55088
- [27] S. Friedenthal, A. Moore, and R. Steiner. (2011). A practical guide to SysML the systems modeling language ([2nd ed.]). Available:<http://www.sciencedirect.com/science/book/9780123852069>
- [28] S. A. White, "Introduction to BPMN," IBM Cooperation, vol. 2, p. 0, 2004.
- [29] J. Rumbaugh, I. Jacobson, and G. Booch, Unified Modeling Language Reference Manual, The: Pearson Higher Education, 2004.
- [30] K. Ishikawa and D. J. Lu, What is total quality control?: the Japanese way vol. 215: Prentice-Hall Englewood Cliffs, NJ, 1985.

- [31] T. J. Peters, R. H. Waterman, and I. Jones, "In search of excellence: Lessons from America's best-run companies," 1982.
- [32] T. H. Davenport and J. E. Short, "Information technology and business process redesign," *Operations management: critical perspectives on business and management*, vol. 1, p. 97, 2003.
- [33] G. A. Pall, *Quality Management: Prentice Hall PTR*, 1987.
- [34] V. D. Hunt, *Process mapping: how to reengineer your business processes: John Wiley & Sons*, 1996.
- [35] M. M. Klein, "The most fatal reengineering mistakes," *Information Strategy*, vol. 10, pp. 21-28, 1994.
- [36] ISO. (2008). *ISO 9000:2008 Quality management*. Available: http://www.iso.org/iso/iso_9000
- [37] EFQM, "The EFQM excellence model," ed: EFQM Brussels, 1999.
- [38] N. Seiichi, "Introduccion al TPM (Mantenimiento Productivo Total)," ed: Productivity Press, 1992.
- [39] A. Hochstein, R. Zarnekow, and W. Brenner, "ITIL as common practice reference model for IT service management: formal assessment and implications for practice," in *e-Technology, e-Commerce and e-Service, 2005. EEE'05. Proceedings. The 2005 IEEE International Conference on*, 2005, pp. 704-710.

- [40] M. C. Paulk, B. Curtis, M. B. Chrissis, and C. V. Weber, "Capability maturity model, version 1.1," *Software, IEEE*, vol. 10, pp. 18-27, 1993.
- [41] G. Ridley, J. Young, and P. Carroll, "COBIT and its Utilization: A framework from the literature," in *System Sciences, 2004. Proceedings of the 37th Annual Hawaii International Conference on*, 2004, p. 8 pp.
- [42] P. Pande, R. Neuman, and R. R. Cavanagh, *The six sigma way: How GE, Motorola, and other top companies are honing their performance: McGraw Hill Professional*, 2000.
- [43] J. P. Womack and D. T. Jones, "From lean production to lean enterprise," *Harvard business review*, vol. 72, pp. 93-103, 1994.
- [44] M. L. George and M. George, *Lean six sigma for service: McGraw-Hill New York, NY*, 2003.
- [45] OpenO&M. (2015). OpenO&M. Available: <http://www.openoandm.org>
- [46] J. Fernandez and A. Marquez, "Framework for implementation of maintenance management in distribution network service providers," *Reliability Engineering & System Safety*, vol. 94, pp. 1639-1649, OCT 2009 2009.
- [47] J. F. Fernandez and A. C. M. Juan F Gomez Fernandez, *Maintenance Management in Network Utilities: Springerverlag London*, 2012.

- [48] C. Lopez and A. Crespo Márquez, "Review, classification and comparative analysis of maintenance management models," *Journal of Automation Mobile Robotics and Intelligent Systems*, vol. 3, pp. 110-115, 2009.
- [49] L. M. Pintelon and L. N. Van Wassenhove, "A maintenance management tool," *Omega*, vol. 18, pp. 59-70, 1990.
- [50] S. Vanneste and L. Van Wassenhove, "An integrated and structured approach to improve maintenance," *European Journal of Operational Research*, vol. 82, pp. 241-257, 1995.
- [51] T. Wireman, "World class maintenance management," *AUTOFACT'89*, p. 1989, 1989.
- [52] J. Moubray, *Reliability-centered maintenance*: Industrial Press Inc., 1997.
- [53] M. Wooldridge, *An introduction to multiagent systems*: John Wiley & Sons, 2009.
- [54] Y. Shoham, "Agent-oriented programming," *Artificial intelligence*, vol. 60, pp. 51-92, 1993.
- [55] F. Bellifemine, A. Poggi, and G. Rimassa, "JADE—A FIPA-compliant agent framework," in *Proceedings of PAAM*, 1999, p. 33.
- [56] M. Wooldridge, N. R. Jennings, and D. Kinny, "The Gaia methodology for agent-oriented analysis and design,"

- Autonomous Agents and multi-agent systems, vol. 3, pp. 285-312, 2000.
- [57] P. Bresciani, A. Perini, P. Giorgini, F. Giunchiglia, and J. Mylopoulos, "Tropos: An agent-oriented software development methodology," *Autonomous Agents and Multi-Agent Systems*, vol. 8, pp. 203-236, 2004.
- [58] C. A. Iglesias, M. Garijo, and J. C. González, "A survey of agent-oriented methodologies," in *Intelligent Agents V: Agents Theories, Architectures, and Languages*, ed: Springer, 1999, pp. 317-330.
- [59] M. Wooldridge and P. Ciancarini, "Agent-oriented software engineering: The state of the art," in *Agent-oriented software engineering*, 2001, pp. 1-28.
- [60] N. R. Jennings, "Agent-oriented software engineering," in *Multiple Approaches to Intelligent Systems*, ed: Springer, 1999, pp. 4-10.
- [61] A. Hald, "On the history of maximum likelihood in relation to inverse probability and least squares," *Statistical Science*, pp. 214-222, 1999.
- [62] A. Mettas and W. Zhao, "Modeling and analysis of repairable systems with general repair," in *Reliability and Maintainability Symposium*, 2005. Proceedings. Annual, 2005, pp. 176-182.

- [63] S. H. Zanakis, "Computational experience with some nonlinear optimization algorithms in deriving maximum likelihood estimates for the three-parameter Weibull distribution," *TIMS Studies in Management Science*, vol. 7, pp. 63-77, 1977.
- [64] W. Leithead and Y. Zhang, "O(N²)-Operation approximation of covariance matrix inverse in Gaussian process regression based on quasi-Newton BFGS method," *Communications in Statistics—Simulation and Computation*®, vol. 36, pp. 367-380, 2007.
- [65] D. J. Matich, "Redes Neuronales: Conceptos básicos y aplicaciones," *Cátedra de Informática Aplicada a la Ingeniería de Procesos—Orientación I*, 2001.
- [66] N. C. Metropolis, G. Reitwiesner, and J. von Neumann, "Statistical treatment of values of first 2,000 decimal digits of π ," *Mathematics of Computation*, vol. 4, pp. 109-111, 1950.
- [67] A. M. Turing, "Computing machinery and intelligence," *Mind*, pp. 433-460, 1950.
- [68] W. S. McCulloch and W. Pitts, "A logical calculus of the ideas immanent in nervous activity," *The bulletin of mathematical biophysics*, vol. 5, pp. 115-133, 1943.
- [69] M. Minsky, "Steps toward artificial intelligence," *Proceedings of the IRE*, vol. 49, pp. 8-30, 1961.

- [70] F. Rosenblatt, "The perceptron: a probabilistic model for information storage and organization in the brain," *Psychological review*, vol. 65, p. 386, 1958.
- [71] R. Morris, "DO Hebb: The Organization of Behavior, Wiley: New York; 1949," *Brain research bulletin*, vol. 50, p. 437, 1999.
- [72] K. S. Lashley, "In search of the engram," 1950.
- [73] B. WIDROW and M. E. HOFF, "Adaptive switching circuits," 1960.
- [74] M. Minsky and P. Seymour, "Perceptrons," 1969.
- [75] J. A. Anderson, *An introduction to neural networks*: MIT press, 1995.
- [76] S. Grossberg, "Behavioral contrast in short term memory: Serial binary memory models or parallel continuous memory models?," *Journal of Mathematical Psychology*, vol. 17, pp. 199-219, 1978.
- [77] K. Fukushima, "Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position," *Biological cybernetics*, vol. 36, pp. 193-202, 1980.
- [78] J. J. Hopfield and D. W. Tank, "'Neural' computation of decisions in optimization problems," *Biological cybernetics*, vol. 52, pp. 141-152, 1985.

- [79] J. L. McClelland, D. E. Rumelhart, and P. R. Group, "Parallel distributed processing," *Explorations in the microstructure of cognition*, vol. 2, 1986.
- [80] A. Lapedes and R. Farber, "Nonlinear signal processing using neural networks," 1987.



PARTE II

4. SISTEMA PARA EL CONTROL Y LA ADQUISICIÓN DE DATOS EN FUENTES DE ENERGÍAS RENOVABLES

El resultado de este capítulo ha sido publicado en la revista *Trends in Applied Intelligent Systems* con la siguiente referencia de publicación:

	<i>García-Pedrajas, N., Fyfe, F. H. C., & Ali, J. M. B. M. (2010). Trends in Applied Intelligent Systems. Lecture Notes in Computer Science, 6096.</i>
	Para citar este trabajo: <i>Polo, F. A. O., del Rosario, J. J. A., & García, G. C. (2010). Supervisory control and automatic failure detection in grid-connected photovoltaic systems. In Trends in Applied Intelligent Systems (pp. 458-467). Springer Berlin Heidelberg.</i>
Referencia de indicios de calidad:	ISBN 978-3-642-13022-9

4 SISTEMA PARA EL CONTROL Y ADQUISICIÓN DE DATOS EN FUENTES DE ENERGÍA RENOVABLE

En este capítulo se describe un nuevo sistema SCADA (Supervisory, Control and Data Acquisition System) para la monitorización on-line de plantas solares fotovoltaicas. Las principales contribuciones de este desarrollo son la incorporación de tecnologías multiagente, de un módulo de análisis multidimensional con tecnología OLAP para mejorar la eficiencia en consultas tipo big-data, y de un procedimiento para la detección de fallos basado en la comparación de la producción real de los inversores de la planta con la de sus pares.

Gracias a este entorno de trabajo es posible estudiar la influencia de las condiciones climatológicas, la radiación solar y la temperatura de los módulos, entre otros factores, en la generación de energía. El sistema propuesto no solo identifica fallos en el Sistema, sino que proporciona información sobre el origen más probable de fallo, el protocolo de actuación a seguir para alcanzar una rápida solución y genera alarmas en el SCADA para el envío de e-mails y SMS a los responsables de mantenimiento.

La aplicación de esta metodología de trabajo es extensible al análisis de otras fuentes de energía renovables, como la energía termosolar, también analizada dentro de esta línea de investigación, o la eólica.

4.1 INTRODUCCIÓN

En la actualidad existente una enorme dependencia de elementos fósiles en la generación de energía. Este hecho origina la emisión de grandes cantidades de gases contaminantes y constituye una fuente de inseguridad derivada del potencial agotamiento de los recursos naturales no renovables con la consecuente incertidumbre y variabilidad en los precios de mercado de la energía.

Para paliar ambos problemas se ha promovido con intensidad el empleo de fuentes de energía renovables [1]. Como ejemplo, en la Unión Europea la potencia instalada de energía solar fotovoltaica y solar termoeléctrica, sólo en el periodo comprendido entre 2005 y 2008, ha sido de 9.050 MWp.

Las fuentes de energía renovable se caracterizan generalmente por presentar una alta variabilidad y dependencia de la naturaleza aleatoria de los fenómenos climatológicos.

Es muy importante conocer y predecir la cantidad de energía generada, así como detectar con la suficiente antelación la variabilidad en la misma debida tanto a la climatología esperada como a la existencia de potenciales fallos en las plantas generadoras, para una integración adecuada en las redes eléctricas convencionales.

La legislación en muchos países contempla penalizaciones y bonos económicos a los productores de energías renovables en función del grado de cumplimiento de su compromiso anticipado de producción.

La línea de investigación de la presente tesis se ha desarrollado, principalmente, en torno a una planta solar fotovoltaica de 6,1 MWp con 1.342 seguidores solares de 2 ejes, ubicada en la provincia de Córdoba (ver Figura 16) y propiedad del Grupo Magtel (<http://www.magtel.es>). Los principales elementos involucrados en la generación y gestión de la energía son los siguientes:

- **Seguidores solares:** reciben la energía solar y la transforman mediante el efecto fotoeléctrico en un flujo de corriente continua.
- **Inversores:** Convierten la corriente continua generada en los seguidores solares en corriente alterna que es inyectada en la red eléctrica convencional a través de unos centros de transformación. Cada inversor tiene una potencia nominal de 100KW.
- **Contadores:** Registran la cantidad de energía activa y reactiva producida en cada uno de los inversores.



Figura 16. Planta solar El Molino Energía (Córdoba)

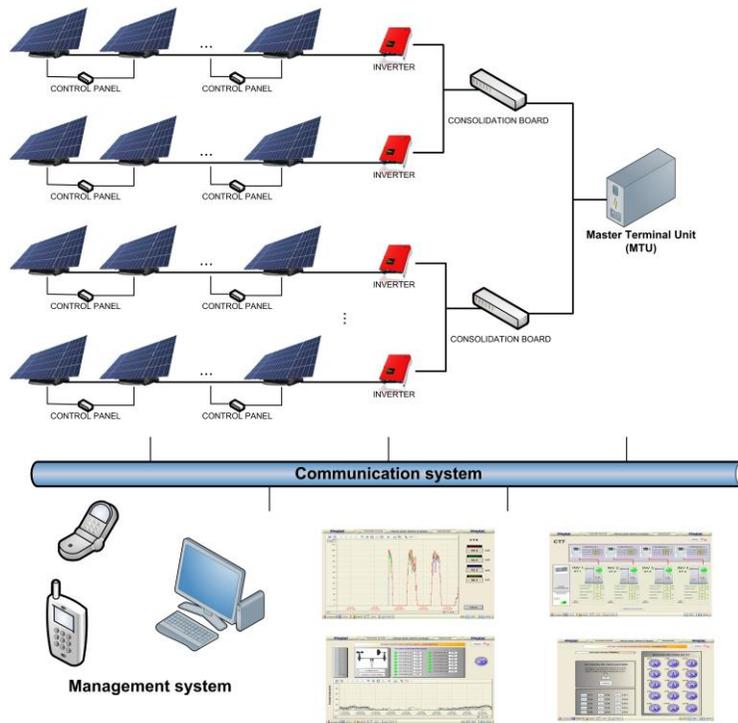


Figura 17. Arquitectura física del sistema de control

4.2 SISTEMA DE SUPERVISIÓN, CONTROL Y ADQUISICIÓN DE DATOS (SCADA)

En la Figura 17 se muestra la arquitectura del sistema de control de la planta, mientras que en la Figura 18 se detalla la arquitectura del sistema SCADA desarrollado en este trabajo, estando compuesto por los siguientes módulos:

- **Sistema de gestión (MTU: Master Terminal Unit).** Este módulo permite monitorizar el comportamiento de la planta fotovoltaica conectada a red. Muestra alertas

cuando se detectan potenciales o reales errores de funcionamiento y permite la configuración y control de ciertos parámetros del parque.

- **Sensores distribuidos.** Es el conjunto de anemómetros, sensores de temperatura, estaciones meteorológicas y células de irradiancia.
- **Cuadros de control de pares de seguidores solares maestro-esclavo.** Los seguidores solares de la planta bajo estudio están organizados desde el punto de vista del sistema de control en parejas maestro-esclavo, compartiendo un sistema local de adquisición de datos (sitio remoto).
- **Cuadros de concentración (Consolidation Boards).** Se localizan en las casetas de inversores y concentran los datos procedentes de los elementos de la propia caseta y de toda la red de sensores y seguidores solares dependientes.
- **Servidor central.** Tiene la función de recolectar los datos procedentes de todos los cuadros de concentración y proporciona una interfaz HMI (Human Machine Interface) a los operadores. Está ubicado en la propia planta e implementado en un clúster de servidores. Opcionalmente se puede disponer de un sistema en alta disponibilidad ubicado en un centro de control remoto.

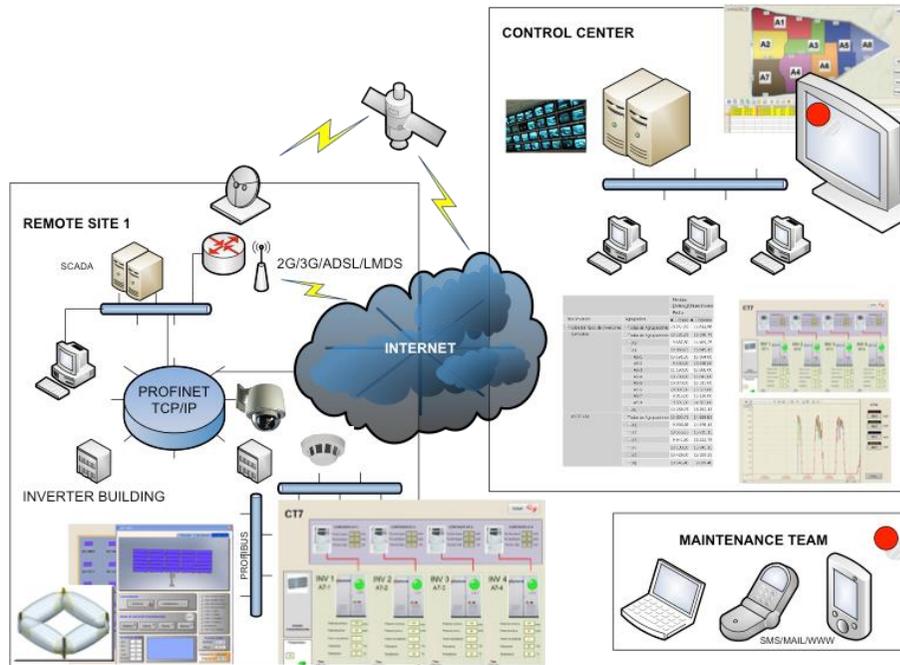


Figura 18. Arquitectura del sistema SCADA

- **Sistema de análisis.** El sistema de gestión procesa más de 30.000 variables en tiempo real. Con el objetivo de analizar las series temporales correspondientes a estas variables, se ha desarrollado una herramienta OLAP (On-Line Analytical Processing) [12].
- **Sistema de comunicaciones.** Se compone de 5 redes:
 - **Red troncal TCP/IP.** Es una red de fibra óptica con topología física en anillo e interconecta el sistema de gestión con los cuadros de distribución.

- **Redes de distribución PROFIBUS DP.** Permiten la comunicación de los cuadros de distribución con los cuadros de control de los pares de seguidores maestro-esclavo.
- **Redes de distribución MODBUS.** Son internas a las casetas de los inversores y permiten la interconexión de los sensores ambientales y los inversores a los cuadros de distribución.
- **Redes MODBUS de comunicación maestro-esclavo.** Cada pareja de seguidores solares tiene su propia red de comunicaciones para la supervisión y control.
- **Red de enlace 3G.** Permite el acceso remoto a la planta mediante un acceso de consola o una sesión web. A través de esta red es posible el envío de alertas y alarmas a los operadores de planta mediante correos electrónicos o mensajes SMS.

Este sistema permite la monitorización en tiempo real de la producción de la planta, además de detectar la ocurrencia de fallos en los seguidores solares e inversores. Sin embargo, no es posible identificar fallos de diseño o de funcionamiento en elementos como paneles fotovoltaicos, fusibles u otros dispositivos de protección.

Usando adecuadamente la información disponible en el SCADA es posible hacer una identificación general de fallos y detectar el malfuncionamiento de elementos pasivos, e incluso, predecir la

producción y la potencial ocurrencia de fallos en la planta. Para ello, se procedió a reorganizar y modificar los elementos descritos anteriormente en varias capas:

- **Organización multiagente 1: SCADA pre-existente.** A nivel lógico este sistema se compone de los siguientes agentes:
 - **Real Time-Logger.** Recolecta los datos procedentes de la red de sensores.
 - **Historian.** Archiva los datos en bruto registrados por los diferentes loggers, así como el procesado posterior de los mismos.
 - **Human Machine Interface (HMI).** Es el componente que permite la interacción con los operadores del sistema.
 - **Módulo de alarmas.** Este agente lanza eventos a otros componentes del sistema.

- **Organización multiagente 2: subsistema de mantenimiento predictivo.** Los agentes que constituyen este subsistema se relacionan a continuación:
 - **Modelador.** Recolecta datos de la red de sensores y actualiza el modelo de predicción de la producción de energía.

- **Predictor.** Aplica el modelo de predicción para calcular la producción estimada de la planta.
- **Detector de fallos.** Compara la salida del modelo con la producción en tiempo real medida en la planta.
- **Localizador de fallos.** Analiza la información disponible en el SCADA conjuntamente con la salida del agente detector para determinar el punto más probable de fallo.
- **Middleware.** Protocolos de comunicación entre agentes basados en el lenguaje de comunicación de agentes (ACL: Agent Communications Language) de FIPA (Foundation for Intelligent Physical Agents)
- **Interacción con el entorno (sensores/actuadores)**

Los registradores (real-time loggers) recolectan periódicamente información y se la facilitan al agente de archivo (historian). El modelador accede con una periodicidad preestablecida al histórico para actualizar el modelo de predicción, generando un evento para avisar al agente predictor de la disponibilidad del mismo.

El agente detector interactúa con el predictor y el registrador para obtener los valores reales y las estimaciones de la producción, comparando ambos valores, e informando al agente localizador de fallos en el caso de detectar alguna anomalía, procediendo a analizar la información disponible en el SCADA para identificar el potencial punto de fallo y emitiendo un aviso al equipo de mantenimiento.

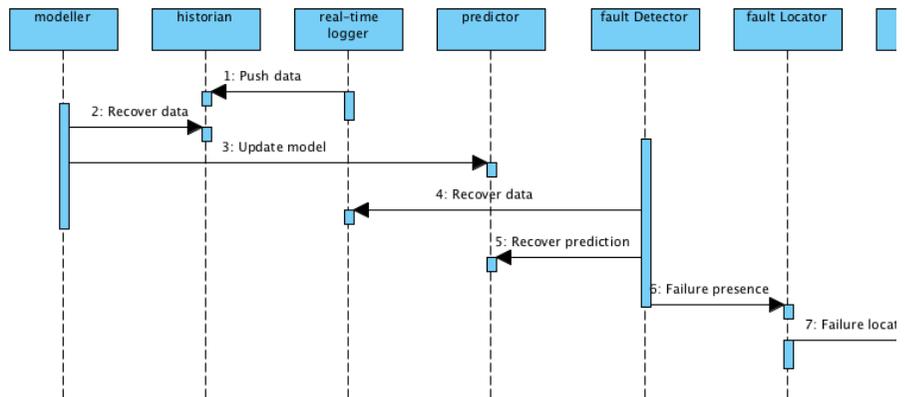


Figura 19. Diagrama de colaboración multiagente

El procedimiento para la detección de fallos se ha ido perfeccionando a lo largo de este trabajo de investigación, siendo inicialmente implementado con se describe en el siguiente apartado.

4.3 MÉTODO DE DETECCIÓN DE FALLOS

El fallo o el malfuncionamiento de un elemento se manifiesta como una desviación en su comportamiento funcional con respecto el esperado. En esta línea, es posible obtener un modelo del comportamiento de los elementos de la planta y evaluar las desviaciones numéricas en sus variables de estado con respecto a los valores esperados para la identificación de fallos.

Por otro lado, otra posible forma de detectar la presencia de fallos funcionales consiste en encontrar discrepancias significativas en

el comportamiento de elementos similares trabajando en las mismas condiciones de operación.

Para representar el comportamiento de un parque fotovoltaico podemos utilizar la producción de energía normalizada con respecto a su capacidad pico. En la Figura 20 se muestran las series temporales de producción normalizada en 5 elementos de la planta entre los meses de enero y agosto de 2009. Si los elementos de producción fuesen idénticos, su producción sería muy similar, ya que las condiciones de operación de las que depende la producción (irradiancia y temperatura ambiente) tienen una distribución temporal casi uniforme en la planta.

Por tanto, podemos utilizar la correlación de dos series temporales para analizar la similitud del comportamiento de dos elementos de producción. En condiciones normales de operación la correlación de las series de producción es prácticamente igual a 1. Cuando alguno de los elementos experimenta un comportamiento anómalo o tiene un fallo de configuración aparece una disminución significativa en el coeficiente de correlación cruzada.

La Figura 21 muestra en su parte izquierda la matriz de correlación correspondiente a las series temporales de 56 inversores de los 61 que constituyen la planta solar fotovoltaica “El Molino Energía”. En la parte derecha de la figura se muestra un detalle de la matriz de correlación para varios inversores seleccionados aleatoriamente.

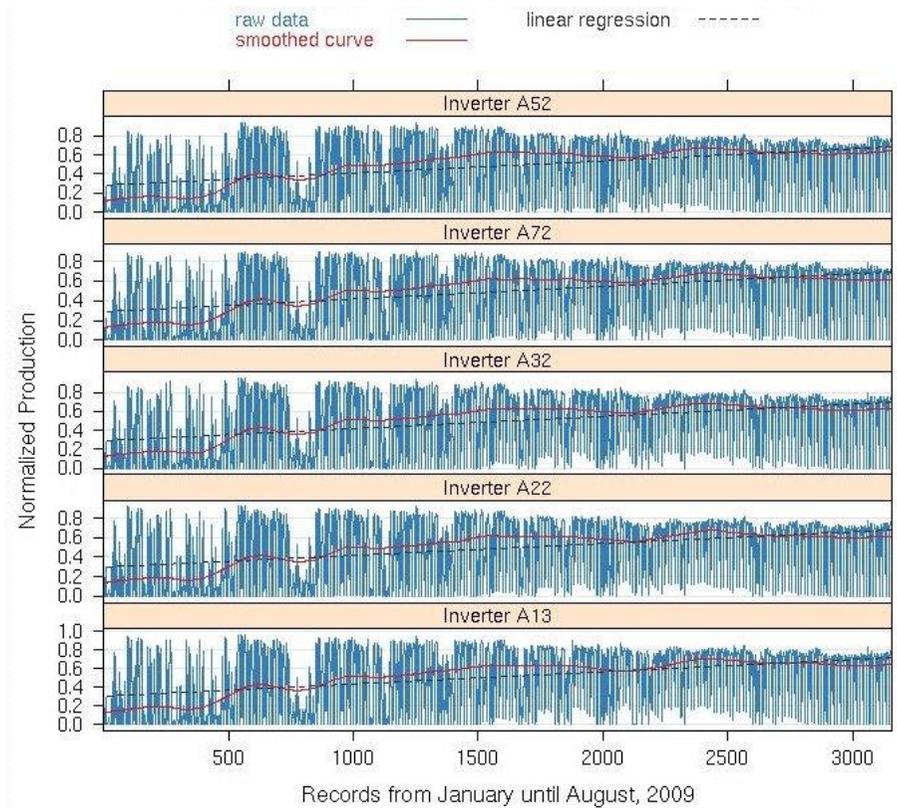


Figura 20. Producción normalizada de energía en 5 inversores de la planta Molino Energía entre enero y agosto de 2009

En el análisis efectuado se encontró un mínimo en la correlación existente entre los inversores A42 y A57. La regresión lineal de la serie de producción del inversor A57 con variable independiente A42 (Figura 22) se describe en la Tabla 1.

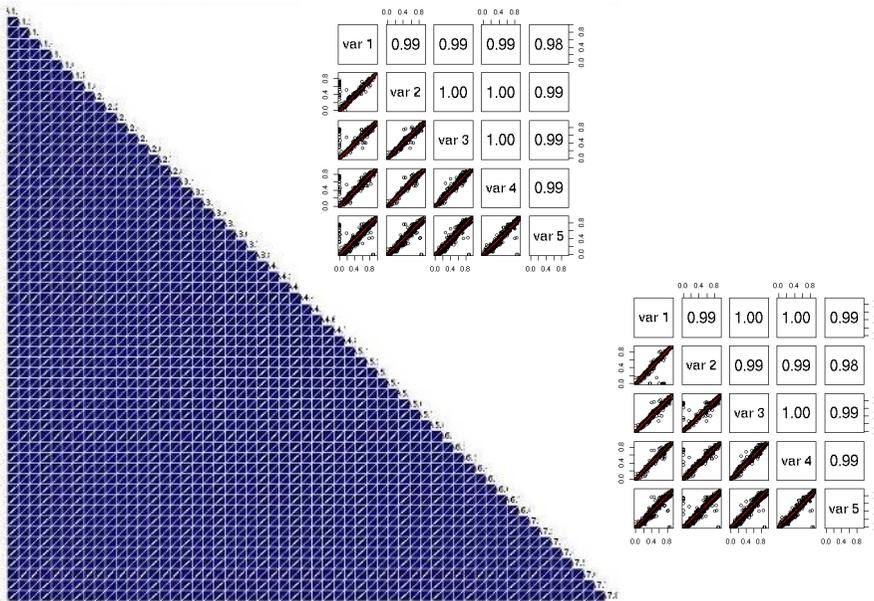


Figura 21. Matriz de correlación de la producción de 56 inversores Molino Energía

R	R ²	Adjusted R ²	Std. Error	Change Statistics					D.W.
				R ² Change	F Change	df	df2	Sig. Change	
0.967	0.936	0.936	0.0775	0.936	45863.77	1	3156	0.00	0.816

Tabla 1. Coeficientes de regresión lineal (A57 vs. A42)

La capacidad de producción del inversor A57 es un 93,6% de la capacidad de producción del elemento A42, aunque debería ser mucho más similar. De esta forma se detectó la existencia de un

problema en el inversor A57. Efectivamente, desde la puesta en servicio del mismo existía un error en la configuración de los umbrales de operación.

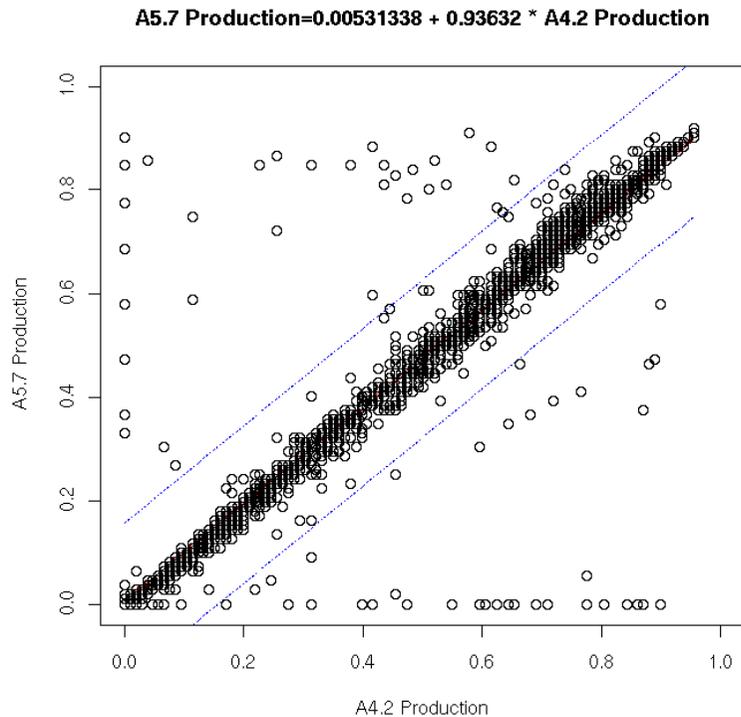


Figura 22. Regresión lineal de la producción en el A57 frente a la producción del inversor A42

4.4 AUTOMATIZACIÓN DEL PROCESO DE DETECCIÓN DE FALLOS

El algoritmo que se propone para la detección de fallos se basa en la comparación de la producción real de los inversores con respecto a la producción estimada en función de la producción real de otros elementos de la planta. Este método, además de permitir la detección de la existencia de fallos en el funcionamiento del sistema, proporciona

información adicional, que tras su análisis, permite identificar el origen más probable del fallo, lo que posibilita la elección del protocolo de actuación más apropiado para una rápida solución.

La Figura 23 muestra la secuencia de actuaciones del proceso. En primer lugar se establecen ciertos parámetros como la frecuencia de aplicación del algoritmo de detección (ptda), el intervalo de confianza en la detección de errores (iconf) para reducir las incertidumbres en la estimación de la producción, y los medios de notificación de fallos (fne).

El proceso de detección de fallos gestiona todos los pasos del método anteriormente definido: comprueba la producción real con respecto a la producción estimada, identificando los inversores que están funcionando incorrectamente.

Para todos los inversores problemáticos (N fallos) se ejecuta un algoritmo de clasificación del fallo, en el que se analizan algunas propiedades de las pérdidas de energía, tales como la cantidad, duración y frecuencia.

Por ejemplo, los fallos de un inversor o de un dispositivo de control generalmente producen una pérdida total en la producción, mientras que una pérdida constante de energía puede estar originada por defectos en los módulos fotovoltaicos de los seguidores solares, por la presencia de suciedad en las células fotovoltaicas o un error en la configuración de los umbrales de operación de los inversores.

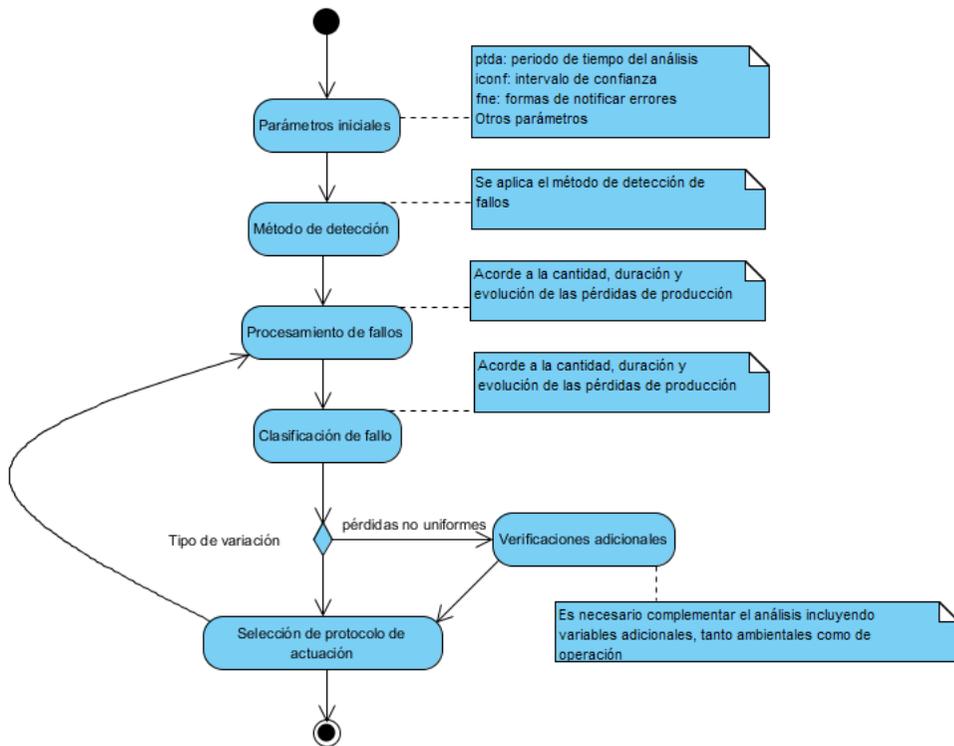


Figura 23. Proceso para la detección automática de fallos de producción

Cuando la intensidad de las pérdidas de energía no se mantiene uniforme en el tiempo, se pueden deber a la presencia de sombras, altas temperaturas ambientales o sobrecalentamiento de los inversores.

Es posible discriminar entre las posibles causas del fallo utilizando la información procedente de estaciones meteorológicas y de la base de datos de mantenimiento. Para estos casos se realizan comprobaciones adicionales, descartando, por ejemplo, fallos

asociados a la presencia de altas temperaturas cuando la temperatura real es inferior a 30° C o fallos derivados de actuaciones programadas de mantenimiento.

Finalmente, el procedimiento de detección de fallos propone un plan de acción en función de la clasificación de fallo y realiza las notificaciones oportunas al equipo de mantenimiento.

4.5 CONCLUSIONES

Se ha propuesto, implementado y probado un nuevo sistema SCADA para la supervisión y control de una planta solar fotovoltaica conectada a red. El diseño permite una fácil adaptación a otras fuentes de energía renovable (termosolar, eólica, ...), de tal forma que es posible la identificación de fallos en el sistema así como el análisis de la influencia de las condiciones meteorológicas y los efectos de la temperatura de operación de los módulos fotovoltaicos e inversores en la eficiencia del sistema.

La arquitectura interna del sistema SCADA ha sido reconfigurada como un sistema multiagente que permite desplegar con facilidad los nuevos algoritmos desarrollados en la línea de investigación desarrollada en el marco de esta tesis doctoral y el sistema de información ha sido optimizado con la creación de cubos OLAP para la ejecución eficiente de consultas multidimensionales.

La posibilidad de predecir la producción de energía de un elemento generador en función de otros elementos similares de la planta, comparando este valor con la producción medida real, permite

detectar la presencia de fallos de funcionamiento. Es más, el procedimiento presentado no sólo permite la detección de fallos sino que proporciona información sobre el origen más probable de fallo, así como el protocolo de actuación más adecuado para solventar la incidencia.

4.6 BIBLIOGRAFÍA

- [1] Singh R. and Sood Y. R. Policies for promotion of renewable energy sources for restructured power sector. Proceedings of the 3rd International Conference on Electric Utility Deregulation and Reconstructing and Power Technologies, 1-5 Nanjuing China (2008).
- [2] Cardoso, F. J. A., A universal system for laboratory data acquisition and control. IEEE Trans. Nucl. Sci. 472 , 154 –157 2000.
- [3] Singlachar, R. and Mukherjee, B., An advanced PC-PLC-based SCADA system for a commercial medical cyclotron. Nucl. Instrum. Methods Phys. Res. A 399, 396 – 406 1997.
- [4] Dieu, B., Application of the SCADA system in waste-water treatment plants. ISA Trans. 40, 267–281 (2001).
- [5] Patel, M. Cole, G.R. , Pryor, T.L. , Wilmot, N.A. Development of a Novel SCADA System for Laboratory Testing. ISA Transactions. 43 (3), 477 - 490 (2004).

- [6] Guasch, D., Silvestre, S., Calatayud, R., Automatic failure detection in photovoltaic systems, Proceedings of 3rd World Conference on , vol.3, pp. 2269-2271 (2003)
- [7] Silvestre, S., Guasch, D., Goethe, U., and Castarier, L., Improved PV battery modeling using Matlab", Proc. Of the Seventeenth European Photovoltaic Solar Energy Conference and Exhibition, (Munich, Germany, 2001), pp. 507-509.
- [8] Guasch, D. and Silvestre, S., Dynamic battery model for Photovoltaic applications, Progress in Photovoltaics: Research and applications, Vol 11, pp.193-206, (2003).
- [9] Drews, A., Keizer, A. C., Beyer, H.G, Lorenz, E., Betcke, J., van Sark, W.G.J.H.M., Heydenreich, W., Wiemken, E., Stettler. S., Toggweiler, P., Bofinger, S., Schneider M., Heilscher, G., Heinemann, D., Monitoring and remote failure detection of grid-connected PV systems based on satellite observations, Solar Energy, Volume 81, Issue 4, Pages 548-564 (2007).
- [10] Hammer, A., Heinemann, D., Hoyer, C., Kuhlemann, R., Lorenz, E., Mueller, R.W., Beyer, H.G. Solar energy assessment using remote sensing technologies. Remote Sensing of the Environment 86, 423–432 (2003)
- [11] Stettler, S., Toggweiler, P., Wiemken, E., Heydenreich, W., de Keizer, A.C., van Sark, W.G.J.H.M., Feige, S., Schneider, M., Heilscher, G., Lorenz, E., Drews, A., Heinemann, D., Beyer, H.G. Failure detection routine for grid-connected PV systems as

part of the PVSAT-2 project. In: Proceedings of the 20th European Photovoltaic Solar Energy Conference & Exhibition, Barcelona, Spain, pp. 2490–2493 (2005).

- [12] F. Olivencia Polo, On-Line Analytical Processing in Photovoltaic System. MAGTEL Systems Technical Report MGTSYS0508, Cordoba, Spain (2008).
- [13] C. Emrich, R. Acosta, A. Kalu, D. Kifer, W. Wilson Supervisory Control and Data Acquisition Experiment Using the Advanced Communications Technology Satellite. Technical report FSEC-CR-1296-01, Florida Solar Energy Center/University of Central Florida (2001).

5. MODELADO ESTADÍSTICO PARAMÉTRICO DE LA PRODUCCIÓN

5 MODELADO ESTADÍSTICO PARAMÉTRICO DE LA PRODUCCIÓN

5.1 INTRODUCCIÓN

El modelado de la producción descrito en el capítulo anterior, donde se utilizan otros elementos de la planta similares para establecer una relación lineal entre la producción de un elemento y sus pares, a pesar de su utilidad, adolece del hecho de que desconocemos, a priori, el estado de buen funcionamiento de los pares y el grado de uniformidad de las condiciones ambientales y radiación solar en función de la extensión del terreno, por lo que se puede introducir una distorsión importante en el modelo.

Por ello, la línea de investigación se orientó a explorar la posibilidad de modelar estadísticamente la producción de un elemento en un estado de ausencia de fallo, ya que como veremos más adelante, la obtención de un modelo físico del sistema completo es compleja.

La energía solar fotovoltaica presenta una gran variabilidad y dependencia de la naturaleza aleatoria de los fenómenos climatológicos, siendo muy importante conocer y predecir tanto la cantidad de energía generada como los fallos de los sistemas de producción para una integración práctica y exitosa en las redes de transporte eléctricas [1].

Algunas investigaciones han estado enfocadas en el estudio de los mecanismos de coordinación para la integración en la red de diferentes fuentes de energía renovable [2,3]. Sin embargo, en los últimos años el esfuerzo académico ha estado dirigido hacia el mantenimiento predictivo de las instalaciones para minimizar el impacto de la integración en las redes de transporte.

La ejecución regular de tests de funcionamiento y el seguimiento continuo de la producción requiere un sistema de monitorización complejo, y el análisis estadístico de las series temporales de la producción necesita de una importante red de sensores distribuidos, registradores y otros dispositivos inteligentes, por lo que se requiere de un mantenimiento intensivo y de alto coste de los mismos, sólo justificado en grandes instalaciones fotovoltaicas de varios MWp.

Para asegurar los beneficios, incrementando la eficiencia de la planta fotovoltaica, es muy importante desarrollar métodos efectivos para la detección temprana de fallos en el sistema.

Tradicionalmente, la detección automática de fallos en los sistemas fotovoltaicos requieren el registro y análisis de una gran cantidad de variables eléctricas, tales como las corrientes que circulan por los paneles solares y las tensiones de las cadenas constituidas por los mismos, conjuntamente con datos ambientales y de operación, como la irradiancia y la temperatura.

Muchas investigaciones han estado orientadas al estudio de la relación existente entre la vida útil de los componentes de un sistema fotovoltaico y las condiciones de operación de estrés, tales como la presencia de humedad, altas temperaturas y elevadas tensiones de polarización, así como con las limitaciones del proceso, como el estado de las soldaduras, presencia de defectos en células fotovoltaicas, corrosión, etc. [4,5]. Algunas propuestas tratan de reducir la complejidad del algoritmo de detección de fallos utilizando un número limitado de variables y complejos análisis estadísticos [6].

Otras propuestas no utilizan redes de sensores en la planta, sino que la inferencia se basa en la comparación de la producción real con respecto a la estimada exclusivamente en función de la información disponible de irradiancia, la ficha técnica de los dispositivos instalados, la localización geográfica y otros parámetros estáticos. En [7] se propone un sistema de este tipo donde se estima la producción horaria de la planta en función de los mapas de radiación solar obtenidos por el satélite Meteosat-8, aplicando una versión mejorada del método Heliostat [8]. El operador del sistema introduce la información de los principales componentes de la planta (fabricante, tipo y número de módulos). La energía realmente producida se registra con una periodicidad horaria y es analizada diariamente por el sistema automático de detección de fallo [9]

Por otro lado, muchos estudios sugieren que las causas que afectan de forma más importante a la fiabilidad de la planta son los fallos en los inversores [10]. En las referencias [11,12] se analizan

diferentes arquitecturas de inversores, concluyendo que el factor de estrés dominante en los mismos es la temperatura de operación, destacando que la presencia de dispositivos MOSFET es el punto más vulnerable.

Otros estudios sugieren que la principal causa de fallo en los inversores es la presencia de condensadores electrolíticos. En [13,14] se presenta una nueva tipología de inversor que evita el empleo de grandes condensadores.

Además, es especialmente importante una adecuada gestión térmica dentro de los inversores, puesto que sus componentes son especialmente sensibles a los efectos de la temperatura.

Algunos fallos son debidos a causas naturales como las tormentas eléctricas o la introducción de agua en los inversores, y otros están relacionados con la interconexión con la red eléctrica interna y/o externa a la planta (fallos de aislamiento y eficiencia en la inyección [5]).

En la referencia [11] se propone una estrategia para estudiar de forma sistemática el efecto de los parámetros de los diseño de un inversor en los diferentes modos de fallo del mismo, y para mejorar la fiabilidad de los inversores, se presenta en [15] una metodología para el análisis detallado de los mismos en diferentes subsistemas.

En la referencia [16] se describe un método para el cálculo de la tasa de fallo de un inversor conforme al estándar MIL-HDBK 217, en configuraciones de dos y tres etapas. Los transistores de conmutación

fueron los elementos identificados como más débiles, desde el punto de vista de la fiabilidad. Otros componentes, sin embargo, como las bobinas de inducción no contribuían significativamente a la tasa de fallo.

En la referencia [17] se proponen modelos de fiabilidad para inversores simples y en configuraciones en paralelo para determinar configuraciones óptimas. Aplicando un análisis de sensibilidad es posible identificar el efecto de los diferentes parámetros de diseño tanto en la fiabilidad como en el coste del sistema.

En este capítulo se presenta el estado del arte de los modelos de predicción existentes para la producción de plantas solares fotovoltaicas y los resultados de la aplicación del modelo estadístico paramétrico desarrollado en este trabajo de investigación sobre la distribución de Weibull.

5.2 ESTADO DEL ARTE DE LOS MODELOS DE PREDICCIÓN DE LA PRODUCCIÓN DE PLANTAS SOLARES FOTOVOLTAICAS

La tecnología de fabricación de componentes para instalaciones solares fotovoltaicas está muy madura. Los principales elementos han sido estudiados en laboratorio y entornos controlados. La energía producida depende de los siguientes factores:

- **Especificaciones de los módulos**, tales como la tensión y corriente características, los coeficientes térmicos de los semiconductores y las formas de

interconexión y las tolerancias de las células fotovoltaicas. El efecto de este factor puede alterar la producción hasta en un 10% de la potencia nominal. Asimismo, esto origina una distribución irregular de las pérdidas de energía cuando se conectan módulos con similares pero no idénticas características, lo que hace que todos funcionen al nivel mínimo.

- **Factores ambientales** que afectan significativamente al generador: radiación solar (directa y difusa), temperatura ambiente, suciedad de los paneles, y, en general, fenómenos atmosféricos como el viento o las precipitaciones.
- Factores derivados del **diseño de la instalación**: seguimiento solar, la existencia de sombreados parciales o la correcta ventilación de los módulos, entre otros.

Aunque se han desarrollado modelos físicos para los diferentes componentes de una instalación solar fotovoltaica, la presencia de los citados factores hace que una caracterización práctica de la misma sea muy difícil. No es posible obtener analíticamente una función de transferencia para una predicción ajustada de la producción. Es más, considerar la degradación temporal de los componentes, la deposición de polvo en los módulos y/o el mantenimiento aplicado dificultan aún más esta posibilidad.

Por ese motivo, los investigadores han desarrollado diferentes propuestas para abordar esta problemática [21]. En la referencia [7] se

propone un modelo para estimar la producción de energía como una función de la irradiancia y la temperatura ambiente, considerando que los módulos están trabajando en su punto de operación de máxima potencia [22], y unas aproximaciones de las pérdidas del sistema.

La eficiencia de un generador fotovoltaico trabajando en condiciones de máxima potencia se puede caracterizar por un modelo paramétrico de la irradiancia y de la temperatura del dispositivo. Esta aproximación se basa en los trabajos [23,24] donde se demuestra su aplicación tanto en módulos convencionales como de capa fina.

Otros modelos físicos se basan en el conocido modelo del doble diodo [25], aplicado en diferentes líneas de investigación [26-30]. Este modelo es extendido con la aplicación de una red neuronal de tres capas en [31].

El empleo de sistemas inteligentes en la simulación del comportamiento de los paneles fotovoltaicos se desarrolla en [32,33], empleando redes neuronales [34], lógica difusa [35] e incluso sistemas híbridos [36]. Sin embargo, es difícil obtener un modelo que contemple todos los elementos de una instalación solar fotovoltaica.

Nuestra propuesta parte de la hipótesis de considerar que la producción de energía de un sistema generador fotovoltaico puede ser caracterizada durante las horas de actividad de la planta como un proceso estocástico con una distribución de Weibull de dos parámetros (1), en la que el factor de forma (β) es característico de la planta y su ubicación, y el factor de escala (η) es dependiente de la

temperatura (T) y del logaritmo neperiano de la irradiancia (R), de acuerdo al modelo generalizado de Eyring (2), comúnmente utilizado en los test acelerados en el ámbito de la teoría de la fiabilidad [37].

$$f(x) = \frac{\beta}{\eta} \cdot \left(\frac{x}{\eta}\right)^{\beta-1} \cdot e^{-\left(\frac{x}{\eta}\right)^{\beta}} \quad (1)$$

La contribución de Henry Eyring a la teoría de las reacciones químicas [38] condujo al desarrollo de un modelo muy potente de la degradación acelerada en condiciones de estrés, o equivalentemente, de la evolución del tiempo de supervivencia de un elemento en condiciones de estrés.

$$\eta(T, R) = \frac{1}{T} \cdot e^{(A+\frac{B}{T}+C*R+D*\frac{R}{T})} \quad (2)$$

En este estudio, se establece una analogía entre la supervivencia definida en la teoría de la fiabilidad y la capacidad de producir una determinada energía en condiciones de estrés.

5.3 DETECCIÓN DE FALLOS EN PLANTAS SOLARES FOTOVOLTAICAS MEDIANTE EL MODELADO ESTADÍSTICO DE LA PRODUCCION

El modelo de Eyring incorpora los principales factores que afectan tanto a los dispositivos semiconductores de los módulos fotovoltaicos como a los de la electrónica de potencia. Los cambios en la irradian vía y en la temperatura se consideran factores de estrés con respecto a la operación del sistema en condiciones normales.

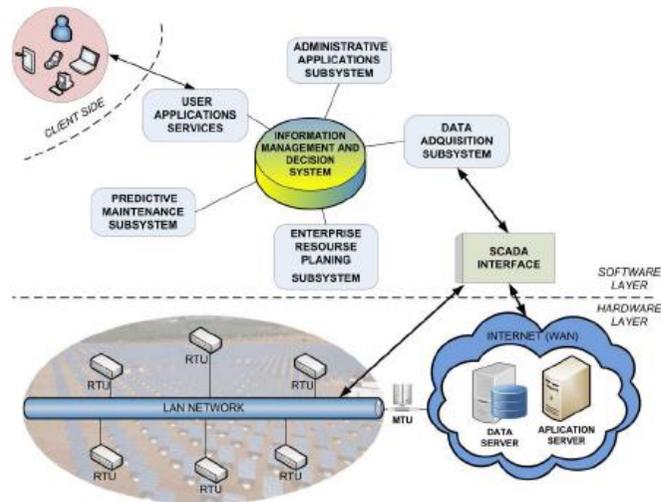


Figura 24. Arquitectura lógica del SCADA

Para estimar la producción horaria de la planta se utilizó la mediana de la distribución de Weibull (3) obtenida mediante un ajuste por MLE (Maximum Likelihood Estimation) de los datos históricos.

$$\hat{P} = \eta \cdot (\ln 2)^{1/\beta} \quad (3)$$

La incorporación de este algoritmo al SCADA del entorno de trabajo se realizó aplicando la metodología de desarrollo de sistemas SysML [39] sobre el agente Modelador. El algoritmo fue implementado en los siguientes componentes dentro del subsistema de mantenimiento predictivo:

- **Modelador.** En este módulo se analizan dentro de una ventana de tiempo predefinida las series R, T y P (producción real), generando varios modelos: uno para la predicción de la generación de energía (\hat{P}), otro para la predicción del comportamiento atmosférico en las siguientes 48 horas (\hat{R}, \hat{T}) y, por último, el umbral de la diferencia máxima de producción utilizado en el algoritmo de detección de fallo.
- **Predictor.** Los modelos generados se utilizan para la predicción a medio y largo plazo de la producción de energía. La predicción del comportamiento atmosférico se utiliza con el fin de detectar fallos en los sensores ambientales.
- **Detector de fallos.** Este módulo compara la energía real con respecto a la estimada. Si la diferencia excede el umbral establecido, se envía una señal al módulo de localización de fallos.
- **Localizador de fallos.** Este módulo analiza las señales disponibles en el SCADA en combinación con una red neuronal para tratar de identificar el origen del fallo.

Para evaluar el comportamiento del sistema propuesto, se seleccionó un subsistema generador de 105,32 KWp. La Figura 25 muestra las funciones de densidad de probabilidad obtenidas mediante la aplicación de un ajuste MLE de los parámetros β , A, B, C y D, a los registros de producción correspondientes a los meses de julio de 2009 y octubre de 2011, estableciendo como condiciones normales de operación una temperatura ambiente de 298°K y una irradiancia de 1000 W/m².

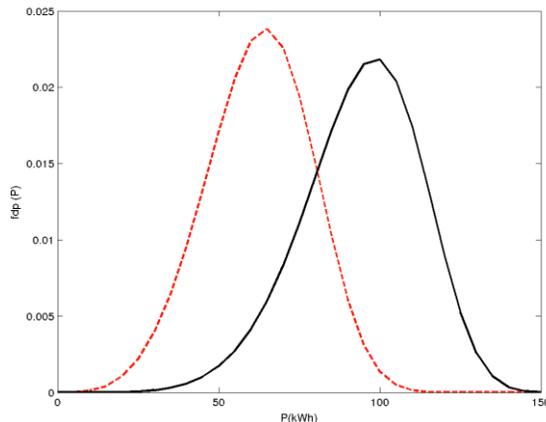


Figura 25. Distribuciones de Weibull obtenidas por ajuste MLE

La Tabla 2 muestra los coeficientes obtenidos tras el ajuste MLE. En el análisis de los resultados se apreció que conforme las condiciones climatológicas son más uniformes dentro del periodo de tiempo analizado, el valor del factor de forma de la Weibull (β) es mayor. Asimismo, es posible observar que en periodos de mayor producción, el factor de escala es mayor.

Period	β	A	B	C	D
July 09	5.95	7.21	-966.74	0.34	173.99
October 11	4.31	29.22	-7337.79	-2.24	898.59

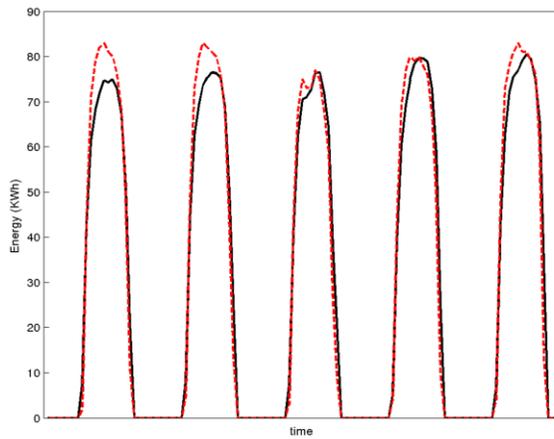
Tabla 2. Coeficientes ajuste MLE distribución Weibull

Los coeficientes de correlación entre las series de predicción y la producción real se calculan conforme a la siguiente fórmula (4):

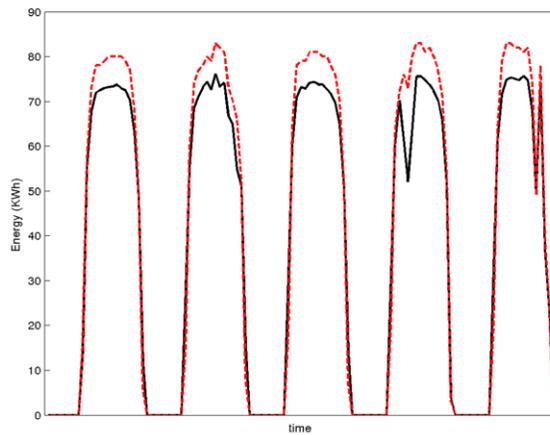
$$R = \frac{n \sum x_i y_i - \sum x_i \sum y_i}{\sqrt{n \sum x_i^2 - (\sum x_i)^2} \sqrt{n \sum y_i^2 - (\sum y_i)^2}} \quad (4)$$

La Figura 26 muestra la producción estimada y la real durante los primeros 5 días de octubre de 2011 (a) y julio de 2009 (b), considerando en cada caso el modelo obtenido a partir de los datos de producción del mes completo en el que se realiza en análisis. El error de la estimación de la producción en la primera semana de octubre es del 1,33%, siendo del 7,07% en la primera semana de julio, y del 4,45% considerando el mes completo.

A continuación se realizaron análisis con respecto a modelos de producción obtenidos a partir del análisis de series temporales de generación de periodos diferentes (modelos cruzados).

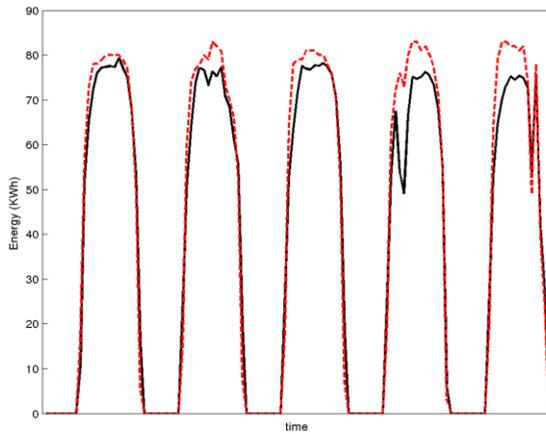


(a) $R=0.9949$

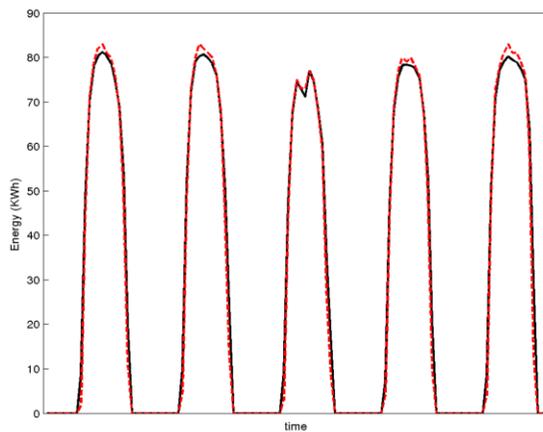


(b) $R=0.9981$

Figura 26. Comparativa producción real (rojo) frente a estimación (negro): (a) octubre 2011; (b) julio 2009



(a) $R = 0.9979$



(b) $R = 0.9962$

Figura 27. Comparativa producción real (rojo) frente a estimación (negro) con modelos cruzados: (a) julio 2009; (b) octubre 2011

La Figura 27 (a) muestra los resultados obtenidos si comparamos la producción real de la primera semana del mes de julio de 2009 con el modelo obtenido del mes completo de octubre de 2011. De forma análoga, comparando la producción real de la primera semana del mes de octubre de 2011 con la estimada a partir del modelo generado a partir del mes completo de julio de 2009, obtenemos los resultados de la Figura 27 (b).

En la estimación de la producción de la primera semana del mes de octubre de 2011 se obtuvo un error del -2,21% mientras que para el mes entero fue del 2,90%. Para el mismo análisis en julio de 2009 se obtuvo un error del 5,30%.

A pesar del error, de este análisis se concluyó que existe en todos los casos una correlación alta entre las series de producción real y estimada que hace posible establecer una línea base de la producción real. En la Figura 28 se observa la distribución del cociente entre la energía producida y la real en los periodos de estudio, para las diferentes horas del día.

Es posible obtener para diferentes periodos horarios un umbral mínimo de producción, de tal forma que si la producción real de la planta no alcanza dicho valor, el sistema detecta la existencia de un posible fallo, cuya naturaleza puede ser determinada en función de la

cantidad de energía perdida y su extensión en el tiempo, generado una alarma en el sistema de gestión (Figura 29).

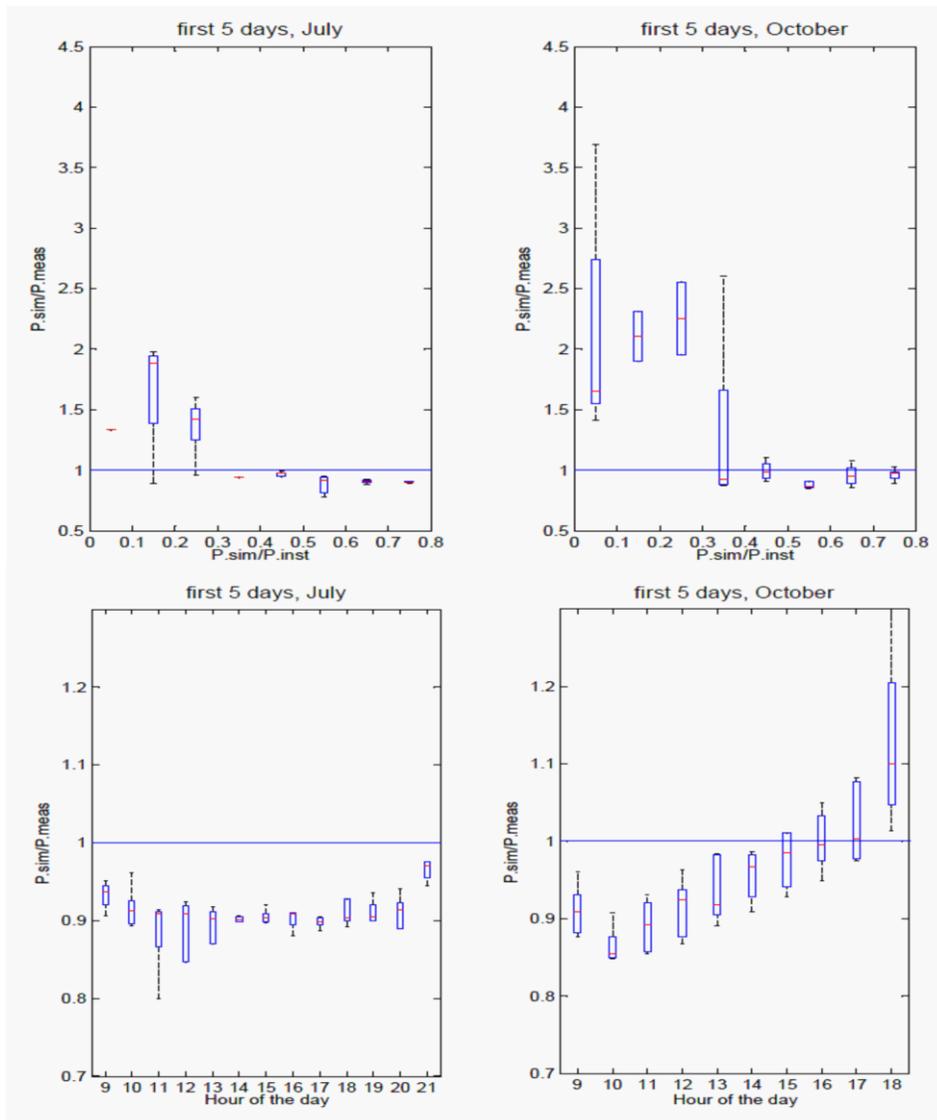


Figura 28. Análisis temporal de la ratio producción estimada / real

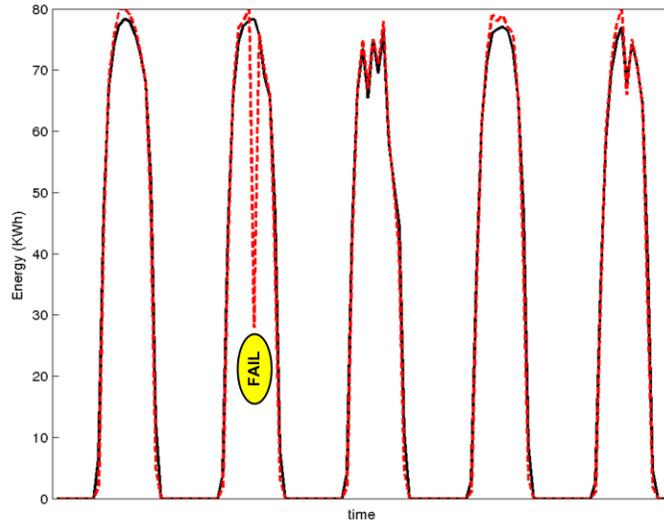


Figura 29. Escenario de detección de fallo (real: roja discontinua)

5.4 CONCLUSIONES

Es posible predecir la producción de una planta solar fotovoltaica mediante un modelo estadístico basado en una distribución de Weibull de 2 parámetros y modificado para incorporar las condiciones de operación como variables de estrés acorde a la fórmula de Eyring.

Se observa que, a pesar del error del modelo, la predicción en las horas centrales de producción es una buena referencia para la detección de fallos significativos en la planta, siendo su cálculo computacionalmente eficiente.

A partir de este punto, la línea de investigación se enfocó a la obtención de modelos no paramétricos más potentes, sacrificando la eficiencia de cálculo en aras de una mayor exactitud en las aproximaciones.

5.5 BIBLIOGRAFÍA

- [1] H. Kanchev et al., “Energy Management and Operational Planning of a Microgrid With a PV-Based Active Generator for Smart Grid Applications,” *Industrial Electronics, IEEE Transactions on*, vol. 58, no. 10, pp. 4583-4592, 2011.
- [2] R. Badawy et al., “A novel multi-agent system utilizing quantum-inspired evolution for demand side management in the future smart grid,” *Integrated Computer-Aided Engineering*, vol. 20, no. 2, pp. 127-141, 2013.
- [3] R. Badawy, B. Hirsch, and S. Albayrak, “Agent-based coordination techniques for matching supply and demand in energy networks,” *Integrated Computer-Aided Engineering*, vol. 17, no. 4, pp. 373-382, 2010.
- [4] E. D. Dunlop, D. Halton, and H. A. Ossenbrink, “20 years of life and more: where is the end of life of a PV module?,” in *Photovoltaic Specialists Conference, 2005. Conference Record of the Thirty-first IEEE*, 2005, pp. 1593-1596.
- [5] G. Petrone et al., “Reliability Issues in Photovoltaic Power Processing Systems,” *Industrial Electronics, IEEE Transactions on*, vol. 55, no. 7, pp. 2569-2580, 2008.

- [6] D. Guasch, S. Silvestre, and R. Calatayud, "Automatic failure detection in photovoltaic systems," in *Photovoltaic Energy Conversion, 2003. Proceedings of 3rd World Conference on, 2003*, pp. 2269-2271 Vol.3.
- [7] A. Drews et al., "Monitoring and remote failure detection of grid-connected PV systems based on satellite observations," *Solar Energy*, vol. 81, no. 4, pp. 548-564, 2007.
- [8] A. Hammer et al., "Solar energy assessment using remote sensing technologies," *Remote Sensing of Environment*, vol. 86, no. 3, pp. 423-432, 2003.
- [9] F. J. A. Cardoso, "A universal system for laboratory data acquisition and control," in *Real Time Conference, 1999. Santa Fe 1999. 11th IEEE NPSS, 1999*, pp. 140-143.
- [10] A. B. Maish et al., "Photovoltaic system reliability," in *Photovoltaic Specialists Conference, 1997., Conference Record of the Twenty-Sixth IEEE, 1997*, pp. 1049-1054.
- [11] F. Chan, and H. Calleja, "Design Strategy to Optimize the Reliability of Grid-Connected PV Systems," *Industrial Electronics, IEEE Transactions on*, vol. 56, no. 11, pp. 4465-4472, 2009.
- [12] F. Chan, H. Calleja, and E. Martinez, "Grid Connected PV Systems: A Reliability-Based Comparison," in *Industrial Electronics, 2006 IEEE International Symposium on, 2006*, pp.1583-1588.

- [13] T. Shimizu, K. Wada, and N. Nakamura, "Flyback-Type Single-Phase Utility Interactive Inverter With Power Pulsation Decoupling on the DC Input for an AC Photovoltaic Module System," *Power Electronics, IEEE Transactions on*, vol. 21, no. 5, pp. 1264-1272, 2006.
- [14] W. Bower, R. West, and A. Dickerson, "Innovative PV Micro-Inverter Topology Eliminates Electrolytic Capacitors for Longer Lifetime," in *Photovoltaic Energy Conversion, Conference Record of the 2006 IEEE 4th World Conference on*, 2006, pp. 2038-2041.
- [15] A. Ristow et al., "Development of a Methodology for Improving Photovoltaic Inverter Reliability," *Industrial Electronics, IEEE Transactions on*, vol. 55, no. 7, pp. 2581-2592, 2008.
- [16] F. Chan, and H. Calleja, "Reliability Estimation of Three Single-Phase Topologies in Grid-Connected PV Systems," *Industrial Electronics, IEEE Transactions on*, vol. 58, no. 7, pp. 2683-2689, 2011.
- [17] Y. Xiaoxiao, and A. M. Khambadkone, "Reliability Analysis and Cost Optimization of Parallel-Inverter System," *Industrial Electronics, IEEE Transactions on*, vol. 59, no. 10, pp. 3881-3889, 2012.
- [18] R. Singlachar, and B. Mukherjee, "An advanced PC-PLC-based SCADA system for a commercial medical cyclotron," *Nuclear Instruments and Methods in Physics Research Section A*:

- Accelerators, Spectrometers, Detectors and Associated Equipment, vol. 399, no. 2–3, pp. 396-406, 1997.
- [19] B. Dieu, “Application of the SCADA system in wastewater treatment plants,” *ISA Transactions*, vol. 40, no. 3, pp. 267-281, 2001.
- [20] M. Patel et al., “Development of a novel SCADA system for laboratory testing,” *ISA Transactions*, vol. 43, no. 3, pp. 477-490, 2004.
- [21] A. Orioli, and A. Di Gangi, “A procedure to calculate the five-parameter model of crystalline silicon photovoltaic modules on the basis of the tabular performance data,” *Applied Energy*, vol. 102, no. 0, pp. 1160-1177, 2013.
- [22] J. M. Blanes et al., “In-Site Real-Time Photovoltaic I-V Curves and Maximum Power Point Estimator,” *Power Electronics, IEEE Transactions on*, vol. 28, no. 3, pp. 1234-1240, 2013.
- [23] J. F. Randall, and J. Jacot, “Is AM1.5 applicable in practice? Modelling eight photovoltaic materials with respect to light intensity and two spectra,” *Renewable Energy*, vol. 28, no. 12, pp. 1851-1864, 2003.
- [24] S. R. Williams et al., “Modelling long-term module performance based on realistic reporting conditions with consideration to spectral effects,” in *Photovoltaic Energy Conversion, 2003. Proceedings of 3rd World Conference on*, 2003, pp. 1908-1911 Vol.2.

- [25] I. Caluianu et al., "Photovoltaic energy generation under partially shading conditions," in *Advanced Electromechanical Motion Systems & Electric Drives Joint Symposium*, 2009. *ELECTROMOTION 2009. 8th International Symposium on*, 2009, pp. 1-6.
- [26] K. F. Teng, and P. Wu, "PV module characterization using Q-R decomposition based on the least square method," *Industrial Electronics, IEEE Transactions on*, vol. 36, no. 1, pp. 71-75, 1989.
- [27] K. Araki, and M. Yamaguchi, "Novel equivalent circuit model and statistical analysis in parameters identification," *Solar Energy Materials and Solar Cells*, vol. 75, no. 3–4, pp. 457-466, 2003.
- [28] J. Merten et al., "Improved equivalent circuit and analytical model for amorphous silicon solar cells and modules," *Electron Devices, IEEE Transactions on*, vol. 45, no. 2, pp. 423-429, 1998.
- [29] J. Merten et al., "The role of the buffer layer in the light of a new equivalent circuit for amorphous silicon solar cells," *Solar Energy Materials and Solar Cells*, vol. 57, no. 2, pp. 153-165, 1999.
- [30] T. Ikegami et al., "Estimation of equivalent circuit parameters of PV module and its application to optimal operation of PV system," *Solar Energy Materials and Solar Cells*, vol. 67, no. 1–4, pp. 389-395, 2001.

- [31] E. Karatepe, M. Boztepe, and M. Çolak, "Development of a suitable model for characterizing photovoltaic arrays with shaded solar cells," *Solar Energy*, vol. 81, no. 8, pp. 977-992, 2007.
- [32] S. K. H. Chow, E. W. M. Lee, and D. H. W. Li, "Short-term prediction of photovoltaic energy generation by intelligent approach," *Energy and Buildings*, vol. 55, no. 0, pp. 660-667, 2012.
- [33] G. Capizzi, C. Napoli, and F. Bonanno, "Innovative Second-Generation Wavelets Construction With Recurrent Neural Networks for Solar Radiation Forecasting," *Neural Networks and Learning Systems, IEEE Transactions on*, vol. 23, no. 11, pp. 1805-1815, 2012.
- [34] A. Al-Amoudi, and L. Zhang, "Application of radial basis function networks for solar-array modelling and maximum power-point prediction," *Generation, Transmission and Distribution, IEEE Proceedings-*, vol. 147, no. 5, pp. 310-316, 2000.
- [35] M. T. Elhagry et al., "Fuzzy modeling of photovoltaic panel equivalent circuit," in *Circuits and Systems, 1997. Proceedings of the 40th Midwest Symposium on*, 1997, pp. 60-63 vol.1.
- [36] M. AbdulHadi, A. M. Al-Ibrahim, and G. S. Virk, "Neuro-fuzzy-based solar cell model," *Energy Conversion, IEEE Transactions on*, vol. 19, no. 3, pp. 619-624, 2004.

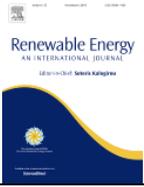
- [37] J. F. Gómez Fernández, Crespo Márquez, Adolfo, Maintenance Management in Network Utilities, London, 2012.
- [38] H. Eyring, "The Activated Complex in Chemical Reactions," The Journal of Chemical Physics, vol. 3, no. 2, pp. 107-115, 1935.
- [39] A. M. S. Friedenthal, and R. Steiner, A practical guide to SysML the systems modeling language, 2011.

6. APLICACIÓN DE REDES NEURONALES A LA DETECCIÓN DE FALLOS EN PLANTAS SOLARES FOTOVOLTAICAS

La línea de investigación descrita en este capítulo ha sido presentada en el Institute of Mathematics and Applications de Oxford con la siguiente referencia de publicación:

	<p><i>8th IMA International Conference on Modelling in Industrial Maintenance and Reliability Wadham College 10 July, St Catherine's College 11 - 12 July 2014, Oxford, UK</i></p>
	<p>To cite this article: <i>Maintenance optimization through dynamic failure mode reliability analysis. 8th IMA International Conference on Modelling in Industrial Maintenance and Reliability. F. Olivencia, J. Ferrero, J. Gómez, A. Crespo</i></p>

El desarrollo completo de este trabajo ha sido publicado en la revista *RENEWABLE ENERGY an International Journal* con la siguiente referencia de publicación:

	<p><i>Elsevier Renewable Energy, an International Journal 81, 227-238. ISSN: 0960-1481.</i></p>
	<p>To cite this article: <i>Polo, F. A. O., Bermejo, J. F., Fernández, J. F. G., & Márquez, A. C. (2015). Failure mode prediction and energy forecasting of PV plants to assist dynamic maintenance tasks by ANN based models. Renewable Energy, 81, 227-238.</i></p>
<p>Referencia de indicios de calidad:</p>	<p><i>Journal Citation Reports</i></p>
<p>Índice de impacto:</p>	<p>3.476 (5-Year: 3.982)</p>

6 APLICACIÓN DE REDES NEURONALES A LA DETECCIÓN DE FALLOS EN PLANTAS SOLARES FOTOVOLTAICAS

6.1 INTRODUCCIÓN

El modelo estadístico paramétrico desarrollado en el capítulo anterior, si bien permite detectar fallos en la planta mediante el establecimiento de una línea base de producción e incluso una caracterización razonablemente adecuada de los mismos, no permite adaptar fácilmente de forma dinámica los controles de fiabilidad. Para ello, se incorporó como herramienta de trabajo a esta línea de investigación la teoría de las redes neuronales.

Las energías renovables presentan una alta dependencia de la naturaleza aleatoria de los fenómenos climatológicos. Esta variabilidad tiene un impacto importante en los compromisos de producción establecidos en la legislación de muchos países. Por tanto, hay un gran interés en predecir la producción de las plantas, tanto en ausencia como en presencia de fallos, destacando hasta la fecha los siguientes enfoques:

- Predicción de variables climatológicas y uso de modelos físicos que consideren las curvas irradiancia-energía.
- Modelado estadístico de variables climatológicas.

Además de la necesidad de predicción del comportamiento de la planta, los sistemas fotovoltaicos conectados a red requieren una

monitorización más o menos avanzada en función de la tecnología (estructura fija, seguidor solar 1-eje, seguidor solar 2-ejes) seleccionada, para el funcionamiento regular y las comprobaciones de estado.

Los datos obtenidos del sistema de monitorización necesitan un adecuado análisis. De hecho, la detección automática de fallos en sistemas fotovoltaicos es un proceso complejo que requiere el registro de un gran número de variables eléctricas (corrientes y tensiones, principalmente, en todos los elementos), conjuntamente con variables ambientales (irradiancia y temperatura) [1,2]. Por este motivo, las operadoras de este tipo de instalaciones ejecutan costosos programas de mantenimiento que sólo tienen viabilidad económica en grandes instalaciones o con una concentración importante de pequeñas instalaciones.

Para simplificar este proceso y reducir la complejidad del proceso de detección de fallos, se han desarrollado nuevas propuestas que consideran un número más reducido de variables y análisis estadísticos complejos [3,4]. En este marco se encuentra la línea de investigación descrita en este capítulo, que considera la aplicación de redes neuronales para este fin.

Las redes neuronales (ANN: Artificial Neural Network) son herramientas matemáticas utilizadas de forma intensiva en la resolución de numerosos problemas complejos, especialmente en procesos de clasificación y predicción.

Las redes neuronales tratan de emular el comportamiento biológico de las neuronas humanas, aprendiendo de la experiencia pasada (datos históricos) y generalizando los comportamientos previos (series temporales).

El componente más simple de una red neuronal es la neurona, cuya misión es procesar un conjunto de entradas y activar una salida que a su vez se convierte en una nueva entrada para otra neurona enlazada (sinapsis). La combinación de las neuronas se puede representar como un grafo dirigido para el transporte y procesamiento de la información [5].

Las redes neuronales generalmente presentan una arquitectura basada en capas: capa de entrada, una o más capas ocultas y una capa de salida. Su principal característica es su capacidad de aprendizaje y generalización mediante el procesamiento de variables de forma no-lineal con un alto nivel de ejecución paralela, eliminando ruido en los datos [6,7,28].

En comparación con otros métodos, las redes neuronales tienen una gran capacidad de auto-adaptación computacionalmente eficiente, aprendiendo de ejemplos y capturando relaciones funcionales sutiles analíticamente difíciles de establecer.

Además, las redes neuronales proporcionan una alta tolerancia a la presencia de ruido en los datos debido a la gran cantidad de información que es posible utilizar en su entrenamiento.

Por tanto, las redes neuronales son adecuadas para la resolución de problemas donde el conocimiento explícito es difícil de especificar, pero donde existen suficientes datos [8-10]. En este sentido, en la referencia [11] se demuestra como las redes neuronales superan en un orden de magnitud los métodos convencionales de regresión lineal y polinómica para el tratamiento de series temporales caóticas.

La aplicación de estas técnicas al campo de las energías renovables, y más específicamente a los sistemas fotovoltaicos conectados a red ha estado en continuo desarrollo durante los últimos años en las áreas de:

- Predicción de variables meteorológicas [12,13]
- Dimensionado de plantas solares [14,17]
- Modelado, simulación y control [18]

Existen referencias de trabajos previos que utilizan redes neuronales en la predicción de la producción de plantas solares fotovoltaicas [19,20]. Sin embargo, nuestro trabajo se centra en el desarrollo de algoritmos para la detección temprana de fallos y la adaptación dinámica de los controles de fiabilidad, con la intención de ser incluido en los programas de mantenimiento predictivo dentro de un marco RCM (Reliability-Centered Maintenance).

6.2 SELECCIÓN DEL MODELO

El mantenimiento centrado en la fiabilidad (RCM) es la metodología más difundida para estudiar el programa de

mantenimiento de un activo dentro de un contexto operacional [21], cuantificar los riesgos [22] y evaluar las medidas a aplicar para detectar, eliminar o prevenir un fallo funcional [23].

Atribuibles a condiciones sub-óptimas de operación, los fallos a menudo ocurren en activos que sufren cambios en las condiciones ambientales (limpieza, estancamiento, temperatura, etc.) o de operación (configuración, mantenimiento preventivo, uso inadecuado, etc.), siendo su estudio complejo. Por otra parte, los defectos no evidentes en los activos (imperfección diseño, errores de ejecución, calidad de materiales, etc.) también pueden conducir a fallos [24,25].

El análisis de confiabilidad de equipos de energía renovable, de acuerdo con el método RCM, es una tarea muy compleja dependiendo de las condiciones ambientales y de funcionamiento.

Este análisis considera los efectos, en la función de los equipos, de los diferentes modos de fallo que degradan la funcionalidad de los mismos a través de las desviaciones de las condiciones de funcionamiento estándar [38]. Con base en datos reales como eventos históricos, esta degradación se puede observar o predecir siguiendo una curva de fallo.

Debido a su propia complejidad, este análisis está asociado a herramientas cuantitativas y tendrá que ser implementado principalmente en profundidad en los equipos críticos o equipo en el cual las consecuencias de los fallos no sean admisibles (debido a su impacto ambiental, seguridad y salud, etc.).

Un ejemplo de este tipo de análisis es el conocido como Survival Data Analysis, centrado en un grupo de activos y cómo reaccionan al fallo después de cierto período de tiempo [29-31]. La información sobre estos factores puede ser decisiva para derivar, e incluso para actualizar con el tiempo, las estimaciones de fiabilidad sobre la contribución de algunos eventos, representada a través de variables explicativas, para obtener el tiempo hasta el fallo (Tiempo de supervivencia).

Existen varias técnicas para resolver las estimaciones de supervivencia [32,33], en el que las funciones típicas de distribución de fracaso son asimétricas (censurado a la derecha). La influencia de estos factores explicativos puede obedecer a diferentes patrones que podrían ser luego utilizados para calcular el riesgo real de un activo.

Esta técnica basada en variables explicativas podría ser paramétrica, cuando las distribuciones de riesgo son conocidas, semiparamétrica cuando la distribución de riesgos es desconocida pero con supuestos de proporcionalidad en el tiempo e independencia de las variables, o no paramétrica, cuando estas no son necesarias para especificar el tiempo de supervivencia [34-36].

En el mantenimiento, la toma de decisiones, por lo general, se caracteriza por efectuarse en condiciones de incertidumbre y el estudio de la evolución histórica de las variables no controladas o de su relación con otras variables. En la práctica, con un conocimiento limitado, los técnicos de mantenimiento se sienten a menudo más

seguros tomando decisiones conservadoras en base a su experiencia, en lugar de ser óptima [47].

Por lo tanto, se recomienda para mejorar la capacidad de decisión usar los marcos formales que son adecuados para el nivel de información requerida y de los datos que están disponibles. Es preferible utilizar herramientas cuantitativas para buscar una mayor precisión en la elección de estrategias, pero esta es la elección de lo que es "mejor", entre lo que es "posible" [48].

Además, el proceso de decisión es interactivo, no sólo para predecir algo, sino para replicar la realidad; debe ser actualizable con la mejora continua en obtener y compartir conocimientos.

Los métodos paramétricos, como Weibull, modelos actuariales y gráficos (EM), se emplean generalmente cuando se dispone de suficiente información acerca de los errores con un patrón regular, para generar un modelo de fallos, la mayoría de las veces, a medida de cada equipo.

Por otro lado, como previamente se ha mencionado anteriormente, se utilizan métodos semiparamétricos, como el Proportional Hazard Model (PHM) de Cox [37], basado en una expresión log-lineal-polinómica de las covariables bajo la hipótesis de independencia entre ellas y constante con el tiempo, cuando se desconoce la distribución de fallos.

Entre los métodos no paramétricos destacan aquellos que utilizan redes neuronales, por su naturaleza auto-adaptativa, incluso

ante información ruidosa y la existencia de relaciones no lineales entre las covariables.

Todas estas técnicas: paramétricas, semiparamétricas y no-paramétricas, se emplean para estimar la función de fiabilidad dependiendo del grado de conocimiento de que se disponga en relación con la distribución del tiempo de fallo (de mayor a menor, respectivamente), aumentando la carga computacional cuanto más flexible sea el método (de menor a mayor, respectivamente) [39].

Además, en numerosos trabajos [39,40], el PHM y ANN se comparan en la adaptación de funciones de supervivencia, no mostrando diferencias significativas entre las predicciones de regresión de Cox y modelos de redes neuronales cuando la complejidad de los modelos es baja.

En el caso de los modelos complejos, con muchas variables y términos de interacción las ventajas de la aplicación de redes neuronales son importantes:

- Las predicciones ANN eran mejores que las predicciones Cox PHM con altas tasas de censura (tasa de 60% o más) [46].
- Las predicciones ANN ofrecen mejores predicciones en presencia de relaciones no lineales complejas entre las variables.

- Las predicciones ANN pueden incorporar factores pronósticos que pueden haber sido pasados por alto en el pasado.

Como resultado, la toma de decisiones en las actuaciones preventivas de los activos puede ser apoyada por el uso de redes neuronales ya que:

- Es adecuada al grado de conocimiento de la naturaleza de los fallos.
- Su puede implementar en sistemas SCADA.
- Es actualizable de forma iterativa, conforme a la experiencia.
- Es flexible y se puede integrar jerárquicamente.

De acuerdo con los párrafos anteriores, la contribución principal de trabajo es una herramienta de decisión lógica que permite predecir la producción de sistemas fotovoltaicos conectados a red, y que al mismo tiempo es un elemento a incluir dentro del programa de mantenimiento preventivo alineado con los programas RCM para controlar los modos críticos de fallo.

Para verificar las hipótesis de esta investigación, se han aplicado los modelos de redes neuronales en el escenario descrito. La red neuronal considerada es un perceptrón sin realimentación [50], compuesta por una capa de entrada de P neuronas, correspondientes a un vector P-dimensional, $X = (X_1, X_2, \dots, X_P)$, una capa intermedia

(también denominada oculta) con M neuronas, y una capa de salida con 1 neurona, Y.

La salida de cada neurona (i) de la capa de entrada tiene un valor igual a la componente X_i , mientras que la salida de cada neurona de la capa intermedia Z_m (1) es igual a la función de activación σ de una combinación lineal de las componentes de entrada X_i corregida por un umbral α_0^m [50].

$$Z_m = M_m = \sigma(\sum_{i=0}^P \alpha_i^m \cdot X_i); X_0 = 1 \quad (1)$$

Las funciones de activación más comunes son la sigmoide (2) y la tangente hiperbólica (3).

$$\sigma(x) = \frac{e^x}{(1 + e^x)} \quad (2)$$

$$\sigma(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3)$$

La salida de la red neuronal, Y (4), es una función (generalmente la identidad en problemas de regresión) de la combinación lineal de las salidas de las neuronas de la capa intermedia corregida por otro umbral β_0 , considerando $M_0 = 1$.

$$Y = f(x) = g(\sum_{j=0}^M \beta_j \cdot M_j) \quad (4)$$

Todos los pesos utilizados en las combinaciones lineales mencionadas anteriormente son aprendidos mediante en el entrenamiento de la red neuronal. El algoritmo seleccionado para el

entrenamiento de la red neuronal es el conocido como de propagación hacia atrás (back-propagation), utilizado con frecuencia en perceptrones multicapa [27] donde las funciones de activación de las neuronas son diferenciables (lineal, sigmoide y tangente hiperbólica) en conjunción con métodos de optimización como el gradiente descendente.

La suma cuadrática de los errores, R (5), en un conjunto de entrenamiento de N elementos $T = \{(X^{(i)}, Y^{(i)}) | i \in \{1, \dots, N\}\}$, es optimizada utilizando un método quasi-newton incluyendo únicamente los términos en primera derivada (6,7), definiendo los siguientes vectores:

- $M^{(i)} = (\mathbf{1}, Z_1(X^{(i)}), \dots, Z_m(X^{(i)}), \dots, Z_M(X^{(i)}))$
- $\beta = (\beta_0, \beta_1, \dots, \beta_m, \dots, \beta_M)$
- $\alpha_m = (\alpha_0^m, \alpha_1^m, \dots, \alpha_j^m, \dots, \alpha_p^m)$

$$R = \sum_{i=1}^N R_i = \sum_{i=1}^N (Y^{(i)} - f(X^{(i)}))^2 \quad (5)$$

$$\frac{\partial R_i}{\partial \beta_m} = -2 (Y^{(i)} - f(X^{(i)})) g'(\beta^T M^{(i)}) M_m^{(i)} = \delta^{(i)} \cdot M_m^{(i)} \quad (6)$$

$$\frac{\partial R_i}{\partial \alpha_j^m} = -2 (Y^{(i)} - f(X^{(i)})) g'(\beta^T M^{(i)}) \beta_m \sigma'(\alpha_m^T X^{(i)}) X_j^{(i)} = s_m^{(i)} \cdot X_j^{(i)} \quad (7)$$

El algoritmo de propagación hacia atrás de los errores consiste en los siguientes pasos [51]:

- **Inicialización.** Las variables de entrada son normalizadas con media 0 y varianza 1. Se seleccionan

valores iniciales de los pesos próximos a 0. De esta forma la red neuronal comienza su proceso de aprendizaje de forma casi lineal. Se ejecuta un bucle de un máximo de R pasos, donde cada iteración r se ejecutan una serie de acciones *hacia delante* y *hacia atrás*.

- **Hacia delante:**

- Se selecciona un vector del conjunto de entrenamiento: $\mathbf{X}^{(i)} = (\mathbf{X}_1^{(i)}, \mathbf{X}_2^{(i)}, \dots, \mathbf{X}_P^{(i)})$
- Se procesa este vector de entrada a través de la red neuronal y se calcula la salida $\widehat{Y}^{(i)(r)}$
 - En la capa oculta, el valor de salida de cada neurona se calcula aplicando la función de activación a la combinación lineal de las entradas (1), considerando como pesos el vector $\alpha^{(r)}$.
 - La salida de la red neuronal, $\widehat{Y}^{(i)(r)}$, se calcula conforme a la expresión (4), considerando como pesos el vector $\beta^{(r)}$.
- Dependiendo de la aproximación seleccionada para implementar el algoritmo del gradiente descendente, se calculará en cada iteración la salida

correspondiente a uno, varios o todos los elementos del conjunto de entrenamiento.

- **Hacia atrás:**

- Se actualizan los pesos conforme a las expresiones (8,9), donde γ_r es el parámetro conocido como tasa de aprendizaje, utilizando a su vez las fórmulas (6,7)

$$\beta_m^{(r+1)} = \beta_m^{(r)} - \gamma_r \sum_{i=1}^N \frac{\partial R_i^{(r)}}{\partial \beta_m} \quad (8)$$

$$\alpha_j^{m(r+1)} = \alpha_j^{m(r)} - \gamma_r \sum_{i=1}^N \frac{\partial R_i^{(r)}}{\partial \alpha_j^m} \quad (9)$$

- **Condiciones de finalización:**

- Los pasos hacia adelante y hacia atrás se repiten hasta que la expresión (5) es optimizada siendo la diferencia existente entre dos iteraciones inferior a un umbral predefinido o se ejecuta el número máximo de pasos establecido.
- Debido a la no linealidad de la expresión (4) el mecanismo de aprendizaje requiere de un algoritmo heurístico que garantice que se alcanza un mínimo global (esto se realiza mediante un método quasi-newton en el software libre R o el método de Levenberg-Marquardt en Matlab). Sin embargo, alcanzar un mínimo global puede suponer un sobreajuste y falta de capacidad de generalización

del modelo, por lo que se emplea un versión regularizada (10) de la expresión (5).

$$L = R + \lambda \cdot \left(\sum_{i=0}^M \beta_i^2 + \sum_{i=0, j=0}^{i=P, j=M} \alpha_i^{j^2} \right) \quad (10)$$

Es importante señalar que dentro del proceso de validación cruzada seguido para determinar la arquitectura óptima de la red se han contemplado los siguientes supuestos:

- **Número de neuronas de la capa oculta.** El parámetro λ en (10) modula la fuerza de los diferentes pesos, de tal forma que es posible entrenar la red neuronal con un alto número de neuronas en la capa oculta y descartar aquellas con pesos poco significativos. En cualquier caso no es recomendable emplear en la capa oculta más del doble de neuronas que el número de variables de entrada [51,52].
- **Pesos iniciales.** Son seleccionados aleatoriamente varias veces y el algoritmo es ejecutado para cada conjunto inicial.
- **Selección de la función de activación.** Se emplea la función logística (sigmoide) como función de activación de las neuronas de la capa oculta, mientras que en la capa de salida se utiliza la identidad.

6.3 CASO PRÁCTICO

La tecnología solar fotovoltaica está incorporada en sistemas de producción con más de 25 años. Las reducciones en los incentivos a la generación de energía eléctrica a partir de fuentes renovables han obligado a las compañías a estudiar las posibilidades de extensión de la vida útil de los componentes de las mismas.

Debido a esto, se deben de re-evaluar los planes de reinversión incorporando las futuras condiciones ambientales y de operación y realizando un análisis de la fiabilidad de los equipos para evitar futuras interrupciones en la producción.

La inversión en cada bloque de 100 Kwp en la planta El Molino Energía supuso una cantidad de cerca de 600K€. Este tipo de configuración es comúnmente empleado, por lo que es posible extrapolar los resultados de este estudio a numerosas instalaciones.

Nuestros modelos de producción basados en redes neuronales presentan aportaciones importantes al estado del arte. Los modelos desarrollados emplean no sólo las variables de entorno como la temperatura o la radiación externa, sino también las variables de operación de los activos como la temperatura interna y los tiempos de funcionamiento.

Gracias a estos modelos es posible la detección temprana de la degradación del sistema y una medida cuantitativa del riesgo. Es importante conocer cómo el riesgo de fallos incluso puede llegar a representar diez veces el costo de adquisición de los equipos [26]. El

modelo debe, asimismo, considerar todo el coste del ciclo de vida de los equipos: garantías, reparaciones, indemnizaciones, sanciones, etc.

El análisis de fallos tiene que ser realizado por cada modo de fallo crítico del sistema, ya que los síntomas y las causas pueden ser diferentes entre ellos, y su efecto en las condiciones de funcionamiento del equipo podría ser diferente.

En nuestro caso de estudio se ha considerado un análisis funcional y de modos de fallo de tipo FMECA (Failure Mode Effect and Criticality Analysis) realizado con antelación en la planta, donde se seleccionaron 2 componentes fundamentales del sistema de producción: los inversores y los seguidores solares.

La planta solar fotovoltaica El Molino Energía se encuentra en producción desde septiembre de 2008 con una potencia instalada de 6,1 MWp. En ella hay 1.342 seguidores solares con un total de 37.180 paneles fotovoltaicos organizados en agrupaciones de 100 KWp. Los seguidores solares orientan los paneles fotovoltaicos hacia el sol para maximizar la energía solar recogida, mientras que el inversor transforma la corriente continua (DC) en alterna (CA) y es enviada a un centro de transformación en conjuntos de 4 o 5 inversores. En la Tabla 3 se puede observar la configuración de uno de los transformadores de la planta.

Los aspectos de fiabilidad son importantes, no sólo para considerar los costos directos de los fallos, sino también el lucro

cesante. Las modificaciones introducidas en el sistema de gestión estarán orientadas a la anticipación de estos fallos.

CT	ID	KWn	Ref. module	N° strings	N° panels strings
CT15	A8-1	100	IS-220	528	12
	A8-2	100	IS-220	528	12
	A8-3	100	IS-220	528	12
	A8-4	100	IS-220	528	12
	A8-5	100	IS-220	528	12

Tabla 3. Configuración típica de estructura de producción por centro de transformación de la planta

Los modos de fallo analizados son aquellos que son consecuencia del deterioro de los equipos y de la reducción de la vida útil de los mismos debido a las condiciones ambientales y de operación. Para ello se utilizan las series de producción de los últimos 5 años, conjuntamente con las de las variables ambientales y las condiciones de operación.

El mantenimiento centrado en la fiabilidad contempla un proceso genérico para la selección lógica de las actuaciones de mantenimiento con el objeto de prevenir o eliminar la ocurrencia de un modo de fallo [21]. Como extensión de este método para considerar actuaciones de mantenimiento basadas en la condición se propone el proceso ilustrado en la Figura 30, que consiste en los siguientes pasos:

- El flujo comienza con la inspección y recolección de datos de fallo, así como su relación con las condiciones ambientales y de operación.
- A continuación se evalúa si es posible obtener una función de pérdidas gradual para estos factores.

- Posteriormente se desarrolla el análisis de los modos de fallo y su relación con la función de pérdidas.
- Después, se emplea un árbol lógico de decisión para seleccionar entre los diferentes modelos de predicción:
 - Sí hay suficientes datos para hacer un entrenamiento estadístico conforme a una distribución conocida o hay linealidad con las variables, los modelos paramétricos son recomendables.
 - Si hay suficientes datos relativos a los fallos, pero no se puede hacer un modelado estadístico y se cumplen las condiciones de proporcionalidad entre los riesgos y las variables e independencia entre las mismas, siendo la tasa de censura inferior al 60%, se sugiere el empleo de PHM Cox.
 - Si no hay suficientes datos relativos a los fallos, independientemente de que sea posible su modelado estadístico o no, y no hay censura, pero hay suficientes datos de variables de control del proceso aunque sea en presencia de ruido, es recomendable emplear redes neuronales (incluso para reproducir funciones físicas complejas).
 - Cuando hay suficientes datos relativos a los fallos pero no es posible el modelado estadístico y existe una interacción compleja con el ruido y dependencia temporal entre las variables, o la tasa de censura de

los datos es superior al 60%, se recomienda también el empleo de redes neuronales. Aunque en este caso existe la limitación de que el conjunto de datos debe ser reorganizado para replicar la función de supervivencia.

- A continuación se define el mecanismo de detección y se evalúan mediante un análisis coste beneficio las distintas alternativas posibles, con carácter previo a su implementación y a la comunicación a la organización.
- Para una mejora continua del proceso, una vez implantado, se utilizarán los propios datos recolectados del servicio.

En este trabajo de investigación se han desarrollado dos modelos basados en la aplicación de redes neuronales, demostrando la capacidad de estas técnicas para replicar procesos complejos de forma auto-adaptativa en entornos ruidosos:

- Caso A) en ausencia de suficientes datos para caracterizar estadísticamente el modo de fallo, reproduciendo la producción de energía del sistema (inexistencia de expresión analítica).

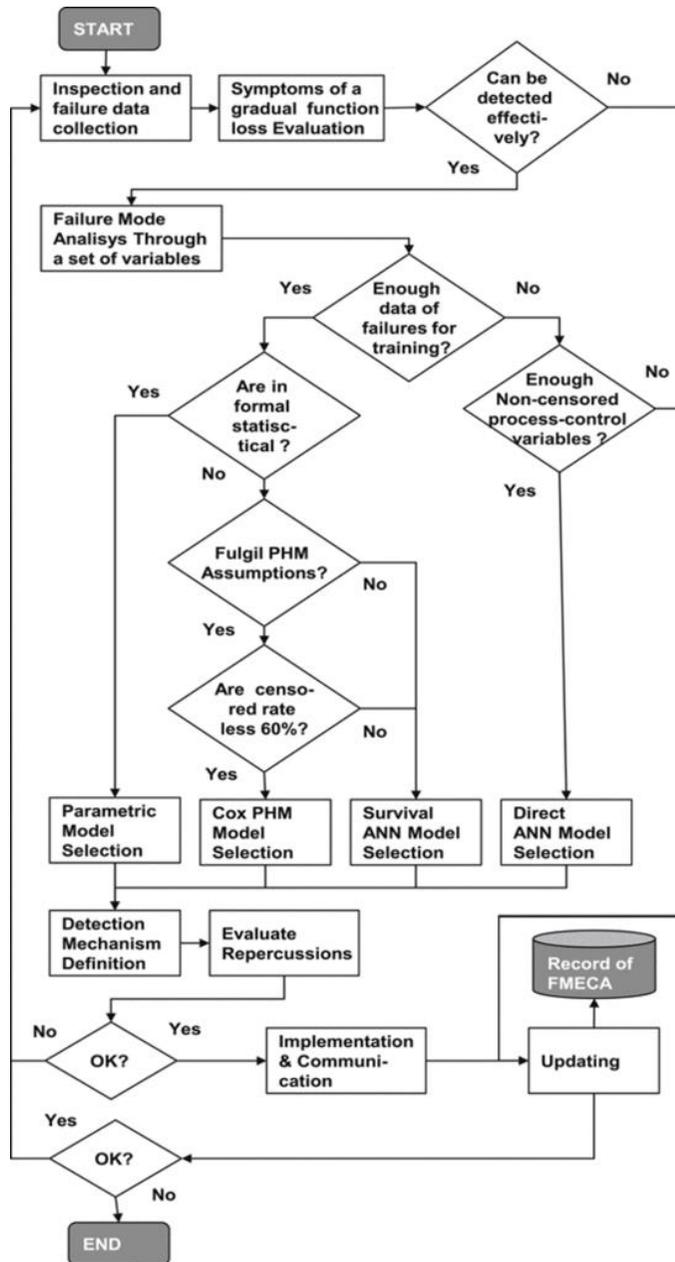


Figura 30. Lógica de decisión para la selección del modelo

- Caso B) en ausencia de suficientes datos para caracterizar estadísticamente el modo de fallo, pero en número suficiente para entrenar la red neuronal en presencia de interacciones complejas de las variables, modelando la función de supervivencia de los motores de los seguidores solares.

En ambos casos, para la aplicación del método en tiempo real, se han seleccionado variables disponibles en el SCADA con la suficiente tasa de refresco. Las variables han de ser normalizadas para independizar su contribución de la escala utilizada, en aras de facilitar el análisis y discriminación de fallos.

Caso A) Predicción del modo de fallo de pérdida de aislamiento

El modo de fallo seleccionado corresponde a la pérdida de aislamiento en un módulo inversor, debido a su impacto significativo en las pérdidas de producción. Este fallo es identificado en el SCADA como prioritario.

Este fallo se manifiesta debido a la corrosión y a las condiciones ambientales, con independencia del tiempo de funcionamiento del equipo. Las variables ambientales y las más representativas de la operación han de ser seleccionadas para evaluar sus efectos en el modo de fallo. Las variables disponibles en el SCADA en el caso de los inversores de potencia son: temperatura ambiental (°C), temperatura interna del inversor (°C), la irradiancia global horizontal

(W/m²), el tiempo de operación del inversor (h) y la energía activa producida de forma acumulada en el inversor (KWh).

En este escenario no hay suficientes datos para poder caracterizar estadísticamente el fallo. Por tanto, la predicción puede realizarse sobre las variables de control del proceso, aunque no con una función de transferencia analítica sino mediante otras aproximaciones [1,49], entre las que se encuentra el uso de las redes neuronales.

La arquitectura de la red neuronal tiene que ser desarrollada en función del número de variables de entrada y la complejidad de la función de estimación (ver Figura 31). El modelo de red neuronal propuesto tiene una capa de entrada con 5 neuronas, correspondientes a la temperatura ambiental (°C), la temperatura interna del inversor (°C), la radiación global horizontal (W/m²), el tiempo de operación del equipo (h), ver tabla Tabla 4, y una neurona de ajuste.

Variable	Max	Ref	Min	Unit
Ambient temperature	61	37	1	°C
Internal temperature	57	40	17	°C
Global horizontal radiation	1,291	644	10	W/m ²
Operation time		49,640		h
Accumulated active energy	99	60	1	KWh

Tabla 4. Variables de trabajo caso A

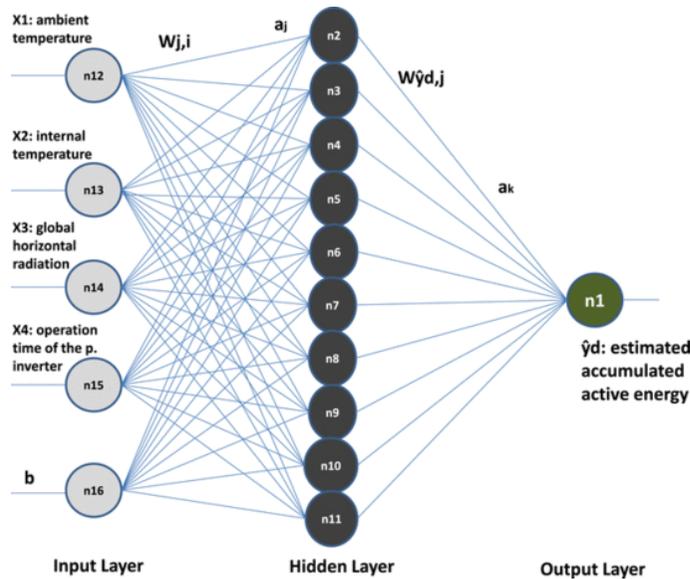


Figura 31. Arquitectura red neuronal Caso A)

La capa de salida contiene una única neurona que corresponde a la energía estimada por el modelo en condiciones de ausencia de fallo. Se han contemplado, además, los siguientes supuestos:

- Histórico de datos de los últimos 5 años.
- Selección de periodos de tiempo en los que se presenta el modo de fallo analizado.
- En el caso de reparación de los activos a consecuencia del modo de fallo, se consideran como nuevos con posterioridad a la reparación.
- El 75% de los registros se utiliza para el entrenamiento y validación cruzada, y el 25% para el test.

Los parámetros utilizados para el entrenamiento de la red fueron los siguientes: a) máximo número de ciclos = 980, b) máximo

número de fallos de validación = 40, c) $\text{min_grad} = 1.0\text{e-}10$, d) $\text{goal} = 0$, e) $\mu = 0.005$, f) $\mu_dec = 0.1$, g) $\mu_inc = 10$, h) $\lambda = 0$, i) $\text{min Error} = 19.47$. Los resultados obtenidos en este caso garantizan la consecución de un buen modelo de optimización, como se muestra en la Tabla 5.

Results	Value
MSE training	72.47686
MSE test	83.41932
R2 training	0.910275
R2 test	0.8912438

Tabla 5. Resultados test caso A

La red es entrenada con datos históricos procedentes de periodos de funcionamiento en ausencia de fallos. Con este modelo de red estimaremos la energía acumulada por un inversor en un periodo horario (\hat{y}_d), para compararla con la energía real producida en el mismo periodo (y_d).

La desviación existente entre el modelo de producción ideal y la producción real será utilizada para detectar de forma temprana la aparición del modo de fallo analizado, no sólo en el elemento bajo consideración, sino también en otros elementos análogos de la planta.

El modelo explica el 89.12% de la producción real. La Figura 32 representa las predicciones obtenidas, indicando la mejor aproximación para la minimización del error con una línea recta.

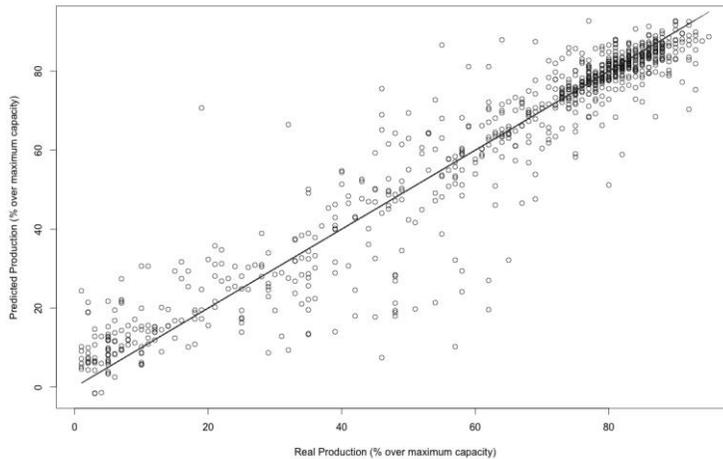


Figura 32. Predicciones red neuronal caso A)

Una vez que el modelo es validado se debe definir el mecanismo de detección. Considerando el entrenamiento realizado con cinco años de datos, el modelo de producción ideal pretende ser una aproximación a la producción real en estados de ausencia de fallos, a través del proceso de aprendizaje experimentado en la red neuronal (modificación de los pesos de las diferentes combinaciones lineales que forman parte de una función no-lineal).

La producción ideal debe ser comparada con la real, de tal forma que se pueda detectar con la suficiente antelación la existencia de fallos. En este caso práctico, que analiza el modo de fallo de pérdida de aislamiento, es posible detectar con al menos 48 horas de antelación la existencia probable del mismo. Téngase en cuenta que

en este caso la diferencia entre la producción real y la estimada es de un 40%.

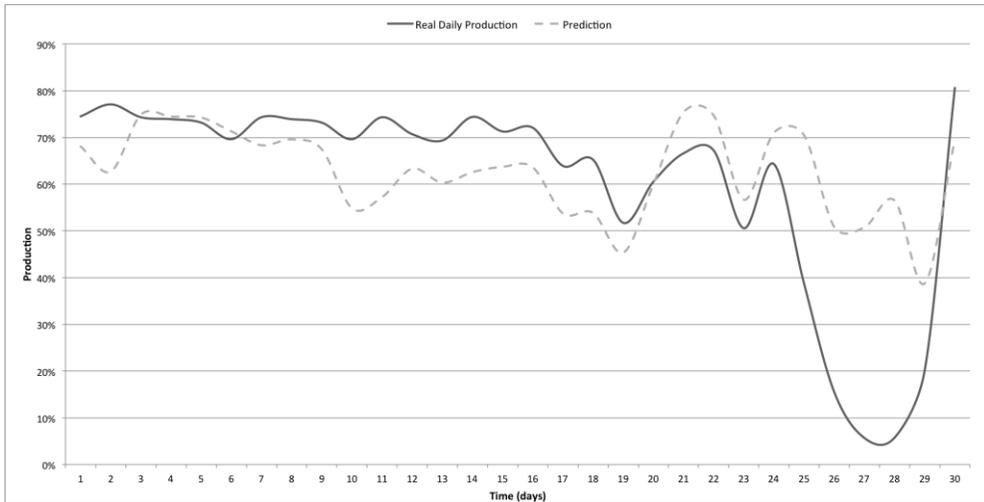


Figura 33. Comparación producción real frente a predicción

Para proteger el sistema de detección de la generación de falsas alarmas, se mantiene el umbral del 40% de caída de producción durante 4 horas consecutivas para el envío de la misma, solicitando la planificación inmediata de una acción correctiva. En la Tabla 6 se resume este proceso.

Date	Time	Real Production	Ideal Production	Alarm Counter
25-9-12	10	85.03	73.9	0
25-9-12	11	52.82	81.4	0
25-9-12	12	35.88	83.5	1
25-9-12	13	47.99	83.7	2
25-9-12	14	43.59	81.1	3
25-9-12	15	26.37	74.1	4
25-9-12	16	21.06	77.6	5
25-9-12	17	33.69	83	6

Tabla 6. Detección de evento de identificación de fallo de aislamiento

De esta forma, el modelo puede ser fácilmente implementado en el SCADA de la planta y replicado para todos los inversores de la misma, así como de otras plantas y el conocimiento respecto a este modo de fallo puede ser ampliado incorporando los resultados obtenidos de otros modelos de inversores, redefiniendo el modelo o incorporando variables adicionales, nuevas o derivadas de las anteriores, como por ejemplo, la diferencia entre la temperatura ambiente y la de funcionamiento de los equipos, tratando de obtener umbrales de comparación que permitan alcanzar una anticipación mayor a las 48 horas de este caso práctico.

Gracias a esta investigación del modo de fallo de la pérdida de aislamiento se redujo el coste indirecto, así como el lucro cesante en 68.591 € en la planta (575 KWh/día con MTBF de 3 ocurrencias de fallo anuales y 61 elementos). Es más extrapolando estos datos al ciclo de vida de la planta (25 años), los beneficios derivados de la implementación de este sistema alcanzan la producción de uno de sus elementos durante 5 años.

El modelo generado para esta planta se aplicó en otras dos plantas fotovoltaicas de diferentes ubicaciones geográficas en España: Toledo y Zamora, donde las condiciones ambientales y de operación son diferentes. En ambas, el modelo de red neuronal predijo el modo de fallo de pérdida de aislamiento en el inversor pero de forma más suave que en el caso de Córdoba, debido, principalmente, a la diferencia de las variables meteorológicas (ver Figura 34).

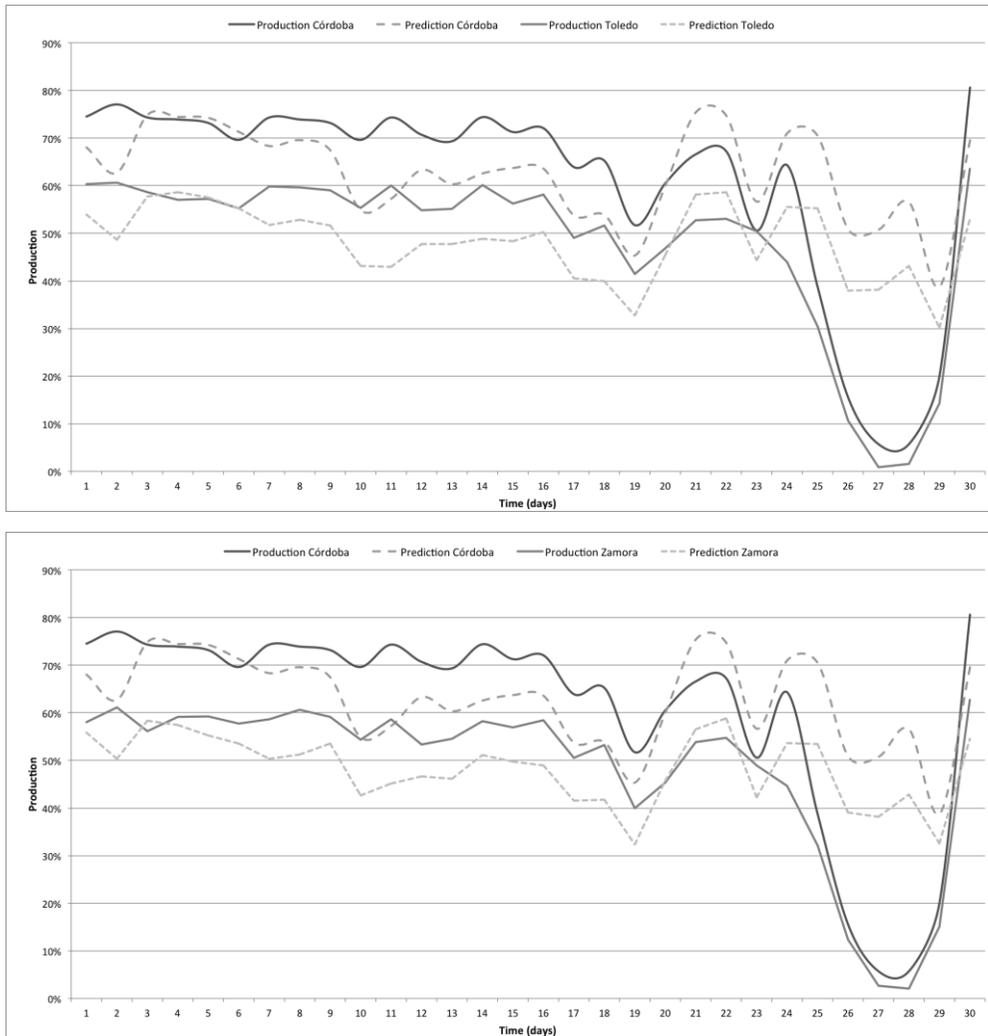


Figura 34. Comparación producción real frente a predicción en otras plantas de Zamora y Toledo

Caso B) Predicción del modo de fallo de bloqueo de seguidor solar

El modo de fallo seleccionado en el seguidor solar es el fallo de bloqueo, que se repite con frecuencia en campo debido al alto número de seguidores desplegados. Este modo de fallo se origina por la corrosión, siendo las condiciones ambientales determinantes para su aparición así como el tiempo de operación.

Este caso práctico está caracterizado por la presencia de suficientes datos asociados a los fallos, pero no es posible su modelado estadístico debido a la fuerte variación entre plantas y a la alta tasa de censura en los datos. Por tanto, la predicción se puede realizar modelando la función de supervivencia con una red neuronal.

Se han seleccionado las variables de operación y ambientales más representativas (ver Tabla 7) para analizar su efecto en el modo de fallo en el SCADA: medias diarias de la humedad (%), velocidad del viento (m/s), radiación global horizontal (W/m²) y el tiempo de operación del seguidor (días).

Variable	Max.	Ref.	Min.	Unit
Tiempo	400	205	10	h
Humedad relativa	100	74.5	27.3	%
Velocidad Media Viento	17.2	4.59	0.6	m/s
Radiación Global	379.5	106.64	1.4	W/m ²
Supervivencia	1	0.5	0	

Tabla 7. Variables de trabajo caso B

Sin embargo, para implementar la función de supervivencia es preciso reorganizar los datos disponibles, ya que hay que considerar los eventos de fallo. En función del modo en que se incluyan, se generan diferentes modelos de redes neuronales [39,40], por ejemplo:

- Empleando redes neuronales en lugar de las combinaciones lineales de los coeficientes en un modelo Cox PHM, conforme al trabajo de Farragi y Simon [41], siendo necesario resolver el problema mediante Partial Maximum Likelihood Estimation (P-MLE).
- Usando una entrada con el estado de supervivencia en intervalos disjuntos de tiempo donde las variables son replicadas con una variable binaria cuyo valor es 0 antes del evento de fallo y 1 con posterioridad al mismo, conforme al trabajo de Liestol et al. [42] y Brown et al. [43] constituyendo, por tanto un vector del estado de supervivencia.
- Utilizando un estimador de Kaplan-Meier (K-M) para definir los intervalos de tiempo como dos entradas adicionales, en lugar de un vector: una de ellas es la secuencia de intervalos de tiempo definida por el estado de supervivencia, y la otra el estado de supervivencia en sí. Este es el caso de los trabajos de Radvin y Clark [44] y los modelos de Biganzoli et al. [45] (estos últimos conocidos como modelos proporcionales de Kaplan-Meier).

De forma análoga al caso A), se utiliza en este caso práctico la misma arquitectura de red neuronal anteriormente propuesta, pero enfocando su uso en las ideas de Radvin y Clark con algunas modificaciones matemáticas:

- Se emplean intervalos disjuntos (para todos los casos de fallo) cuya duración es el máximo tiempo de fallo, para ser coherentes con el nivel de información del fallo disponible, en lugar de utilizar los intervalos de la estimación de Kaplan-Meier.
- Se utilizan variables en cada periodo de tiempo que se actualizan iterativamente (media) en lugar de repetir los valores.
- Se genera una estimación paramétrica a partir de una distribución de Weibull del estado de supervivencia, en lugar de emplear el estimador de Kaplan-Meier, para ajustar la curva mejor y reducir el efecto negativo de una curva de supervivencia que no fuese monótonamente decreciente.

Con estos supuestos, el modelo definido tendría como entrada la humedad ambiente (%), velocidad del viento (m/s), radiación global horizontal (W/m²), tiempo de operación del seguidor solar (días) y estado de supervivencia (modelado a partir de la Weibull), mientras que la salida de la red se corresponde con la estimación de la función de supervivencia.

El modelo semiparamétrico de Weibull consiste en crear intervalos de tiempo, de duración igual al máximo tiempo de fallo, donde en lugar de mantener una simple variable binaria con el estado del fallo, se utiliza un valor creciente entre 0 y 1. El algoritmo desarrollado consiste, por tanto, en:

- Estimar la función de supervivencia con una Weibull paramétrica sobre grupos donde las variables sean las mismas. Por ejemplo (ver Tabla 8), si se analizan 8 fallos en dos plantas fotovoltaicas, se generan dos modelos de Weibull, uno para cada planta, sin considerar las variables, únicamente los tiempos entre fallos.
- Mantener la β en cada planta y utilizarla conjuntamente con el tiempo de fallo para estimar la función de supervivencia en cada fallo con un incremento gradual entre 0 y 1 a partir de la función de distribución de Weibull (CDF) en cada intervalo de tiempo.

De esta forma se generan las dos entradas adicionales a la red neuronal: una con los intervalos de tiempo y la otra con la función de distribución de Weibull muestreada en dichos intervalos. Aunque para ajustar la función de distribución con un incremento gradual desde el instante inicial hasta el momento exacto del fallo, se utiliza una β ponderada por 0,693 (vida mediana: $\alpha \cdot \ln 2^\beta ; \beta = 1$). De esta forma, para cada fallo particular, la probabilidad de fallo aumenta hasta 1 en el momento de fallo y después.

En (11) se representa con F_n el número de fallo de la planta, con TTF_i el tiempo hasta el fallo, con t_i el intervalo de tiempo y con α_i , el α ponderado.

$$CDF(t) = \begin{cases} 1 - \left(1/e^{\left(\frac{t_i}{0,693 \cdot TTF_i} \right)^\beta} \right) & \text{if } t_i < TTF_i \\ 1 & \text{if } t_i \geq TTF_i \end{cases} \quad (11)$$

Pv1 Fn	TTF _i	Pondered α _i	Pv2 Fn	TTF _i	Pondered α _i
1	105.82	73.34	1	305.58	211.77
2	88.59	61.39	2	119.36	82.71
3	84.06	58.25	3	277.89	192.57
4	128.03	88.73	4	110.34	76.47
5	88.28	61.18	5	99.94	69.26
6	167.21	115.88	6	134.14	92.96
7	188.90	130.91	7	170.53	118.18
8	181.78	125.97	8	375.92	260.51
α	144.15		α	226.58	
β	3.47		β	2.19	

Tabla 8. Modelo de Weibull semiparamétrico para reorganización de datos de supervivencia

En la Tabla 8 se muestran 16 fallos de plantas (F_n) con sus tiempos de fallo (TTF), los valores iniciales de α y β , así como α_i . De esta forma, los datos para el entrenamiento y test de la red neuronal se reorganizacon como se muestra en la Tabla 9 para el fallo número 1.

Failure Number (Fn)	1	1	1	1	1	1	1	1	1	1	1
Time Interval	10	20	30	40	50	60	70	80	90	100	110
Ambient humidity (%)	95	93	99	91	95	92	84	62	40	53	89
Wind Speed (m/s)	11	8.8	6.7	11.3	6.7	11.6	10.9	12.1	8.2	7.3	4.3
G.H.Radiation (W/m2)	35.4	53.4	43.5	31.9	38.7	51.7	80.1	68.1	54.7	68	86
Weibull CDF	0.001	0.011	0.044	0.115	0.232	0.392	0.573	0.741	0.869	0.947	1

Tabla 9. Reorganización de datos de supervivencia para entrenamiento de red

La salida de la red neuronal es una estimación de la probabilidad de fallo (CDF), aprendiendo de una estimación semiparamétrica de Weibull afectada por las variables, ligeramente proporcional a una función de supervivencia de Weibull.

El cómputo de la red neuronal sigue un proceso de validación cruzada análogo al del caso A), siendo los parámetros del algoritmo de aprendizaje los siguientes: a) máximo número de ciclos = 1000, b) máximo número de fallos de validación = 40, c) $\text{min_grad} = 1.0\text{e-}10$, d) $\text{goal} = 0$, e) $\mu = 0.005$, f) $\mu_dec = 0.1$, g) $\mu_inc = 10$, h) $\lambda = 0$, i) $\text{min Error} = 0.00001833$. Los resultados garantizan un buen modelo de optimización, como se muestra en la Tabla 10. Mientras que si hubiésemos empleado directamente el modelo de Ravdin y Clark los resultados habrían sido más inexactos (ver Tabla 11).

Results	Value
MSE training	0.01551932
MSE test	0.01641588
R2 training	0.8681797
R2 test	0.8540106

Tabla 10. Resultados test caso B

En el modelo desarrollado, R2 explica el 85.4% de los datos de supervivencia. En la Figura 35 se muestran las predicciones del modelo, remarcando con una línea recta la mejor aproximación para minimizar el error.

Results	Value
MSE training	0.08595152
MSE test	0.08493271
R2 training	0.6371432
R2 test	0.6520446

Tabla 11. Resultados test caso B con Ravdin y Clark

Como resultado, para una rápida convergencia y ajuste de la curva se ha utilizado una estimación semiparamétrica con una distribución de Weibull.

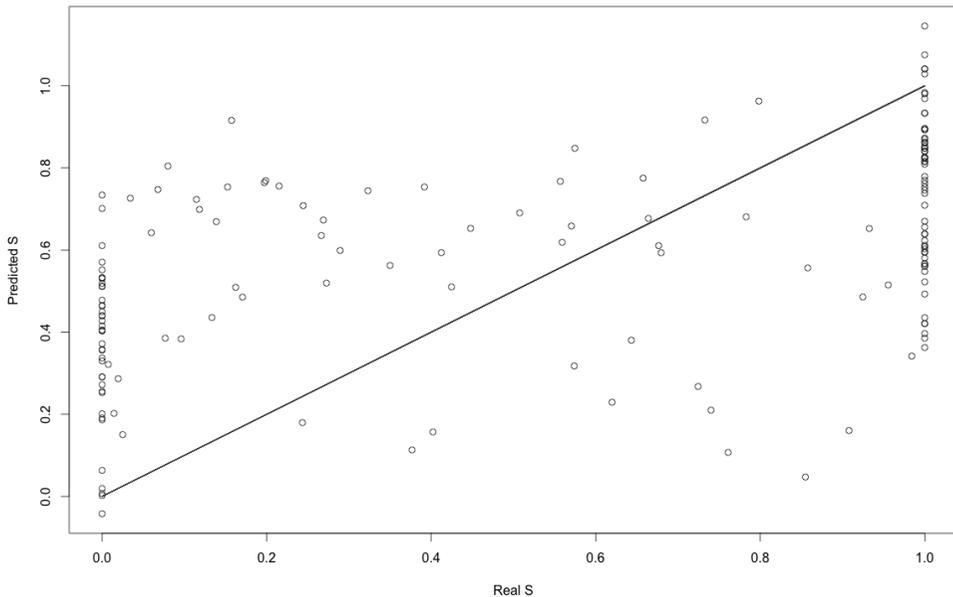


Figura 35. Predicciones red neuronal caso B

Los dos casos prácticos desarrollados pretenden explorar la capacidad de las redes neuronales para obtener conocimiento de las variables, actualizando su experiencia con nuevas secuencias de datos válidos, aunque la suma ponderada de las entradas de los nodos de la red neuronal no pueden ser interpretadas como coeficientes de las variables, y, por tanto, no proporcionen una explicación del comportamiento del fenómeno.

No obstante, el objetivo es estimar los fallos de la planta solar fotovoltaica, y este modelo puede ser utilizado para su estimación directa o como entrada de otro modelo en el que se relacione de forma más directa las variables con el resultado esperado.

6.4 CONCLUSIONES

Los gestores de las plantas solares fotovoltaicas quieren prolongar los periodos de rentabilidad de las instalaciones con plantas más fiables. Para asegurar la rentabilidad durante todo el ciclo de vida de las plantas, los departamentos de mantenimiento deben asegurar la fiabilidad de los equipos críticos y extender al máximo su ciclo de vida. En otro caso, los costes de los fallos penalizarían el beneficio.

En este capítulo se sugiere la aplicación de un modelo de red neuronal para diferentes modos de fallo de la planta, de fácil implementación en los sistemas SCADA.

La metodología propuesta supone una mejora del proceso de toma de decisiones con un mantenimiento basado en la condición y un modelado de los riesgos, permitiendo reducir los costes directos e indirectos de un mantenimiento correctivo, aumentando la vida útil de los equipos.

En los casos donde no existen suficientes datos para un entrenamiento adecuado, la implantación de nuestra metodología ayudará a reducir los costes y aumentará el conocimiento sobre ciclo de vida de la planta ante condiciones de operación y ambientales heterogéneas.

La capacidad de auto-aprendizaje de las redes neuronales en presencia de datos ruidosos es significativa. En nuestro caso práctico, una cantidad importante de datos procede de diferentes plantas remotas donde las redes de sensores no se encuentran optimizadas o donde con frecuencia aparecen fallos en las comunicaciones.

El algoritmo de propagación de errores hacia atrás utilizado para el entrenamiento de las redes neuronales de este caso práctico es recomendable para implementaciones en sistemas de trabajo en tiempo real.

Es importante conocer el comportamiento del modo de fallo para poder realizar un pretratamiento de los datos históricos, de tal forma que se eliminen registros anormales que podrían distorsionar los resultados.

Como continuación de esta línea de investigación, se aplicará esta metodología de trabajo a la detección de fallos en otro tipo de plantas renovables, en concreto, a las centrales del tipo solar termoeléctrica.

6.5 BIBLIOGRAFÍA

- [1] A. Orioli and A. Di Gangi, A procedure to calculate the five-parameter model of crystalline silicon photovoltaic modules on the basis of the tabular performance data, *Appl Energy* 102, Feb 2013, 1160–1177.
- [2] V. Kostylev and A. Pavlovski, Solar power forecasting performance—towards industry standards, In: 1st international

- workshop on the integration of solar power into power systems, Aarhus, Denmark, 2011.
- [3] D. Guasch, S. Silvestre and R. Calatayud, Automatic failure detection in photovoltaic systems, In: Proceedings of 3rd world conference on photovoltaic energy conversion vol. a-C, 2003, 2269–2271.
- [4] F. Olivencia Polo, J. Alonso del Rosario and G. Cerruela García, Supervisory control and automatic failure detection in grid-connected photovoltaic systems, Trends Appl Intelligent Syst 2010, 458–467.
- [5] W.T. Miller, III, F.H. Glanz and L.G. Kraft, III, Cmas: an associative neural network alternative to backpropagation, Proc IEEE 78, 1990, 1561–1567.
- [6] I.A. Basheer and M. Hajmeer, Artificial neural networks: fundamentals, computing, design, and application, J Microbiol Methods 43, Dec 1 2000,3–31.
- [7] G.Q. Zhang, B.E. Patuwo and M.Y. Hu, Forecasting with artificial neural networks: the state of the art, Int J Forecast 14, Mar 1998, 35–62.
- [8] B. Curry, P. Morgan and M. Beynon, Neural networks and flexible approximations, IMA J Manag Math 11, 2000, 19–35.

- [9] B. Malcolm, C. BRUCE and P. Morgan, Neural networks and finite-order approximations, *IMA J Manag Math* 10, 1999, 225–244.
- [10] C. Kuo, Cost efficiency estimations and the equity returns for the US public solar energy firms in 1990–2008, *IMA J Manag Math* 22, 2011, 307–321.
- [11] A. Lapedes and R. Farber, *Nonlinear signal processing using neural networks*, 1987.
- [12] A. Mellit, M. Benghanem, M. Bendekhis and leee, Artificial neural network model for prediction solar radiation data: application for sizing, stand-alone photovoltaic power system, In: 2005 IEEE power engineering society general meeting vols. 1–3, 2005, 40–44.
- [13] R. Yacef, M. Benghanem and A. Mellit, Prediction of daily global solar irradiation data using Bayesian neural network: a comparative study, *Renew Energy* 48, Dec 2012, 146–154.
- [14] M. Benghanem and A. Mellit, Radial basis function network-based prediction of global solar radiation data: application for sizing of a stand-alone photovoltaic system at Al-Madinah, Saudi Arabia, *Energy* 35, Sep 2010, 3751–3762.
- [15] A. Mellit, M. Benghanem, A.H. Arab, A. Guessoum and leee, Modelling of sizing the photovoltaic system parameters using artificial neural network, 2003.

- [16] A. Mellit, M. Benghanem, A.H. Arab, A. Guessoum and K. Moulai, Neural network adaptive wavelets for sizing of stand-alone photovoltaic systems,2004.
- [17] A. Mellit, M. Benghanem, A.H. Arab and A. Guessoum, An adaptive artificial neural network model for sizing stand-alone photovoltaic systems: application for isolated sites in Algeria, *Renew Energy* 30, Aug 2005,1501–1524.
- [18] T. Hiyama, Neural network based estimation of maximum power generation from PV module using environmental information - discussion, *Ieee Trans Energy Convers* 12, Sep 1997, 247.
- [19] I. Ashraf and A. Chandra, Artificial neural network based models for forecasting electricity generation of grid connected solar PV power plant, *Int J Glob Energy Issues* 21, 2004, 119–130.
- [20] A. Mellit and S. Shaari, Recurrent neural network-based forecasting of the daily electricity generation of a photovoltaic power system, In: *Ecological vehicle and renewable energy (EVER)*, Monaco, March, 2009, 26–29.
- [21] J. Moubray, *Reliability-centered maintenance*, 1997, Industrial Press Inc.
- [22] M. Rausand and A. Høyland, *System reliability theory: models, statistical methods, and applications* 396, 2004, John Wiley & Sons.

- [23] J. Campbell and A. Jardine, Maintenance excellence: optimising equipment life-cycle decisions, 2001, Marcel Dekker; New York, NY.
- [24] A. Crespo Márquez, The maintenance management framework: models and methods for complex systems maintenance, 2007, Springer; Verlag, London.
- [25] H. Pham and H. Wang, Imperfect maintenance, Eur J Operational Res 94, 1996, 425–438.
- [26] R.L. Wilson, Operations and support cost model for new product concept development, Comput Industrial Eng 11, 1986, 128–131.
- [27] J.L. McClelland and D.E. Rumelhart, P. R. Group, Parallel distributed processing,” Explorations in the microstructure of cognition 2, 1986.
- [28] K. Hornik, M. Stinchcombe and H. White, Multilayer feedforward networks are universal approximators, Neural Netw 2, 1989, 359–366.
- [29] D.R. Cox and D. Oakes, Analysis of survival data, 1984, Chapman and Hall; London.
- [30] J. Klein and M. Moeschberger, Survival analysis techniques for censored and truncated data, 1997, Springer, New York Inc.
- [31] A.M. Law and W.D. Kelton, Simulation modeling and analysis, 1991, McGraw-Hill; New York.

- [32] J.K. Lindsey, *The statistical analysis of stochastic processes in time*, 2001, Cambridge Univ Press.
- [33] P.J. Smith, *Analysis of failure and survival data*, 2002, Chapman-Hall; New York.
- [34] P. Hougaard, *Analysis of multivariate survival data*, 2000, Springer; New York.
- [35] E.T. Lee, *Statistical methods for survival data analysis*, 1992, Wiley.
- [36] W.R. Blischke and D.N.P. Murthy, *Reliability modelling, prediction and optimization*, 2000, Wiley; New York.
- [37] D.R. Cox, *Regression models and life-tables*, *J R Stat Soc Ser* 34, 1972, 187–220.
- [38] K. Mobley, *An introduction to predictive maintenance*, 2002, Elsevier; Amsterdam.
- [39] L. Ohno-Machado, *Modeling medical prognosis: survival analysis techniques*, *J Biomed Informatics* 34, 2001, 428–439.
- [40] A. Xianga, P. Lapuerta, A. Ryutova, J. Buckley and St Azena, *Comparison of the performance of neural network methods and cox regression for censored survival data*, *Comput Statistics Data Analysis* 34 (2), 2000, 243–257.
- [41] D. Faraggi and R. Simon, *A neural network model for survival data*, *Stat Med* 14, 1995, 73–82.

- [42] K. Liestol, P.K. Andersen and U. Andersen, Survival analysis and neural nets, *Statistics Med* 13, 1994, 1189–1200.
- [43] S.F. Brown, A. Branford and W. Moran, On the use of artificial neural networks for the analysis of survival data, *IEEE Transaction Neural Netw* 8, 1997, 1071–1077.
- [44] P.M. Ravdin and G.M. Clark, A practical application of neural network analysis for predicting outcome of individual breast cancer patients, *Breast Cancer Res Treat* 22, 1992, 285–293.
- [45] E. Biganzoli, P. Boracchi, L. Mariani and E. Marubini, Feed forward neural networks for the analysis of censored survival data: a partial logistic regression approach, *Stat Med* 17, 1998, 1169–1186.
- [46] Biglarian A., Bakhshi E., Baghestani A.R., Gohari M.R., Rahgozar M., Karimloo M., Nonlinear survival regression using artificial neural network. Hindawi Publishing Corporation. *J Probab Statistics*, 2013, Article ID 753930.
- [47] E. Mitchell, A. Robson and V.B. Prabhu, The impact of maintenance practices on operational and business performance, *Manag Audit J* 11 (1), 2002, 25–39.
- [48] T. Stewart, A critical survey on the status of multiple criteria decision-making theory and practice, *OMEGA, Int J Manag Sci* 20 (5/6), 1992, 569–586.

- [49] J.M. Blanes, F.J. Toledo, S. Montero and A. Garrigos, In-site real-time photovoltaic i-v curves and maximum power point estimator, IEEE Trans Power Electron 28, Mar 2013, 1234
- [50] F. Rosenblatt, "The perceptron: a probabilistic model for information storage and organization in the brain," Psychological review, vol. 65, p. 386, 1958.
- [51] S. Lawrence, C. L. Giles, and A. C. Tsoi, "What size neural network gives optimal generalization? Convergence properties of backpropagation," 1998.
- [52] A. Paugam-Moisy, "Size of multilayer networks for exact learning: analytic approach," Advances in Neural Information Processing Systems, vol. 9, p. 162, 1997.



PARTE III

7. CONCLUSIONES

Las conclusiones de esta tesis doctoral, aplicadas a la tecnología solar termoeléctrica han sido aceptadas para su publicación, encontrándose en fase de revisión, en la siguiente referencia:

	<i>IMA Journal of Applied Mathematics. Oxford University Press</i>	
Referencia de indicios de calidad:	<i>Journal Citation Reports</i>	
Índice de impacto:	0.947 (5-Year: 1.030)	

7 CONCLUSIONES

En este capítulo se presentan las conclusiones de este proyecto de investigación mediante el análisis del cumplimiento de los objetivos iniciales, sus implicaciones y líneas futuras de investigación.

7.1 CUMPLIMIENTO DE OBJETIVOS

Con esta tesis doctoral se propusieron alcanzar los siguientes objetivos:

- **O1.** Diseño de un sistema de supervisión, control y adquisición de datos para la explotación de los parques solares fotovoltaicos adaptado a los requerimientos de la línea de investigación (capítulo 4)
- **O2.** Modelado de la producción de un sistema de generación solar fotovoltaico conectado a red (capítulos 4, 5, 6)
- **O3.** Detección de errores de configuración en elementos activos de parques solares fotovoltaicos en explotación (capítulo 4)
- **O4.** Detección de fallos no asociados directamente a alarmas generadas por los propios equipos (capítulos 4, 5, 6)
- **O5.** Identificación de modos de fallo susceptibles de ser tratados mediante un mantenimiento predictivo, así como su detección (capítulo 6).

En los siguientes apartados se analiza el cumplimiento de cada uno de los objetivos propuestos para esta investigación.

7.1.1 O1. Diseño de un Sistema de Supervisión, Control y Adquisición de Datos

En el Capítulo 4 se presenta la arquitectura del sistema de control de la planta solar fotovoltaica “El Molino Energía” (ver Figura 17). El diseño del sistema responde a la necesidad de incorporar los requerimientos del marco de referencia para la gestión del mantenimiento basado en estándares industriales y de comunicaciones, especialmente en la especificación de la gestión de activos ISO 55000:2014, en el estándar de gestión de la calidad ISO 9001:2008 y el estándar abierto de intercambio de información OpenO&M.

Desde el punto de vista de su arquitectura software, su implementación ha sido realizada conforme a un diseño multiagente con el objetivo de independizar la generación y actualización de los modelos de predicción respecto a la aplicación de los algoritmos de detección e identificación de fallos (Figura 19).

El análisis y tratamiento de los datos se facilita con la creación de una base de datos OLAP a partir del sistema de gestión de base de datos convencional preexistente.

7.1.2 O2. Modelado de la Producción

En esta línea de investigación se desarrollan 3 modelos para estimar la producción de la planta solar fotovoltaica:

- En el capítulo 4 se presenta un modelo de la producción de un elemento generador de la planta solar fotovoltaica a partir de la producción de sus iguales, aplicando una regresión lineal (Figura 22). Este modelo presenta el inconveniente de que es muy sensible a la diferencia real existente entre los elementos analizados, así como a la diferencia de estado de los mismos.
- En el capítulo 5 se describe un modelo estadístico paramétrico de la producción de la planta, basado en modular una distribución de Weibull de 2 parámetros en función de las condiciones ambientales y de operación, de forma análoga a como se modelan los tests acelerados de fiabilidad (Figura 25). Frente al modelo anterior, presenta la ventaja de que no se requieren otros elementos generadores para desarrollar el modelo. Sin embargo, los errores de predicción existentes aconsejan el empleo del modelo únicamente para establecer una línea de base de la producción en ausencia de fallos en los periodos diarios de máxima producción (Figura 28).
- En el capítulo 6 se presenta una arquitectura de red neuronal (Figura 31) con la capacidad de estimar la producción solar de la planta a partir de las condiciones ambientales y de operación (Tabla 4) con unos resultados más exactos que el modelo anterior (Tabla 5),

y con la ventaja de poder adaptarse de forma dinámica a las mismas.

7.1.3 O3. Detección de Errores de Configuración de Elementos Activos

Los métodos propuestos en esta tesis doctoral, además de permitir la detección e identificación de fallos de funcionamiento de los elementos de la planta, permiten detectar errores en la configuración de los mismos. En el capítulo 4 se presenta un ejemplo donde fue posible la detección de un error de configuración en un inversor de la planta solar fotovoltaica “El Molino Energía” que estaba trabajando en un rango de operación de aproximadamente un 2% inferior que el resto de equipos de la planta. La detección de este fallo de configuración se realizó mediante el cálculo de la matriz de correlación de las series de producción de todos los equipos de producción de la planta (Figura 21).

7.1.4 O4. Detección de Fallos no Asociados Directamente a Alarmas Generadas por los Propios Equipos

A partir de los modelos de producción generados en los capítulos 4, 5 y 6 es posible detectar fallos del sistema solar fotovoltaico en los que se produce una degradación gradual del sistema o de una parte del mismo y no existen necesariamente alarmas en el SCADA correspondientes al malfuncionamiento de equipos, comparando la evolución de la producción real con respecto a la estimada en los respectivos modelos (Figura 23, Figura 29 y Tabla 6).

7.1.5 O5. Identificación de Modos de Fallo Susceptibles de ser Tratados mediante un Mantenimiento Predictivo

En el capítulo 6 se introduce el uso de las redes neuronales para predecir la ocurrencia de 2 modos de fallo en la planta solar fotovoltaica: la presencia de un fallo de aislamiento (Tabla 6) y el bloqueo de un seguidor solar (Figura 35).

La mayor exactitud del modelo de predicción de la producción basado en redes neuronales con respecto al resto de modelos permite establecer un mecanismo de detección en el caso del fallo de aislamiento, mientras que en el caso del modo de fallo de bloqueo de un seguidor solar, se obtiene un modelo basado en redes neuronales para la estimación de la supervivencia del equipo, en lugar de un modelo de producción como tal.

Acorde a la información proporcionada por el Departamento de Mantenimiento de la planta, la aplicación del programa de mantenimiento predictivo en los modos de fallo estudiados ha permitido:

- Incrementar la eficiencia y los beneficios (ROI 10:1)
- Eliminar mantenimiento preventivo innecesario hasta en un 30%
- Reducir las consecuencias de los fallos hasta un 55%
- Reducir los tiempos de reparación hasta un 60% y el inventario de repuestos en un 30%

- El tiempo medio entre fallos se ha incrementado hasta un 30% en función del elemento

7.2 LÍNEAS FUTURAS DE INVESTIGACIÓN

Como resultado de esta tesis doctoral se plantea el desarrollo de varias líneas de investigación:

- **LF1.** Mejora de la exactitud de los modelos de predicción.
- **LF2.** Aplicación del conocimiento generado a otras tecnologías renovables.

7.2.1 LF1. Mejora de la Exactitud de los Modelos de Predicción

A pesar de la bondad de los modelos de redes neuronales utilizados en el presente trabajo de investigación, existen otros métodos ampliamente utilizados en problemas de regresión, como por ejemplo, los vectores soporte o SVM (Support Vector Machines) y la programación genética. La comparación de los modelos de predicción generados a partir de estas técnicas constituye una interesante línea de investigación, donde la selección de un método u otro depende de la naturaleza del problema y de la cantidad y calidad de los datos disponibles.

En el desarrollo de las redes neuronales, las aplicaciones prácticas precedieron a la teoría, mientras que en el caso de los vectores soporte, la teoría precedió a las aplicaciones [1]. Los vectores soporte garantizan en los problemas de optimización un mínimo global

y proporcionan una interpretación geométrica simple [2], no dependiendo su complejidad computacional de la dimensión del espacio de entrada.

En las referencias [3,4] se realizan comparaciones entre los métodos basados en redes neuronales y SVM en aplicaciones de detección de fallos mecánicos.

Por otro lado, los algoritmos utilizados en esta tesis doctoral consideran únicamente la optimización de la función de error tanto en la fase de entrenamiento como de validación de los modelos. Sin embargo, la aplicación de técnicas de decisión multicriterio permitiría abordar múltiples objetivos, tanto cuantitativos como cualitativos, de forma simultánea. Por ejemplo, con respecto al mantenimiento predictivo, la disponibilidad de personal especializado (criterio cualitativo) o el coste de las intervenciones (criterio cuantitativo). El uso de funciones de scoring [5] o técnicas de análisis jerárquico [6-8] resultarían de utilidad en este sentido.

7.2.2 LF2. Aplicación del Conocimiento Generado a otras Tecnologías Renovables

En paralelo con la mejora de las técnicas de modelado de la producción y de los algoritmos de detección de fallos, es posible extrapolar los resultados obtenidos a otras áreas dentro del ámbito de las energías renovables como la generación solar termoeléctrica o la eólica.

Concretamente, se ha planteado el desarrollo a corto plazo de un modelo de fiabilidad de los circuitos de bombeo del fluido HTF para una planta termosolar de tecnología de concentración cilindro-parabólica de 50 MW en Córdoba, desarrollada por el Grupo Magtel conjuntamente con las empresas TSK y Grupo Ortiz (ver Figura 36).

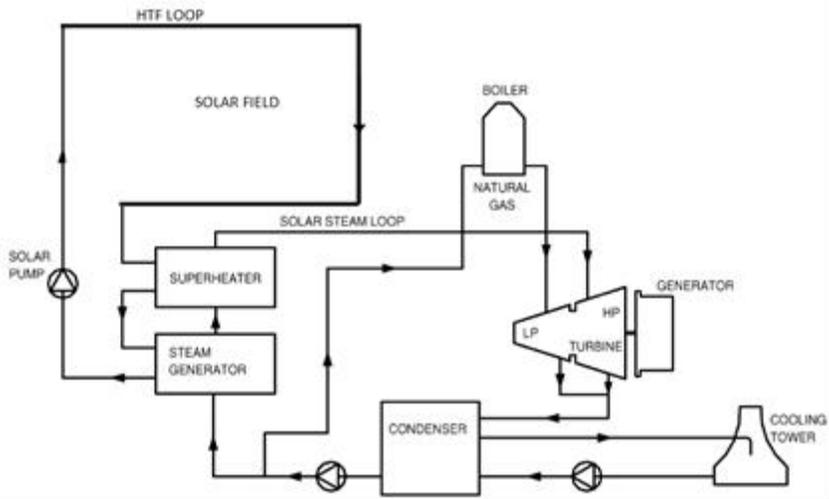


Figura 36. Planta termosolar La Africana Energía

Los resultados de este trabajo han sido aceptados para su publicación y se encuentran en fase de revisión en el Journal of Applied Mathematics del Institute of Mathematics de Oxford University Press.

7.3 BIBLIOGRAFÍA

- [1] L. Wang, Support Vector Machines: theory and applications vol. 177: Springer Science & Business Media, 2005.
- [2] C. J. Burges, "A tutorial on support vector machines for pattern recognition," Data mining and knowledge discovery, vol. 2, pp. 121-167, 1998.
- [3] L. Jack and A. Nandi, "Fault detection using support vector machines and artificial neural networks, augmented by genetic algorithms," Mechanical systems and signal processing, vol. 16, pp. 373-390, 2002.
- [4] B. Samanta, "Gear fault detection using artificial neural networks and support vector machines with genetic algorithms," Mechanical Systems and Signal Processing, vol. 18, pp. 625-644, 2004.
- [5] M. C. C. Moya, "The control of the setting up of a predictive maintenance programme using a system of indicators," Omega, vol. 32, pp. 57-75, 2004.

- [6] A. Parida and U. Kumar, "Maintenance performance measurement (MPM): issues and challenges," *Journal of Quality in Maintenance Engineering*, vol. 12, pp. 239-251, 2006.
- [7] C. A. B. e Costa, M. C. Carnero, and M. D. Oliveira, "A multi-criteria model for auditing a Predictive Maintenance Programme," *European Journal of Operational Research*, vol. 217, pp. 381-393, 2012.
- [8] L. Wang, J. Chu, and J. Wu, "Selection of optimum maintenance strategies based on a fuzzy analytic hierarchy process," *International Journal of Production Economics*, vol. 107, pp. 151-163, 2007.