

UNIVERSIDAD DE LAS PALMAS DE GRAN CANARIA

INSTITUTO UNIVERSITARIO SIANI



UNIVERSIDAD DE LAS PALMAS
DE GRAN CANARIA




INSTITUTO UNIVERSITARIO
SIANI
DINÁMICA DE MEDIOS
CONTINUOS Y ESTRUCTURAS

TRABAJO DE FIN DE MÁSTER

MÁSTER EN SISTEMAS INTELIGENTES Y APLICACIONES
NUMÉRICAS EN INGENIERÍA

ESTUDIO SOBRE LA GESTIÓN INTELIGENTE DE LA GENERACIÓN
EN SISTEMAS ELÉCTRICOS DE POTENCIA AISLADOS PARA MINIMIZAR
LOS DESLASTRES POR SUBFRECUENCIA



Autor:Santiago Padrón Hernández

Tutor:Dr. D. Mario Hernández Tejera

Co-tutor:Dr. D. Antonio Falcón Martel

Septiembre de 2011

Índice general

Índice de figuras	v
Índice de cuadros	vii
1. Introducción	1
1.1. Origen y justificación del trabajo	1
1.2. Introducción a los sistemas eléctricos de potencia	3
1.3. Descripción del problema	7
1.4. Posibles soluciones	11
1.5. Solución adoptada	13
1.6. Estado del arte	16
1.7. Contenido y estructura de la memoria	18
2. Modelado del sistema	19
2.1. Red equivalente	20
2.1.1. Modelado de la inercia	22
2.1.2. Modelado del regulador de velocidad	23
2.1.3. Modelado de la banda muerta del regulador	26
2.1.4. Limitación de potencia del generador	27
2.2. Modelos de los relés	27
2.2.1. Relés de subfrecuencia	28
2.2.2. Relés de derivada de la frecuencia	29
2.3. Método de integración	30
2.4. Validación del modelo	32
3. Obtención del conjunto de entrenamiento	37
3.1. Metodología	37
3.2. Obtención de los casos a analizar	38
3.2.1. Generador secuencial	38
3.2.2. Restricciones	40
3.2.3. Evaluación inicial	42

3.3. Obtención de las salidas	43
3.3.1. Metodología	43
3.3.2. Búsqueda exhaustiva	46
3.3.3. Mejoras de rendimiento	48
3.3.3.1. Paralelización	48
3.3.3.2. Generalización del optimizador	49
4. Configuración de la red neuronal	51
4.1. Introducción	51
4.2. Configuración inicial de la red neuronal	53
4.3. Metodología	55
4.4. Procesado de datos	56
4.5. Regla de propagación	59
4.6. Regla de activación	62
4.7. Neuronas de la capa oculta	65
4.8. Número de capas ocultas	66
4.9. Métodos de entrenamiento	68
4.10. Configuración final de la red neuronal	70
4.11. Implementación de la red	72
5. Aplicación y resultados	77
5.1. Sistemas a analizar	78
5.1.1. Gran Canaria	78
5.1.2. La Gomera	80
5.2. Generación de conjuntos de entrenamiento	80
5.3. Entrenamiento de la red neuronal	85
5.4. Interpretación de la red neuronal	88
5.5. Evaluación de los resultados	91
5.6. Ejemplo de aplicación	94
6. Conclusiones y futuras líneas de trabajo	101
6.1. Sobre el simulador	101
6.2. Sobre la generación del conjunto de entrenamiento	103
6.3. Sobre la configuración de la red neuronal	104
6.4. Sobre la aplicación práctica	105
6.5. Generales	106
6.6. Futuras líneas de trabajo	106
Bibliografía	109

Índice de figuras

1.1. Número de incidentes totales en Canarias 2005-2010	2
1.2. Número de incidentes en Canarias con pérdida de mercado. 2006-2010)	2
1.3. Estructura de un S.E.E	4
1.4. Previsión de la generación	7
1.5. Representación simplificada de un SEP	8
1.6. Representación del equilibrio de un SEP	9
1.7. Disminución de la frecuencia ante una desequilibrio de generación	10
1.8. Esquema básico de trabajo	15
2.1. Regulador de velocidad tipo IEEE GAST2A	19
2.2. Representación del desacople entre potencia activa y potencia reactiva	21
2.3. Función de transferencia entre la potencia y la frecuencia	23
2.4. Característica de un control primario con estatismo	24
2.5. Respuesta dinámica de un generador con estatismo	24
2.6. Respuesta dinámica de un generador	25
2.7. Sistema equivalente de un grupo de generadores en paralelo	26
2.8. Filtro de banda muerta de un regulador	28
2.9. Modelado final del sistema eléctrico	31
2.10. Salida del simulador	33
2.11. Comparativa de la simulación de incidentes reales	35
2.12. Comparativa de la simulación de incidentes reales	36
3.1. Esquema de creación del conjunto de aprendizaje	38
3.2. Discretización del espacio de búsqueda	39
3.3. Representación del espacio de búsqueda	40
3.4. Soluciones encontradas para un problema tipo	47
4.1. Ejemplo de Red Neuronal Artificial	52
4.2. Elementos básicos de una neurona artificial	53
4.3. Comparativa de procesamiento de datos	59
4.4. Comparativa de reglas de propagación	61

4.5. Función de transferencia (a) Sigmoidal (b) Log-Sigmoidal (c) Lineal (d) lineal saturada	63
4.6. Comparativa de reglas de activación	64
4.7. Comparativa de reglas de activación	65
4.8. Comparativa del número de neuronas en la capa oculta	67
4.9. Comparativa del número de capas ocultas	68
4.10. Comparativa de los métodos de entrenamiento	70
4.11. Comparativa de los métodos de entrenamiento	71
4.12. Comparativa de los métodos de entrenamiento	72
4.13. Comparativa de los métodos de entrenamiento	73
4.14. Comparativa de los gradientes de los métodos de entrenamiento	74
4.15. Comparativa de los gradientes de los métodos de entrenamiento	74
4.16. Comparativa de los gradientes de los métodos de entrenamiento	75
4.17. Comparativa de los gradientes de los métodos de entrenamiento	75
5.1. Red eléctrica de Gran Canaria	80
5.2. Red eléctrica de La Gomera	82
5.3. Aprendizaje del caso de Gran Canaria	87
5.4. Gradiente del aprendizaje del caso de Gran Canaria	87
5.5. Aprendizaje del caso de La Gomera	88
5.6. Gradiente del aprendizaje del caso de La Gomera	88
5.7. Representación de los pesos de la red Gran Canaria	89
5.8. Representación de los offset de la red de Gran Canaria	90
5.9. Representación de los pesos de la red de La Gomera	90
5.10. Representación de los offset de la red de de La Gomera	91
5.11. Histograma de errores en el caso de Gran Canaria	93
5.12. Histograma de errores en el caso de La Gomera	94
5.13. Error en función de la demanda en el caso de Gran Canaria	96
5.14. Error en función de la demanda en el caso de La Gomera	96
5.15. Ejemplo de demanda horaria en Gran Canaria	97
5.16. Ejemplo de programación horaria en Gran Canaria	98
5.17. Solución obtenida por la red neuronal	98
5.18. Evaluación de los resultados de la Red Neuronal	99

Índice de cuadros

4.1. Comparativa de procesado de datos	58
4.2. Comparativa de reglas de propagación	61
4.3. Comparativa de reglas de activación	66
4.4. Comparativa del número de neuronas en la capa oculta	66
4.5. Comparativa del número de capas ocultas	69
4.6. Comparativa de los métodos de entrenamiento	76
5.1. Grupos de generación de Gran Canaria	79
5.2. Grupos de generación de La Gomera	81
5.3. Discretización del espacio de búsqueda	82
5.4. Resultados de la discretización	83
5.5. Comparativa del tamaño del conjunto de aprendizaje	84
5.6. Resultados de la optimización	84
5.7. Error en el conjunto de aprendizaje	86
5.8. Discretización del conjunto de evaluación	91
5.9. Grupos de generación	92
5.10. Errores de entrenamiento y generalización	92
5.11. Grupos de generación	95
5.12. Grupos de generación de La Gomera	95

Capítulo 1

Introducción

1.1. Origen y justificación del trabajo

Los sistemas eléctricos canarios presentan ciertas peculiaridades debido a su handicap de sistemas aislados. Como se expondrá a lo largo de este capítulo, uno de los principales inconvenientes que se presentan en estos sistemas es su baja inercia y capacidad de regulación de velocidad. Esto conlleva una baja relación potencia-frecuencia, en el caso de Canarias de entre 5-70 MW/Hz según la isla, frente a los 15.000 MW/Hz en el sistema interconectado peninsular. Esta relación expresa la caída de frecuencia respecto a un desequilibrio en la generación. Es decir, si se pierden 70 MW en Gran Canaria, el equivalente a una sola turbina, la frecuencia caerá un hercio, sin embargo, en el sistema peninsular es necesario perder 15.000 MW para llegar esta disminución de frecuencia, lo que equivale a perder en el mismo instante unas 20 centrales de gran tamaño.

Esta baja sensibilidad genera problemas frecuentes en la estabilización de la frecuencia, y como consecuencia se obtienen pérdidas de mercado no deseadas. Las desconexiones de consumidores por inestabilidad de la frecuencia es algo bastante habitual en las Islas Canarias como se desprende de los datos del Operador del Sistema en Canarias, Red Eléctrica de España (figuras 1.1 y 1.2).

En respuesta a este problema surgió la necesidad, en primer lugar, de predecir dichas desconexiones, y en segundo lugar de minimizarlas y en la medida de lo posible anularlas. Por ello, este trabajo surge para cubrir una necesidad real de

los sistemas eléctricos canarios, y su objetivo no es otro que mejorar la calidad del suministro y disminuir la Energía No Suministrada.

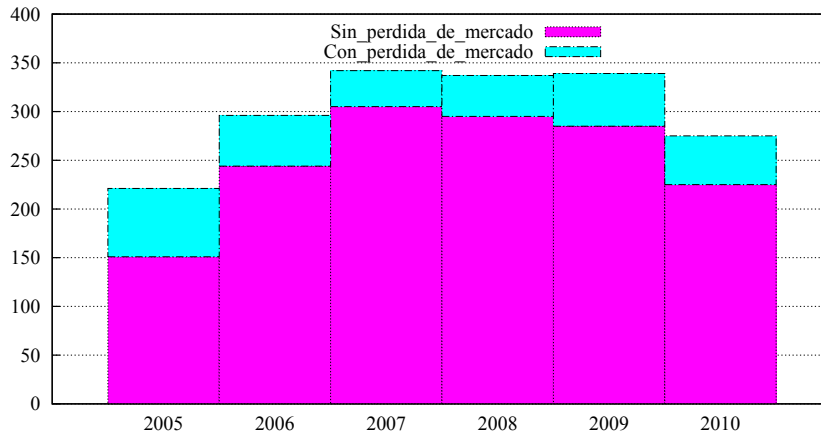


Figura 1.1: *Número de incidentes totales en Canarias 2005-2010*

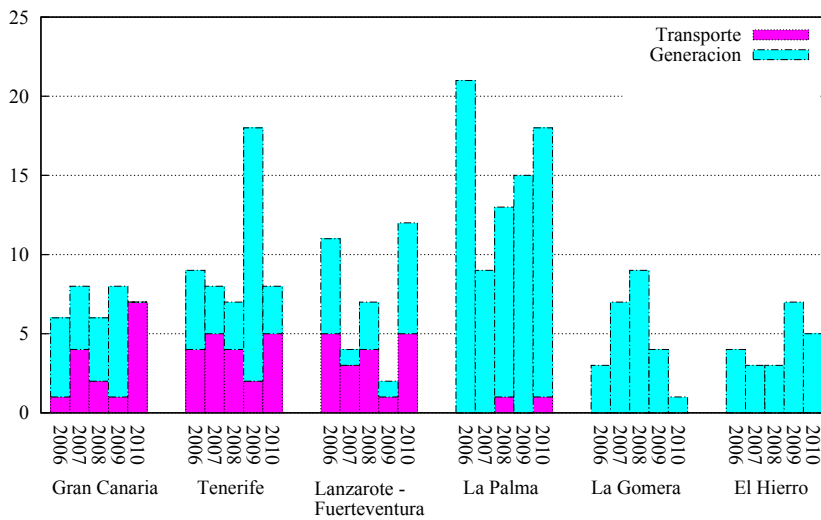


Figura 1.2: *Número de incidentes en Canarias con pérdida de mercado. (2006-2010)*

1.2. Introducción a los sistemas eléctricos de potencia

Generalmente se emplea el término Sistema de Energía Eléctrica (S.E.E.), así como el de Sistema Eléctrico de Potencia (S.E.P.), para hacer referencia a aquellos sistemas relacionados con la generación, transporte, distribución y utilización de la energía eléctrica.

Elementos que constituyen un S.E.E. son, pues, los presentes en: Centrales Generadoras de Energía Eléctrica, Redes Eléctricas de Transporte y Distribución de esa energía en Alta Tensión (A.T.), Media Tensión (M.T.) y Baja Tensión (B.T.), Subestaciones Eléctricas A.T.-M.T., Centros de Transformación en B.T. y consumos en A.T., M.T. y B.T.

Por tanto, como característica de los S.E.E. cabe destacar el hecho de estar formados por un gran número de elementos. No obstante, estos elementos pueden ser estructurados en unos pocos grupos, como se establece en la siguiente clasificación: Generación, Transporte, Distribución y Consumo, tal y como aparece en la figura 1.3. Gran parte de los elementos de estos grupos pueden ser modelados de forma relativamente simple, facilitando así la realización de estudios concernientes a diversos aspectos de los S.E.E. Éste es el caso de las líneas de transporte y distribución de energía eléctrica, la mayoría de las cuales son susceptibles de ser modeladas mediante un simple esquema en π .

La utilización de la energía eléctrica está presente en casi todas las actividades que se desarrollan habitualmente en los países de alto desarrollo económico, previéndose para los próximos decenios un gran crecimiento del consumo eléctrico en el resto de los países del planeta. De hecho, uno de los índices económicos generalmente empleado a la hora de evaluar la situación económica de un país, es precisamente el consumo de energía eléctrica y su crecimiento anual, situándose las empresas eléctricas entre las mayores y más importantes.

En consonancia con lo anterior, los S.E.E. han observado una enorme evolución desde sus orígenes hasta hoy, tanto en lo que se refiere a medios de generación, transporte, distribución y utilización, como a materiales empleados, estrategias de operación, nuevas aplicaciones y fuentes de energía, principalmente. En los últimos años, la llamada crisis energética ha acelerado las iniciativas tendentes a




Figura 1.3: Estructura de un S.E.E

lograr una mayor eficiencia en todos los aspectos relacionados con la energía, lo cual, unido a la creciente preocupación por el medio ambiente, ha reactivado el interés por las denominadas energías renovables.

Entre las energías renovables, la procedente del viento es hoy día la que ofrece una mayor interés desde el punto de los costos asociados a instalación y explotación, exceptuando aquellos casos en los que la hidroeléctrica pueda considerarse como una energía renovable.

La ubicación geográfica de los centros de generación suele obedecer a razones de proximidad a fuentes primarias de energía o instalaciones receptoras: puertos marítimos, oleoductos, etc., más que a razones de proximidad a los centros de consumo. Al objeto de minimizar las pérdidas, el transporte de energía eléctrica desde los centros de generación hasta los centros de consumo se efectúa a través de las redes A.T.

Aunque los consumos son aleatorios, se ha comprobado que su evolución diaria a lo largo de todos los meses del año obedece aproximadamente a ciertos modelos, empleándose las Curvas de Demanda Diaria para predecir en primera instancia cuál va a ser la demanda en cada periodo. El número de grupos generadores que deben entrar en funcionamiento se puede programar con criterios lógicos y se hace posible la optimización de la explotación.

Los consumos, a su vez, no son concentrados en lugares óptimos en cuanto a la explotación de los S.E.E., sino que se establecen de acuerdo a criterios ajenos a las singularidades y objetivos de éstos. Esta dispersión geográfica de centros de generación y consumo se ve acompañada por una dispersión topológica, ya que no todos ellos están conectados entre sí, debido al alto coste de instalación que ello supondría.

Por otro lado, la energía eléctrica no es susceptible de ser almacenada en grandes cantidades, con lo cual hay que establecer los mecanismos adecuados para ajustar la generación a la demanda existente en cada momento. Surge así la necesidad de incluir controles automáticos que vigilen y realicen esa y otras funciones, tales como las relacionadas con los valores de las variables del sistema (tensión, frecuencia, etc.), las cuales no pueden desviarse mucho de sus valores nominales, ya que afectaría negativamente al buen funcionamiento y a la seguridad de los receptores y de las instalaciones.

Aunque el principal objetivo de un S.E.E. es el de satisfacer la demanda, existen otros objetivos relacionados con la idea de cumplir el objetivo principal de la mejor forma posible, considerando aspectos tales como seguridad, fiabilidad, economía y estabilidad. Aparece así un conjunto de funciones a realizar:

- Planificación
- Mantenimiento y política de crecimiento
- Plan de funcionamiento de las centrales
- Análisis de seguridad del sistema
- Funcionamiento económico
- Control de frecuencia-potencia
- Actuación de los sistemas de protección

La introducción de nuevas formas de energía, como la energía eólica, ha de ser contemplada a la hora de definir y realizar las funciones anteriormente señaladas, si se persigue el fin de satisfacer la demanda de la mejor forma posible. Asimismo,

es necesario considerar sus características a la hora de efectuar los estudios y análisis frecuentes en los S.E.E.:

- Cortocircuito
- Flujo de potencia
- Estabilidad
- Análisis de contingencias
- Previsión de cargas
- Asignación de generación
- Despacho económico
- Estimación de estado

Estos seis últimos apartados son el objetivo de este trabajo. Para entender un poco mejor este asunto, es necesario dedicar unas líneas a comprender como se gestiona el sistema eléctrico. Dentro del conjunto de las tres partes de un SEP está la figura del operador del sistema. El operador del sistema gestiona la red de transporte y planifica la generación de las centrales eléctricas. Este proceso de planificación es el comienzo de este trabajo.

En primer lugar, el operador realiza un previsión de demanda eléctrica durante las siguientes 24 horas tal como se observa en la figura 1.4. La curva verde representa la demanda prevista. Sobre esta demanda se realiza un programación de la generación horaria representada por la curva roja. Y finalmente la curva amarilla representa el consumo real producido.

Esta programación de la demanda se realiza atendiendo al penúltimo punto de la lista anterior, el despacho económico. Es decir, programar la generación minimizando su coste total. Sin embargo, tal y como se verá en el siguiente apartado, en Canarias existen limitaciones que requieren que esta programación se encarezca para poder mejorar la calidad del suministrado realizando el punto 4, análisis de contingencias.

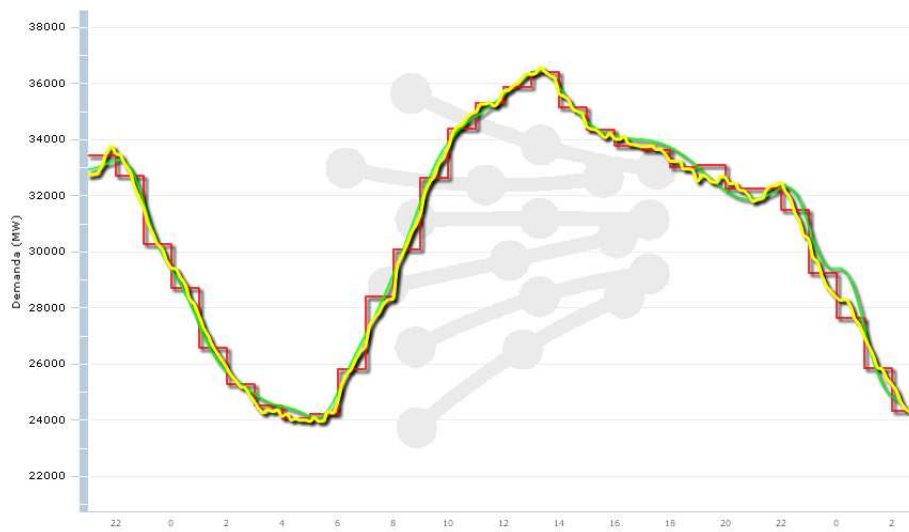


Figura 1.4: *Previsión de la generación*

1.3. Descripción del problema

La frecuencia de la onda de tensión, al igual que su valor eficaz, es uno de los parámetros que debe permanecer dentro de unos límites estrictos para que el suministro eléctrico se realice en condiciones de calidad aceptables [47]. Variaciones de frecuencia de la tensión alejadas del valor nominal pueden provocar el mal funcionamiento de equipos industriales o domésticos. Por ejemplo, algunos motores pueden verse forzados a girar a velocidades distintas de aquella para la que fueron diseñados, estos motores que no funcionen a la frecuencia especificada por el productor tenderán a sobrecalentarse y dañarse, y relojes y automatismos que miden el tiempo en función de la frecuencia de alimentación pueden adelantar o atrasar.

En general, la frecuencia de la onda de tensión generada aumenta cuando disminuye la carga y viceversa, la caída brusca de la carga del sistema tiende a aumentar la velocidad de los generadores y por ello aumenta la frecuencia [6]. Debido a que la carga varía a través del tiempo, se tiene que la frecuencia también lo hace, pese a todos los sistemas de control existentes.

En la figura 1.5 se representa la red eléctrica como una caja a la que hay conectada un número de unidades generadoras y de cargas en los nodos fronteras.

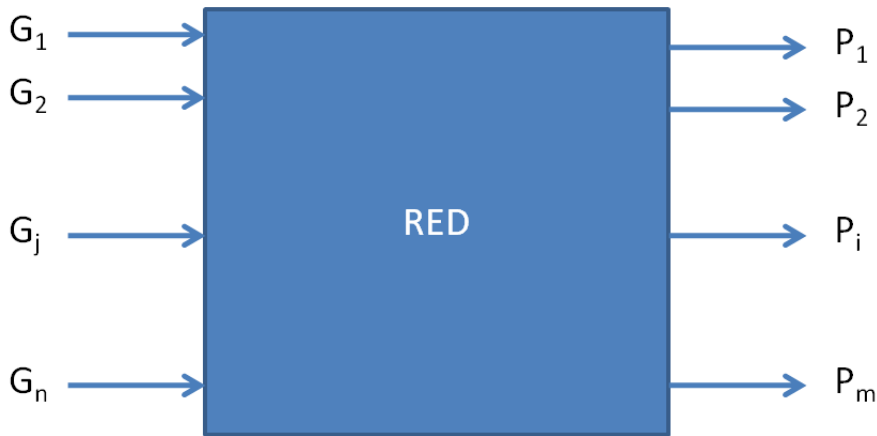


Figura 1.5: Representación simplificada de un SEP

La frecuencia de un sistema eléctrico está estrechamente relacionada con el equilibrio entre generación y carga. En régimen permanente, todos los generadores sincrónicos de una red eléctrica funcionan en sincronismo, es decir, la frecuencia de giro de cualquiera de ellos multiplicada por el número de polos es precisamente la frecuencia eléctrica del sistema. Este equilibrio viene representado por la ecuación de oscilación de la máquina síncrona (Ecuación 1.1). La misma expresa que la derivada de frecuencia con el tiempo es proporcional al desequilibrio de potencia e inversamente proporcional a la inercia del sistema (H).

$$\frac{d\omega}{dt} = \frac{\sum_{j=1}^n G_j - \sum_{i=1}^m P_i}{2H} \quad (1.1)$$

Como se observa en la ecuación 1.1, la condición para que el sistema se encuentre en equilibrio es que la generación sea igual a la demanda en todo momento. En general, los generadores eléctricos son masas giratorias, y por lo tanto, para comprender un poco mejor esta ecuación, se puede utilizar la figura 1.6, que representa una masa giratoria con un par mecánico a cada lado. El par de carga representa el par electromecánico producido en el generador como consecuencia de la carga eléctrica que tiene conectada, mientras que el par de generación representa par producido por la máquina motriz [63].

Por lo tanto, una disminución de la generación provocará una derivada negativa y un frenado del sistema, y una disminución de carga provocará una derivada




Figura 1.6: Representación del equilibrio de un SEP

positiva y una aceleración del sistema. Estas unidades generadoras están formadas por multitud de equipos auxiliares. Cuando un generador tiene un problema interno, lo primero que hace es desconectarse de la red. Esta circunstancia es bastante frecuente en los sistemas eléctricos Canarios como se vio en el apartado 1.1, figuras 1.1 y 1.2 [55]. Cuando uno de los generadores del sistema se desconecta, el desequilibrio producido es directamente proporcional a la potencia que producía el grupo antes de la desconexión, e inversamente proporcional a la inercia del resto de generadores acoplados al sistema.

Cuando se produce esta derivada negativa de la frecuencia, la misma comienza a caer de forma muy rápida, figura 1.7. Cuando esto se produce, los sistemas de regulación automática incrementan las potencias de las máquinas motrices para intentar compensar esta caída y devolver la frecuencia a su nivel nominal.

Al igual que ocurre con otros elementos del sistema, los generadores se ven alterados debido a estas variaciones de frecuencia llegando incluso a sufrir tensiones internas que pueden dañar de forma permanente los mismos, aunque el problema más frecuente es que los servicios auxiliares de los generadores no pueden funcionar correctamente con estos valores de frecuencia y no pueden alimentar correctamente los servicios requeridos por el generador pudiendo provocar daños en el mismo. Para evitar estos daños, los generadores se desconectan de la red de forma automática cuando la frecuencia disminuye por debajo de un valor umbral, generalmente 47.5 Hz [66].

Sin embargo, el disparo de más generadores aumenta considerablemente el de-




Figura 1.7: *Disminución de la frecuencia ante una desequilibrio de generación*

sequilibrio de generación, y por tanto provoca una mayor caída de la frecuencia que inducirá a que otros generadores se desconecten hasta provocar un cero total en el sistema [51]. Para evitarlo se diseñan los conocidos como Esquemas de Deslastre de Carga por Subfrecuencia. Estos esquemas se basan la monitorización constante de la frecuencia de la red que realizan relés instalados en la cabecera de las líneas de media tensión que dan orden de apertura a los interruptores cuando la frecuencia sobrepasa el valor umbral tarado en relé [52, 70]. Al disminuir la potencia demandada, se corrige el desequilibrio y se puede normalizar la situación. Esto provoca dejar a consumidores sin suministro eléctrico durante cierto tiempo, lo que se conoce como Energía No Suministrada (ENS).

En los sistemas eléctricos asilados de Canarias, el problema se agrava aún más debido a su baja inercia, lo que induce caídas de frecuencia mucho más profundas y rápidas. Como la inercia es una propiedad intrínseca de los generadores que no puede modificarse, y el parque de generación no puede modificarse a medio plazo, las únicas variables de actuación de las que dispone el Operador del Sistema se basan en la modificación las potencias generadas y demandadas [54]. Existen multitud de estudios que persiguen la optimización de dichos planes de deslastre, pero la variable sobre la que se pretende actuar es este trabajo es la potencia que inyectan los generadores a la red, ya que si la derivada de la frecuencia es proporcional a la potencia previa del generador que se desconecta, un reparto adecuado de la generación puede disminuir las interrupciones de suministro eléctrico de la

población.

Esta optimización de la generación se puede realizar, como se veía en el apartado anterior, en el momento de realizar la programación. Si embargo esto tiene ciertas desventajas. Esta programación es en intervalos de horas [43–45]. La distribución de las potencias se ve modificada dentro de cada franja horaria para adaptarse a la demanda real. Además, las energías renovables provocan variaciones rápidas y en general no gestionables en su producción, modificando así el reparto de generación y la inercia del sistema. También se suman los factores de indisponibilidades de grupo no esperadas, variaciones de la demanda prevista, etc.

Por ello se plantea la posibilidad de que el optimizador trabaje en tiempo real. Esto quiere decir, que el sistema esté constantemente monitorizado, haciendo un predicción de la posible ENS que se podría dar con el estado actual del sistema, y que corrija el estado actual de la generación para minimizar esta ENS. Este es el objetivo final del presente trabajo. Construir un sistema de optimización en tiempo real, que utilice las potencias de los grupos conectados a la red en cada momento para mejorar la calidad del suministro.

1.4. Posibles soluciones

Para solucionar el problema descrito se plantea la posibilidad de realizar una optimización o corrección que determine cuál es el reparto óptimo de generación (equilibrio economía-seguridad del suministro) que minimice en tiempo real el mercado que se puede perder.

Como paso previo de este optimizador, es necesario conocer, para una combinación cualquiera del parque de generación, qué potencia se deslastraría con cada posible desconexión individual de cada grupo. De esta forma se se puede formular como el de la obtención de una función de transferencia:

$$(P_1^D, P_2^D \dots P_i^D \dots P_n^D) = F(P_1^G, P_2^G \dots P_i^G \dots P_n^G) \quad (1.2)$$

donde:

- P_i^D es la potencia deslastrada cuando dispara el grupo i

- P_i^G es la potencia generada por el grupo i
- F es una simulación en el dominio del tiempo.

Por lo tanto se requiere construir un simulador que permita estimar las variables requeridas con un coste computacional mínimo. Este simulador es el objetivo del capítulo 2.

El objetivo del optimizador será por tanto minimizar la suma de las variables P_i^D (el objetivo deseado es que la suma sea cero) modificando las potencias generadas de cada grupo P_i^G y cumpliendo las restricciones que se plantearán más adelante.

Una vez determinada la función objetivo, puede plantearse qué método se empleará para resolverla. Para ello hay que tener en cuenta que el objetivo es que el sistema genere soluciones en tiempo real, es decir, proporcione una solución con cada actualización de datos. Esto es, en general, un tiempo de procesado de entre 5 y 10 segundos. Como se verá en el capítulo 2, la simulación del sistema resulta lenta, estando en torno a los 3 segundos en un ordenador de sobremesa, y cualquier método de optimización requiere resolver la función objetivo una gran cantidad de veces.

Se concluye así, que el método de optimización que se aplique no puede requerir utilizar el simulador para resolver el problema en modo on-line, solo en modo off-line. Por lo tanto, se debe interpretar el problema como de reconocimiento de patrones. De forma que el sistema identifique, según el caso, que correcciones es apropiado llevar a cabo. Utilizando la formación del programa de investigación, se decide restringir el área de búsqueda a los métodos de inteligencia artificial y minería de datos entre los que cabe contemplar:

- Numérico
 - Teoría bayesiana
 - Clustering: Familia K-media, Jerárquicos
 - Redes Neuronales: Perceptron, Backpro, RBF, SOM
- Refuerzo
 - Q-learning

- Adaptación
 - Homeostasis

Estos métodos se ajustan a los requerimientos del problema, ya que utilizan el simulador para discernir los patrones necesarios para corregir cada caso y conservan esa información de manera que tenga una resolución rápida.

1.5. Solución adoptada

De los métodos presentados se decide implementar una red neuronal clásica. Se escoge este método ya que a la vista de los trabajos realizados anteriormente sobre esta línea, este tipo de redes neuronales producen soluciones muy buenas. Además, debido a que este problema tiene entradas y salidas numéricas, unido a que el aprendizaje se puede equiparar a un reconocimiento de patrones, lo hace perfecto para que una red neuronal bien configurada pueda resolver el problema planteado.

Por otro lado, las redes neuronales, una vez entrenadas, son de un resolución muy rápida, casi inmediata, respondiendo así a una de las importantes restricciones del problema.

Una vez seleccionado la red neuronal como método de optimización, hay que destacar la RN no optimiza ella misma los datos de entrada, sino que debe ser entrenada para tal fin. Dicho entrenamiento puede realizarse por alguno de los siguientes métodos:

Aprendizaje supervisado Para cada grupo de entradas se le conocen también las salidas deseadas, es decir, los datos de entrenamiento están disponibles en la forma de pares (entrada, salida). El objetivo es, por tanto, aprender cuál debe ser la salida correcta ante futuras nuevas entradas no conocidas previamente y una vez efectuado el aprendizaje sobre los datos de entrenamiento. Dependiendo de la naturaleza de la salida:

- Si es continua, el problema se corresponde con regresión
- Si es discreta, cualitativa o categórica, el problema se denomina clasificación

Aprendizaje no supervisado Solo son dadas las entradas, es decir, no está disponible el conjunto de entrenamiento en forma de pares (entrada, salida). El objetivo en este caso es construir un modelo del objeto de estudio que pueda usarse para razonamiento, toma de decisión (decision making) predicción, comunicación, etc. Algunos ejemplos de estas técnicas pueden ser:

- Reducción de la dimensionalidad
- Compresión de datos
- Detección de valores atípicos (outlier detection)
- Clasificación
- Segmentación/clustering
- Estimación de la densidad de probabilidad

Aprendizaje semisupervisado Se utiliza para el aprendizaje, tanto con datos etiquetados en forma de pares (entrada, salida) como datos no etiquetados. Cuando el etiquetado de datos es un asunto costoso, las técnicas semisupervisadas pueden ser útiles. Ejemplos: modelos generativos, autoentrenamiento, coentrenamiento.

Aprendizaje mediante refuerzo Es el problema al que se enfrenta un agente que debe aprender su comportamiento a través de interacciones prueba-error con un entorno dinámico done:

- No hay profesor (asistente) que le indique al agente si es erróneo o correcto lo que hace.
- Hay un crítico que da una recompensa/penalización para las acciones del agente.
- La máquina también produce acciones a_1, a_2, \dots que afectan al estado del mundo y recibe recompensas (o castigos) r_1, r_2, \dots

El objetivo aquí es aprender a actuar de manera que se maximicen las recompensas a largo plazo. Aplicaciones:

- Robótica,
- Problemas de búsqueda combinatoria (juegos)
- Manufactura industrial

Gracias a la construcción del simulador, se puede implementar un método de aprendizaje supervisado, ya que se pueden generar todas los casos posibles de entrada y para cada caso utilizar un método clásico de optimización que produzca la salida deseada o salida objetivo. De esta forma se tienen los pares entrada-salida.

En la figura 1.8 se muestra, de forma simplificada, este sistema. En primer lugar se generan, para unas restricciones dadas, todos los estados que puede tener el sistema, es decir todos los casos posibles. Estos casos posibles forman el conjunto de entradas. A continuación se realiza con el simulador las correcciones oportunas sobre cada estado para alcanzar los objetivos iniciales, obteniendo así los casos optimizados o salidas. Cada pareja entrada-salida forma un caso del conjunto de entrenamiento de la red. Una vez entrenada la red se implementan los pesos resultantes de ese aprendizaje permitiendo simular los casos en tiempo real.

Así, la red neuronal adquiere, mediante este entrenamiento, la base de conocimiento que le permite reconocer patrones y actuar ante nuevos casos de entrada en base al conocimiento adquirido.

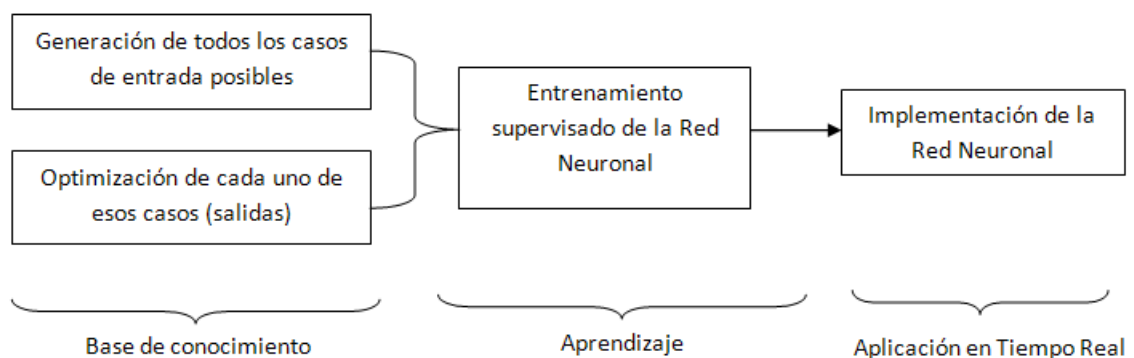


Figura 1.8: Esquema básico de trabajo

1.6. Estado del arte

El problema que se pretende resolver es bien conocido, sin embargo el enfoque resulta algo novedoso. Existe mucha bibliografía relacionada con el despacho económico de cargas y con el flujo de potencias óptimo e incluso flujo de potencias óptimo con restricciones de red. Toda esta parte ha sido obviada ya que se corresponde con análisis financiero, y en nuestro caso eso no se tendrá en cuenta, pues el objetivo no es realizar la programación, sino corregir en tiempo real un posible impacto sobre la demanda.

También existen multitud de trabajos de optimización de los planes de deslastre de carga que tampoco han sido tenidos en cuenta. Solucionar el problema de los deslastres actuando sobre la generación no es algo frecuente y no se encuentran demasiados trabajos exactamente en esta línea. De entre todos estos cabe destacar el artículo de Furong Li Changchau Clie [1] sobre el dimensionamiento de reserva rodante. Que es una aplicación de red neuronal de Kohonen para la predicción de la demanda y estimación de los niveles de reserva que se deben establecer. Este aspecto está muy relacionado con la línea del trabajo.

Otros trabajos similares se recogen en los artículos [2, 3]. Aunque este último está más relacionado con el control de los AGC. Más relacionado con la aplicación existen los artículos [4, 5]. En donde se desarrollan métodos matemáticos de predicción de la características de respuesta de la frecuencia y desarrollan así una formulación para determinar los niveles óptimos de reserva. Finalmente, sobre esta parte se tiene como referencia fundamental para la construcción del modelo el artículo [6].

Dados los diferentes tópicos relacionados con este trabajo de investigación, como son la estabilidad de redes eléctricas, simulación, inteligencia artificial, aprendizaje, etc., las referencias de partida pueden ser muchas y diversas. Se ha escogido un subconjunto especialmente significativo de las mismas, por su grado de relación con el trabajo propuesto y por constituir el soporte científico-técnico relevante básico.

La aproximación clásica al control y estabilidad de los sistemas eléctricos lleva algunas décadas experimentándose e implantándose en sistemas reales. A continuación se referencian algunos de los trabajos de estado del arte y referencias

relativas a nuevas aproximaciones. En este sentido, un estado del arte en control de estabilidad de sistemas eléctricos de potencia, así como algunas recomendaciones acerca de los retos en investigación y desarrollo pueden encontrarse en las referencias [7,8]. Que se encuentran desarrolladas de manera más extensa en [9,10].

La interacción entre diferentes subsistemas de control es el objeto de [11].

También se ha repasado la aplicación de sistemas multiagente para el desarrollo de un nuevo sistema de defensa que evalúe las vulnerabilidades de los sistemas eléctricos de potencia, monitorice los fallos de los dispositivos de protección y genere acciones de control adaptativo para prevenir fallos catastróficos y secuencias de eventos en cascada [18,19].

En [12,20,21] se discuten los problemas del modelado de esquemas de control, y en [22–25] se identifica la necesidad de un método sistemático de aprendizaje automático para poder aprender y actualizar las capacidades de toma de decisión de los controladores de los sistemas eléctricos de potencia. Dado uno de ellos operando con la asistencia de nuevos dispositivos de control, comunicaciones avanzadas y hardware de computación, emerge una aproximación de control como un modo atractivo para abordar la complejidad creciente en el control de estabilidad de sistemas eléctricos de potencia. En [26] se propone un interesante y seminal marco computacional basado en aprendizaje mediante refuerzo para el control de estabilidad.

En lo que se refiere a los simuladores a utilizar para desarrollar esquemas de control para la red inteligente, resulta fundamental la reciente referencia [27]. Que es un artículo de posicionamiento (positioning paper) que describe cuáles son los retos a abordar por la simulación para la red inteligente y cuál debe ser la aproximación a tomar para implementarla.

Se incluye aquí también una referencia algo más clásica [28], pero en la que se sentaron bases conceptuales para lo que deberían ser los simuladores como laboratorios digitales futuros o e-laboratorios para desarrollar las futuras re-conceptualizaciones de las redes eléctricas:

En lo referente al uso de agentes inteligentes para el desarrollo de simulaciones y subsistemas de control de redes eléctricas inteligentes y dentro de la bibliografía existente, son de resaltar los artículos [29–32]

Así como el muy interesante y reciente trabajo recopilatorio y tutorial que

incluye la revisión de herramientas y aproximaciones de simulación [33]

Por último, se citan las referencias que se consideran básicas en lo referente al uso aplicado de soluciones de Inteligencia Artificial, tanto general, como específica al uso de agentes inteligentes, como relativas a técnicas de aprendizaje [34–36].

1.7. Contenido y estructura de la memoria

Este trabajo está estructurado en seis capítulos. El presente capítulo pretende realizar una adaptación suave al tema que se desarrolla, comenzando por el origen y el objetivo del trabajo, para a continuación desarrollar conceptos básicos relacionados con los Sistemas Eléctricos de Potencia necesarios para comprender este trabajo. Con esta información se puede plantear de forma más desarrollada el problema el cuestión, las posibles formas de atacarlo, y la solución final.

El capítulo 2 recoge la creación de un simulador simplificado de redes eléctricas. Se describen con detalle los modelos y ecuaciones empleados para el mismo, así como una justificación de su efectividad basada en la comparación de los resultados del modelo con incidentes reales.

El capítulo 3 recoge el proceso de creación de la base de datos de aprendizaje de la red neuronal. Por un lado el sistema de generación de casos, y por otro lado el sistema de optimización de los mismos. En conjunto, estos representan la creación de los pares entrada salida necesarios para la utilización de un método de aprendizaje supervisado.

Obtenido el grupo de aprendizaje, se configura la red neuronal en el capítulo 4 y se ensayan aquellos factores que influyen en el resultado final de la red. Estas comprobaciones se realizarán con pequeñas muestras de datos obtenidas del capítulo 5.

Finalmente, cuando se tiene la base de datos y la red neuronal configurada, es el momento de aplicarla a casos reales en el capítulo 5. Para ello se utilizarán datos reales de algunos sistemas eléctricos Canarios. Se generará la base de datos, se entrenará la red y se simularán casos reales para comprobar la efectividad y las ventajas de la red neuronal.

El capítulo 6 recoge las conclusiones generales y específicas extraídas durante el desarrollo de este trabajo así como posibles líneas futuras de investigación.

Capítulo 2

Modelado del sistema

Como paso previo a la solución de este problema, es necesario desarrollar un modelo que permita simular la variación de la frecuencia del sistema ante los disparos de grupos generadores y por lo tanto calcular la potencia de mercado deslastrada. Los modelos actuales son cada vez más complejos y tienen en cuenta más efectos. En la figura 2.1 se muestra un modelo de regulador de velocidad de turbina de gas empleado habitualmente en estudios de red (IEEE GAST2A). Sin embargo en el fenómeno concreto que se estudia en este trabajo, dicha complicación añadida no aporta nada a la respuesta debido a la naturaleza de la perturbación como se verá en este capítulo.

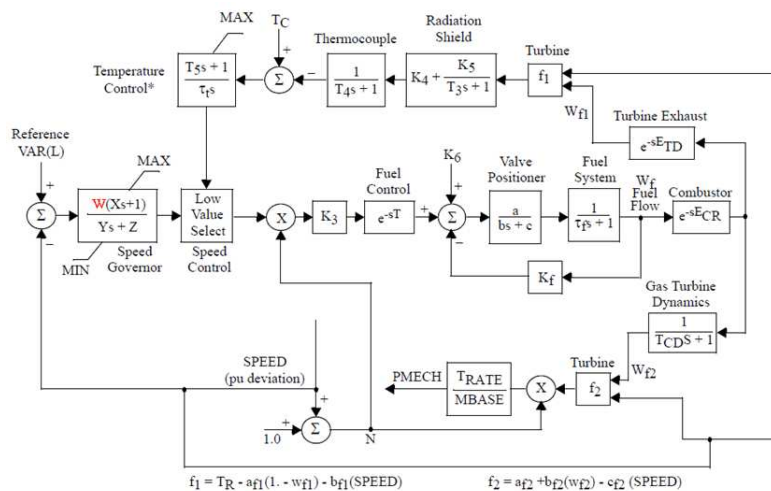


Figura 2.1: Regulador de velocidad tipo IEEE GAST2A

2.1. Red equivalente

En contingencias provocadas por pequeños desequilibrios de carga, la frecuencia sufre notables variaciones, sin embargo, la dinámica de tensiones permanece prácticamente constante. Esto es debido a que las tensiones están ligadas a las potencias reactivas y la velocidad a las potencias activas. La ecuación 2.1 representa la ecuación de estado de una red eléctrica, donde los términos son agrupados por potencias, tensiones y fases y la matriz de estado se desglosada en cuatro submatrices que representa la interrelación entre las variables. Según el planteamiento anterior se puede asumir que N y J son nulas.

$$\begin{bmatrix} \Delta P \\ \Delta Q \end{bmatrix} = \begin{bmatrix} H & N \\ J & R \end{bmatrix} \begin{bmatrix} \Delta \delta \\ \Delta V \end{bmatrix} \quad (2.1)$$

Este efecto también se puede explicar teniendo en cuenta que al disparar un grupo, la potencia reactiva que se pierde es muy baja y en muchos casos nula, por lo que las tensiones no se ven afectadas. Al no verse afectadas las tensiones se puede obviar su cálculo.

En este caso se puede sacar mucho partido al desacoplamiento natural entre potencia activa y módulo de tensión, y entre potencia reactiva y frecuencia. Esto quiere decir que el análisis de la red eléctrica puede dividirse en dos problemas:

- Regulación Tensión-Potencia reactiva
- Regulación Frecuencia-Potencia activa

Por lo tanto, se omite toda la parte de tensiones y se desarrolla únicamente la parte mecánica frecuencia-potencia. La figura 2.2, representa un esquema completo del funcionamiento de un sistema generador. Este desacople propicia que el esquema pueda ser cortado por la línea roja, desacoplando así la parte eléctrica de la que interesa, la parte mecánica.

La principal ventaja de esta simplificación reside en que no es necesario resolver el flujo de potencias en cada paso de integración, que es una de las tareas que más tiempo de cómputo consume. Por otro lado, al ser el sistema tan pequeño, la frecuencia se comporta de forma homogénea en toda la red. Por lo tanto se pueden suponer todos los generadores acoplados en un nudo único.

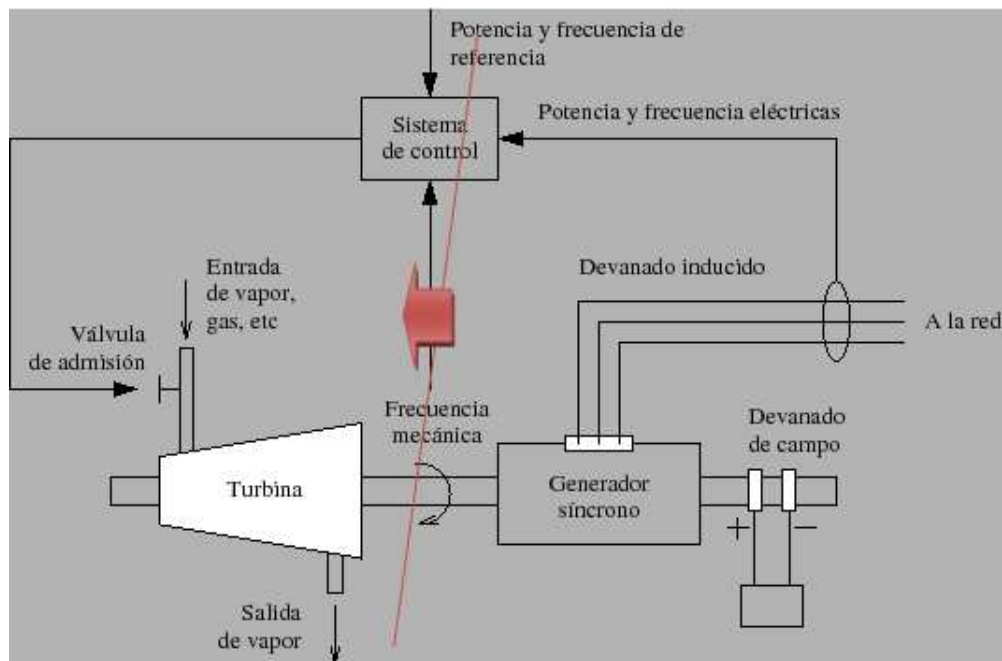


Figura 2.2: Representación del desacople entre potencia activa y potencia reactiva

Estas dos simplificaciones tienen asociadas las siguientes consecuencias:

- No es necesario conocer la red eléctrica al no tener que calcular potencias eléctricas.
- Solo se necesitan como variables de entrada la potencia generada por cada unidad.
- Solo es necesario calcular 3 variables en cada paso de tiempo de integración.
- Solo se necesita modelar los siguientes elementos:
 - Inercia de los grupos generadores
 - Regulación primaria de los grupos
 - Banda muerta de los reguladores
 - Limitador de potencia de generación
 - Relés de deslastre de carga por subfrecuencia y derivada de la frecuencia

Estas simplificaciones permiten desarrollar un modelo más simple, compacto, rápido de resolver y fácil de ajustar a la respuesta real. Además se elimina la necesidad de conocer la demanda en los nudos frontera, tensiones de generación, estado de los interruptores, etc.

A continuación se construirá y validará el modelo de red con los elementos listados antes.

2.1.1. Modelado de la inercia

Como se comenta en el capítulo 1, las variaciones de frecuencia vienen dominadas por la magnitud de las variaciones de carga y por la magnitud de la inercia del sistema, según la ecuación de oscilación de la máquina síncrona (ecuación 2.2).

$$\frac{d\omega}{dt} = \frac{\Delta P_G - \Delta P_L}{2H + D} \quad (2.2)$$

En los grupos síncronos convencionales, se puede considerar que no existe amortiguamiento de forma que $D=0$, quedando:

$$\frac{d\omega}{dt} = \frac{\Delta P_G - \Delta P_L}{2H} \quad (2.3)$$

Si se desacopla la potencia se puede obtener que la frecuencia en el instante $t+1$ será igual a la frecuencia en el instante anterior más la variación expresada en el cociente. Teniendo en cuenta la correcta adaptación de las unidades de los términos del cociente:

$$w_{t+1} = w_t + \frac{\Delta P_G - \Delta P_L}{2H} \quad (2.4)$$

Si el sistema tiene varios generadores, cada generador aporta su inercia al sistema proporcionalmente a su potencia aparente. Por lo tanto se puede calcular una inercia equivalente de los generadores acoplados ponderando sobre sus potencias aparentes:

$$H_e = \frac{\sum_{i=1}^n S_i H_i}{\sum_{i=1}^n S_i} \quad (2.5)$$

donde n es el número total de generadores, S es la potencia base de cada generador, H su inercia y H_e la inercia equivalente del conjunto. Quedando de esta forma la función de transferencia del generador según el esquema de la figura 2.3.




Figura 2.3: Función de transferencia entre la potencia y la frecuencia

2.1.2. Modelado del regulador de velocidad

Cuando la frecuencia disminuye o aumenta, los reguladores de velocidad de los generadores tratan de devolver la frecuencia a su valor de consigna actuando sobre la alimentación de la máquina motriz: válvula de combustible en los motores diésel, válvula de vapor en las turbinas de vapor, válvula de agua en las turbinas hidráulicas, etc. Los modelos de los reguladores de velocidad de los grupos de generación se pueden hacer todo lo complejos que se quiera, alcanzando órdenes elevados. Sin embargo, como ya se ha comentado, para este tipo de simulaciones basta con un modelo de primer orden. Este modelo simula un estatismo y retardo en la respuesta:

$$\Delta P'_G = \frac{1}{T}(\Delta P_G + K\Delta W) \quad (2.6)$$

donde T es el retardo en segundos, y k la ganancia. Cada generador tendrá su respuesta primaria definida por su K y su T . El estatismo, la inversa de la ganancia, tiene una respuesta proporcional a la desviación de la frecuencia de su punto nominal según la figura 2.4.

Examinando la ecuación anterior, puede comprobarse que la constante K , denominada ganancia, es la que determina la característica del regulador en régimen permanente. El estatismo, inversa de la ganancia de un generador, es igual a la relación entre el incremento relativo (por unidad) de velocidad $\Delta\omega$, y el incremento relativo de potencia de salida ΔP . Puede escribirse:

$$R = -\frac{\text{Incremento relativo de la frecuencia}}{\text{Incremento relativo de la potencia}} \quad (2.7)$$

En la figura 2.4, que representa la ecuación 2.6 gráficamente, el estatismo es la pendiente de la característica frecuencia/potencia cambiada de signo.




Figura 2.4: Característica de un control primario con estatismo

El estatismo puede expresarse en valores unitarios o porcentuales. Por ejemplo, un estatismo del 5 % significa que un incremento de frecuencia del 5 % provoca un incremento del 100 % en la apertura de la válvula y en la potencia de salida.




Figura 2.5: Respuesta dinámica de un generador con estatismo

La presencia del estatismo provoca la aparición de un error en la frecuencia en régimen permanente. La figura 2.5 representa la respuesta dinámica de un sistema con control primario de frecuencia ante un escalón de carga. Como puede verse, la frecuencia final es distinta de la inicial. Sin embargo, este mecanismo permite

la participación simultánea de varias unidades generadoras en el control primario de frecuencia.

También se incluye en el modelo la constante de tiempo T , que representa el tiempo que tarda el generador en dar su potencia final cuando es sometido a una entrada escalón tal como aparece en la figura 2.6. Este tiempo puede interpretarse como el tiempo de retardo entre la detección de la oscilación de la frecuencia, y la verdadera inyección de potencia de la máquina motriz.

Para modelar el sistema, las ganancias se expresan en tanto por uno respecto a la potencia base del generador. Por ello es necesario adaptar estos valores a una base global:

$$K_i = \frac{k_i S_i}{\sum_{i=1}^n S_i} \quad (2.8)$$

De esta forma se tienen n bloques de regulación primaria, uno por generador, y un bloque equivalente de la respuesta inercial del sistema tal como se representa en la figura 2.7.

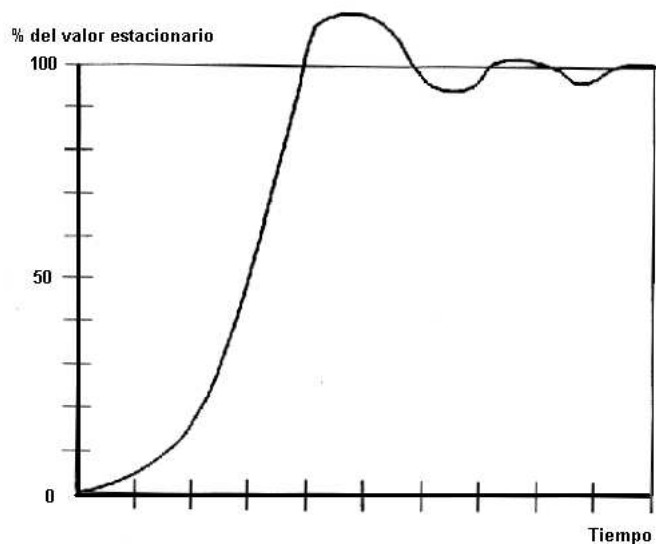


Figura 2.6: *Respuesta dinámica de un generador*




Figura 2.7: Sistema equivalente de un grupo de generadores en paralelo

2.1.3. Modelado de la banda muerta del regulador

Para evitar que los reguladores estén constantemente modificando la posición de las válvulas de las máquinas y haciendo que los generadores estén constantemente oscilando, sobre todo en sistemas de baja inercia, y en consecuencia se pueda perder el sincronismo y generar inestabilidades, se habilita la denominada banda muerta o insensibilidad del regulador. La banda muerta es un filtro a la entrada del regulador que evita que el regulador actúe si la frecuencia se encuentra oscilando dentro de un margen establecido.

En los sistemas aislados, las oscilaciones de frecuencia por adaptación de la demanda son mucho más graves, por lo que estas bandas muertas son mucho más amplias para evitar problemas como las oscilaciones de potencia entre centrales. Esto tiene un efecto negativo cuando un incidente tiene lugar. Si se produce un desequilibrio de carga, los reguladores tardan más tiempo en compensar la diferencia de generación debido a que esperan a que la frecuencia baje más para empezar a actuar. Esto conlleva mayores derivadas de frecuencia y alcanzar menores fre-

cuencias, lo que se traduce en mayores cargas deslastradas.

Este comportamiento se modela con un simple filtro que se puede definir con las siguientes reglas:

- Si $f < db \implies$ Permitir actuación del regulador
- Si $f > db \implies$ No permitir actuación del regulador

2.1.4. Limitación de potencia del generador

Puede darse la situación que la salida del regulador de velocidad emita una consigna mayor que la potencia máxima o menor que la potencia mínima que el generador puede dar. Por ello es necesario efectuar un filtrado posterior a la salida del regulador para evitar esta situación. Este comportamiento se puede resumir en las siguientes reglas:

- Si $P > P_{max} \implies P = P_{max}$
- Si $P < P_{min} \implies P = P_{min}$
- Si $P_{min} < P < P_{max} \implies P = P$

La figura 2.8 representa este filtro, donde en el eje x se representa en la valor de la frecuencia de entrada y en el eje y el valor de la frecuencia de salida. Las curvas representa dos características habituales de estos modelos, donde se observa que para ambas, en el intervalo $[-0.5, 0.5]$ la salida es siempre nula. Este intervalo es regulable y conocido como banda muerta o insensibilidad del regulador.

2.2. Modelos de los relés

Los relés de subfrecuencia y derivada de la frecuencia son equipos de protecciones habituales en las subestaciones. Estos relés monitorizan la frecuencia de la onda de la tensión y si se cumplen ciertas condiciones ordenan el disparo de alguna/s línea/s de media tensión.

La potencia deslastrada depende del valor de la demanda de la línea en ese momento, pero por lo general, este valor mantiene una proporcionalidad a la demanda total del sistema prácticamente constante. Por lo tanto no es necesario




Figura 2.8: *Filtro de banda muerta de un regulador*

conocer en cada momento el valor de la potencia demandada en caso caso, basta con conocer qué porcentaje medio de la demanda supone dicha línea.

En los siguientes apartados se realiza un breve descripción del funcionamiento de estos equipos.

2.2.1. Relés de subfrecuencia

Los relés de deslastre tienen un principio de funcionamiento bastante simple. Están constantemente midiendo la frecuencia de la onda de la tensión de la red. Cuando la frecuencia cae por debajo de un umbral establecido, el relé activa un temporizador. Si la frecuencia se recupera por encima del valor umbral, el temporizador se detiene y se vuelve a poner a cero. Si el temporizador alcanza su valor umbral antes de ponerse a cero, da orden de apertura al interruptor de media tensión que tenga asignado, desconectando la demanda pertinente.

Este funcionamiento se puede describir más fácilmente por un paquete de tres reglas:

- Activar temporización: Si $f < f_U \implies t_i = t$
- Detener temporización: Si $f > f_U \implies t_i = 0$

- Deslastrar carga: Si $t - t_i > t_U \implies$ Deslastrar

donde t es el tiempo instantáneo, f la frecuencia instantánea, t_i es el momento en el que se inicia el temporizador, f_U es la frecuencia umbral del relé y t_U es la temporización umbral de relé.

De esta forma cada relé de deslastre requiere de tres parámetros, frecuencia umbral, temporización umbral y carga que deslastra. Así se puede construir lo que se denomina un plan de deslastre, en el que distintos relés se programan para que, de forma secuencial, poder compensar desde desequilibrios leves a muy graves.

Este tema centra varias líneas de investigación, ya que la correcta organización del plan de deslastre evita el colapso del sistema y por otro lado debe minimizar la demanda deslastrada para ello. Existe multitud de métodos de optimización de estos esquemas, pero esto no es el objeto de este trabajo.

Además de las líneas de media tensión, como medida correctora, se ha creado la figura del Cliente Interrumpible. Esto es, un gran consumidor de electricidad, cuyo proceso necesita de electricidad constante y por lo tanto tiene instalados sistemas de generación de emergencia, o bien su proceso puede sufrir cortes de energía sin suponer una gran molestia. Por lo tanto estos consumidores pueden instalar su propio relé de deslastre tal que su tarado es más conservador que los de la demanda general. De esta forma se pueden paliar la desconexiones de consumidores domésticos o pequeñas industrias a costa de grandes consumidores que está preparados para ello y además son compensados económicamente.

2.2.2. Relés de derivada de la frecuencia

Estos relés tienen un funcionamiento muy similar a los anteriores. Están pensados para corregir desequilibrios grandes y rápidos. Por ello actúan midiendo la derivada de la frecuencia, es decir, la pendiente de caída. Esto es debido a que si el desequilibrio es muy grande, la frecuencia bajará mucho muy rápidamente, y puede alcanzar el tarado de los relés de protección de los generadores antes de que actúen las temporizaciones de los relés de deslastre de carga por subfrecuencia.

Por tanto, la diferencia reside en que tienen tres criterios que se deben cumplir para activar el temporizador. La frecuencia tiene que superar un valor umbral y la

derivada de la frecuencia también, ambas durante una temporización establecida. De esta forma el paquete de reglas queda:

- Activar temporización: Si $f < f_U$ y $df < df_U \implies ti = t$
- Detener temporización: Si $f > f_U$ o $df > df_U \implies ti = 0$
- Deslastrar carga Si $t - ti > t_U \implies$ Deslastrar

Finalmente, cuando alguno de los relés da orden de apertura a un interruptor de media tensión, hay que sumar el tiempo efectivo en que esta maniobra se realiza. En general, una medida conservadora puede suponer un tiempo de apertura de entre 50-100ms.

2.3. Método de integración

Una vez definidos todos los elementos, se puede representar el modelo completo según la figura 2.9, donde están representados de forma genérica de 1 a N generadores con su regulación primaria, banda muerta y limitación de potencia, y de 1 a n relés de deslastre de carga, tanto por subfrecuencia como por derivada de la frecuencia.

Realizar una simulación requiere resolver la integración numérica de un sistema de ecuaciones diferenciales no lineales. La figura 2.9 representa gráficamente el siguiente sistema de ecuaciones diferenciales no lineales:

$$\Delta\dot{\omega} = \frac{1}{2H} \left(\sum_i \Delta P_{i,m} - \Delta P_d(\Delta\omega) \right) \quad (2.9)$$

$$\Delta\dot{P}'_{i,m} = \frac{-1}{T} \left(\Delta P'_{i,m} + K\Delta\omega \right), i = 1, \dots, n \quad (2.10)$$

$$\Delta\dot{P}_{i,m} = g \left(\Delta P'_{i,m}, \Delta\dot{P}'_{i,m} \right) = \begin{cases} 0, \Delta P'_{i,m} \geq \Delta P_{i,max} \text{ y } \Delta\dot{P}'_{i,m} > 0 \\ P'_{i,m} \\ 0, \Delta P'_{i,m} \leq \Delta P_{i,min} \text{ y } \Delta\dot{P}'_{i,m} < 0 \end{cases} \quad (2.11)$$

donde $\Delta P_d(\Delta\omega)$ representa la posible variación de la carga debido a la actuación del esquema de deslastre de cargas. Se utiliza el método de integración




Figura 2.9: Modelado final del sistema eléctrico

de Heun, también conocido como el método de Euler modificado, para resolver numéricamente el sistema de ecuaciones diferenciales no lineales (2.9, 2.10, 2.11).

Este método se puede considerar como una extensión del método Euler en un método de segundo orden de dos etapas. De hecho, el método de Heun divide la integración en una etapa de predicción y una etapa de corrección. Consideremos el sistema genérico de ecuaciones diferenciales no lineales dado en (2.12).

$$\dot{y}(t) = f(t, y(t) \mid y(t_0)) = y_0 \quad (2.12)$$

donde y es un vector que contiene las variables de estado y $f()$ un vector de funciones de t e y . Una solución numérica del problema (2.12) se puede obtener aplicando el método de Heun:

$$y_{i+1}^* = y_i + hf(t_i, y_i) \quad (2.13)$$

$$y_{i+1} = y_i + \frac{h}{2} (f(t_i, y_i) + f(t_{i+1}, y_{i+1}^*)) \quad (2.14)$$

donde h es el paso de integración. El método de Heun calcula primero una predicción y^* utilizando el método de Euler y posteriormente determina y mediante una etapa de corrección utilizando el método trapezoidal. La precisión de la integración numérica depende principalmente de h . En general, la décima parte de la constante de tiempo más pequeña como paso de integración da resultados muy precisos.

2.4. Validación del modelo

Una vez construido el modelo, es necesario verificar que el mismo alcanza, con los parámetros facilitados por el operador del sistema, una precisión aceptable. Para ello se recurrirá a incidentes reales acontecidos en los sistemas de las Islas Canarias. Concretamente se escogerán todos aquellos incidentes de las características de los estudiados en este trabajo, es decir, disparo de grupo simple.

En la figura 2.10 se muestra la salida gráfica habitual que se obtiene del uso del simulador. En ella se encuentran representadas tres curvas. La curva azul representa la evolución de la frecuencia. La curva roja representa la generación total y la verde la demanda total. Se observa en el ejemplo que a los 0.5 segundos de la simulación dispara un grupo con 6 MW de generación. Por eso la curva

roja baja drásticamente y la frecuencia comienza a caer. A los 2.7 segundos el primero de los relés de subfrecuencia da orden de disparo y se pierden 3.3 MW de demanda. En ese instante la generación supera a la demanda y la frecuencia sube por encima de la frecuencia nominal.

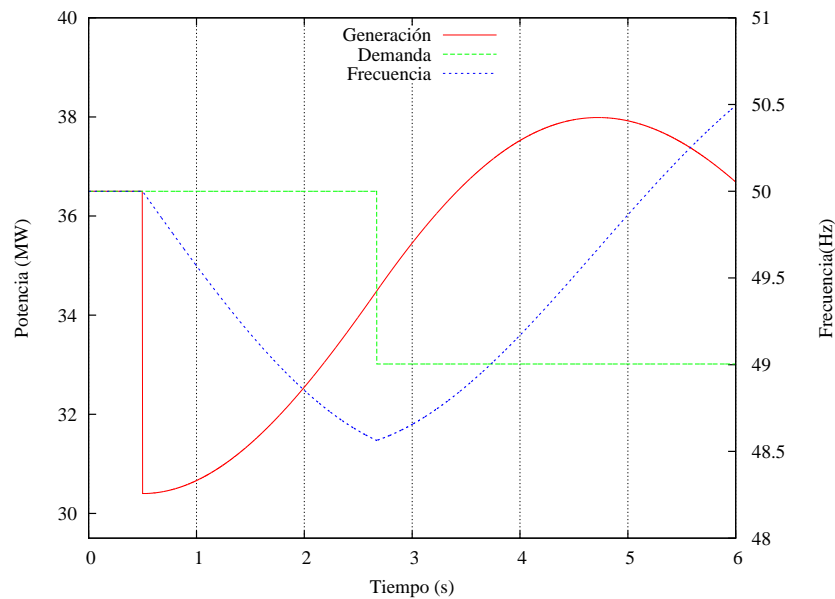


Figura 2.10: Salida del simulador

Una vez interpretadas las salidas del simulador, se seleccionan incidentes ocurridos durante los últimos dos años en todos los subsistemas insulares que sean provocados por disparos individuales de grupos de generación, que no estén generados por faltas previas, oscilaciones de potencia o mal funcionamiento previo de la red. Es decir se evitan todos aquellos incidentes en los que no aplica la optimización, y por lo tanto queda fuera del alcance del trabajo.

Para realizar cada simulación se parte de una "fotografía" del estado del sistema instantes antes de la contingencia. Es decir, hay que conocer las potencias de los grupos previas al incidente. Por otro lado se necesita conocer los registros de los osciloperturbógrafos para comparar la respuesta en el tiempo de la frecuencia y las actuaciones de los relés. La información necesaria para realizar las simulaciones y comparaciones a sido proporcionada por Red Eléctrica de España.

En total se estudian 80 incidentes. Estos están representados en la figura 2.11 donde se muestran tres gráficas. En la primera se compara el número de escalones

realmente deslastrados y el resultado de la simulación. La segunda compara la potencia eléctrica perdida y la tercera compara el porcentaje de mercado perdido.

De las tres comparativas anteriores solo es determinante la primera, ya que las otras dos dependen de la potencia real que circula por las líneas de salida, que es un dato desconocido para el operador del sistema y por lo tanto no se le puede pedir precisión, aunque a la vista de los resultados, las estimaciones de potencia proporcionan resultados prometedores.

Se observa que el simulador acierta en el 100 % de los casos si hay o no deslastre, nunca predice un deslastre que no se ha dado ni predice que no se dará deslastre cuando se ha dado. Por otro lado, la precisión en el número de escalones deslastrados es del 95.35 %. A la vista de estos resultados se puede concluir que la precisión del modelo es buena y suficiente para el propósito de este trabajo.

Finalmente se comparan de forma gráfica las evoluciones de la frecuencia en algunos de los incidentes recogidos en la comparativa anterior solo por tener una referencia visual de la precisión del simulador. En las gráficas de la figura 2.12 se observa la comparación de la respuesta de la frecuencia obtenida en el simulador y la frecuencia real registrada en barras de central. En todos los casos se confirma que las curvas tienen una evolución similar durante el periodo de bajada y el comienzo de la subida, que es la parte de la respuesta que determina los deslastres que pueden tener lugar, y por lo tanto es la parte en la que hay que requerir precisión, validando así el modelo.




Figura 2.11: Comparativa de la simulación de incidentes reales




Figura 2.12: Comparativa de la simulación de incidentes reales

Capítulo 3

Obtención del conjunto de entrenamiento

3.1. Metodología

Como ya se ha comentado, el modelo inicial de red neuronal elegido es el formato clásico de red unidireccional. La red se someterá a un aprendizaje supervisado. Es decir, conocemos para cada caso de entrada el caso de salida con la ayuda del simulador desarrollado en el capítulo anterior.

El proceso de generación del conjunto de aprendizaje se realizará en tres fases según se indica en la figura 3.1. En primer lugar se generarán de forma secuencial todas los estados en los que puede estar el sistema, es decir, las combinaciones posibles que se pueden dar a la entrada y se seleccionan las que cumplan con las restricciones impuestas en el problema. Hay que tener en cuenta, que discretizando las potencias de los grupos, los estados posibles del sistema son finitos. Cuando la discretización tiende a cero, el número de estados tiende a infinito.

En segundo lugar se realizará una evaluación preliminar de cada estado generado que sea validado para determinar si dicho estado del sistema produciría deslastre de carga en caso de que algún grupo disparase. Los casos que produzcan deslastre de cargas pasarán a la fase tres ya que ese es el principal objetivo del trabajo. En los casos en los que se produzca deslastre de carga se realizarán las correcciones necesarias para su optimización.

En esta tercera etapa se introducirá la combinación de entrada en un procedimiento de optimización que modifique el caso de entrada cumpliendo restricciones de forma que se minimicen los deslastres de carga.

De esta forma se generarán un conjunto de aprendizaje en el que cada caso lo constituye un par de vectores, uno el de la configuración de entrada correspondiente a un reparto de generación y el otro la correspondiente salida conformada por la solución óptima de reparto que minimiza deslastres. Este conjunto de datos se utilizará para entrenar la red neuronal.

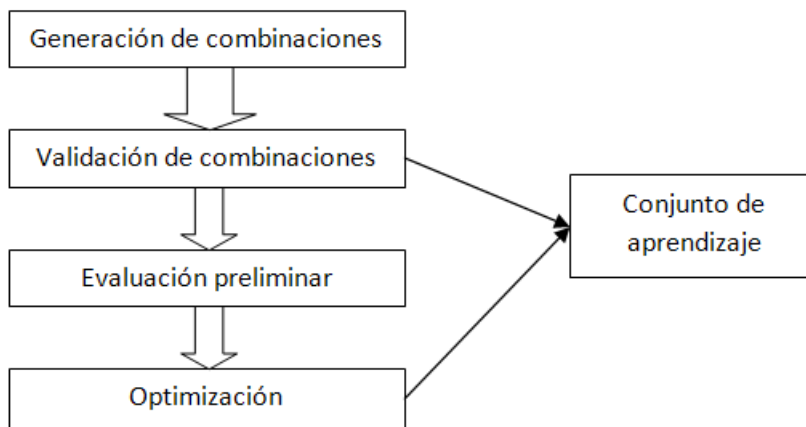


Figura 3.1: Esquema de creación del conjunto de aprendizaje

3.2. Obtención de los casos a analizar

3.2.1. Generador secuencial

Supóngase que se tiene un sistema con n generadores donde cada uno tiene una potencia mínima P_i^{min} y una potencia máxima P_i^{max} . La potencia mínima viene determinada por el mínimo técnico-económico. Esto es, el punto mínimo en el que el grupo puede operar de forma estable con un coste específico de producción aceptable. La potencia máxima viene determinada por la corriente máxima que puede circular por el devanado estático.

Para resolver el problema, primero se discretiza el rango de trabajo de cada grupo según la figura 3.2. Para ello se define el parámetro Step, que define el

tamaño de los intervalos en los que se dividirá el rango de trabajo de cada grupo. Este parámetro corresponde con la precisión de la discretización, pues cuanto más alto es el Step, mayor distancia existe entre unos casos y otros y viceversa para valores más bajos.




Figura 3.2: *Discretización del espacio de búsqueda*

En la figura 3.3 se representan tres ejemplos simbólicos de esta discretización. En el primer caso se tiene un espacio de búsqueda S con un Step alto que genera pocos estados posibles C_i . Al ir disminuyendo Step se van seleccionando cada vez más puntos tal como se representa en B. Cuando Step tiende a cero, la discretización tiende a ocupar todo el espacio de búsqueda como se representa en C. Pero al contrario de lo que se pueda pensar esto no tiene porqué ser lo óptimo, ya que un conjunto de aprendizaje demasiado grande puede empeorar la capacidad de generalización de la red neuronal por sobreentrenamiento o sobreaprendizaje pudiendo aumentar el error medio de la red. Este aspecto se estudiará en el capítulo 5.

Elegido el Step, el número de intervalos de cada grupo será:

$$m_i = \text{floor} \left(\frac{P_{max} - P_{min}}{step + 1} \right) \quad (3.1)$$

Donde la función $\text{floor}()$ realiza el redondeo al entero más cercano por debajo, es decir elimina la parte decimal. Se suma uno para tener en cuenta el estado apagado. Una vez definido el número de estados en los que puede estar cada grupo, se puede estimar el número final de casos que se generarán según:

$$M = \prod_1^N m_i \quad (3.2)$$

Definido el número de estados posibles de cada grupo se obtiene el valor de la potencia generada de cada grupo en cada estado posible. Una vez que se tienen esos




Figura 3.3: Representación del espacio de búsqueda

vectores su pueden generar de forma secuencial todas las posibles combinaciones de casos de forma sencilla.

3.2.2. Restricciones

Hay que tener en cuenta que todas las combinaciones generadas no pueden introducirse en el conjunto de aprendizaje ya que algunas pueden estar fuera de márgenes o simplemente ser técnicamente inviables. Por ello, es necesario verificar las siguientes restricciones:

- Potencia máxima total: Se realiza la suma de todas las potencias de los grupos en cada combinación obteniendo de esta forma la potencia total de-

mandada en el sistema. Al comienzo del problema se define la punta máxima de demanda que se prevé. Si esta potencia total obtenida en cada combinación es mayor que el límite establecido, esta combinación se desecha y se genera la siguiente.

- **Potencia mínima total:** Se realiza la suma de todas las potencias de los grupos en cada combinación obteniendo de esta forma la potencia total demandada en el sistema. Al comienzo del problema se define el valle mínimo de demanda que se prevé. Si esta potencia total obtenida en cada combinación es menor que el límite establecido, esta combinación se desecha y se genera la siguiente.
- **Número de grupos acoplados:** Por motivos de estabilidad, existe un número mínimo de grupos que deben permanecer acoplados al sistema en todo momento. Por ello, si el número de grupos que en cada combinación se encuentra en un estado distinto a cero es menor que límite establecido, esta combinación se desecha y se genera la siguiente.
- **Reserva a subir:** Por motivos de seguridad se establece según los Procedimientos de Operación [54], que la suma de las diferencias entre la potencia asignada a cada grupo y su potencia máxima, llamado reserva a subir, debe ser mayor que la potencia máxima del grupo mayor del conjunto de grupo acoplados en cada combinación. Si esta condición no se cumple, esta combinación se desecha y se genera la siguiente.
- **Reserva a bajar:** Por motivos de seguridad se establece según los Procedimientos de Operación [54], que la suma de las diferencias entre la potencia asignada a cada grupo y su potencia mínima, llamado reserva a bajar, debe ser mayor que la mitad de la potencia máxima del grupo mayor del conjunto de grupo acoplados en cada combinación. Si esta condición no se cumple, esta combinación se desecha y se genera la siguiente.
- **Restricciones entre generadores:** Es posible que en algunos casos las potencias que puedan generar algunos grupos dependa de la potencia que estén generando otros grupos. Por ejemplo, en el caso de los ciclos combinados

2+1, la potencia máxima que puede generar la turbina de vapor será igual a la mitad de la suma de las potencias de las turbinas de gas. Si esta condición no se cumple, esta combinación se desecha y se genera la siguiente. Si una combinación supera todas estas restricciones se la considerará válida y podrá pertenecer al grupo de aprendizaje.

3.2.3. Evaluación inicial

Una vez definida una combinación válida, es necesario hacer una evaluación previa. Hay que recordar que el objetivo de este trabajo es realizar en tiempo real los mínimos cambios necesarios sobre el parque de generación de manera que permita minimizar, o en su caso suprimir, los posibles deslastes de demanda por subfrecuencia. Por ello, las combinaciones que no produzcan deslastre de carga no deben ser modificadas ya que solo se quiere que se modifiquen los casos que conlleven deslastre de cargas.

De esta forma se prefiere hacer una evaluación preliminar de cada combinación válida para marcar las que tienen deslastre como aptas para entrenar en el optimizador que se desarrollará a continuación. Esta evaluación preliminar consiste en introducir las combinaciones válidas en el simulador, y simular los disparos individuales de cada grupo. Si alguno de estos disparos produce deslastre de cargas, el caso será marcado para optimizar.

Es importante destacar este último punto. Es decir, que solo se considerarán los disparos simples. Podrían considerarse disparos múltiples, pero esta es una circunstancia muy poco frecuente y que en general no suele acontecer. Podría darse el caso en generadores que compartan servicios auxiliares y el disparo venga provocado por un fallo en los mismos. Pero la optimización, o la mejora de este caso tan peculiar, tienden a empeorar la respuesta general ante el fallo más frecuente que es el disparo simple.

3.3. Obtención de las salidas

3.3.1. Metodología

Como salida del apartado anterior, se van generando casos que tiene alguno de los grupos configurado de tal forma que su disparo producirá una subfrecuencia que a su vez provocará que actúe alguno de los relés de deslastre de carga provocando pérdidas de mercado. Como se ha venido comentado durante todo el trabajo, es posible encontrar un reparto de potencias entre los grupos que corrija estos disparos. Por lo tanto, para cada combinación marcada para optimizar se debe buscar la combinación que optimice estos dos objetivos:

- Función objetivo 1: Minimizar los deslastres de carga.

Se pretende optimizar la demanda total en riesgo, es decir que al simular cada uno de los disparos, la suma de las demandas que se deslastrarían en cada caso sea mínima. Como ejemplo, sea el caso de que solo exista un grupo en riesgo, y que ese grupo tenga el riesgo de perder 20 MW de demanda si dispara. Pero es posible que la configuración óptima conlleve que en lugar de 1 sean 2 los grupos en riesgo, pero que la demanda que podría perderse como máximo sería de 10MW entre los dos. Como se ve, siguiendo este criterio se puede aumentar el número de grupos en riesgo y disminuir la potencia total en riesgo. Podría ser perfectamente válido utilizar como criterio la minimización del número de grupos en riesgo, en función de las preferencias del usuario, o incluso una estrategia combinada. En este trabajo se aplicará el primer criterio ya que se prefiere más posibilidad de disparos con disparos más pequeños, que pocos disparos grandes ya que tiene menor impacto en el sistema.

- Función objetivo 2: Minimizar las desviaciones con respecto al estado inicial.

Se va a considerar que el reparto de generación que exista en cada momento es el óptimo en cada instante según otros criterios: económicos, de flujo de potencias, etc. Por ello, se buscará la solución que menos modificaciones requiera sobre el caso de entrada.

Siendo prioritario siempre el objetivo 1 sobre el 2. Por lo tanto queda clara la regla de decisión en esta optimización multiobjetivo: se buscarán todas las soluciones con el mismo mejor nivel de la función objetivo 1, y de entre ellas se elegirá la que tenga el mejor nivel de la función objetivo 2. Hay que tener en cuenta que este proceso de minimización se realiza considerando las siguientes restricciones:

- La potencia total demandada en el sistema debe ser la misma.
- Los grupos desconectados deben permanecer desconectados.
- Los grupos acoplados deben permanecer acoplados.
- Los grupos deben de estar dentro de sus rangos de trabajo.

Por lo tanto, el problema se puede plantear según:

$$f_1 = \sum_{i=1}^n P_i^{des} \quad (3.3)$$

$$f_2 = \sum_{i=1}^n \text{abs}(P_i^0 - P_i^1) \quad (3.4)$$

Sujeto a:

$$\sum_{i=1}^n P_i^0 = \sum_{i=1}^n P_i^1$$

$$\text{Si } P_i^0 = 0 \longrightarrow P_i^1 = 0 \forall i$$

$$\text{Si } P_i^0 > 0 \longrightarrow P_i^1 > 0 \forall i$$

$$P_i^{max} > P_i^1 > P_i^{min}$$

donde:

- P_i^{des} representa la potencia deslastra por el disparo del grupo i que viene dada por la respuesta del simulador y es función de las potencias generadas por el resto de grupos: $P_i^{des} = F(P_1^1, P_2^1, \dots, P_i^1, \dots, P_n^1)$
- P_i^0 es la combinación a optimizar

- P_i^1 es la solución propuesta por el optimizador

Para resolver este problema se pueden implementar distintos métodos como se planteaba en el capítulo 1. Por la naturaleza del problema y debido a que las funciones a optimizar son implícitas, no lineales y con gran número de variables, se hace necesario el uso de algún método heurístico de optimización:

- Métodos Constructivos
 - Heurísticos del Vecino más Próximo
 - Heurísticos de Inserción
 - Heurísticos basados en Árboles Generadores
 - Heurísticos basados en Ahorros
- Métodos de Búsqueda Local
 - Procedimientos de 2-intercambio
 - Procedimientos de k -intercambio
 - Algoritmo de Lin y Kernighan
- Métodos Combinados
 - Procedimientos Aleatorizados
 - Métodos Multi-Arranque
 - GRASP
- Búsqueda Tabu
- Templado Simulado
- Métodos Evolutivos
 - Algoritmos Genéticos
 - Scatter Search
 - Re-encadenamiento de trayectorias

- Nuevos Métodos
 - Algoritmo Meméticos
 - Colonias de Hormigas
 - Métodos de Entorno Variable

Hay que destacar que esta optimización se realizará una sola vez, por ello no resulta vital que el método sea rápido o de bajo coste computacional. El factor más importante es que converja siempre al óptimo local. Dado que no es el objetivo de presente trabajo desarrollar un gran método de optimización, se elegirá un método de convergencia asegurada y fácil implementación.

3.3.2. Búsqueda exhaustiva

Se ha optado por implementar un método de búsqueda exhaustiva para realizar la optimización de los casos. A priori se podría pensar que este método será más ineficiente ya que explorará todos los casos posibles. Sin embargo, el número de casos factibles es reducido, tal como se verá en el capítulo 5, una media de un 10 % de los casos posibles serán evaluados y solo introducirá en la función objetivo dichos casos mientras los métodos iterativos suelen utilizar la función objetivo muchas más veces en una misma iteración, llegando incluso a repetir la evaluación del mismo estado en varias iteraciones. Debido a las limitaciones de tiempo y al extenso alcance de este trabajo, se decide no indagar más en otros métodos que pudieran resultar más eficaces pero de más compleja implementación.

Esta es una optimización multiobjetivo, los objetivos f_1 y f_2 no están en oposición directa. f_1 representa la suma de los deslastre posibles por el disparo individual de cada grupo. Mientras que f_2 representa el sumatorio del valor absoluto de la diferencia entre la potencia inicial y la potencia de la solución propuesta. De esta forma f_2 representa el desvío con respecto al estado inicial. El objetivo f_1 presenta resultados discretos. Esto es lógico ya que el valor de la potencia deslastrada depende del número de escalones que actúan, y como para un mismo escenario esta potencia es fija, la función f_1 solo podrá tomar valores discretos.

Es por ello que distintas soluciones muy diferentes entre ellas pueden producir el mismo valor de f_1 . Cada una de estas soluciones estará caracterizada por un

valor de f_2 . Por ello, para cada f_1 posible, pueden existir varias f_2 , y no se puede decir que f_1 y f_2 están en oposición directa.

En la figura 3.4 aparece un ejemplo de la aplicación de esta optimización. En el eje Y está representado f_1 , que como se esperaba solo toma valores discretos. En el eje X está representado f_2 . Se observa, que para el mismo nivel de f_1 se obtienen varios niveles de f_2 . El óptimo de Pareto está representado por la línea roja. La regla de decisión en este frente es clara y se tomará por tanto el valor con menor f_1 de los tres.




Figura 3.4: Soluciones encontradas para un problema tipo

Este proceso de búsqueda se ejecutará de la misma forma que la planteada para la generación de los posibles casos de entrada. Es decir, se discretizan los rangos de trabajo de los grupos, pero en este caso solo de los grupos acoplados. Se generarán secuencialmente todas las combinaciones posibles. Se verificarán las soluciones válidas según las restricciones del generador de casos más las restricciones particulares planteadas para el optimizador.

Cada solución válida se introducirá en el simulador y se evaluarán las funciones

objetivo. En cada iteración se comprobará si esa solución es el mínimo global encontrado o no. Finalmente se tendrá registrada la solución óptima de todas las generadas.

3.3.3. Mejoras de rendimiento

Para mejorar el rendimiento de los procesos generados en este capítulo, se aplican las siguientes modificaciones. Por limitaciones de tiempo y de extensión del trabajo no se han podido realizar evaluaciones de la efectividad y del ahorro que suponen estas mejoras.

3.3.3.1. Paralelización

Debido a que estos procesos son muy extensivos en tiempo, paralelizarlos supone una importante mejora de rendimiento. Esta paralelización del código se realizará con la librería `openmp`. Existen varios puntos donde poder realizar la separación de los hilos, pero en general, interesa que esta separación y unión de los hilos consuma menos tiempo que el que se gana con las instrucciones que se realizan de forma paralela, por ello se intentará aplicar en bloques del mayor tamaño posible.

La parte que más tiempo de simulación consume es el simulador. Pero al ser este una integración temporal no puede ser paralelizado. Por este mismo motivo tampoco se puede paralelizar el generador de casos, ya que se realiza de forma secuencial y cada caso depende del anterior. Con todo esto, la solución consiste en ejecutar el generador de casos de forma secuencial, de manera que solo genere y almacene tantos casos como hilos se hayan creado. En este punto se dividen los hilos y cada hilo realiza todo el proceso de uno de los casos en paralelo con el resto de hilos, la evaluación preliminar, la optimización y el almacenamiento de resultados. Esta es la forma en la que menos acciones de crear y destruir hilos se producen. Se ha perseguido este efecto por el hecho de que las acciones de crear y destruir hilos consumen tiempo, y si las sentencias dentro de la parte paralelizada son muy cortas, probablemente el tiempo de creación y destrucción compense el tiempo de paralelización y no se mejore el proceso.

3.3.3.2. Generalización del optimizador

Para optimizar cada estado, el método de búsqueda comprueba una a una todas las soluciones posibles. Para todos los estados a optimizar las soluciones posibles ensayadas son las mismas aunque las factibles, y por supuesto la óptima son distintas. Es por ello que el método generara todos los casos posibles muchas veces y evaluará muchos de ellos de forma repetida. Por eso, si el número de combinaciones a optimizar es elevado, puede resultar rentable evaluar todas y cada una de las soluciones posibles y mantenerlas en memoria al principio del algoritmo y que posteriormente cada hilo realice la búsqueda dentro de las soluciones factibles para la combinación que está estudiando sin necesidad de evaluarlas, pues para cada solución posible se almacenarán los valores de f_1 y f_2 .

Esto solo es rentable en grandes grupos de combinaciones, donde la suma del número de casos factibles en cada combinación sea mayor que el número de casos posibles.

Capítulo 4

Configuración de la red neuronal

Como se estableció en el capítulo 1, para resolver el problema propuesto se decide implementar una red neuronal unidireccional. En el presente capítulo se estudiará la configuración que mejor se adapte al problema planteado. Para evaluar la efectividad de las distintas alternativas desarrolladas a lo largo de este capítulo, se han utilizado parte de los datos de aplicación que se describen en el capítulo 5.

4.1. Introducción

Los elementos básicos de un sistema neuronal biológico son las neuronas, que se agrupan en conjuntos compuestos por millones de ellas organizadas en capas, constituyendo un sistema con funcionalidad propia. Un conjunto de estos subsistemas da lugar a un sistema global.

En la figura 4.1 se puede ver una Red Neuronal Artificial (RNA) como una colección de procesadores paralelos conectados entre ellos en forma de un grafo dirigido, organizados de tal manera que la estructura de la red lleva por sí misma a considerarla como una característica a tener en cuenta a la hora de crear la RNA. Se puede representar de manera sistemática cada elemento de proceso (unidad) de la red como un nodo, con conexiones entre unidades representadas mediante arcos. Además estos arcos nos indican la dirección en la que fluye la información.

De manera formal Rumelhart [?, 40] definió los componentes de un sistema neuronal:

- Un conjunto de procesadores elementales o neuronas
- Un patrón de conectividad entre las neuronas o arquitectura
- Una dinámica de activaciones.
- Una regla de aprendizaje
- El entorno donde opera




Figura 4.1: *Ejemplo de Red Neuronal Artificial*

En la figura 4.2 se describen la mayor parte de componentes de una neurona artificial. Estas neuronas o componentes pueden organizarse ordenadamente por capas, que delimitan los patrones de interconexión, y son válidos aun cuando sean usadas en cualquiera de las capas de neuronas que la constituyen: entrada, salida, o capas internas u oculta.

En este capítulo se configurarán los aspectos mencionados utilizando la experiencia previa, y de forma empírica se verificará que la solución es la que mejor se adapta al problema planteado. No se encuentra dentro del alcance de este trabajo implementar los métodos de entrenamiento, por ello se aprovechará la implementación de los mismos en MATLAB[©]. Por tanto, todas las pruebas que se realicen sobre la red neuronal se harán utilizando las facilidades que suministra MATLAB[©].

Para comparar los resultados se utilizarán como figuras de mérito el valor de la media de los errores cuadráticos estimado por MATLAB[©] (MSE) y una medida

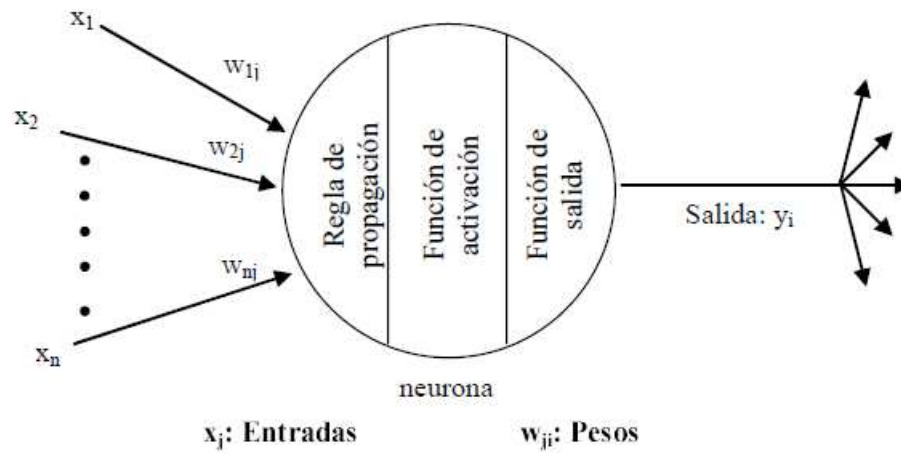


Figura 4.2: Elementos básicos de una neurona artificial

del error propia, que es la sumatoria del valor absoluto de la diferencia entre la salida obtenida y la salida esperada dividido por el número de elementos (ecuación 4.1).

$$E_{abs} = \frac{\sum_i^{\text{casos}} (\sum_j^{\text{grupos}} |\text{salida}_i^j - \text{objetivo}_i^j|)}{\text{casos} * \text{grupos}} \quad (4.1)$$

Aunque la figura de mérito empleada por MATLAB[©] es el MSE, se considera más apropiado el error de valor absoluto. Esto es debido a que ofrece una interpretación de los resultados más cercana a la realidad. Sin embargo, se utilizará, por un lado, el MSE para evaluar la tendencia del error, y por otro lado, el error de valor absoluto como una medida de la precisión general del método empleado, y por tanto será, este último, el criterio en el que se basará la selección.

4.2. Configuración inicial de la red neuronal

Existen en la bibliografía de referencia distintas aplicaciones que manejan información y metodología similar a la empleada en este trabajo. Por ello se aprovechará dicha experiencia para plantear la configuración inicial de la red. Sin embargo, dado que este trabajo pretende introducir al autor en esta línea de investigación, no se dará por válida la configuración inicial obtenida por la

experiencia previa, sino que se verificará empíricamente que esta configuración propuesta es la mejor.

Como ya se ha comentado en varias ocasiones, el modelo de red elegido es el del perceptron. Se descartan en un comienzo las redes retroalimentadas, ya que el sistema no es dependiente del tiempo. También se descartan las redes de base radial en contraste con las redes unidireccionales ya que son las que mejores resultados proporcionan en los trabajos de referencia.

Como entradas del sistema se podrían plantear distintas alternativas. Potencia de cada grupo, porcentajes de carga de cada grupo, potencias máximas y mínimas, demanda total del sistema, niveles de calidad. En aplicaciones de predicción de frecuencias mínimas con redes neuronales como en [41], se concluye que la red debe de conocer los niveles de reserva a subir, por ello se alimenta la red con la potencia de cada grupo y su potencia máxima. Se podría reducir el número de entradas a la mitad introduciendo únicamente el porcentaje de carga. Sin embargo, nuestra red no realizará dicha previsión, la cual será realizada por el simulador, sino que debe reconocer los patrones de modificación de las potencias de los grupos. Por lo tanto la primera entrada que debe asignarse es la potencia de cada grupo y se descartan los niveles de reserva, ya que es un aspecto implícito en el patrón del conjunto de aprendizaje. También se descartan variables auxiliares como valores binarios indicando los grupos con riesgo o potencias totales demandas ya que es información que el simulador refleja en el conjunto de aprendizaje y sin valor añadido para la red neuronal.

Las salidas son un aspecto que está mucho más claro, ya que solo es necesario conocer la potencia total corregida de cada grupo. Se podría plantear que la salida fuera la magnitud de la modificación, pero se prefiere conserva el formato de unidades para evitar errores de fase.

Para este tipo de reconocimiento de patrones, suele resultar más efectiva una sola capa oculta. Aumentar el número de capas no tiene porqué mejorar los resultados, sin embargo si incrementa los tiempos y costes de aprendizaje y evaluación de la red. Por ello se comenzará con la configuración habitual de única capa oculta ensayando más adelante la efectividad real de más capas ocultas.

El número de neuronas plantea una duda similar. Para la capa de salida se fijan tantas neuronas como grupos tiene el sistema. Para la/s capa/s oculta/s se

utilizará el tamaño habitual en la bibliografía de referencia, 20 neuronas. Aun así se ensayará también el efecto al aumentar y disminuir el número de neuronas.

Los valores de entrada a la red son ajustados mediante un cambio de escala respecto a los valores máximos y mínimos que toma cada variable en el conjunto de entrenamiento. Esto se aplicará tanto en el preprocesado como en el postprocesado de los datos.

En cuanto a las funciones de activación y propagación, se utilizarán las funciones habituales, como propagación la sumatoria ponderada de las entradas, y como activación una función sigmoideal en la capa oculta, para contemplar una no linealidad de los datos, y una función lineal en la capa de salida.

Finalmente, como método de entrenamiento se utilizará uno de los métodos clásicos con tiempos de cómputo bajos por iteración y bajos requerimientos de memoria, el resilient backpropagation.

Con todo, la configuración inicial de la red se resumen en:

- Método de procesado: Escalado respecto al máximo y mínimo [-1,1]
- Regla de propagación: Sumatorio-Sumatorio
- Regla de activación: Sigmoideal-Lineal
- Neuronas en la capa oculta: 20
- Número de capas ocultas: 1
- Método de entrenamiento: Resilient backpropagation

4.3. Metodología

Como objetivo secundario de este trabajo se persigue la familiarización con las redes neuronales por parte del autor. Por lo tanto, se ensayarán distintas variantes de la red inicial para encontrar la mejor solución. Para realizar estos ensayos se supondrá que los distintos aspectos configurables son independientes entre si. Es decir, no se realizarán pruebas cruzadas.

Para realizar las pruebas se partirá de la configuración inicial establecida en el apartado anterior y se modificará solo uno de sus parámetros en el rango establecido, de forma que las conclusiones extraídas en cada ensayo no se aplicarán a los siguientes ensayos, realizándose todos en las mismas condiciones. No se realizan las pruebas cruzadas por limitaciones de tiempo y alcance, y porque solo se persigue extraer la influencia que cada parámetro tiene sobre el sistema.

Cada vez que se realiza un análisis se inicializan los pesos de la red de forma aleatoria. Esto conlleva que cada ejecución de la prueba genere resultados diferentes. Por ello, cada test ha sido repetido 5 veces y escogido el mejor de ellos.

Las curvas de entrenamiento presentadas se corresponden con los resultados sobre el grupo de test, que se forma con el 20% de los casos de entrenamiento escogidos de forma aleatoria.

4.4. Procesado de datos

Antes de introducir los datos en la red neuronal es necesario realizar un pre-procesado de los mismos para normalizarlos. Esta normalización dependerá del método, pero por lo general, los valores obtenidos se encuentran acotados entre -1 y 1. Esta necesidad se debe a que las reglas de activación tienen, por lo general, salidas acotadas entre -1 y 1 o entre 0 y 1. A continuación se exponen brevemente los métodos utilizados.

Escalado respecto al máximo y mínimo

Este método permite realizar un escalado independiente para cada una de las variables de entrada. Este escalado necesita cuatro parámetros:

- Ymax: Valor máximo en la escala de salida.
- Ymin: Valor mínimo de la escala de salida.
- Xmax: Valor máximo que alcanza cada variable de entrada en todo el conjunto de aprendizaje.
- Xmin: Valor mínimo que alcanza cada variable de entrada en todo el conjunto de aprendizaje.

Con estos cuatro parámetros se puede escalar cualquier valor de entrada de cada variable según la expresión:

$$Y = \frac{(Y_{max} - Y_{min})(X - X_{min})}{X_{max} - X_{min}} \quad (4.2)$$

La expresión inversa es aplicada para obtener el valor de cada salida asignada a cada entrada. Con este método se probarán dos combinaciones distintas de la escala de salida. Por un lado entre 0 y 1, y por otro entre -1 y 1.

Escalado respecto a la media y la desviación

Este método permite realizar un escalado independiente para cada una de las variables de entrada. Este escalado también necesita cuatro parámetros:

- Ymean: Valor de la media que se quiere en la escala de salida.
- Ystd: Valor de la desviación estándar que se quiere en la escala de salida.
- Xmean: Valor de la media de cada variable de entrada en todo el conjunto de aprendizaje.
- Xstd: Valor de la desviación estándar de cada variable de entrada en todo el conjunto de aprendizaje.

Con estos cuatro parámetros se puede escalar cualquier valor de entrada de cada variable según la expresión:

$$Y = (X - X_{mean}) \frac{Y_{std}}{X_{mean}} + Y_{std} \quad (4.3)$$

La expresión inversa es aplicada para obtener el valor de cada salida asignada a cada entrada. Con este método se probarán solo la combinación normal 0,1.

Escalado respecto a cada fila

Este método procesa las matrices mediante el análisis de componentes principales, para que cada fila no esté correlacionada, las filas están en el orden de

contribución a la variación total, y las filas cuya contribución a la variación total son menos de lo establecido se eliminan.

Se puede escalar cualquier valor de entrada de cada variable según la expresión:

$$Y = \frac{2(X - X_{min})}{X_{max} - X_{min}} - 1 \quad (4.4)$$

Comparativa

Una vez evaluados los cuatro métodos en la red neuronal de partida se obtienen las curvas de aprendizaje de la figura 4.3. Se observa que todos los métodos proporcionan un error monótonamente decreciente con características muy similares entre ellas, estabilizándose en valores ligeramente diferentes.

En la tabla 4.1 se muestra la comparativa de los errores absolutos calculados sobre todo el conjunto de aprendizaje para cada método de procesado de datos. Se observa que el escalado respecto a cada fila produce resultados con un error elevado. El escalado entre máximo y mínimo para $Y_{min}=0$ produce errores bastante elevados tanto si se utilizan reglas de activación entre 0 y 1 como si se utilizan reglas de activación entre -1 y 1. El escalado respecto al máximo y mínimo proporciona un error aceptable, sin embargo, el escalado respecto a la media y a la desviación se obtiene el error más bajo posible.

No queda duda de que por lo tanto, el método elegido para el pre y post procesado de los datos será el cambio de media y desviación estándar hacia una representación con media cero y desviación estándar 1.

	Método	Error medio(MW)
1	Maxmin [-1,1]	2.4347
2	Media y desviación	1.0916
3	Maxmin [0,1]	5.3401
4	Filas	7.4177

Cuadro 4.1: Comparativa de procesado de datos




Figura 4.3: Comparativa de procesado de datos

4.5. Regla de propagación

La función de propagación, como su propio nombre indica, es la responsable de tomar las salidas de la capa anterior y propagarlas hacia adelante. Esta regla permite obtener, a partir de las entradas y los pesos el valor del potencial postsináptico h_i de la neurona. La función más habitual es la suma ponderada de todas las entradas. Se pueden agrupar las entradas y pesos en dos vectores (X_1, X_2, \dots, X_n) y $(W_{1j}, W_{2j}, \dots, W_{nj})$ y calcular esta suma realizando el producto escalar sobre estos dos vectores.

$$h_i = \sum_j^n w_{i,j} x_j \quad (4.5)$$

La función de propagación puede ser más compleja que simplemente una suma de productos. Las entradas y los pesos pueden ser combinados de diferentes ma-

neras antes de pasarse el valor a la función de activación. Por ejemplo se puede usar como función de propagación, el mínimo, máximo, la mayoría, producto, o diversos algoritmos de normalización.

$$h_i = \prod_i^n w_{i,j} x_j \quad (4.6)$$

En este trabajo se han planteado dos métodos, la sumatoria (ecuación 4.5) y el producto (ecuación 4.6). Como se está estudiando una red neuronal de una capa oculta y una capa de salida, se ensayaran las cuatro combinaciones entre las capas oculta y de salida, que serán:

- Sumatoria-Sumatoria
- Sumatoria-Producto
- Producto-Producto
- Producto-Sumatoria

Comparativa

Evaluadas las cuatro combinaciones en la red neuronal de partida, se obtienen las curvas de aprendizaje de la figura 4.4. Se observa que todos los métodos proporcionan un error monótonamente decreciente con características muy similares entre ellas, estabilizándose en valores muy cercanos. Sin embargo se observa que la combinación sumatoria-sumatoria tiene un descenso del error mucho más rápido y un valor final ligeramente menor.

En la tabla 4.2 se muestra la comparativa de los errores absolutos calculados sobre todo el conjunto de aprendizaje para cada una de las combinaciones planteadas. Se observa que todas las combinaciones generan resultados aceptables y muy cercanos entre sí. Se observa un ligero empeoramiento con el producto. La mejor combinación se obtiene con la sumatoria-sumatoria, al introducir el producto en alguna de las capas el resultado empeora, y al introducirlo en las dos se produce el mayor error.

En consecuencia, se elige como regla de comparación para todas las neuronas de la red en todas las capas la sumatoria de la entradas, que ha demostrado proporcionar un aprendizaje más rápido y el menor error final.

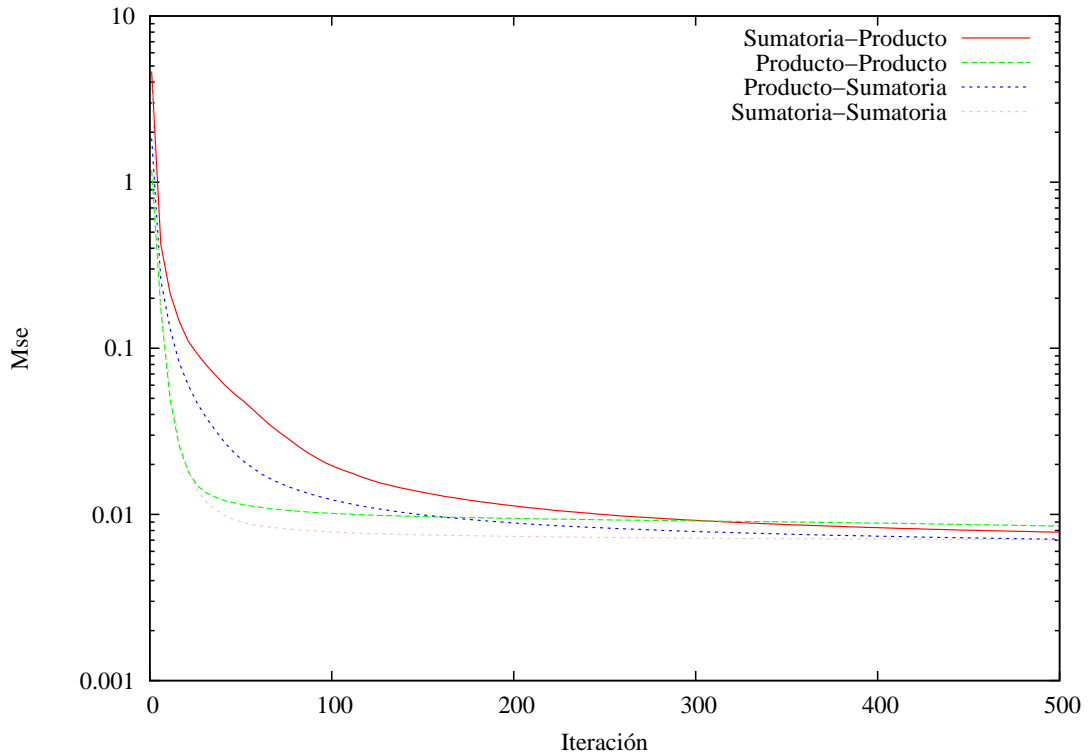


Figura 4.4: Comparativa de reglas de propagación

	Combinación	Error medio(MW)
1	Sumatoria-Producto	2.5294
2	Producto-Producto	2.5581
3	Producto-Sumatoria	2.4458
4	Sumatoria-Sumatoria	2.4347

Cuadro 4.2: Comparativa de reglas de propagación

4.6. Regla de activación

El siguiente factor de gran influencia a tener en cuenta son las funciones de activación de las distintas neuronas. El resultado de la función de propagación, que en este caso es una suma ponderada, es transformada en la salida real de la neurona mediante un proceso algorítmico conocido como función de activación.

En la función de activación el valor de la salida de combinación puede ser comparada con algún valor umbral para determinar la salida de la neurona. Si la suma es mayor que el valor umbral, la neurona generará una señal. Si la suma es menor que el valor umbral, ninguna señal será generada.

Normalmente el valor umbral, o valor de la función de transferencia, es no lineal. El uso de funciones lineales da como resultado redes neuronales con muchas limitaciones ya que el valor de la salida es proporcional al de la entrada, de hecho éste fue uno de los problemas en los primeros modelos de redes neuronales como fue identificado por Minsky y Papert en Perceptrons [42].

Se han tenido en cuenta cuatro tipos de funciones representadas en la figura 4.5.

- Sigmoidal
- Log Sigmoidal
- Lineal
- Lineal saturada

Para comprobar cuál de las funciones se ajusta mejor al problema a resolver, se realiza una comparativa de resultados del aprendizaje utilizando las siguientes combinaciones entre la capa oculta y la capa de salida de la configuración de red inicial:

- Log Sigmoidal-Log Sigmoidal
- Sigmoidal-Sigmoidal
- Lineal-Lineal
- Lineal-Sigmoidal




Figura 4.5: Función de transferencia (a) Sigmoidal (b) Log-Sigmoidal (c) Lineal (d) lineal saturada

- Sigmoidal-Lineal
- Log Sigmoidal-Sigmoidal
- Sigmoidal-Log Sigmoidal
- Log Sigmoidal-Lineal
- Lineal-Log Sigmoidal
- Sigmoidal-Saturada

Comparativa

Evaluadas las diez combinaciones en la red neuronal de partida, se obtienen las curvas de aprendizaje de las figuras 4.6 y 4.7. Se observa que todos los métodos proporcionan un error monótonamente decreciente con dos tendencias diferentes.

Las combinaciones con la función Log-Sigmoidal en la primera capa proporcionan un error muy elevado, mientras que el resto de las combinaciones proporcionan errores más bajos y cercanos entre si.

En la tabla 4.3 se muestra la comparativa de los errores absolutos calculados sobre todo el conjunto de aprendizaje para cada una de las combinaciones planteadas. Se observa que todas las combinaciones que no presentan la función Log-Sigmoidal en la primera capa generan resultados aceptables y muy cercanos entre sí.

Aunque todos los resultados son muy similares, se elige como regla de activación para todas las neuronas de la red en todas las capas la función sigmoideal, que ha demostrado proporcionar el menor error final. De este hecho se deduce que la relación entre las entradas y salidas es ligeramente no lineal, aunque el error de considerarla lineal es bajo.

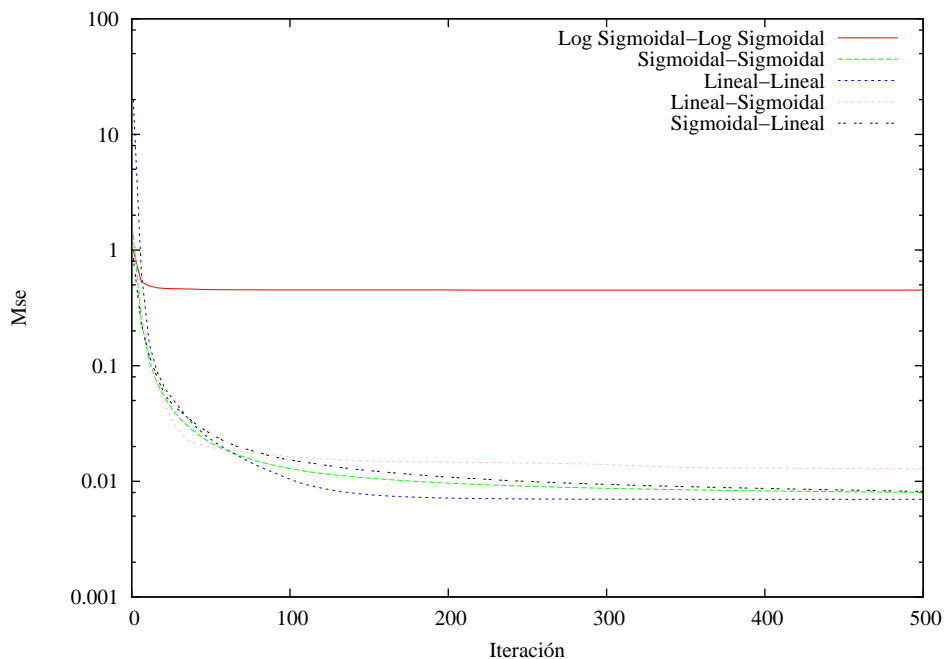


Figura 4.6: Comparativa de reglas de activación




Figura 4.7: Comparativa de reglas de activación

4.7. Neuronas de la capa oculta

Es muy importante que la(s) capa(s) oculta(s) tengan pocas neuronas ya que demasiadas neuronas podrían llevar a que los patrones de entrada fueran memorizados de manera que ningún tipo de generalización fuera posible, haciendo que la red fuera inútil con nuevos datos de entrada.

Por tanto, aumentar el número de capas ocultas de manera indefinida no mejora los resultados de aprendizaje de la red. Es por ello que se han comprobado distintas cantidades de neuronas en la capa oculta. Se han probado 10, 20 y 30 neuronas en la capa oculta manteniendo las 17 neuronas de la capa de salida. A continuación se muestran los resultados de dichas simulaciones.

Comparativa

Evaluadas las tres cantidades de neuronas de la capa oculta en la red neuronal de partida, se obtienen las curvas de aprendizaje de la figura 4.8. Se observa que todas las cantidades proporcionan un error monótonamente decreciente, donde 10

	Combinación	Error medio(MW)
1	Log Sigmoidal-Log Sigmoidal	11.7303
2	Sigmoidal-Sigmoidal	2.4180
3	Lineal-Lineal	2.4557
4	Lineal-Sigmoidal	2.5352
5	Sigmoidal-Lineal	2.4347
6	Log Sigmoidal-Sigmoidal	11.0283
7	Sigmoidal-Log Sigmoidal	2.5681
8	Log Sigmoidal-Lineal	11.0118
9	Lineal-Log Sigmoidal	2.4512
10	Sigmoidal-Saturada	2.4958

Cuadro 4.3: *Comparativa de reglas de activación*

neuronas en la capa oculta proporcionan un error muy elevado.

En la tabla 4.4 se muestra la comparativa de los errores absolutos calculados sobre todo el conjunto de aprendizaje para cada una de las cantidades planteadas. Se observa que tanto con 20 neuronas como con 30 neuronas se obtienen resultados muy similares, quedando descartada la opción de diez neuronas.

Aunque 20 y 30 neuronas producen un error muy cercano, como ya se ha comentado se prefiere minimizar el número de neuronas para mejorar así la capacidad de generalización de la red. Por tanto se elige la configuración de 20 neuronas en la capa oculta, ya que además es la que menor error produce.

	Neuronas	Error medio(MW)
1	10	5.5112
2	20	2.4347
3	30	2.4581

Cuadro 4.4: *Comparativa del número de neuronas en la capa oculta*

4.8. Número de capas ocultas

Tal como se comenta al comienzo del capítulo, la configuración inicial contiene una sola capa oculta y una capa de salida. Normalmente, si el proceso que se




Figura 4.8: Comparativa del número de neuronas en la capa oculta

está modelando es separable en dos etapas, entonces pueden añadirse nueva(s) capa(s). Si el proceso no es separable en varias etapas, entonces las capas adicionales simplemente permiten memorizar y no siempre es una solución general. A continuación se comprueban los resultados con ninguna, una, dos y tres capas ocultas, todas ellas de 20 neuronas.

Comparativa

Evaluadas las cuanto combinaciones de capas ocultas en la red neuronal de partida, se obtienen las curvas de aprendizaje de la figura 4.9. Se observa que todas las cantidades proporcionan un error monótonamente decreciente, donde no tener ninguna capa oculta proporciona un error muy elevado.

En la tabla 4.5 se muestra la comparativa de los errores absolutos calculados sobre todo el conjunto de aprendizaje para cada una de las cantidades planteadas.

Se observa que tanto con 1, 2 y 3 capas ocultas se obtienen resultados muy similares, quedando descartada la opción de no tener capa oculta.

Aunque 1, 2 y 3 capas ocultas producen un error muy cercano, como ya se ha comentado se prefiere minimizar el número de capas ocultas para mejorar así la generalización de la red y disminuir el tiempo de evaluación de la misma. Además, al aumentar el número de capas ocultas, los algoritmos de entrenamiento consumen más tiempo de cómputo y memoria durante el proceso. Por tanto se elige la configuración de una sola capa oculta.




Figura 4.9: Comparativa del número de capas ocultas

4.9. Métodos de entrenamiento

Uno de los aspectos que más influencia puede tener en la precisión final de una red neuronal es el método de aprendizaje empleado para entrenar la red. Existe una gran diversidad de métodos de aprendizaje para redes unidireccionales. Cada

	Capas	Error medio(MW)
1	0	18.425
2	1	2.4347
3	2	3.4438
4	3	2.4528

Cuadro 4.5: *Comparativa del número de capas ocultas*

uno de ellos tiene sus particularidades y sus campos de aplicación. Siguiendo la metodología usada en los apartados anteriores, se intentará determinar el mejor método para el problema propuesto de forma empírica.

Como estos métodos son bien conocidos, no se harán referencias a su funcionamiento, ya que dicha información se encuentra ampliamente recopilada en la bibliografía de referencia. Por tanto solo se mostrarán los resultados de aplicar cada uno de los métodos sobre el mismo conjunto de aprendizaje en las mismas circunstancias.

Comparativa

Por simplicidad, se hará referencia a los métodos únicamente por su número en la tabla 4.6. Una vez evaluados los 20 métodos de entrenamiento en la red neuronal de partida, se obtienen las curvas de aprendizaje de la figuras 4.10, 4.11, 4.12 y 4.13. En las figuras 4.14, 4.15, 4.16 y 4.17 se representa la evolución de los gradientes durante las iteraciones.

Se observan varias tendencias diferentes. Los métodos 2 y 9 son los únicos que no son monótonamente decrecientes y que tienen alternancias o sobreaprendizaje. Los métodos 10, 11, 19 y 20 se adaptan muy mal al problema planteado. Mientras que el resto de los métodos producen resultados similares, destacando los métodos 1, 12 y 17 por alcanzar el error final en menos iteraciones.

En la tabla 4.6 se muestra la comparativa de los errores absolutos calculados sobre todo el conjunto de aprendizaje para cada uno de los métodos de entrenamiento y los tiempos de computación al realizar las 500 iteraciones cada uno. Salvo los métodos 2, 9, 10, 11, 19 y 20, todos los métodos se adaptan perfectamente al problema y proporcionan resultados similares.

Aunque con los métodos 1 y 17 se perfilan como los mejores, cada iteración requiere un gran tiempo de computo y sobretodo mucha memoria disponible. Para el conjunto de datos utilizados en estos ensayos, estos métodos resultan ser los mejores, sin embargo, el conjunto total empleado en el capítulo 5 es excesivamente grande para los mismos, y por lo tanto se elije el método 12, que a pesar de ser uno de los más básicos es, de los disponibles, el método más efectivo.




Figura 4.10: Comparativa de los métodos de entrenamiento

4.10. Configuración final de la red neuronal

Una vez realizados los ensayos pertinentes, se obtiene la configuración óptima de la red para el problema propuesto de forma empírica. Dicha configuración se resume en:

- Entradas: Igual al número de grupos
- Salidas: Igual al número de entradas

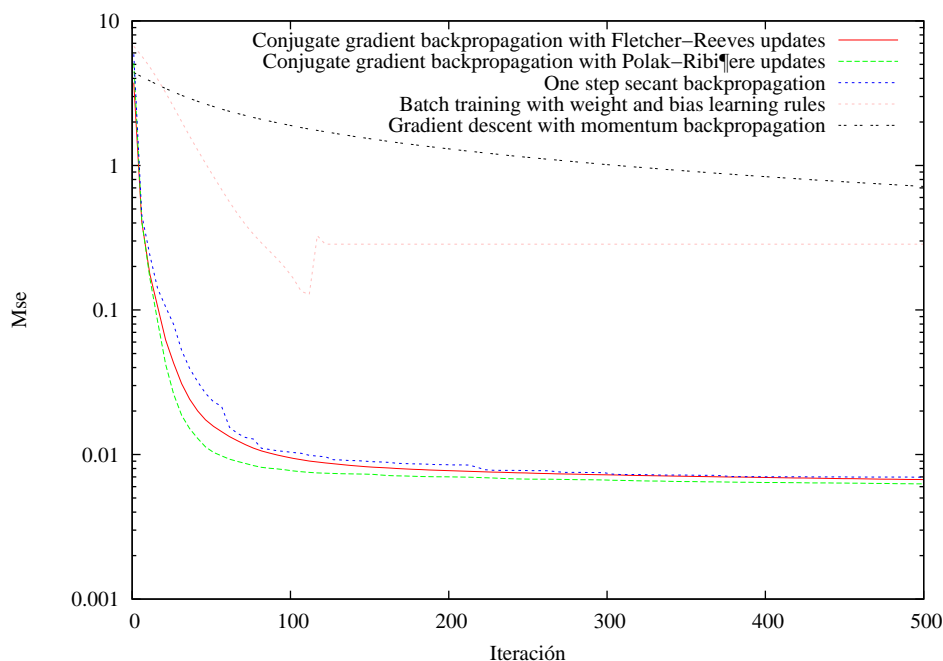


Figura 4.11: Comparativa de los métodos de entrenamiento

- Método de procesado: Escalado respecto a una media 0 y a una desviación estándar 1
- Regla de propagación: Sumatorio en todas las capas
- Regla de activación: Sigmoideal en todas las capas
- Neuronas en la capa oculta: 20
- Número de capas ocultas: 1
- Método de entrenamiento: Resilient backpropagation

Los resultados de los ensayos son satisfactorios, ya que muestran que la configuración inicial estaba bien enfocada. Solo se han realizado dos cambios, el que mayor influencia tiene es el cambio en el método de procesado de datos. El otro cambio afecta a la función de propagación de la capa oculta sin que tenga una influencia notable en el error final.




Figura 4.12: Comparativa de los métodos de entrenamiento

4.11. Implementación de la red

Una vez determinada la configuración óptima de la red neuronal para el problema propuesto, se realiza su implementación en el mismo formato que el resto de código construido en este trabajo. Se implementa el pre-procesado y el post-procesado, la capa oculta de neuronas y la capa de salida. A continuación de la capa de salida se realiza un ajuste final de los resultados de la red. Este ajuste persigue los siguientes objetivos:

- Impedir resultados técnicamente no válidos, como por ejemplo, potencias negativas, grupos acoplados que no lo están a la entrada, errores en la potencia total generada, etc.
- Disminuir el error medio final

Para ello se realizan las siguientes correcciones:

- Poner a cero todas las salidas cuyas entradas están a cero




Figura 4.13: Comparativa de los métodos de entrenamiento

- Poner a su potencia máxima todos los grupos que la hayan superado
- Poner a su potencia mínima todos los grupos que estén por debajo.
- Calcular el error entre la demanda total de la salida y de la entrada y compensarlo homogéneamente este todos los grupos conectados que no estén en sus límites inferior o superior para que toda la demanda quede abastecida y no se de un respuesta no válida.




Figura 4.14: Comparativa de los gradientes de los métodos de entrenamiento




Figura 4.15: Comparativa de los gradientes de los métodos de entrenamiento




Figura 4.16: Comparativa de los gradientes de los métodos de entrenamiento

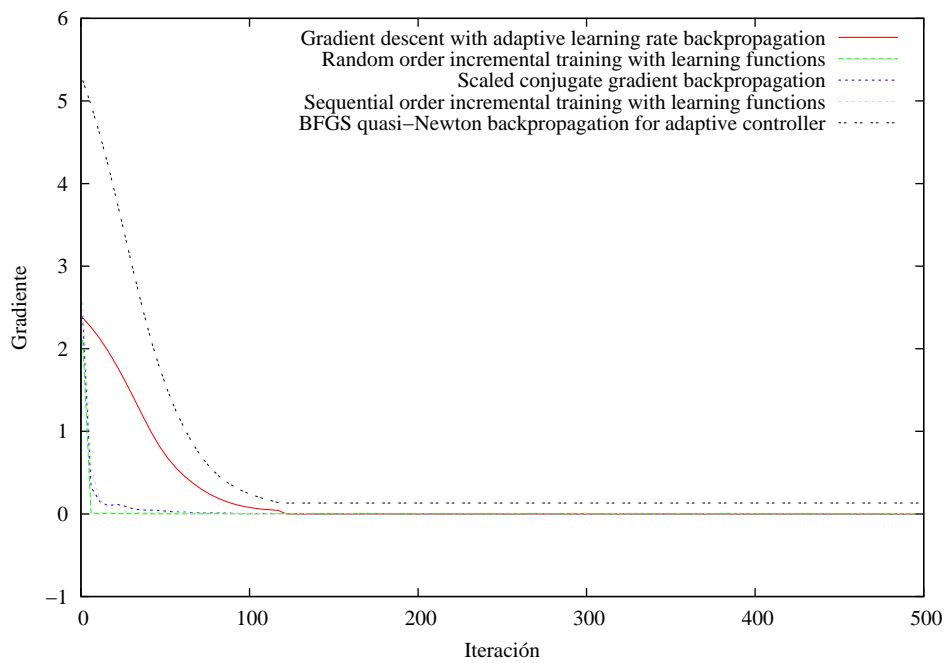


Figura 4.17: Comparativa de los gradientes de los métodos de entrenamiento

	Método	Error medio(MW)	Tiempo (s)
1	Levenberg-Marquardt	2.2859	1.23 e5
2	Gradient descent with momentum and adaptive learning rate	6.5860	11.25 e3
3	BFGS quasi-Newton backpropagation	2.4993	1.26 e3
4	Scaled conjugate gradient backpropagation	2.4416	1.25 e3
5	Conjugate gradient backpropagation with Powell-Beale restarts	2.4078	1.29 e3
6	Conjugate gradient backpropagation with Fletcher-Reeves updates	2.4898	1.05 e3
7	Conjugate gradient backpropagation with Polak-Ribière updates	2.5347	1.25 e3
8	One step secant backpropagation	2.5131	11.33 e3
9	Batch training with weight and bias learning rules	14.8513	475
10	Gradient descent with momentum backpropagation	14.2541	662
11	Gradient descent backpropagation	14.2926	661
12	Resilient backpropagation	2.4347	505
13	Bayesian regularization backpropagation	2.4837	1.78 e5
14	Sigmoidal-Saturada	5.1945	766
15	Cyclical order incremental training with learning functions	5.6986	1.44 e5
16	Gradient descent with adaptive learning rate backpropagation	6.6724	616
17	Random order incremental training with learning functions	2.3550	1.07 e5
18	Scaled conjugate gradient backpropagation	2.4417	1.04 e3
19	Sequential order incremental training with learning functions	14.6797	624
20	BFGS quasi-Newton backpropagation for adaptive controller	13.3215	645

Cuadro 4.6: Comparativa de los métodos de entrenamiento

Capítulo 5

Aplicación y resultados

Una vez creado el método de generación del conjunto de aprendizaje, obtenida la configuración óptima de la Red Neuronal y su implementación, se puede proceder a aplicar todas las herramientas a sistemas reales. Para ello se utilizarán los sistemas aislados del Archipiélago Canario.

En primer lugar se utilizará el sistema de Gran Canaria, por ser el sistema más grande, por su problemática y potencial de mejora. El sistema de Tenerife se descarta ya que su configuración y propiedades son idénticas a las del sistema de Gran Canaria, por lo que los resultados obtenidos no tendrían ningún valor añadido.

En segundo lugar se utilizará el sistema de La Gomera, porque al ser casi 40 veces más pequeño que el sistema de la isla de Gran Canaria y con una configuración muy diferente, puede aportar valor añadido e identificar las variaciones de la efectividad de la red con el tamaño del sistema.

El sistema de Lanzarote-Fuerteventura queda descartado por el elevado número de grupos que posee el sistema combinado, lo que provoca una base de datos de aprendizaje desmesurada, para una red demasiado grande. Además está la peculiaridad del enlace submarino, que impediría aplicar el modelo de nudo único si se pretende, como sería lo razonable, optimizar, además del disparo de los grupos, el posible disparo del cable, ya que esto provocaría un desequilibrio importante y la separación en dos sub-sistemas.

Finalmente, los casos de La Palma y El Hierro tienen la particularidad de que los generadores más recientes tienen un tamaño demasiado grande con respecto

a la demanda de los sistemas. Esto conlleva que apenas tengan posibilidad de mejora con el parque de generación actual. Y aunque podrían ser válidos para comprobar la capacidad de aprendizaje de la red, la mayor parte de los casos de entrada terminarían siendo iguales en la salida debido a la poca capacidad de mejora de los sistemas, por lo que las medidas del error no serían significativas.

En resumen, los sistemas analizados serán los instalados a fecha de realización de este proyecto en las islas de Gran Canaria y La Gomera.

5.1. Sistemas a analizar

A continuación se describirán los sistemas eléctricos a analizar para poner a prueba la solución desarrollada.

5.1.1. Gran Canaria

El sistema consta de dos centrales, una en el sur, Tirajana, y otra en noreste de la isla, Jinamar, tal como muestra la figura 5.1. La central del noroeste está en proceso de desmantelamiento progresivo, lo que implica que cada vez se traslada más generación a la central del sur de la isla.

La configuración de la red no es importante para nuestro simulador, ya que se ha desarrollado en base a la consideración de nudo único. Gracias a la línea de doble circuito de 220 kV que une ambas centrales, esta condición queda garantizada.

Actualmente, el sistema cuenta con 17 grupos activos de generación térmica, con varias tecnologías: turbinas de vapor, turbinas de gas, motores diésel y ciclos combinados. Se ha eliminado toda la generación no gestionable, en este caso la eólica y la fotovoltaica, ya que con la potencia actualmente instalada, la misma no es origen de subfrecuencias. Por lo tanto en la optimización del escenario, su potencia nunca se verá reducida, y tampoco se podrá incrementar ya que no es una potencia gestionable. Las propiedades básicas de las unidades de generación incluidas en el estudio se resumen en la tabla 5.1.

Nombre de la unidad de producción	Pot(MW)	Tensión (kV)	Nudo de conexión
JINAMAR 10, GAS 2	37,500	66	S.E. JINAMAR
JINAMAR 11, GAS 3	37,500	66	S.E. JINAMAR
JINAMAR 12, DIESEL 4	24,000	66	S.E. JINAMAR
JINAMAR 13, DIESEL 5	24,000	66	S.E. JINAMAR
JINAMAR 7, GAS 1	23,450	66	S.E. JINAMAR
JINAMAR 8, VAPOR 4	60,000	66	S.E. JINAMAR
JINAMAR 9, VAPOR 5	60,000	66	S.E. JINAMAR
BCO. DE TIRAJANA 1, GAS 1	37,500	66	S.E. BCO. DE TIRAJANA
BCO. DE TIRAJANA 2, GAS 2	37,500	66	S.E. BCO. DE TIRAJANA
BCO. DE TIRAJANA 3, VAPOR 1	80,000	220	S.E. BCO. DE TIRAJANA I
BCO. DE TIRAJANA 4, VAPOR 2	80,000	220	S.E. BCO. DE TIRAJANA I
BCO. DE TIRAJANA 5, GAS 3 (CC 1)	75,500	220	S.E. BCO. DE TIRAJANA I
BCO. DE TIRAJANA 6, GAS 4 (CC 1)	75,500	220	S.E. BCO. DE TIRAJANA I
BCO. DE TIRAJANA 7, VAPOR 3 (CC 1)	79,650	220	S.E. BCO. DE TIRAJANA I
BCO. DE TIRAJANA 8, GAS 5 (CC 2)	75,500	220	S.E. BCO. DE TIRAJANA II
BCO. DE TIRAJANA 9, GAS 6 (CC 2)	75,500	220	S.E. BCO. DE TIRAJANA II
BCO. DE TIRAJANA 10, VAPOR 4 (CC 2)	83,000	220	S.E. BCO. DE TIRAJANA II

Cuadro 5.1: Grupos de generación de Gran Canaria



Figura 5.1: Red eléctrica de Gran Canaria

5.1.2. La Gomera

El sistema eléctrico de La Gomera es considerablemente menor. No cuenta con red de transporte, la generación se distribuye directamente en 20 kV. En la figura 5.2 se recoge la localización de la central de El Palmar.

Todas las unidades de generación se encuentran acopladas a la misma subestación, validando así la consideración de nudo único. En total se han considerado 8 unidades de generación, todas ellas de tecnología diésel. Por las mismas causas que en el sistema de Gran Canaria, no se ha considerado la pequeña generación no gestionable instalada en la isla. Las propiedades básicas de las unidades de generación incluidas en el estudio se resumen en la tabla 5.2.

5.2. Generación de conjuntos de entrenamiento

Una vez presentados los sistemas, se comienza el proceso de construcción del sistema de optimización por la generación de los conjuntos de entrenamiento. Como paso previo es necesario establecer los niveles de discretización de las potencias

Nombre de la unidad de producción	Pot(MW)	Tensión	Nudo de conexión
EL PALMAR 13, DIESEL 12	1,4	20	S.E. SAN SEBASTIAN
EL PALMAR 14, DIESEL 13	1,4	20	S.E. SAN SEBASTIAN
EL PALMAR 15, DIESEL 14	1,84	20	S.E. SAN SEBASTIAN
EL PALMAR 16, DIESEL 15	1,84	20	S.E. SAN SEBASTIAN
EL PALMAR 17, DIESEL 16	2,51	20	S.E. SAN SEBASTIAN
EL PALMAR 18, DIESEL 17	2,51	20	S.E. SAN SEBASTIAN
EL PALMAR 19, DIESEL 18	3,4	20	S.E. SAN SEBASTIAN
EL PALMAR 20, DIESEL 19	3,4	20	S.E. SAN SEBASTIAN

Cuadro 5.2: Grupos de generación de La Gomera




Figura 5.2: Red eléctrica de La Gomera

de los generadores y las restricciones planteadas en el capítulo 2. En la tabla 5.3 se encuentran las restricciones generales y la discretización aplicada.

	Gran Canaria	La Gomera
Punta de demanda	600 MW	14 MW
Valle de demanda	200 MW	5 MW
Discretización	20 MW	0.15 MW

Cuadro 5.3: Discretización del espacio de búsqueda

A estas restricciones se le añaden las restricciones individuales de que cada grupo debe estar dentro de su rango de trabajo en ambos casos de estudio y los niveles de reserva a subir y a bajar según los Procedimientos de Operación de los S.E.I.E. de REE. Como caso particular se establecen condiciones específicas en Gran Canaria para los ciclos combinados. Esto se debe a que la turbina de vapor es alimentada con los gases de escape de las turbinas de gas. Por lo tanto la potencia que puede generar la turbina de gas está limitada por la potencia que estén generando las turbinas de gas del ciclo combinado. Estas condiciones reflejan la potencia máxima que puede generar la turbina de vapor de cada ciclo

en función de las potencias de sus turbinas de gas.

Una vez planteadas las restricciones se ejecuta el procedimiento de generación de casos. Según el nivel de discretización se generan unos casos posibles. De ellos, solo una parte cumple las restricciones, convirtiéndose así en casos factibles. Cada caso factible es evaluado en el simulador para conocer si produce deslastre de cargas o no, solo si el caso tiene riesgo de deslastre es introducido en el optimizador, ya que si no, la salida del optimizador sería la misma que el estado de entrada porque la función objetivo es nula desde el principio. En la tabla 5.4 se muestran los resultados obtenidos.

	Gran Canaria	La Gomera
Casos posibles	5.598.720	15.523.200
Casos factibles	586.834	522.338
Casos a optimizar	247.591	341.483

Cuadro 5.4: *Resultados de la discretización*

El nivel de discretización se elige con el criterio de obtener el mayor número de casos de entrada para la red neuronal teniendo en cuenta los siguientes aspectos. Para evaluar este aspecto se eligen distintos niveles de discretización, para cada nivel se obtiene un número de casos determinado y la red es entrenada con ese conjunto. En la tabla 5.5 se presentan resultados del entrenamiento de la red neuronal con distintos niveles de discretización. Los ensayos 5 y 6 no han podido ser evaluados con los medios disponibles por el excesivo tamaño de los mismos que implica un uso muy intensivo de memoria. Se verifica empíricamente que la red no pierde generalización con el aumento de casos. Es decir, cuanto más casos, mejores resultados se consiguen. Al aumentar el número de casos el error no disminuye indefinidamente ya que tiene una asíntota inferior. Como ya se ha visto, hay que tener en cuenta también que el número de casos está limitado por la capacidad de la máquina en la que se entrena la red.

Se observa por tanto, que elegir un nivel de discretización de 20 MW resulta más que suficiente para explorar el espacio de búsqueda completo. Una vez seleccionados los datos de entrada de la red, se generan los datos de salida para el aprendizaje supervisado. Para ello se introducen los casos con deslastre en el

Ensayo	Discretización	Casos posibles	Error medio
1	30	24.576	16.32 MW
2	25	73.728	8.65 MW
3	20	5.598.720	2.51 MW
4	15	765.275.504	2.46 MW
5	10	15.728.640.000	-
6	5	150.459.197.161.472	-

Cuadro 5.5: *Comparativa del tamaño del conjunto de aprendizaje*

buscador exhaustivo de la mejor solución. De estos casos, una parte podrán ser corregidos de tal forma que se eviten completamente los desastres, otra será corregida de forma que evite el desastre de algunos grupos o se disminuya su impacto, y quedará un grupo en el que no podrá mejorarse el estado actual y por tanto el caso de salida será igual al caso de entrada. En la tabla 5.6 se presentan los resultados obtenidos en ambos sistemas.

Sistema	Casos a optimizar	Deslastre cero	Deslastre mínimo	Deslastre no evitado
Gran Canaria	247.591	246.324	1.185	82
La Gomera	341.483	1324	245.734	94.425

Cuadro 5.6: *Resultados de la optimización*

En los casos obtenidos, que en la evaluación previa no han sido marcados para optimizar, su caso de salida será el mismo que el de entrada. Es decir, al no haber demanda en riesgo, la red neuronal no debe realizar ningún cambio en el estado actual.

Estos resultados muestran el margen de mejora que tiene el sistema de Gran Canaria, ya que más del 99 % de los casos en los que hay riesgo de deslastre pueden corregirse a deslastre cero, consiguiéndose así una enorme mejora en la calidad del suministro. Sin embargo, el sistema de La Gomera muestra lo contrario, ya que solo el 0.4 % de los casos pueden corregirse a deslastre cero, y un 72 % de los mismos puede reducirse su deslastre pero no anularlo. En resumen, es difícil eliminar por completo el riesgo de deslastre en La Gomera debido, sobre todo, al

tamaño excesivo de los grupos respecto al tamaño del sistema y la baja inercia específica de los mismos, es decir [62], al ser los generador muy grandes, la pérdida de uno de ellos puede suponer hasta el 40 % de la demanda en un momento dado, mientras que en Gran Canaria sería como máximo del del 20 %. Por eso en Gran Canaria resulta más factible corregir los deslastres, mientras que en La Gomera se tienen una limitaciones técnicas insalvables.

Se resume todo el proceso en los siguientes pasos:

1. Se elige el mejor nivel de discretización.
2. Se generan todos los estados posibles que puede tener el sistema con ese nivel de discretización.
3. Se seleccionan los estados, o casos, que cumplen con las restricciones iniciales. Estos compondrán las entradas a la red neuronal.
4. Se evalúan los casos en el simulador si se marcan aquellos que tienen riesgo de deslastre.
5. Los casos con riesgo de deslastre son introducidos en el optimizador. Estos compondrán las salidas objetivo de la red neuronal.

Con todo este proceso se generan los conjuntos de entrenamiento para los sistemas de Gran Canaria y La Gomera.

5.3. Entrenamiento de la red neuronal

Con los conjuntos de entrenamiento generados en el apartado anterior, se procede a entrenar la red neuronal. La red neuronal se configura según los resultados del capítulo 4. Para el caso de Gran Canaria se ajusta el número de entradas y salidas a 17, y para La Gomera a 8.

Este entrenamiento se realiza cinco veces y se toma la mejor de ellas. Aunque la diferencia entre unas y otras es mínima, al ser la inicialización de los pesos aleatoria, se parte de puntos diferentes que pueden desembocar en resultados diferentes, aunque este no sea el caso.

El conjunto de entrenamiento es dividido de forma aleatoria en tres conjuntos: un 15 % para el conjunto de test, un 15 % para el conjunto de validación, y un 70 % para el conjunto de entrenamiento.

En la tabla 5.7 se muestran los errores medios en el conjunto de aprendizaje. Los errores han sido calculados para el conjunto completo, incluyendo el grupo de entrenamiento, el grupo de test y el de validación. Para el sistema de Gran Canaria se ha obtenido un error menor de 1 MW, lo que supone un error del 2 % de media sobre la potencia total del grupo. Teniendo en cuenta los errores de medida habituales en la potencia generada por los grupos que suelen estar entre el 4-5 % y las cifras significativas con las que habitualmente se gestiona la generación (una sola cifra significativa), se considera que un error por debajo del 5 % es bueno. Por lo que el 2 % es un resultado aceptable. Por otro lado, la desviación estandar es ligeramente amplia, con una distancia média de 6.35 MW, lo que da a entender que existen errores mayores que la media, sin embargo, al ser la media tan baja, los errores elevados son casos aislados.

En el caso de La Gomera, el error es de una centésima de MW, lo que supone menos del 0.4 % respecto al tamaño medio de los grupos. En este caso un error en torno al 5 % también se consideraría bueno. Por lo tanto, un error del 0.4 % es un resultado aceptable, al igual que su desviación estandar.

	Gran Canaria	La Gomera
Error Medio	0.9185 MW	0.0113 MW
Desviación std	6.3454 MW	0.2123 MW

Cuadro 5.7: *Error en el conjunto de aprendizaje*

Al proceso de entrenamiento de la red se le ha puesto como condición de parada el número máximo de iteraciones a realizar, en este caso 2000. En las figuras 5.3 y 5.4 se muestran los resultados del aprendizaje de Gran Canaria y La Gomera respectivamente. Se observa que los conjuntos de test, validación y entrenamiento tienen errores casi idénticos. Esto puede inducir a pensar que el sistema está generalizando correctamente en ambos casos. Destaca también el hecho de que el error es siempre monótonamente decreciente, no existiendo efecto de sobreaprendizaje. En las figuras 5.5 y 5.6 se muestra la evolución del gradiente

a lo largo del aprendizaje.

A la vista de estos resultados puede concluirse que el aprendizaje ha sido correcto. En el apartado siguiente se comprobará la capacidad de generalización de la red neuronal.




Figura 5.3: *Aprendizaje del caso de Gran Canaria*




Figura 5.4: *Gradiente del aprendizaje del caso de Gran Canaria*




Figura 5.5: Aprendizaje del caso de La Gomera




Figura 5.6: Gradiente del aprendizaje del caso de La Gomera

5.4. Interpretación de la red neuronal

Una vez entrenada la red neuronal los pesos y las bias, u offsets, adquieren los valores definitivos. Con estos valores se puede utilizar la red neuronal en fase

de recuerdo para obtener soluciones a cualquier caso de entrada que se quiera evaluar. Se puede realizar una interpretación de los valores finales de la red.

La figura 5.7 representa las magnitudes de los pesos en la capa oculta (izquierda) y la capa de salida (derecha). En la figura de la izquierda, el eje y representa cada variable de entrada. Para cada fila se tiene el valor de los pesos que conectan esa entrada con la salida correspondiente. En la figura de la derecha se tiene en el eje y las neuronas de la capa oculta enlazadas con sus correspondientes neuronas de la capa de salida.

Se observa que en general los pesos tienen un valor más bajo en la capa oculta que en la capa de salida, fácilmente comprobable observando los fondos de escala. No se observa que los pesos sigan un tipo de distribución específica. La interrelación entre las distintas neuronas parece bastante homogénea, sobre todo en la capa de salida. Sin embargo, en la capa oculta, las neuronas 8 y 9 parecen resultar dominantes sobre las demás, y las neuronas 3 y 20 las menos influyentes. En la




Figura 5.7: Representación de los pesos de la red Gran Canaria

figura 5.8 se representan los offset de las neuronas de la capa oculta y de la capa de salida. Este valor es sumando entre la función de propagación y la función de activación. Los resultados son bastante dispares. En general los valores son bajos respecto a los pesos. En la capa oculta, las neuronas 8 y 9, que son las que mayores pesos de entrada tienen, tienen offsets negativos, mientras que las neuronas 3 y 20 que tienen pesos más bajos, tienen offsets más altos, de forma que se compensan los efectos. Las figuras 5.9 y 5.10 representan lo mismo que las anteriores pero para la red de La Gomera. En general, las conclusiones extraídas en este caso son




Figura 5.8: Representación de los offset de la red de Gran Canaria

similares a las de Gran Canaria. Los pesos de la capa oculta son menores que los de la capa de salida y parece que su distribución es, también, bastante homogénea, observándose efectos similares de compensación entre los pesos y los offsets más disimulados, sobre todo en las neuronas 18, 19 y 20 de la capa oculta, y la 1 de la capa de salida.

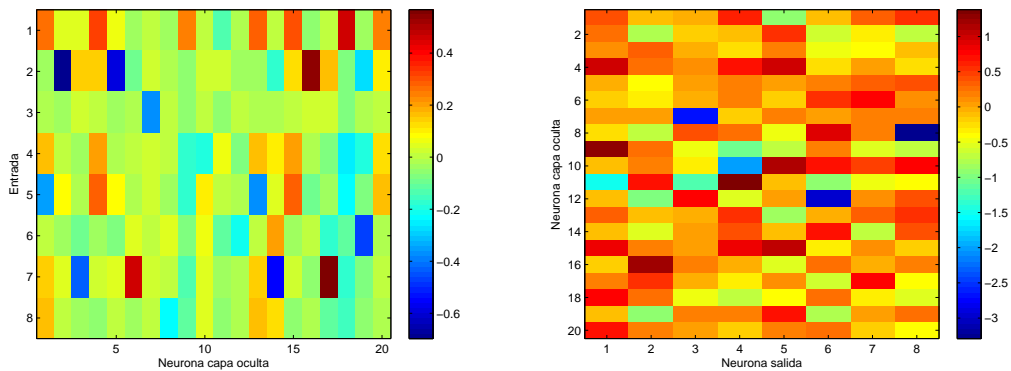


Figura 5.9: Representación de los pesos de la red de La Gomera

5.5. Evaluación de los resultados

En los apartados anteriores se entrena la red neuronal y se muestran los resultados del aprendizaje sobre los conjuntos de test, validación y entrenamiento.




Figura 5.10: Representación de los offset de la red de de La Gomera

Esto verifica la capacidad de aprendizaje de la red. Sin embargo, para realizar una verdadera valoración de la eficacia de la red, es necesario evaluar su capacidad de interpolación. Para ello se generará un conjunto de evaluación utilizando las herramientas utilizadas para generar el conjunto de aprendizaje.

Para este conjunto de evaluación se aplicará un factor de discretización menor, de esta forma se generan casos en el espacio de búsqueda que no pertenecen al conjunto de entrenamiento. Además, al ser menor el factor de discretización, el número de casos a evaluar crece exponencialmente con la disminución del mismo, con lo se explora el espacio de forma más exhaustiva. Los criterios utilizados se resumen en la tabla 5.8.

	Gran Canaria	La Gomera
Punta de demanda	600 MW	14 MW
Valle de demanda	200 MW	4 MW
Discretización	15 MW	0.05 MW

Cuadro 5.8: Discretización del conjunto de evaluación

Con estos niveles de detalle se generan un gran número de casos, tal y como aparece en la tabla 5.9.

Se evalúan todos estos casos en la red neuronal ya entrenada y se calculan los errores en cada caso con la solución esperada. Estos errores se desglosan para poder interpretar mejor los resultados. La figura de mérito utilizada en estos análisis es

	Gran Canaria	La Gomera
Casos posibles	76.527.504	235.952.640
Casos factibles	8.021.287	24.731.551
Casos a optimizar	3.384.259	10.434.483

Cuadro 5.9: *Grupos de generación*

la medida empleada en el capítulo 4, el error medio absoluto.

En primer lugar se obtiene un error medio global en todo los casos analizados para los dos sistemas (tabla 5.10).

	Gran Canaria	La Gomera
Error de entrenamiento	0.9185 MW	0.0113 MW
Desviación std de entrenamiento.	6.3454 MW	0.2123 MW
Error de generalización	2.5127 MW	0.1531 MW
Desviación std. de generalización	8.7513 MW	0.5391 MW

Cuadro 5.10: *Errores de entrenamiento y generalización*

Como cabía esperar, el error medio y la desviación estándar aumentan con respecto a los resultados obtenidos con el conjunto de entrenamiento, sin embargo estos errores siguen estando por debajo de los umbrales máximos aceptables estando ambos en el 5 % de media. De esta forma se confirma la correcta capacidad de aprendizaje e interpolación de las redes neuronales implementadas.

En segundo lugar se desglosa el error según un histograma de errores (figuras 5.11 y 5.12). En estas figuras se muestra el porcentaje de errores por intervalos de magnitud. El rango de posibles errores se divide en categorías, y para cada error evaluado, por su magnitud se determina a que categoría pertenece y se suma uno en dicha categoría. Una vez evaluados todos los errores se divide el número de errores en cada categoría por la cantidad total de errores para obtener el porcentaje relativo. De esta forma se puede observa que, por ejemplo, solo el 0.1 % de los casos tienen un error comprendido entre -15 y -14.5 MW.

Se observa que esta distribución sigue una tendencia muy similar a la de un ley normal. Destaca que en ambos casos el error es bastante simétrico y centrado en cero. En el caso de Gran Canaria existen unos pocos casos con errores elevados,

estando el 99.99% entre -15 y +15 MW, valor menor que el nivel de discretización, y el 72% de los casos entre -5 y 5 MW.

El caso de La Gomera estos errores tienen unas cotas más estrechas, estando el 95% de los errores entre -1 y 1 MW y el 81% de los errores entre -0.5 y 0.5 MW.




Figura 5.11: *Histograma de errores en el caso de Gran Canaria*

En tercer lugar se desglosan los errores por grupos de generación, es decir, se calcula el error medio diferenciado para cada grupo entre la salida obtenida de la red neuronal y la salida objetivo para estudiar si el error se distribuye o no de forma uniforme entre los grupos y si sus características influyen en dicho error. En las tablas 5.11 y 5.12 se muestran los errores medios de cada grupo en el conjunto de aprendizaje. Como era previsible, todos los grupos tienen errores cercanos entre si y cercanos a la media sin que se pueda destacar un patrón en el mismo.

Finalmente se desglosan los errores por la potencia total demandada en cada caso. En las figuras 5.13 y 5.14 se muestra la media del error según la demanda total en el sistema en cada caso. Se observa que para potencias muy bajas o




Figura 5.12: *Histograma de errores en el caso de La Gomera*

potencias muy altas el error aumenta, encontrándose el menor error en la zona media de la gráfica. Se podría plantear por tanto un aumento de las restricciones del conjunto de entrenamiento. De esta forma la zona media abarcaría la verdadera zona de trabajo. Sin embargo, la magnitud y distribución del error se considera buena, con lo que no es necesario realizar este experimento.

Nombre de la unidad de producción	Pot(MW)	Error(MW)
JINAMAR 10, GAS 2	37,500	2.935452
JINAMAR 11, GAS 3	37,500	2.851265
JINAMAR 12, DIESEL 4	24,000	2.082931
JINAMAR 13, DIESEL 5	24,000	2.874528
JINAMAR 7, GAS 1	23,450	2.668993
JINAMAR 8, VAPOR 4	60,000	2.325483
JINAMAR 9, VAPOR 5	60,000	2.028326
BCO. DE TIRAJANA 1, GAS 1	37,500	2.041419
BCO. DE TIRAJANA 2, GAS 2	37,500	2.996456
BCO. DE TIRAJANA 3, VAPOR 1	80,000	2.019669
BCO. DE TIRAJANA 4, VAPOR 2	80,000	2.426834
BCO. DE TIRAJANA 5, GAS 3 (CC 1)	75,500	2.353335
BCO. DE TIRAJANA 6, GAS 4 (CC 1)	75,500	2.611399
BCO. DE TIRAJANA 7, VAPOR 3 (CC 1)	79,650	2.864314
BCO. DE TIRAJANA 8, GAS 5 (CC 2)	75,500	2.582653
BCO. DE TIRAJANA 9, GAS 6 (CC 2)	75,500	2.649359
BCO. DE TIRAJANA 10, VAPOR 4 (CC 2)	79,650	2.734870

Cuadro 5.11: Grupos de generación

Nombre de la unidad de producción	Pot(MW)	Error(MW)
EL PALMAR 13, DIESEL 12	1,4	0.1045
EL PALMAR 14, DIESEL 13	1,4	0.1107
EL PALMAR 15, DIESEL 14	1,84	0.1542
EL PALMAR 16, DIESEL 15	1,84	0.176096
EL PALMAR 17, DIESEL 16	2,51	0.158408
EL PALMAR 18, DIESEL 17	2,51	0.187286
EL PALMAR 19, DIESEL 18	3,4	0.176443
EL PALMAR 20, DIESEL 19	3,4	0.171563

Cuadro 5.12: Grupos de generación de La Gomera

5.6. Ejemplo de aplicación

Una vez comprobada la eficacia de la red neuronal para resolver el problema planteado, se realiza una aplicación práctica. Para ello se tomará una curva diaria real de producción horaria de los grupos del sistema eléctrico de Gran Canaria.




Figura 5.13: *Error en función de la demanda en el caso de Gran Canaria*




Figura 5.14: *Error en función de la demanda en el caso de La Gomera*

La programación elegida es de un día laboral habitual facilitado por Red Eléctrica de España (REE). La figura 5.15 representa la curva de demanda prevista para ese día. Para satisfacer esa demanda, el operador del sistema, REE, planifica una

programación de la generación con el objetivo de minimizar su coste económico, asignando en cada hora la potencia que debe generar cada grupo como se observa en la figura 5.16




Figura 5.15: *Ejemplo de demanda horaria en Gran Canaria*

Se introduce el estado del sistema en cada hora establecido en la programación en la red neuronal y se obtiene el estado óptimo representado en la figura 5.17. A continuación se introducen las salidas de la red neuronal y las programaciones originales en el simulador para evaluar la demanda en riesgo en cada franja horaria. Estas evaluaciones se muestran en la figura 5.18, en primer lugar, se tiene la demanda en riesgo a lo largo de las 24 horas con la programación habitualmente realizada (curva verde) y la demanda en riesgo con la programación obtenida por la red neuronal (curva azul). Y en segundo lugar se calcula la sumatoria del valor absoluto de la diferencia entre la potencia de cada grupo en el caso de partida y la potencia de cada grupo de la solución proporcionada por la red neuronal para evaluar la magnitud de las modificaciones a realizar tal como se vio en el capítulo 3 (curva roja).

Se observa que el mayor nivel de deslastre se encuentra en la rampa de subida




Figura 5.16: Ejemplo de programación horaria en Gran Canaria




Figura 5.17: Solución obtenida por la red neuronal

de la mañana durante el proceso de arranque de los grupos para cubrir la punta de la tarde. Mientras que por la noche, debido a la gran reserva rodante que existe debido a la imposibilidad de desconectar la generación térmica por las noches, se tiene deslastre cero. En las horas de la punta de la noche la demanda en riesgo se mantiene constante ya que aunque los grupos trabajan a mayor carga se conectan más turbinas de gas aumentando así la inercia y la capacidad de regulación del sistema.

Como era de esperar, la magnitud de las correcciones a realizar tiende a ser proporcional al deslastre máximo posible. Situaciones con mucha demanda en riesgo implican desplazar más generación entre grupos que situaciones en las que solo se active el primer escalón.

Se observa que el sistema es capaz de garantizar la calidad del suministro ante posibles desastres por subfrecuencia durante todo el periodo de análisis salvo en




Figura 5.18: Evaluación de los resultados de la Red Neuronal

mitad de la rampa de subida, donde es técnicamente imposible de evitar este caso lo único que puede hacer es minimizar el tamaño de ese deslastre y minimizar a su vez el número de grupos con deslastre.

Se completa de esta forma la visión general de la aplicación final de la herramienta desarrollada y la consecución del objetivo formulado en el capítulo 1.

Capítulo 6

Conclusiones y futuras líneas de trabajo

El presente trabajo pretende resolver un problema real en la operación de los sistemas eléctricos insulares. El problema planteado se resume en la necesidad de mejorar la calidad del suministro eléctrico intentando minimizar los cortes de suministro debido a subfrecuencias en el sistema.

Para ello se plantea la posibilidad de corregir la programación de la generación en tiempo real con dicho fin. Después de revisar las referencias existentes en el ámbito, comprobar resoluciones a problemas similares y plantear las limitaciones del problema, se decide resolverlo utilizando redes neuronales unidireccionales con aprendizaje supervisado.

Después de haber creado, configurado, ensayado y verificado cada una de las partes de las que consta el proyecto, se resumen a continuación las conclusiones e impresiones obtenidas a lo largo de este trabajo, así como las inquietudes o dudas que han surgido que puedan generar nuevas líneas de trabajo.

6.1. Sobre el simulador

Para poder generar el conjunto de entrenamiento se ha construido un simulador dinámico de sistemas eléctricos basado en una serie de consideraciones. Sobre el mismo se han extraído las siguientes conclusiones y observaciones:

- Dadas las consideraciones de partida del simulador, este solo es válido para simular desequilibrios de generación-demanda sin falta previa, con lo que se ajusta correctamente a los requerimientos del problema.
- El simulador solo es válido para sistemas aislados donde se pueda suponer que la frecuencia es homogénea a lo largo de toda la red, como es el caso de los sistemas planteados.
- En principio solo se ha optimizado el disparo simple de grupo por ser el más frecuente y fácil de solventar. Se pueden añadir disparos múltiples siempre que se garantice que no habrá desplazamiento de polos en los grupos conectados ya que el simulador no contempla la posibilidad de pérdida de sincronismo. Sin embargo, todos los incidentes simulados en este trabajo son aptos para el simulador.
- El modelo utilizado para simular el comportamiento de la red necesita solamente de cuatro parámetros (incluyendo potencia) para definir cada grupo, con lo que el ajuste de sus parámetros se simplifica. Estos parámetros han sido ajustados en base a los datos aportados por los propietarios de los grupos y a la experiencia de incidentes del operador del sistema.
- La validez de todo el trabajo está basada en la validez del modelo. La misma queda confirmada al comparar los resultados de la simulación de incidentes reales con el resultado real. A la vista de la comparativa, la precisión y la seguridad en el modelo queda garantizada.
- Hay que tener en cuenta la gran flexibilidad que proporciona el simulador. Si alguno de los elementos de la red se modifica, un grupo o un escalón de deslastre por ejemplo, no es necesario esperar a que tengan lugar incidentes en los que se vea involucrado ese cambio, ya que conociendo su modelo se puede predecir correctamente su comportamiento como ya se ha comprobado.

6.2. Sobre la generación del conjunto de entrenamiento

Al entrenarse la red neuronal por método supervisado es necesario generar tanto los vectores de entrada, como los vectores de salida objetivo. A continuación se resumen las conclusiones sobre ambas partes.

- La metodología planteada para la generación del conjunto de entrenamiento permite abarcar tantos casos como se desee. Si este conjunto se construyera con casos reales, sería muy reducido y poco homogéneo, no permitiendo la generalización de la red. De esta forma, si el Step de discretización del espacio de búsqueda fuera cercano a cero, el conjunto podría abarcar todos y cada uno de los puntos de funcionamiento posibles.
- Cabe la posibilidad de que el número de casos pueda ser menor sin perder precisión realizando un análisis de clustering previo, es decir, seleccionando casos representativos y pudiendo eliminar del conjunto de aprendizaje todos aquellos que no sean representativos de un cluster. De esta forma se optimizaría el proceso de generación del conjunto de aprendizaje así como el propio aprendizaje de la red.
- Para determinar el vector de salida objetivo, es decir, el reparto óptimo de la red en dichas circunstancias, se han planteado diversos métodos. Como el trabajo es bastante extenso y no se requiere que el optimizador sea eficiente, sino rápido, se ha implementado un método de búsqueda exhaustiva.
- Al explorar todas las soluciones posibles se garantiza que la solución encontrada es el óptimo global y no un mínimo local. Esta precisión depende a su vez de la discretización aplicada al realizar la búsqueda.
- Las mejoras del algoritmo de búsqueda permiten reducir el uso del simulador, reduciendo notablemente el tiempo de computación necesario para resolver las entradas al no tener que repetir las mismas simulaciones en cada caso.
- Cuando el nivel de discretización genera un número de casos mayor de lo asimilable por el método de entrenamiento, se ha implementado una se-

lección aleatoria de los mismos para generar un subgrupo homogéneo de tamaño adecuado, aunque para los casos de ejemplo utilizados no ha sido aplicada.

6.3. Sobre la configuración de la red neuronal

El siguiente paso en el proceso consiste en crear un sistema que aprenda los patrones de corrección para disminuir la demanda en riesgo de la misma forma que lo haría un operador en base a su experiencia. Con dicho propósito se ha implementado una red neuronal:

- Existen orientaciones y experiencias previas que permiten orientar la solución a aplicar. En base a la solución aportada por otros autores a problemas que trabajan con las mismas variables y a las características concretas del problema se decidió implementar una red neuronal unidireccional.
- La propia configuración inicial de dicha red se realizó en base a la experiencia previa en trabajos similares. Posteriormente esta configuración fue ensayada y verificada de forma empírica para garantizar el resultado óptimo.
- Se comprobó cada parámetro de la red por separado suponiendo que no existe interacción entre ellos, ya que con estos estudios solo se pretendía verificar la red propuesta e introducir al alumno es esta línea de investigación. Así mismo, desarrollar los ensayos cruzados se extendía más allá de lo pretendido por este trabajo, tanto en tiempo como en alcance.
- A la vista de los ensayos, no fue necesario realizar grandes modificaciones sobre la red de partida, demostrando la valía de la experiencia preliminar.
- El cambio aplicado más influyente ha sido el método de pre y post procesado de datos, resultando más efectivo utilizar un traslado de media y desviación estándar a un sistema de media cero y desviación unidad.
- Se observa que la característica de aprendizaje es siempre monótonamente decreciente. Lo que implica que la red no sufre el fenómeno de sobreaprendizaje. De esta forma, todas las iteraciones son siempre válidas, y se puede

establecer como condición de parada la detección de la llegada a la asíntota inferior.

- Los ensayos de las funciones de activación y propagación muestran que la relación entre las variables de entrada y las de salida es no lineal. Cuanto más horizonte de mejora tenga un sistema, mayor será la diferencia entre las variables de salida y de entrada aumentando así la no linealidad. En sistemas con poco horizonte de mejora, como puede ser La Palma, la mayoría de los casos de salida serían iguales a los casos de entrada, tendiendo así una relación proporcional entre la entrada y la salida.
- Se observa que aumentar más allá de lo inicialmente previsto el número de neuronas o el número de capas ocultas no mejora el error obtenido por la red neuronal.
- Al ser el conjunto de aprendizaje muy grande, no pueden utilizarse métodos de entrenamiento intensivos en memoria ni en cómputo. Es preferible métodos más ligeros aunque con menor velocidad de convergencia.

6.4. Sobre la aplicación práctica

Para poder evaluar la efectividad y la utilidad del sistema desarrollado, es necesario aplicarlo a un caso práctico. Evaluando las características de los sistemas eléctricos insulares se escogen como sistemas de prueba los de Gran Canaria y La Gomera.

- Se aplican una a una todas las partes de este trabajo exponiendo sus resultados. En primer lugar se observa un correcto aprendizaje de la red neuronal, con una característica monótonamente decreciente. Los errores alcanzados en los conjuntos de entrenamiento son muy bajos y más que aceptables para la aplicación requerida.
- Una vez comprobada su capacidad de aprendizaje se evalúa su capacidad de generalización. Para ello se genera una batería de casos muy grande sin coger ninguno de los casos utilizados en el entrenamiento y se observa que

en ambos sistemas los errores aumentan pero permanecen acotados en el nivel requerido.

- De esta forma queda lista una herramienta de optimización que permite obtener en tiempo real las correcciones necesarias a realizar sobre el parque de generación para minimizar los posibles deslastres de cargas por subfrecuencia que puedan tener lugar como consecuencia del disparo de un generador eléctrico.

6.5. Generales

Se verifica que el trabajo planteado ha cumplido con los objetivos planteados:

1. Que el sistema inteligente implementado tenga tiempos reducidos de resolución para su aplicación en tiempo real. Los tiempos de resolución requeridos debían de ser inferiores a 3 segundos, la resolución de las redes planteadas es menor a 1 segundo utilizando ordenadores domésticos.
2. Que el método de entrenamiento sea flexible, permitiendo asimilar las modificaciones en el sistema eléctrico.
3. Que los errores de la red neuronal estén dentro de los márgenes requeridos.

Se ha conseguido así, el objetivo inicial, que pretendía generar un método de apoyo a la operación que permita una reducción de los deslastre por frecuencia con la mínima modificación necesaria sobre el despacho económico de cargas.

6.6. Futuras líneas de trabajo

Durante el desarrollo de este trabajo han surgido distintas inquietudes, otros posibles planteamientos de algunos aspectos del problema o posibles líneas de trabajo como continuación de este. Entre ellas destacan:

- Extender el trabajo a un cambio de filosofía: En lugar de corregir el sistema en tiempo real, realizar un sistema de optimización del despacho de cargas

multivariable, en el que la función objetivo de la seguridad del suministro sea la red neuronal, pero indicando en este caso el nivel de fiabilidad de la solución propuesta.

- Mejora del simulador: Evolución a un sistema de mayor orden sin necesidad de eliminar las consideraciones de desacoplo de potencias y de nudo único, es decir aumentar el número de polos del módulo del regulador de velocidad.
- Mejorar el ajuste de los modelos: Utilizar métodos de autoajuste on-line basados en los resultados de incidencias reales.
- Optimización de la selección de casos: Desarrollar estrategias de clustering que permitan identificar mejor los casos representativos, mejorando así la efectividad de la base de datos.
- Mejora del optimizador de casos: Implementación de técnicas más avanzadas que permitan mejorar el rendimiento reduciendo el error y disminuyendo el número de evaluaciones del simulador.
- Contrastar con aprendizaje mediante refuerzo: Implementar y contrastar los resultados con sistemas inteligentes basados en aprendizaje mediante refuerzo utilizando para ello el simulador de la red.
- Contrastar con sistema de base radial: Desarrollar el contenido de este trabajo utilizando redes neuronales de base radial y contrastar los resultados obtenidos con las redes unidireccionales.
- Ampliar el estudio de resultados: Extender los estudios al resto de sistemas de las Islas Canarias y realizar un análisis de los errores cometidos por la red neuronal empleado técnicas de análisis estadístico.
- Desarrollo de un interface de utilización de la herramienta desarrollada: Crear un software de fácil utilización que permita una aplicación práctica e intuitiva para el usuario tipo.

Bibliografía

- [1] Furong Li Changchau Clien, Sizing a flexible spinning reserve level with artificial neural networks, Department of Electronic, Electrical Engineering University of Bath, United Kingdom, 2000.
- [2] C.C. Wu and N. Chen, Online methodology to determine reasonable spinning reserve requirement for isolated power systems, IEEE Proc-Gener. Transm. Distrib., Vol. 100. No. 4, July 2003.
- [3] C.C. Wu and N. Chen, Frequency-based method for fast-response reserve dispatch in isolated power systems. IEEE Proc.-Gener. Transm. Distrib., Vol. 151, No. 1, January 2004.
- [4] Le-Ren Chang-Chien, Member, IEEE, Yin-Juin Lin, and Chin-Chung Wu, A Real-Time Contingency Reserve Scheduling for an Isolated Power System, IEEE Transactions on reliability, Vol. 56, No. 1, March 2007.
- [5] Le-Ren Chang-Chien, Member, IEEE, Yin-Juin Lin, and Chin-Chung Wu, An Online Approach to Allocate Operating Reserve for an Isolated Power System, Transactions on power systems, Vol. 22, No. 3, August 2007
- [6] Maximum Frequency Deviation Calculation in Small Isolated Power Systems, Ignacio Egido, Fidel Fernández-Bernal, Pablo Centeno, and Luis Rouco, IEEE Transactions on power systems, vol. 24, No. 4, November 2009.
- [7] L. Wehenkel, Emergency control and its strategies, in Proc. 13th Power Syst. Comput. Conf., Trondheim, Norway, 1999, pp. 3548.
- [8] C. Taylor, Advanced Angle Stability Controls, Tech. Rep. 155, <http://transmission.bpa.gov/orgs/opi/CIGRE>, 1999.

-
- [9] C. W. Taylor, Response-based, feedforward wide-area control, in Proc. Nat. Sci. Found./Dept. Of Energy /Elect. Power Res. Inst. Sponsored Workshop on Future Research Directions for Complex Interactive Networks, Washington DC, USA, Nov. 1617, 2000.
- [10] S. Rovnyak, Proc. Nat. Sci. Found./Dept. Of Energy/Elect. Power Res. Inst. Sponsored Workshop on Future Research Directions for Complex Interactive Networks, Washington DC, USA, Nov. 1617, 2000.
- [11] Nelson Martins, Sandro Corsi, Goeran Andersson, Mike J. Gibbard, Juan J. Sanchez-Gasca Aguinaldo, Silva Glauco, N. Taranto, Impact of the Interaction Among Power System Controls, Status Report of CIGRE TF 38.02.16, Brochure No. 166, Paris, 2000.
- [12] Saleem, A. Lind, M. Singh, S.N., Modeling control situations in power system operations, Proc. 2010 International Conference on Autonomous and Intelligent Systems (AIS), pp 1-6, Povoá de Varzim, Portugal, 21-23 June 2010
- [13] Stuart Russell and Peter Norvig, Artificial Intelligence: A Modern Approach, (Third edition), Prentice Hall; third edition, December 11, 2009.
- [14] Vytelingum, P., Ramchurn, S. D., Voice, T. D., Rogers, A. and Jennings, N. R. (2010) Trading agents for the smart electricity grid. In: The Ninth International Conference on Autonomous Agents and Multiagent Systems (AAMAS 2010), May 10 14, 2010, Toronto, Canada. pp. 897 904.
- [15] Martínez Ortiz, Ivan, Introducción a las Redes Neuronales, Facultad de Informática, Universidad Complutense de Madrid
- [16] Neural Network Toolbox, Release Notes, COPYRIGHT 20052010 by The MathWorks, Inc
- [17] Hudson Beale, M., Hagan M., Demuth H., Neural Network Toolbox 7 Users Guide. 2011
- [18] C. C. Liu, J. Jung, G. T. Heydt, and V. Vittal, The strategic power infrastructure defense (SPID) system, IEEE Contr. Syst. Mag., vol. 20, pp. 4052, July 2000

-
- [19] A. Diu and L. Wehenkel, EXaMINE experimentation of a monitoring and control system for managing vulnerabilities of the European infrastructure for electrical power exchange, in Proc. IEEE Power Eng. Soc. Summer Meeting, Panel Sess. Power Syst. Security in the New Market Environ., Chicago, IL, 2002.
- [20] Ruiz-Vega, Daniel and Glavic, Mevludin and Ernst, Damien, Transient stability emergency control combining Open-Loop Closed-Loop Techniques, Proceedings of IEEE PES 2003 Summer Meeting, Toronto, Canada, July 13-17, 2002
- [21] Licheng Jin; Kumar, R.; Elia, N.; Model Predictive Control-Based Real-Time Power System Protection Schemes, IEEE Transactions on Power Systems, Vol. 25, num. 2, pp 988-998, May 2010
- [22] L. Wehenkel, Emergency control and its strategies, in Proc. 13th Power Syst. Comput. Conf., Trondheim, Norway, 1999, pp. 3548.
- [23] C. W. Taylor, Response-based, feedforward wide-area control, in Proc. Nat. Sci. Found./Dept. Of Energy /Elect. Power Res. Inst. Sponsored Workshop on Future Research Directions for Complex Interactive Networks, Washington DC, USA, Nov. 16-17, 2000.
- [24]] C. C. Liu, J. Jung, G. T. Heydt, and V. Vittal, The strategic power infrastructure defense (SPID) system, IEEE Contr. Syst. Mag., vol. 20, pp. 4052, July 2000.
- [25] A. Diu and L. Wehenkel, EXaMINE experimentation of a monitoring and control system for managing vulnerabilities of the European infrastructure for electrical power exchange, in Proc. IEEE Power Eng. Soc. Summer Meeting, Panel Sess. Power Syst. Security in the New Market Environ., Chicago, IL, 2002.
- [26] D. Ernst, M. Glavic and L. Wehenkel, Power systems stability control : Reinforcement learning framework , IEEE Transactions on Power Systems, Volume 19, pages 427-435, February 2004,

-
- [27] Robin Podmore, Marck Ramon Robinson, The Role of Simulators for Smart Grid Development, IEEE TRANSACTIONS ON SMART GRID, VOL. 1, NO. 2, SEPTEMBER 2010.
- [28] North, M., G. Conzelmann, V. Koritarov, C. Macal, P. Thimmapuram and T. Vaselka (2002) E-laboratories: agent based modelling of electricity markets. American Power Conference, Chicago, April 15 17.
- [29] McArthur, S.D.J.; Davidson, E.M.; Catterson, V.M.; Dimeas, A.L.; Hatziargyriou, N.D.; Ponci, F.; Funabashi, T.; Multi Agent Systems for Power Engineering Applications Part I: Concepts, Approaches, and Technical Challenges, IEEE Transactions on Power Systems, Vol 22 num. 4, pp: 1743 1752, Nov. 2007
- [30] McArthur, S.D.J.; Davidson, E.M.; Catterson, V.M.; Dimeas, A.L.; Hatziargyriou, N.D.;
- [31] Ponci, F.; Funabashi, T.; Multi Agent Systems for Power Engineering Applications Part II: Technologies,
- [32] Standards, and Tools for Building Multi agent Systems, IEEE Transactions on Power Systems, Vol 22 num. 4, pp: 1753 1759, Nov. 2007
- [33] C M Macal, M J North, Tutorial on agent-based modelling and simulation, Journal of Simulation, vol 4, pp 151 162, 2010.
- [34] Stuart Russell and Peter Norvig, Artificial Intelligence: A Modern Approach, (Third edition), Prentice Hall; third edition, December 11, 2009.
- [35] Michael Wooldridge, Reasoning about Rational Agents, by The MIT Press, Cambridge,Massachussetts/London,England, June 2000
- [36] Richard S. Sutton, Andrew G. Barto, Reinforcement Learning: An Introduction, MIT Press , Cambridge, MA, 1998
- [37] Rogers, A. and Jennings, N. (2010) Intelligent Agents for the Smart Grid. PerAda Magazine.

-
- [38] Vytelingum, P., Voice, T. D., Ramchurn, S. D., Rogers, A. and Jennings, N. R. (2010) Agent Based Micro Storage Management for the Smart Grid. In: The Ninth International Conference on Autonomous Agents and Multiagent Systems (AAMAS 2010), May 10 14, 2010, Toronto, Canada. pp. 39 46.
- [39] Rumelhart, D.E., J.L. McClelland and the PDP Research Group (1986). Parallel Distributed Processing: Explorations in the Microstructure of Cognition. Volume 1: Foundations, Cambridge, MA: MIT Press
- [40] McClelland, J.L., D.E. Rumelhart and the PDP Research Group (1986). Parallel Distributed Processing: Explorations in the Microstructure of Cognition. Volume 2: Psychological and Biological Models, Cambridge, MA: MIT Press
- [41] Kottick D., Senior Member IEEE, Neural-Networks for Predicting the Operation of an Under-Frequency Load Shedding System. Israel Electric Corp. Ltd. Research and Development Division
- [42] Minsky M. L. and Papert S. A. 1969. Perceptrons. Cambridge, MA: MIT Press.
- [43] Ministerio de industria Turismo y Comercio, *Planificación de los sectores de electricidad y gas 2008-2016, Desarrollo de las redes de transporte*, Mayo 2008.
- [44] Red Eléctrica de España, *Mapa de transporte de la red eléctrica de canarias*, Enero 2009.
- [45] Gobierno de Canarias, Consejería de Industria Comercio y Nuevas Tecnologías, *Plan Energético de Canarias*, 2008.
- [46] Ministerio de Industria y Comercio, *Directorio de actuaciones en la red eléctrica insular*, Junio 2002.
- [47] Grainger, J. *Análisis de sistemas de potencia*, Mc Graw Hill 1996.
- [48] Ministerio de Industria, *RLAT, Reglamento sobre condiciones técnicas y garantías de seguridad en líneas de alta tensión*, BOE 2008.

-
- [49] Ministerio de Industria, *Registro de los grupos de operación instalados en España*, 2008.
- [50] General Electric, *Industrial Power Systems Data Book*.
- [51] ABB *Switchgear technology*
- [52] Martín del Toro, B., *Optimización mediante algoritmos genéticos del proceso de deslastre y reposición de cargas en sistemas eléctricos de potencia aislados ante una subfrecuencia por pérdida de generación usando el despacho de telecontrol*, Tesis Doctoral, 2001
- [53] Bueno, C., Carta, J.A., *Wind powered hydro storage systems, a means of increasing the penetration of renewable energy in the Canary Islands*, September 2004, Elsevier
- [54] Red Eléctrica de España, *SEIE Procedimientos de operación de los sistemas eléctricos peninsulares e insulares*, 2006
- [55] Rouco Rodríguez, L., Centeno Lopez, P., Fernandez Bernal, F., *Estabilidad de los sistemas eléctricos insulares*, Anales de mecánica y electricidad, julio-agosto 2004.
- [56] Arosemena, C. J., *Estabilidad de tensión en un sistema eléctrico de potencia variando la penetración eólica*, CAEsoft Consulting S.L. Diciembre 2004
- [57] Ruiz, E., Torres, A., *Estudios de estabilidad de pequeña señal*, UPME
- [58] Argüello, G., Hermógenes Flores, J., *Estudio de estabilidad de pequeña señal en el sistema nacional interconectado aplicando el método de análisis modal*, XIX Jornadas de Ingeniería eléctrica y electrónica
- [59] López Lezama, J. M., Gallego Pareja, L. A., *Optimal Power Flow using the gradient method to reduce electrical losses in power systems*, Ingeniería y ciencia, junio 2008
- [60] Rouco Rodríguez, L., Rodríguez García, J. M., Lobato Miguélez, E., Echavarrén Cerezo, F. M., *El colapso de tensión. Causas y soluciones*, Anales de mecánica y electricidad, marzo-abril 2006.

-
- [61] Milano, F., *Análisis de sistemas de potencia en ambiente de mercados eléctricos*, Escuela Técnica Superior de Ingenieros Industriales, Universidad de Castilla-La Mancha
- [62] Quilumba Gudiño, F., Játiva Ibarra, J., *Análisis de Estabilidad de Voltaje en Estado Estable de Sistemas Eléctricos de Potencia basado en el Método de Continuación aplicado a Flujos de Potencia*, Facultad de Ingeniería Eléctrica, Proyecto de Titulación, Marzo 2008
- [63] Kundur, P., *Power system stability and control*, McGraw Hill
- [64] Rouco, L., Zamora, J.L., Gonzáles, M., *Ajuste de reguladores de turbinas hidráulicas con técnicas de estimación de parámetros*, Universidad Pontificia Comillas
- [65] Medina Padrón, J. F., *Análisis de sistemas eléctricos ante la integración de parques eólicos. Aplicación al caso de las Islas Canarias*, Tesis doctoral, Universidad de Las Palmas de Gran Canaria.
- [66] Red Eléctrica y Empresas Eléctricas, *Criterios Generales de Protección del Sistema Eléctrico Peninsular Español*, 1995.
- [67] Keith Watt, A., *Simulación dinámica para distintos escenarios de alta penetración eólica en el SIC*, Universidad de Chile, Departamento de Ingeniería Eléctrica.
- [68] Carbajo, A., *La integración de la eólica en el sistema de generación y transporte de electricidad*, Red Eléctrica de España.
- [69] Galván, D., Luengo, G., Tomanovic, S., Portales, R., *Análisis de generación eólica en sistemas eléctricos de potencia*, ABB Transmission and Distribution Systems, S.A., Energuía.
- [70] Rodríguez, J., González, M., Diago, J. R., Domingo, C., Egido, I., Centeno, P., Fernández, F., Rouco, L., *Un esquema centralizado de deslastre de cargas para pequeños sistemas aislados*, Endesa Generación, Universidad Pontificia Comillas.

- [71] Acuña Mora, M., Andrés, J., *Análisis para la Interconexión de una Planta Eólica a un Sistema de Distribución Eléctrica*, Universidad de Costa Rica.