

SEP

SECRETARÍA DE
EDUCACIÓN PÚBLICA



Subsecretario de Educación Superior
Dirección General de Educación Superior Tecnológica
Instituto Tecnológico de la Laguna

DIVISIÓN DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN

“Estimación del Estado de Carga de Baterías de Ciclo Profundo Usando Redes Neuronales”

POR

Ing. Julián Javier Sánchez González.

TESIS

**PRESENTADA COMO REQUISITO PARCIAL PARA OBTENER
EL GRADO DE MAESTRO EN CIENCIAS EN INGENIERÍA
ELÉCTRICA**

ASESOR DE TESIS

Dra. Concepción Hernández Flores.

COASESOR DE TESIS

Dr. Marco Antonio Arjona López

ISSN: 0188-9060



RIITEC: (03)-TMCIE-2014

Torreón, Coahuila. México,
Mayo 2014

2014, Año de Octavio Paz

Torreón, Coah., 30/Abril/2014
Dependencia: DEPI/CPC E
Oficio: DEPIJ/CPCIE/030/2014
Asunto: Autorización de
impresión de tesis.


C. JULIAN JAVIER SÁNCHEZ GONZÁLEZ
CANDIDATO AL GRADO DE MAESTRO EN CIENCIAS EN INGENIERÍA ELÉCTRICA.
PRESENTE

Después de haber sometido a revisión su trabajo de tesis titulado:

**"Estimación del estado de cargas de baterías de ciclo profundo
usando redes neuronales"**

Habiendo cumplido con todas las indicaciones que el jurado revisor de tesis hizo, se le comunica que se le concede la autorización con número de registro **RIITEC: (03)-TMCIE-2014**, para que proceda a la impresión del mismo.

ATENTAMENTE
EDUCACIÓN TECNOLÓGICA FUENTE DE INNOVACIÓN



DR. JOSÉ LUIS MEZA MEDINA
Jefe de la División de Estudios de Posgrado e Investigación
del Instituto Tecnológico de la Laguna

RHSR



DR. JOSE LUIS MEZA MEDINA
JEFE DE LA DIVISIÓN DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN

Por medio de la presente, hacemos de su conocimiento que después de haber sometido a revisión el trabajo de tesis titulado:

**"Estimación del estado de cargas de baterías de ciclo profundo
usando redes neuronales"**

Desarrollado por el **C. JULIÁN JAVIER SÁNCHEZ GONZÁLEZ**, con número de control **M1213004** y habiendo cumplido con todas las correcciones que se le indicaron, estamos de acuerdo que se le conceda la autorización de la fecha de examen de grado para que proceda a la impresión de la misma.

ATENTAMENTE
EDUCACIÓN TECNOLÓGICA FUENTE DE INNOVACIÓN


Dra. Concepción Hernández Flores
Asesor/Director


Dr. Marco A. Arjona López
Coasesor


M.C. Ricardo Vargas Salas
Comité Tutorial


M.C. Carlos A. Morales Bazán
Comité Tutorial



Dedicado a mi familia

Agradecimientos

Agradezco a **Dios** por haberme dado la existencia y salud necesarias para para realizar este proyecto tan importante en mi vida.

Con todo mi amor a mi esposa **L.Lunue** por su apoyo incondicional.

A mis **padres** por su motivación y apoyo que me han brindado para lograr todas y cada una de mis metas así como me impulsan a lograr mis sueños.

A los doctores **Concepción Hernández Flores** y **Marco Antonio Arjona López** por su inmejorable asesoría en la realización de esta tesis, pero sobre todo por su invaluable paciencia y por la confianza que depositaron en mí.

A mis compañeros y amigos: **M.C. Adolfo González, M.C. Fernando Ramírez, M.C. Cristian Espinoza, Ing. David Manríquez** por su apoyo y compañía en esta etapa de mi vida.

Al **Consejo Nacional de Ciencia y Tecnología (CONACyT)** por el apoyo económico brindado para la realización de esta investigación.

Índice general

Resumen	VIII
Capítulo 1 Introducción	1
1.1 Introducción	1
1.2 Objetivo de la tesis	3
1.3 Justificación	3
1.4 Contenido de la tesis	4
Capítulo 2 Fundamentos de las Baterías	7
2.1 Introducción	7
2.2 Clasificación de baterías	8
2.2.1 Baterías primarias	8
2.2.2 Baterías secundarias	9
2.3 Principio de funcionamiento	10
2.4 Elementos que componen la celda electroquímica	10
Capítulo 3 Convertidores de CD-CD	17
3.1 Introducción	17
3.2 Generación del ciclo de trabajo	18
3.3 Convertidor reductor (Buck)	19
3.4 Convertidor elevador (Boost)	23
3.5 Convertidor reductor-elevador (Buck-Boost)	25
Capítulo 4 Redes neuronales artificiales	29
4.1 Definición de una red neuronal	29
4.1.1 <i>la neurona biológica</i>	30
4.1.2 <i>la neurona artificial</i>	30
4.2 Topología de las redes neuronales	31
4.3 Conexión entre neuronas	31
4.4 Mecanismos de aprendizaje	33
4.4.1 <i>Aprendizaje supervisado</i>	34
4.4.1.1 Aprendizaje por corrección de error	35
4.4.2 <i>Aprendizaje no supervisado</i>	36
4.5 Modelo neuronal	37
4.5.1 Neurona con una entrada	37
4.5.2 Funciones de transferencia	38
4.5.2.1 Función de transferencia Hard Limit o escalón	38
4.5.2.2 Función de transferencia lineal	39
4.5.2.3 Función de transferencia log-Sigmoid	39
4.5.3 Neurona con múltiples entradas	40

4.5.4	Arquitectura de redes	42
4.5.4.1	Capa de neuronas	42
4.5.4.2	Neuronas de capas múltiples	43
4.5.5	Red neuronal de <i>retropropagación</i>	45
4.5.5.1	Algoritmo de retropropagación	45
Capítulo 5	Métodos de estimación del estado de carga de baterías	51
5.1	Introducción	51
5.2	definición de estado de carga	52
5.3	métodos de estimación del estado de carga	54
5.3.1	Prueba de descarga	54
5.3.2	Conteo de amperios-hora	54
5.3.3	Mediciones de las propiedades físicas del electrolito	55
5.3.4	Voltaje de circuito abierto	55
5.3.5	Interpretación heurísticas de mediciones	57
5.3.6	Coup de fouet	57
5.3.7	Modelo lineal	58
5.3.8	Redes neuronales artificiales	58
5.3.9	Impedancia estroboscópica	59
5.3.10	Resistencia interna	59
5.3.11	Filtro de kalman	60
Capítulo 6	Diseño y simulación de un algoritmo de estimador del estado de carga para baterías de ciclo profundo con redes neuronales	62
6.1	Introducción	62
6.2	Sistemas fotovoltaicos	62
6.2.1	Modelo matemático del módulo fotovoltaico	64
6.2.2	Panel fotovoltaico utilizado	68
6.3	Algoritmo de seguimiento de punto de máxima transferencia de potencia (MPPT)	70
6.4	Calculo de inductancia y capacitancia de convertidor reductor-elevador	75
6.5	Simulación de convertidor reductor-elevador empleado como cargador de baterías de tres etapas	77
6.5.1	Sistemas de control en lazo cerrado	78
6.5.2	Sistemas de control en lazo abierto	79
6.5.3	Sistema de control en lazo cerrado en comparación con sistemas en lazo Abierto	79
6.6	Simulación de convertidor reductor-elevador con batería y panel fotovoltaico y MPPT	84
6.7	Implementación del convertidor reductor-elevador	88
6.8	Prueba de carga de batería con convertidor reductor-elevador con modulo Fotovoltaico y MPPT	90
6.9	Simulación de algoritmo de estimador de estado de carga con datos de descarga de batería	92
6.9.1	Simulación de la red neuronal de retroalimentación con 4 entradas Con datos de descarga	93
6.9.2	Simulación de la red neuronal de retroalimentación con 3 entradas Con datos de descarga	95

6.10	Simulación de algoritmo de estimador de estado de carga con datos de carga de batería	98
6.10.1	Simulación de la red neuronal de retroalimentación con 4 entradas Con datos de carga	99
6.10.2	Simulación de la red neuronal de retroalimentación con 3 entradas Con datos de carga	101
	Capítulo 7 Conclusiones	104
	7.1 conclusiones	104
	7.2 trabajos futuros	105
	Referencias	107

Índice de figuras

2.1	Esquema de una celda electroquímica	10
2.2	Elementos básicos de una celda recargable	11
2.3	Estructura típica de una batería para aplicaciones de regímenes cíclicos de carga-descarga	15
3.1	Comparación de una señal de referencia con una portadora	19
3.2	Diagrama de circuito de convertidor reductor (Buck)	20
3.3	Funcionamiento de convertidor durante el tiempo de prendido y apagado de interruptor y sus formas de onda.	21
3.4	Diagrama de circuito de convertidor elevador (boost)	23
3.5	Funcionamiento de convertidor durante el tiempo de prendido y apagado del interruptor y formas de onda	24
3.6	Diagrama de circuito de convertidor reductor-elevador (Buck-Boost)	26
3.7	Circuitos equivalentes de convertidor reductor-elevador	26
3.8	Gráficas de onda de corriente en el inductor, corriente en el interruptor, y corriente en el diodo para el convertidor reductor-elevador en modo continuo	27
4.1	Neurona de una entrada	37
4.2	Función de transferencia Hard Limit o escalón	38
4.3	Función de transferencia lineal	39
4.4	Función de transferencia log-sigmoid	40
4.5	Neurona con múltiples entradas	40
4.6	Neurona con R entradas. notación abreviada	41
4.7	Capa de S neuronas	42
4.8	Capa de S neuronas. notación abreviada	43
4.9	Red de tres capas	44
4.1	Red de tres capas. notación abreviada	44
5.1	Dependencia del estado de carga (SOC) y el voltaje de circuito abierto	56
6.1	Modelo de la celda fotovoltaica de un diodo	65
6.2	Modelo de panel fotovoltaico de MATLAB/simulink	67
6.3	Curva característica V-I de modelo de panel fotovoltaico de MATLAB/simulink a 1000 W/m^2	68
6.4	Curva característica P-V de modelo de panel fotovoltaico de MATLAB/simulink a 1000 W/m^2	68
6.5	Panel fotovoltaico empleado	69
6.6	Gráfica de la curva P-V de panel solar SIEMENS 53 W con diferentes irradiaciones	70
6.7	Algoritmo de conductancia incremental	73
6.8	Diagrama de bloques de MPPT conductancia incremental	75
6.9	Diagrama de bloques de un sistema de control industrial	80
6.10	Circuito de convertidor reductor-elevador empleado como cargador de 3 etapas	82
6.11	Gráfica de voltaje (rojo) y corriente (verde) de carga de batería con el convertidor reductor-elevador en tres etapas CC-VC-CC.	83
6.12	Gráfica de eficiencia vs ciclo de trabajo del convertidor reductor-elevador	85
6.13	Gráfica de convertidor reductor-elevador con panel fotovoltaico y MPPT con	

	tres irradiaciones diferentes	86
6.14	Diagrama de bloques de circuito de convertidor reductor-elevador con panel fotovoltaico y MPPT empleado como cargador	86
6.15	Gráfica de corriente de carga en batería de circuito de convertidor reductor-elevador con panel fotovoltaico y MPPT	87
6.16	Gráfica de voltaje de carga en batería de circuito de convertidor reductor-elevador con panel fotovoltaico y MPPT	87
6.17	Etapa de control implementada en convertidor reductor-elevador	88
6.18	Etapa de potencia implementada en convertidor reductor-elevador	89
6.19	Gráficas de eficiencia vs corriente de carga y corriente de IGBT con interruptor IGBT con diodo y sin diodo	89
6.20	Gráfica de eficiencia vs corriente de carga de convertidor reductor-elevador implementado	90
6.21	Corriente de batería en modo carga con convertidor reductor-elevador, panel fotovoltaico, y MPPT	91
6.22	Voltaje de batería en modo carga con convertidor reductor-elevador, panel fotovoltaico, y MPPT	91
6.23	Gráfica comparativa de SOC vs V_{oc} entre datos de tabla de fabricante y ecuación	93
6.24	Arquitectura de la red neuronal del estimador de estado de carga con 4 entradas	93
6.25	Gráfica de desempeño del estimador de estado de carga de la red neuronal	94
6.26	Gráfica de regresión del estimador de la red neuronal	94
6.27	Gráfica de aproximación de salidas con respecto a objetivos del estimador de la red neuronal	95
6.28	Arquitectura de la red neuronal del estimador con 3 entradas	96
6.29	Gráfica de desempeño del estimador de estado de carga	96
6.30	Gráfica de regresión del estimador de la red neuronal	97
6.31	Gráfica de aproximación de salidas con respecto a objetivos del estimador de La red neuronal con 3 entradas	97
6.32	Tabla de datos obtenidos de procedimiento de carga de batería de 6 V.	98
6.33	Arquitectura de la red neuronal con 4 entradas para los datos de carga	99
6.34	Gráfica de desempeño del estimador de estado de carga	100
6.35	Gráfica de regresión del estimador de la red neuronal	100
6.36	Gráfica de aproximación de salidas con respecto a objetivos del estimador de La red neuronal con 4 entradas	101
6.37	Arquitectura de la red neuronal con 3 entradas	102
6.38	Gráfica de desempeño del estimador de estado de carga	102
6.39	Gráfica de regresión del estimador de la red neuronal	103
6.40	Gráfica de aproximación de salidas con respecto a objetivos del estimador de La red neuronal	103

Índice de tablas

5.1	Resumen método de voltaje de circuito abierto	56
5.2	Resumen de las diferentes técnicas de determinación de estado de carga de baterías	61
6.1	Datos de características eléctricas de modulo solar fotovoltaico SOLKAR 36 W	67
6.2	Datos de características eléctricas de modulo solar fotovoltaico marca SIEMENS de 53 W	69
6.3	Comparación de los métodos más comunes de MPPT	74

Resumen

Esta tesis se centra en el estudio del estado de carga (SOC: state of charge) para baterías de ciclo profundo del tipo ácido plomo. El SOC es de suma importancia en aplicaciones donde la batería está sometida permanentemente a situaciones de carga y/o descarga como las que se presentan en vehículos eléctricos y sistemas de energía renovables. El SOC se define como la energía expresada como un porcentaje de la capacidad nominal, que aún está disponible para ser utilizada. Este parámetro no es medible, por lo cual es necesario estimarlo en base a mediciones de otras señales disponibles en la batería, tales como corriente, voltaje y temperatura. Para realizar el control de carga de manera precisa es necesario contar con un medio que nos permita determinar con precisión el estado de carga de las baterías; como las baterías son dispositivos no lineales, la propiedad de representar no linealidades de las redes neuronales es algo muy ventajoso, así como su aprendizaje adaptable ya que las condiciones en que se encuentran las baterías no siempre son predecibles. Es decir, una de las principales ventajas de las redes neuronales es su habilidad de aprender de su medio ambiente que mediante un proceso de entrenamiento pueden “descubrir” la correlación que existe entre las variables de entrada y salida sin recurrir a los métodos tradicionales. Para obtener las variables de carga es necesario un cargador de baterías, el cual tiene como fuente de alimentación un módulo solar y por consiguiente el método de control MPPT (Máximo Peak Power Tracking), el cual es imprescindible en este tipo de sistemas de alimentación de energías renovables para obtener la máxima potencia de las celdas solares.

Abstract

This thesis focuses on the study of the state of charge (SOC: state of charge) battery deep cycle lead acid type. The SOC is critical in applications where the battery is permanently subjected to heavy charge and / or discharge as those that occur in electric vehicles and renewable energy systems. The SOC is defined as the energy expressed as a percentage of rated capacity, which is available for usage. This parameter is not measurable, so it is necessary to estimate it based on measurements of other signals available in the battery, such as current, voltage and temperature. charge control accurately is necessary to have an environment that allows us to accurately determine the state of charge of the battery, as batteries are nonlinear devices, the property of representing a non-linearity of the neural networks is very advantageous and its adaptive learning and the conditions in which they find the batteries are not able to learn from its environment through a process of training can "discover" the correlation between input and output variables without resorting to traditional methods. To obtaining the load variables a battery charger, which is supplied by a solar module and therefore the method MPPT (Maximum Peak Power Tracking), which is essential in this type of renewable energy sources for obtaining the maximum power from solar cells.

Capítulo 1

Introducción

1.1. Introducción

El incremento del uso de las energías renovables, tales como la eólica y fotovoltaica, el uso de baterías de ciclo profundo para el almacenamiento de la energía eléctrica, ha hecho que se estudie con mayor detalle el funcionamiento de las baterías; esto con la finalidad de prolongar su vida útil y predecir con mayor certeza el estado de carga eléctrica residual de las baterías. Además, el incremento global del número de vehículos ha hecho que sus emisiones generen problemas tales como la contaminación del aire, crecimiento del calentamiento global y el agotamiento de recursos no renovables. En recientes años, los países en el mundo han invertido mucho para hacer frente a estos retos para el desarrollo de nuevos o mejores sistemas de almacenamiento de energía. Las baterías se pueden encontrar en sistema de energía renovable de operación aislada o bien en vehículos eléctricos. El sistema de potencia instalado en un vehículo es uno de los tres elementos básicos, ya que es la única fuente de alimentación de los vehículos eléctricos [1]. La determinación de la cantidad de carga almacenada en cada celda del paquete de baterías de ciclo profundo es sin duda crucial para la utilización efectiva de la batería y prevenir daños y prolongar la vida útil de la batería. Sin embargo, la estimación del estado de carga de las baterías es una tarea difícil de realizar. El estado de la carga simboliza la capacidad residual de la batería y es determinada en porcentaje de la capacidad residual por la capacidad nominal. La estimación del estado de carga es un punto clave en el sistema de administración de la batería [2]. El monitoreo y control preciso del estado de carga mantiene en un potencial óptimo a la batería y extiende su vida útil, así como extiende su edad y también evitar ser sobre cargada y sobre descargada. También el estado de carga está ligado con la potencia que puede entregar la batería, así como la energía residual

almacenada. Lo anterior es la base para implementar una estrategia de balance de carga, la cual nos lleva a mejorar la utilización de la batería. Numerosos enfoques han sido presentados en la literatura para monitorear el estado de carga de la batería, tales como medición de la impedancia de la celda, método de corrientes de Eddy, técnicas basadas en lógica difusa, técnicas empleando el filtro Kalman, método de voltaje de circuito abierto, método Amperios-hora (Δh), y método de redes neuronales artificiales. Además de estos métodos, se puede aplicar para realizar los ciclos de carga de las baterías de ciclo profundo, dado que se puede aplicar los criterios tanto para comenzar como para terminar el ciclo de carga. Los métodos usados para llevar a cabo la carga de baterías consisten en la aplicación de un voltaje constante, una corriente constante hacia la batería o una combinación de estas [3]. Generalmente el criterio aplicado es aquel donde se mide el voltaje en las terminales de la batería tomando en cuenta en algunos casos su temperatura y su tiempo de carga y se compara con el voltaje deseado. Los controladores que toman lecturas de voltaje en las terminales no toman en cuenta la degradación de la capacidad de las baterías, que puede darse por el mal uso, por la forma incorrecta de carga o por el tiempo de vida natural de las baterías. La degradación en la capacidad de las baterías cambia su comportamiento, por lo tanto se deben aplicar métodos para conocer el estado de la carga de las baterías que puedan adaptarse a los cambios en las baterías durante su vida útil.

Con la aplicación de las redes neuronales, se pretende que el sistema no solo tome las lecturas de los parámetros asociados a la carga de la batería sino que sea capaz de aprender del funcionamiento de la batería, que proporcione de una lectura que sea confiable y tenga una mayor tolerancia a los errores. El modelo para la estimación de la carga deberá alimentarse con datos, mismos que serán obtenidos con un sistema de registro de datos que se desarrollará para estos fines [4].

La conversión de la energía solar en electricidad usando paneles solares es una atractiva alternativa de electrificar comunidades remotas. La energía que no se usa durante el día, se almacena en bancos de baterías recargables para suministrar energía durante la noche. Para

mantener las baterías en condiciones óptimas de operación es necesario mantener su nivel de carga dentro de su rango de trabajo, que el estado de carga no lo informa, esto para que no sean ni sobre cargadas ni sobre descargadas para asegurar que las baterías sean usadas dentro de la región de seguridad de carga. Un factor crítico para realizar fundamentalmente el control de carga, es la determinación exacta del estado de carga en la batería. El conocimiento del estado de carga también es útil en sistemas de generación de energía eólica y fotovoltaica [5].

El trabajo de tesis que se plantea consiste en la utilización de redes neuronales para la determinación del estado de carga de las baterías de ciclo profundo. Al conocer el estado de carga es posible administrar la energía de una forma más eficiente, así como calcular el tiempo estimado de trabajo en aplicaciones como los vehículos eléctricos, celdas fotovoltaicas, y eólicas.

1.1. Objetivos

El presente estudio de tesis tiene como objetivos el diseño y la simulación de un estimador del estado de carga de baterías de ciclo profundo utilizando redes neuronales. Adicionalmente se tiene como objetivo secundario el diseño e implementación de un cargador de baterías, a partir de un convertidor CD-CD para obtener los datos de la batería que serán empleados para el entrenamiento de la red neuronal. Por consiguiente, se podrá estimar la cantidad de energía almacenada remanente de la batería, y de esta forma podemos prolongar la vida útil de la batería, con la disminución de las sobrecargas y sobre descargas de la misma.

1.3 Justificación

El aumento en los precios del crudo y la sensibilización mundial sobre el medio ambiente cuestiones que han dado lugar a un mayor desarrollo de los sistemas de almacenamiento de energía. La batería es uno de los sistemas de almacenamiento más atractivo debido a su alta eficiencia y baja contaminación. Hay varios tipos de baterías que actualmente se usan en la industria como son: baterías de ácido-plomo, baterías de Niquel Hidruro Metálico (Ni-MH), baterías de Niquel Cadmio (Ni-Cd), baterías de Ion Litio. Las baterías tienen la ventaja de la alta densidad de potencia, baja tasa de auto descarga, baja contaminación, y son utilizadas en vehículos eléctricos y en sistemas de energía renovable.

La estimación del estado de carga de la batería es un reto fundamental, el SOC es un parámetro importante el cual refleja el desempeño de la batería, la estimación precisa del SOC no solo protege la batería, también previene sobredescargas y mejora su vida útil.

Estas son algunas de las razones que justifican el diseño del estimador de estado de carga de una batería utilizando redes neuronales del programa MATLAB/Simulink.

1.4. Contenido de la tesis

Capítulo 1

Introducción

Se presenta una introducción al trabajo realizado y algunos aspectos generales de esta tesis, así como los objetivos y la justificación del proyecto de investigación.

Capítulo 2

Fundamentos de las Baterías

En este capítulo se presentan antecedentes, definición, algunos tipos de baterías, así como sus aplicaciones, clasificación, principio químico de funcionamiento, los elementos básicos de una batería, y la explicación a detalle de cada uno de ellos.

Capítulo 3

Convertidores de CD-CD

En esta parte se presenta historia, características de los convertidores, principio de funcionamiento, algunos tipos de convertidores elevadores y reductores de voltaje de salida, así como su simulación en MATLAB/simulink.

Capítulo 4

Redes Neuronales Artificiales

Se aborda la teoría general de las redes neuronales artificiales, definición, topologías de las redes, mecanismos de aprendizaje, funciones de transferencia, una explicación clara y breve de los fundamentos de las redes neuronales artificiales, así como una breve descripción del método *retropropagación*.

Capítulo 5

Métodos de estimación del estado de carga de baterías

En este capítulo se presenta una introducción a los métodos de estimación de estado de carga, también sus definiciones, se enumeran los principales métodos, y se analizan las ventajas y desventajas de cada uno de las técnicas.

Capítulo 6

Diseño y simulación de un algoritmo del estimador de estado de carga para baterías de ciclo profundo con redes neuronales

Se presenta el diseño del convertidor cd-cd que en este caso se escogió el tipo Buck-Boost (reductor-elevador). El primer lugar se desarrolló un diseño de cargador de baterías de tres etapas y se hicieron pruebas de simulación consiguiendo buenos resultados. En segundo lugar se llevó a cabo la simulación e implementación de pruebas físicas del convertidor empleado como cargador con alimentación de un panel fotovoltaico y con el sistema de control del MPPT, así como el entrenamiento de la red neuronal con los datos de carga y descarga de baterías de ciclo profundo de carro eléctrico y sus resultados con tres y cuatro datos de entrada.

Capítulo 7

Conclusiones

En este capítulo se muestran las conclusiones obtenidas en este trabajo de tesis, así como también el trabajo futuro a realizar en esta área de investigación.

Capítulo 2

Fundamentos de las baterías

2.1 Introducción

Se estima que cerca del 80% de todos los módulos fotovoltaicos (FV) son usados en aplicaciones autónomas. Para obtener una potencia continua de los sistemas FV usan un sistema de almacenamiento de energía con baterías de ácido-plomo.

Las baterías usadas en las aplicaciones de FV tienen diferente desempeño comparado con las baterías usadas en las aplicaciones más tradicionales. En las aplicaciones FV, las baterías de ácido plomo no alcanzan el ciclo de las baterías de plomo ácido usadas en otras aplicaciones tales como fuentes de poder ininterrumpible o vehículos eléctricos. Acortar la vida útil de las baterías contribuye significativamente al costo de un sistema FV.

Las baterías más ampliamente usadas en fuentes de energía renovables son las de tipo gel, las libres de mantenimiento, y las baterías de ácido-plomo. Otros tipos de baterías están disponibles también como son las de Níquel cadmio y Níquel metal hidruro. Estas dos tipos de baterías son consideradas más costosas y no tan fácilmente disponibles.

En 1800, el físico italiano Alejandro Volta construyó la primera celda electroquímica simple, la cual consistía en varillas de cobre y zinc sumergidas en una salmuera [6]. Este elemento constituyó la primera "batería" de la historia y además representó la primera fuente de corriente continua de ese entonces. De un tiempo a esta parte, la batería se ha constituido como un elemento fundamental del mundo globalizado, Es por ello, que este elemento seguirá jugando un rol primordial en el avance de la humanidad, razón por la cual, su estudio abarca gran interés en la comunidad científica.

La electricidad es la forma de energía que más se utiliza en nuestros días, fundamentalmente por la facilidad con la que se transforma en otras formas de energías. En este sentido, se pueden mencionar innumerables aplicaciones donde la energía eléctrica se convierte en energía mecánica, química o térmica para generar una función específica [7].

El principal suministro de energía eléctrica se realiza a través de la red eléctrica. Sin embargo, en muchas ocasiones en que se necesita hacer uso de esta energía no se dispone

de la red eléctrica o esta no se puede utilizar directamente debido a los requerimientos específicos de la aplicación (equipos portátiles, señalizaciones marinas, vehículos eléctricos, etc.). Uno de los principales inconvenientes de la energía eléctrica es la dificultad de su almacenamiento. Las baterías son una de las pocas formas fiables de almacenar energía. Estos dispositivos convierten la energía eléctrica en química y viceversa; de esta manera se consigue almacenar energía eléctrica en forma química para utilizarla en el momento que falle el suministro de la red eléctrica o simplemente cuando la requieran determinadas aplicaciones que funcionen con independencia de red.

El desarrollo en los últimos años de nuevas aplicaciones (vehículos eléctricos, sistemas fotovoltaicos, sistemas de alimentación ininterrumpida, etc.) han propiciado el surgimiento y desarrollo de nuevas tecnologías de baterías, cada vez más eficientes y confiables. Así, además de las conocidas ácido-plomo (lead-acid), han surgido otras tecnologías como la níquel-cadmio (Ni-Cd), la de níquel hidruro-metálico (Ni-MH) y más recientemente la de litio-ion (Li-ion). Estas son algunas de las tecnologías más utilizadas, pues existen innumerables combinaciones químicas que se pueden usar para almacenar energía eléctrica en forma química.

2.2 Clasificación de baterías

Existen muchas maneras de clasificar las baterías, por ejemplo según su diseño (características constructivas), sus características de funcionamiento, el campo de aplicación, etc. Inicialmente, se puede comenzar clasificando las baterías en función de la posibilidad que tienen de ser recargadas una vez que han sido descargadas. En este sentido se pueden definir dos grandes grupos de baterías.

2.2.1 Baterías primarias

Estas baterías no permiten ser recargadas una vez que han sido descargadas. Por lo tanto, cuando una batería primaria ha agotado su energía debe ser sustituida por otra batería. El campo de aplicación de las baterías primarias se enmarca fundamentalmente dentro de potencias bajas y de ahí que sean generalmente de tamaño pequeño.

2.2.2 Baterías secundarias

Estas baterías pueden ser recargadas una vez que han sido descargadas; de ahí que también se les denomine como baterías recargables o acumuladores. Las baterías secundarias se comercializan en un amplio margen de capacidades, desde capacidades bajas (algunos cientos de miliamperios-horas) hasta capacidades medias y altas (varias decenas o centenas de amperios-horas), y cada día adquieren mayor importancia sobre todo en aplicaciones donde se necesitan potencias medias y altas. Generalmente están preparadas para funcionar con razones de descarga altas y en un margen amplio de temperaturas.

En [8], se brinda una definición muy completa de un acumulador, la cual señala que “un acumulador de energía, puede ser definido como un reservorio capaz de entregar energía eléctrica a un circuito exterior a expensas de la energía química contenida en las sustancias internas que lo conforman, si el acumulador admite el proceso inverso, es decir, es capaz de acumular energía química en las sustancias que contiene a costas de la energía eléctrica suministrada desde el exterior, se dice entonces que el acumulador es reversible”.

De la definición anterior, se desprende que dentro de todo acumulador, debe haber una unidad básica de generación/absorción de energía eléctrica, dicha unidad recibe el nombre de celda electroquímica. Una celda electroquímica, desde el punto de vista físico, está compuesta de un electrodo positivo y un electrodo negativo separados por un electrolito, el cual, es capaz de conducir iones entre ambos electrodos. Es preciso mencionar que desde el punto de vista químico, en los electrodos y en el electrolito se encuentran sustancias químicamente activas, que al interactuar bajo ciertas condiciones, producen reacciones electroquímicas responsables de la generación y/o almacenamiento de energía eléctrica [8]. Hay que destacar que generalmente entre ambos electrodos se ubica un separador poroso, que tiene como misión evitar que éstos entren en contacto, con el consecuente corto circuito involucrado. El hecho de que el separador sea poroso, radica en la necesidad de transporte de iones entre un electrodo y otro. [6] [9] [10].

En la Figura 2.1 se presenta un esquema de una celda electroquímica.




Figura 2.1 Esquema de una celda electroquímica

2.3 Principio químico de funcionamiento

La unidad básica de una batería es la celda, pudiendo estar una batería constituida por varias celdas conectadas en serie o en paralelo con el fin de conseguir la tensión y la capacidad deseada.

Una celda funciona con base a un proceso de reacciones químicas de oxidación y reducción; la oxidación es un proceso de liberación de electrones, mientras que la reducción es un proceso de captación de electrones. Una celda se compone básicamente de cuatro elementos, tal y como se muestra en la figura 2.1: un ánodo, hecho de material que aporta electrones; un cátodo, preparado para aceptar electrones; el electrolito y el separador. Las principales reacciones electroquímicas se producen en las interfaces ánodo-electrolito o cátodo-electrolito según se desarrollen los procesos de carga-descarga [9] [11].

2.4 Elementos que componen la celda electroquímica

Algunas de las principales características asociadas con cada uno de los elementos que componen la celda electroquímica son:

Ánodo o electrodo negativo: es el elemento que se oxida durante la descarga de la celda aportando los electrones al circuito exterior. Algunos ejemplos de electrodos negativos son el plomo en baterías de plomo-ácido y el cadmio en las baterías de níquel-cadmio.



Figura 2.2 Elementos básicos de una celda recargable.

Cátodo o electrodo positivo: Es el elemento que se reduce durante la descarga de la celda aceptando electrones del circuito exterior algunos ejemplos de electrodos positivos son el dióxido de plomo en baterías de plomo-ácido y el óxido de níquel en baterías de níquel-cadmio.

Durante la descarga, el ánodo aporta electrones debido a la oxidación y también genera iones positivos. Similarmente, el cátodo genera iones negativos durante el proceso de aceptación de electrones.

Durante la carga, básicamente ocurren los mismos procesos electroquímicos debido a la reversibilidad de las reacciones de oxidación-reducción. En este caso, el electrodo negativo se comporta como cátodo y el electrodo positivo se comporta como ánodo [11].

Típicamente, el electrodo negativo está formado por un metal base y el electrodo positivo está compuesto por un óxido metálico. No obstante, esta definición no es tan restrictiva ya que existen muchas combinaciones de elementos y compuestos que en presencia de algún tipo de electrolito pueden producir corriente eléctrica.

Los electrodos de las celdas se componen de la rejilla y el material activo.

- La rejilla constituye el soporte mecánico del material activo y es el conductor eléctrico de la corriente generada por el sistema. Las características más deseadas con respecto al comportamiento de la rejilla en una celda son:

- Elevada conductividad eléctrica.
- Buena adherencia de toda la superficie en contacto con el material activo.
- Elevada resistencia mecánica.
- Alta resistencia a la corrosión.
- Elevada sobretensión de desprendimiento de gases.

- El material activo es el elemento donde se desarrollan las reacciones electroquímicas. En la actualidad existen diferentes técnicas para lograr una fijación óptima del material activo a la rejilla siendo la más usual su preparación en la forma de una pasta con consistencia adecuada. Las propiedades más destacadas a la hora de escoger el material activo son:

- Elevada tensión.

Posibilita una tensión alta de la celda reduciendo el número de celdas que hay que conectar en serie para lograr una batería con una determinada tensión.

- Elevada eficiencia de las reacciones electroquímicas en las que participa.

Permite una eficiencia energética elevada en el proceso de conversión de energía química en energía eléctrica y viceversa.

- Bajo peso.

Con el empleo de materiales menos pesados pueden conseguirse celdas y en definitiva, baterías mucho más ligeras.

- Buena estabilidad frente a la rejilla.

Permite el diseño de sistemas más estables, capaces de funcionar adecuadamente durante periodos de tiempo largos sin sufrir degradaciones importantes lo que aumenta su fiabilidad.

- Fácil fabricación y bajo costo.

Esta propiedad es importante desde el punto de vista de la penetración en el mercado y de su uso extensivo. Actualmente, existen tecnologías de baterías que a pesar de tener prestaciones altas no ven generalizado su uso por tener costos muy elevados.

○ Electrolito

El electrolito es un conductor iónico que permite la transferencia de electrones en el interior de la celda por medio del desplazamiento de iones entre el ánodo y el cátodo. Generalmente, el electrolito es una solución acuosa de un ácido, de una base o de sales y su concentración determina en gran medida el comportamiento óptimo de la batería durante su funcionamiento. Las propiedades principales a tener en cuenta cuando se selecciona un electrolito son:

- Alta conductividad iónica.
- Buena estabilidad térmica.
- Bajo efecto corrosivo sobre los electrodos.
- Bajo nivel de impurezas.

- Bajo costo.

○ Separador

El separador es un elemento fundamental en la celda ya que proporciona aislamiento eléctrico entre el ánodo y el cátodo, evitando cortocircuito entre electrodos de diferentes polaridades, mientras permite una libre circulación de iones a través del electrolito. Las propiedades a destacar en un buen separador son:

- Elevado poder aislante eléctrico.
- Adecuada porosidad y permeabilidad.
- Buena resistencia mecánica.
- Alta resistencia a la oxidación.
- Ausencias de impurezas y contaminantes.

○ Contenedor

El contenedor es el recipiente o depósito que contiene a todos los elementos de una celda (electrodos, separadores y electrolito). Varias celdas se pueden interconectar en el interior de un contenedor para proporcionar una determinada capacidad y/o tensión denominados al conjunto "Batería" o "Acumulador".

El contenedor proporciona el soporte y la rigidez mecánica necesaria para el funcionamiento de la batería. Algunas características principales que deben tener los contenedores son: elevada resistencia dieléctrica, alta resistencia a los impactos, capacidad para soportar choques térmicos y por supuesto, no degradarse por la acción de los agentes químicos presentes en el interior de la batería [10]. El

contenedor puede estar provisto o no de válvulas de seguridad que regulen la expulsión de gases del interior de la batería hacia el exterior [12].

La figura 2.3 muestra la estructura típica de una batería utilizada en regímenes de ciclos de carga-descarga.



Figura 2.3 Estructura típica de una batería para aplicaciones de regímenes cíclicos de carga-descarga.

Como se ha mencionado anteriormente, la principal característica de las baterías secundarias es la posibilidad de recargarlas una vez que han sido descargadas. Por lo tanto, es deseable que la transformación de energía eléctrica en energía química (y viceversa) que se produce durante las reacciones electroquímicas de carga (descarga) sea un proceso totalmente reversible, de una eficiencia alta y que no de lugar a cambios físicos significativos en los elementos del sistema que acorten la vida útil de la batería.

Durante el funcionamiento en regímenes cíclicos de carga-descarga de una batería se producen reacciones secundarias que impiden la reversibilidad completa del proceso y dan lugar a pérdidas que disminuyen la eficiencia del mismo. Por lo tanto, se debe tratar de minimizar el efecto de estas reacciones que causan además el deterioro de los componentes de la batería con la consiguiente degradación de características y recorte de la vida útil de la misma.

Además, se deben potenciar los compuestos químicos que permitan obtener baterías con mejores prestaciones, gran robustez física y eléctrica, bajo peso y volumen, baja resistencia interna, buen comportamiento en un amplio margen de temperaturas, etc. Evidentemente, los requerimientos mencionados limitan los elementos químicos que se pueden escoger para construir las diferentes tecnologías de baterías secundarias [13].

Capítulo 3

Convertidores de CD-CD

3.1. Introducción

Una de las necesidades que tenemos en este proyecto es la de cargar una batería para obtener datos de entrada para el entrenamiento de la red neuronal artificial y de esta forma determinar su estado de carga y así no sobrecargarla y evitar disminuir su vida útil. Hemos seleccionado un convertidor de CD-CD que en este caso es el tipo Reductor y Elevador (Buck-Boost), para que nos sirva como cargador de baterías, por lo tanto es de suma importancia conocer el funcionamiento de los convertidores y sus algunas de las principales topologías.

Los convertidores de cd-cd son configuraciones de electrónica de potencia que permiten a partir de una fuente de cd constante, controlar el voltaje de cd a la salida del convertidor. En muchas aplicaciones industriales se requiere convertir un voltaje fijo de una fuente de cd en un voltaje variable de suministro de cd. Se puede considerar que un convertidor de cd es el equivalente en cd de un transformador en ca, con una relación de vueltas que varía en forma continua. Al igual que en un transformador, se puede usar para subir o bajar el voltaje de una fuente.

Los convertidores de cd se usan mucho para el control de motores de tracción de automóviles eléctricos, tranvías, grúas marinas, montacargas y elevadores de mina. Proporcionan un control uniforme de aceleración, gran eficiencia y rápida respuesta dinámica. Se pueden usar en el frenado regenerativo de motores de cd para regresar la energía a la fuente y esa propiedad permite ahorros de energía en los sistemas de transporte que tienen frenados frecuentes. Los convertidores de cd se usan en los reguladores de

voltaje de cd, y también se usan en conjunto con un inductor para generar una corriente de cd, en especial para el inversor de fuente de corriente [14] [15] [16]. Los convertidores se pueden usar como reguladores de modo de conmutación, para convertir un voltaje de cd, normalmente no regulado, en un voltaje de salida regulado de cd. La regulación se suele obtener con PWM (modulación de ancho de pulso) a determinada frecuencia, el dispositivo de conmutación es, en el caso normal, un BJT, MOSFET o IGBT.

3.2. Generación de ciclo de trabajo

El ciclo de trabajo k se puede generar comparando una señal de referencia v_r de cd, con una señal portadora en diente de sierra v_{cr} . Esto se ve en la figura 3.1, donde V_r es el valor pico de v_r y V_{cr} es el valor pico de v_{cr} . La señal de referencia v_r se caracteriza por

$$v_r = \frac{V_r}{T} t \quad (3.1)$$

Que debe ser igual a la señal portadora $v_{cr} = V_{cr} = kT$. Esto es,

$$V_{cr} = \frac{V_r}{T} kT$$

Que determina el ciclo de trabajo k como

$$k = \frac{V_{cr}}{V_r} = M \quad (3.2)$$

donde M se llama *índice de modulación*. Al variar la señal de la portadora v_{cr} desde 0 hasta v_{cr} , se puede variar el ciclo de trabajo desde 0 hasta 1.

El algoritmo para generar la señal de disparo para la compuerta es el siguiente:

1. Generar una forma de onda triangular de periodo T como señal de referencia v_r y una señal portadora v_{cr} .

2. Comparar estas señales con un comparador para generar la diferencia $v_c - v_{cr}$ y entonces un limitador preciso para obtener un pulso de onda cuadrada para la compuerta, de ancho kT , que se debe aplicar al dispositivo de conmutación a través de un circuito aislador.
3. Toda variación en v_{cr} es lineal respecto al ciclo de trabajo k .




Figura 3.1 Comparación de una señal de referencia con una portadora

3.3 Convertidor reductor (Buck)

Este convertidor reductor, el voltaje promedio de salida V_a es menor que el voltaje de entrada V_s , por ello el nombre "reductor". El diagrama del circuito de un convertidor reductor que se usa con un transistor de potencia se ve en la figura 3.2.




Figura 3.2 Diagrama de circuito de convertidor reductor (Buck)

El funcionamiento del circuito se puede dividir en dos modos. El modo 1 comienza cuando se cierra el transistor Q_1 cuando $t = 0$. La corriente de entrada, que aumenta, pasa por el inductor de filtro L , el capacitor de filtro C y el resistor de carga R . El modo 2 comienza cuando se apaga el transistor Q_1 cuando $t = t_1$. El diodo de marcha libre D_m conduce, por la energía almacenada en el inductor, y la corriente sigue pasando por L, C , la carga y el diodo D_m . La corriente del inductor baja hasta que el transistor Q_1 se enciende de nuevo, en el siguiente ciclo. Los circuitos equivalentes de los modos de operación y las formas de onda se ven en las figura 3.3 para un paso continuo de corriente por el inductor L . Se supone que la corriente aumenta y disminuye en forma lineal. En los circuitos prácticos el interruptor tiene una resistencia finita y no lineal. En general, su efecto se puede despreciar, en la mayor parte de las aplicaciones. De acuerdo con la frecuencia de conmutación, la inductancia y la capacitancia del filtro, la corriente del inductor puede ser discontinua [14] [17].




Figura 3.3 Funcionamiento de convertidor durante el tiempo de prendido y apagado del interruptor y formas de onda.

Las ecuaciones de diseño para el convertidor Reductor (Buck) son:

$$V_a = k * V_s \tag{3.3}$$

$$I_s = k * I_a \tag{3.4}$$

donde V_a es el voltaje de salida, k el ciclo de trabajo, V_s es el voltaje de entrada, I_s es la corriente de entrada, I_a es la corriente de salida.

Para obtener la corriente de rizo de pico a pico:

$$\Delta I = \frac{V_s + k(1-k)}{fL} \quad (3.5)$$

donde f es la frecuencia de conmutación, y L es el valor de la inductancia.

Y el voltaje de rizo de pico a pico está dado por:

$$\Delta V = \frac{V_s + k(1-k)}{8LCf^2} \quad (3.6)$$

donde C es el valor de la capacitancia.

Valor crítico del inductor es:

$$L_c = L = \frac{(1-k)R}{2f} \quad (3.7)$$

donde R es la resistencia de carga.

El valor crítico del capacitor es

$$C_c = C = \frac{1-k}{16Lf^2} \quad (3.8)$$

El convertidor reductor solo requiere un transistor, es sencillo y tiene una eficiencia alta, mayor que 90%. La tasa di/dt de la corriente de carga se limita con el inductor L . Sin embargo, la corriente de entrada es discontinua, y en el caso normal se requiere un filtro de aislamiento en la entrada. Proporciona voltaje de salida de una polaridad, y corriente unidireccional de salida.

3.4 Convertidor elevador (Boost)

En un regulador elevador el voltaje de salida es mayor que el voltaje de entrada; de ahí el nombre de "elevador". En la figura 3.4 se muestra el convertidor elevador que usa un MOSFET de potencia. El funcionamiento del circuito se puede dividir en dos modos. El modo 1 comienza cuando se cierra el transistor M_1 cuando $t = 0$. La corriente de entrada, que aumenta, pasa por el inductor L y el transistor Q_1 . El modo 2 comienza cuando el transistor M_1 se apaga cuando $t = t_1$. La corriente que pasaba por el interruptor pasa ahora por L, C , la carga y el diodo D_m . La corriente en el inductor cae hasta que se enciende de nuevo el interruptor M_1 , en el ciclo siguiente. La energía almacenada en el inductor L pasa a la carga.




Figura 3.4 Diagrama de circuito convertidor Elevador (Boost)

Los circuitos equivalentes para los dos modos de operación y las formas de onda de voltajes y corrientes se muestran en la figura 3.5 [14] [17].




Figura 3.5 Funcionamiento de convertidor durante el tiempo de prendido y apagado del interruptor y formas de onda.

Las ecuaciones de diseño para el convertidor Elevador (Boost) son:

$$(1 - k) = \frac{V_o}{V_a} \tag{3.9}$$

$$I_s = \frac{I_a}{1 - k} \tag{3.10}$$

para obtener la corriente de rizo de pico a pico:

$$\Delta I = \frac{V_o k}{fLV_o} \quad (3.11)$$

y para obtener el voltaje de rizo de pico a pico:

$$\Delta V_c = \frac{I_o k}{fC} \quad (3.12)$$

Para determinar los valores criticos del inductor y el capacitor:

$$L_c = L = \frac{k(1-k)R}{2f} \quad (3.13)$$

$$C_c = C = \frac{k}{2fR} \quad (3.14)$$

Un convertidor elevador puede subir el voltaje de salida sin un transformador. Como tiene un solo interruptor, se tiene alta eficiencia. La corriente de entrada es continua. Sin embargo, por el transistor de potencia debe pasar un gran pico de corriente. El voltaje de salida es muy sensible a los cambios de ciclo de trabajo k y podría ser difícil estabilizar el convertidor. La corriente promedio de salida es menor que la corriente en el inductor, en un factor de $(1 - k)$ y pasaría una corriente mucho mayor por capacitor filtro, con lo que se requiere usar un capacitor y un inductor filtro mayores que los de un convertidor reductor.

3.5 Convertidor reductor-elevador (Buck-Boost)

Un convertidor reductor y elevador proporciona un voltaje que puede ser menor o mayor que el voltaje de entrada; de ahí el nombre “reductor-elevador”; la polaridad del voltaje de salida es contraria a la del voltaje de entrada. Estos convertidores también se llaman *reguladores inversores*. En la figura 3.6 se muestra el arreglo del circuito de un convertidor reductor-elevador.




Figura 3.6 Diagrama de circuito de convertidor reductor-elevador (Buck-Boost)

El funcionamiento del circuito se puede dividir en dos modos. Durante el modo 1, el interruptor Q_1 está encendido y el diodo D_m tiene polarización inversa. La corriente de entrada, que aumenta, pasa por el inductor L y el interruptor Q_1 . Durante el modo 2, el interruptor Q_1 se apaga y la corriente, que pasaba por el inductor L , pasa a través de L, C, D_m y la carga. La energía almacenada en el inductor L se transfiere a la carga y la corriente en el inductor cae hasta que el interruptor Q_1 se enciende de nuevo en el ciclo siguiente. En la figura 3.7 se muestran los circuitos equivalentes y las formas de onda de corriente y voltaje de estado estable del convertidor reductor-elevador, para una corriente de carga continua [14] [17].

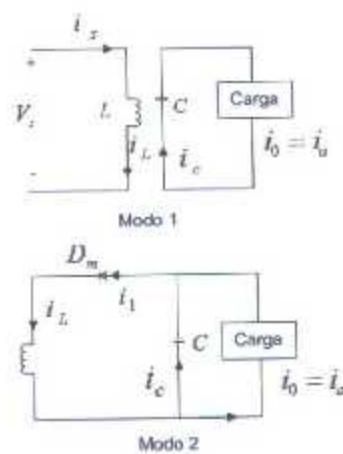


Figura 3.7 Circuitos equivalentes de convertidor reductor-elevador




Figura 3.8 Gráficas de onda de corriente en el inductor, corriente en el interruptor, y corriente en el diodo para el convertidor reductor-elevador en modo continuo.

Las ecuaciones de diseño para el convertidor Buck-Boost son:

$$V_a = \frac{V_s k}{1-k} \tag{3.15}$$

$$I_s = \frac{I_a k}{1-k} \tag{3.16}$$

Para obtener la corriente de rizo de pico a pico es:

$$\Delta I = \frac{V_s k}{fL} \quad (3.17)$$

El voltaje de rizo de pico a pico es:

$$\Delta V_c = \frac{I_a k}{fC} \quad (3.18)$$

Los valores críticos del capacitor e inductor son:

$$L_c = L = \frac{(1-k)R}{2f} \quad (3.19)$$

$$C_c = C = \frac{k}{2fR} \quad (3.20)$$

Un convertidor reductor y elevador proporciona inversión de voltaje de salida sin un transformador, tiene una eficiencia alta. Cuando hay una falla en el interruptor, la tasa di/dt de la corriente de falla queda limitada por el inductor L , y será V_s/L . Sería fácil implementar la protección contra cortocircuito. Sin embargo la corriente de entrada es discontinua, y por el interruptor Q_1 pasa un gran pico de corriente.

Capítulo 4

Redes neuronales artificiales

Una red de neuronas artificiales es un sistema basado en el comportamiento del cerebro humano. Por medio de hardware especializado y software sofisticado, se pretende simular las múltiples capas de elementos de proceso llamadas *Neuronas*. Cada neurona está conectada con algunas de sus vecinas por medio de coeficientes variables de conectividad que representan la fuerza de estas conexiones. El *aprendizaje* se logra ajustando estas fuerzas con el objetivo de que toda la red proporcione resultados apropiados. Las redes neuronales tienen una fuerte similitud con el cerebro biológico y es por ello que una buena parte de la terminología es similar a la utilizada en la neurociencia.

En este capítulo se presenta la descripción y características de las redes neuronales artificiales, iniciando desde la comparación de ellas con el sistema neuronal del cuerpo humano y abordando posteriormente sus principios básicos teóricos de operación y la complejidad que van adquiriendo al requerirse de ellas funciones más complejas, la necesidad de entrenamiento y aprendizaje por medio de diferentes métodos, y poniendo especial énfasis en las redes multicapas *feedforward* entrenadas con el método *retropropagación* [18] [19].

4.1 Definición de una red neuronal

Las redes neuronales no son más que otra forma de emular ciertas características propias de los humanos, como la capacidad de memorizar y de asociar hechos. Si se examinan con atención aquellos problemas que no pueden expresarse a través de un algoritmo, se observará que todos aquellos tienen unas características en común: la experiencia. El

hombre es capaz de resolver estas situaciones acudiendo a la experiencia acumulada. Así, parece claro que una forma de aproximarse al problema consista en la construcción de sistemas que sean capaces de reproducir esta característica humana [18]. En síntesis, una red neuronal es “un nuevo sistema para el tratamiento de la información, cuya unidad básica de procesamiento está inspirada en la célula fundamental del sistema nervioso humano: la neurona” [19].

4.1.1 La neurona biológica.

El elemento más básico del cerebro es un tipo específico de célula que proporciona las habilidades para recordar, pensar y aplicar experiencias pasadas a cada una de nuestras acciones. Estas células se conocen como neuronas y cada una de ellas puede conectarse hasta con otras 200,000 neuronas. El poder del cerebro se basa en el número de estos componentes básicos y las múltiples conexiones que existen entre ellos. Todas las neuronas tienen cuatro componentes básicos: *dendrita*, *soma*, *axón* y *sinapsis*. Básicamente, una neurona biológica recibe entradas de otras fuentes, las combina de cierta forma, realiza una operación generalmente no lineal sobre la entrada y luego da el resultado final a través de sus salidas.

4.1.2 La neurona artificial.

La unidad básica de las redes neuronales, la neurona artificial, simula las cuatro funciones básicas de las neuronas biológicas y son mucho más simples.

Las redes neuronales artificiales son el más sencillo agrupamiento de las neuronas. Este agrupamiento ocurre creando *capas* que luego se conectan a otras. La manera en que estas *capas* se conectan, puede variar. Básicamente todas las redes artificiales tienen una estructura similar de topología. Algunas de estas neuronas sirven de interfase para recibir sus entradas del mundo real y otras neuronas llevan al mundo real las salidas de la red. Cuando la *capa* de entrada recibe señales, sus neuronas producen salidas, la cual a su vez se convierte en entrada para las otras *capas* del sistema. El proceso continúa hasta que son

satisfechas ciertas condiciones o hasta que la *capa* de salida es llamada y entrega su salida al medio exterior.

Para determinar el número de neuronas ocultas (neuronas que conforman las capas existentes entre la capa de entradas y la capa de salida) necesarias para que la red realice su mejor función a menudo se utiliza el método de prueba y error. Si se incrementa demasiado el número de neuronas ocultas, se tendrá una red sobredimensionada, esto significa que tendrá problemas para generalizar. El juego de datos de entrenamiento se memorizará, haciendo la red inútil para nuevos conjuntos de datos.

4.2 Topología de las redes neuronales.

La topología o arquitectura de una red neuronal consiste en la organización y disposición de las neuronas en la misma, formando capas o agrupaciones de neuronas que están un poco alejadas entre la entrada y la salida de dicha red. En este sentido, los parámetros fundamentales de la red son: el número de capas, el número de neuronas por capa, el grado de conectividad y el tipo de conexión entre neuronas.

En las redes monocapa, se establecen las conexiones entre las neuronas que pertenecen a la única capa que contiene la red. Este tipo de redes se utiliza generalmente en tareas relacionadas con lo que se conoce como autoasociación (regenerar información de entrada que se presenta en la red de forma incompleta o distorsionada).

Las redes multicapa o de capas múltiples, son aquellas que disponen de un conjunto de neuronas agrupadas en varios niveles o capas.

4.3 Conexión entre neuronas.

Las neuronas están conectadas a través de una red de caminos, llevando la salida de una neurona, como entrada hacia otra neurona. Estos caminos son generalmente

unidireccionales, sin embargo, puede existir una conexión de dos vías entre dos neuronas, debido a que puede haber un camino en dirección inversa. Una neurona recibe entrada proveniente de muchas neuronas, pero produce una sola salida, la que se comunica a otras neuronas. La neurona en una capa puede comunicarse con las otras o puede no tener conexión. Las neuronas de una capa están siempre conectadas a las neuronas de al menos otra capa.

Hay diferentes tipos de conexiones que se utilizan entre capas:

- a).- Totalmente conectadas.- Cada neurona en la primera capa está conectada a cada neurona de la segunda capa.

- b).- Parcialmente conectadas.- Una neurona de la siguiente capa no tiene que estar conectada a todas en la segunda capa.

- c).- Feedforward (alimentación hacia adelante).- Las neuronas de la primera capa envía sus salidas a las de la segunda capa, pero no reciben ninguna señal de entrada de retorno de las neuronas de la segunda capa.

- d).- Bidireccional.- Existe otro juego de conexiones que llevan la salida de las neuronas de la segunda capa hacia las de la primera capa. Estos dos últimos tipos de conexión, pueden ser total o parcialmente conectadas.

- e).- Jerárquica.- Las neuronas de una capa inferior, solo pueden comunicarse con neuronas del siguiente nivel.

f).- Resonancia.- Las capas tienen conexiones bidireccionales y pueden continuar enviando mensajes por las conexiones, hasta que se alcancen ciertas condiciones.

g).- Recurrente.- Después de que las neuronas en una misma capa reciben entradas de otra capa, ellas se comunican con otras neuronas un determinado número de veces, antes de que se les permita enviar sus salidas a otra capa.

h).- Excitadora/Inhibidora.- En la conexión excitadora, la salida de una neurona aumenta la acción potencial de la neurona receptora. En la inhibidora, la salida de la neurona que envía el mensaje, reduce la acción potencial de la neurona receptora.

Los tipos de conexiones c y d pueden estar total o parcialmente conectadas.

4.4 Mecanismos de aprendizaje.

Las redes neuronales a menudo se conocen como máquinas de *algoritmos de aprendizaje*, debido a que el cambio de los pesos de sus conexiones, proceso conocido como entrenamiento, se hace que la red *aprenda* la solución de un problema. La fuerza de las conexiones entre las neuronas, se almacena como un valor del peso para la conexión específica. El sistema aprende nuevos conocimientos ajustando estos pesos de conexión.

Un aspecto importante respecto al aprendizaje de las redes neuronales es el conocer como modifican los valores de los pesos, es decir, cuales son los criterios que se siguen para cambiar el valor asignado a las conexiones cuando se pretende que la red aprenda nueva información.

Se pueden distinguir dos métodos importantes de aprendizaje:

1.- Aprendizaje supervisado.- Se caracteriza porque el proceso de aprendizaje se realiza mediante un entrenamiento controlado por un agente externo (supervisor, maestro) que determina la respuesta que debería generar la red a partir de una entrada determinada. El supervisor controla la salida de la red y en caso de que esta no coincida con la deseada, se procederá a modificar los pesos de las conexiones, con el fin de conseguir que la salida obtenida se aproxime a la deseada.

2.- Aprendizaje no supervisado.- Las redes con este tipo de aprendizaje no requieren influencia externa para ajustar los pesos de las conexiones entre neuronas, no reciben ninguna información por parte del entorno que les indique si la salida generada en respuesta a una determinada entrada es o no correcta.

Otro criterio que se puede utilizar para diferenciar las reglas de aprendizaje se basa en considerar si la red puede aprender durante su funcionamiento habitual o si el aprendizaje supone la desconexión de la red, es decir, su inhabilitación hasta que el proceso termine. En el primer caso, se trataría de un aprendizaje *en línea*, mientras que en el segundo se considera *fuera de línea*.

4.4.1 Aprendizaje supervisado.

En este tipo de aprendizaje se suelen considerar, a su vez, tres formas de llevarlo a cabo, que dan lugar a los siguientes tipos de aprendizaje supervisado:

a).- Aprendizaje por corrección de error.- Consiste en ajustar los pesos de las conexiones de la red en función de la diferencia entre los valores deseados y los obtenidos a la salida de la red, es decir, en función del error cometido en la salida.

b).- Aprendizaje por refuerzo.- Es más lento que el anterior y se basa en la idea de no disponer de un ejemplo completo del comportamiento deseado, es decir, de no indicar durante el entrenamiento exactamente la salida que se desea que se proporcione la red ante una determinada entrada. La función del supervisor se reduce a indicar mediante una señal de refuerzo si la salida obtenida en la red se ajusta a la deseada, y en función de ello se ajustan los pesos basándose en un mecanismo de probabilidades.

c).- Aprendizaje estocástico.- Consiste básicamente en realizar cambios aleatorios en los valores de los pesos de las conexiones de la red y evaluar su efecto a partir del objetivo deseado y de distribuciones de probabilidad.

4.4.1.1. Aprendizaje por corrección de error.

Un ejemplo de este tipo de algoritmos lo constituye la *regla de aprendizaje Perceptron*, la cual es muy simple. Para cada neurona en la capa de salida se calcula la desviación a la salida objetivo como error, δ , el cual se utiliza posteriormente para cambiar los pesos sobre la conexión de la neurona precedente.

Otro algoritmo muy conocido y que pertenece a esta clasificación es la *regla de aprendizaje delta* o regla del mínimo error cuadrado, que también utiliza la desviación a la salida objetivo, pero toma en consideración a todas las neuronas predecesoras que tiene la neurona de salida. Esto permite cuantificar el error global cometido en cualquier momento durante el proceso de entrenamiento de la red, lo cual es importante, ya que cuanto más información se tenga sobre el error cometido, más rápido se puede aprender. Luego, el error calculado es igualmente repartido entre las conexiones de las neuronas predecesoras.

Por último, se debe mencionar la *regla de aprendizaje de propagación hacia atrás* o de *retropropagación*, la cual es una generalización de la regla de aprendizaje Delta. Esta es la primera regla de aprendizaje que permitió realizar cambios sobre los pesos en las conexiones de la capa oculta.

4.4.2 Aprendizaje no supervisado.

En cuanto a los algoritmos de aprendizaje no supervisados, en general se suelen considerar dos tipos, que dan lugar a los siguientes aprendizajes:

1.- *Aprendizaje hebbiano*.- esta regla de aprendizaje es la base de muchas otras y pretender medir la familiaridad o extraer características de los datos de entrada. El fundamento es una suposición bastante simple: si dos neuronas N_i y N_j toman el mismo estado simultáneamente (ambas activas o ambas inactivas), el peso de la conexión entre ambas se incrementa.

2.- *Aprendizaje competitivo y comparativo*.- Se orienta a la clasificación de los datos de entrada. Como característica principal del aprendizaje competitivo se puede decir que, si un patrón nuevo se determina que pertenece a una clase reconocida previamente, entonces la inclusión de este nuevo patrón a esta clase matizara la representación de la misma. Si el patrón de entrada se determinó que no pertenece a ninguna de las clases reconocidas anteriormente, entonces la estructura y los pesos de la red neuronal serán ajustados para reconocer la nueva clase.

4.5 Modelo neuronal.

4.5.1 Neurona con una entrada.

En este caso, como se muestra en la figura, la entrada (p) es un escalar y esta multiplicada por un peso escalar (w) dando como resultado wp , el cual se conectara al sumador. Existe otra entrada 1, y es multiplicada por una polarización (offset o *bias*), y se conecta también al sumador. La salida del sumador n , se somete a una función de transferencia f , que da como resultado la salida de la neurona, que es un escalar a .

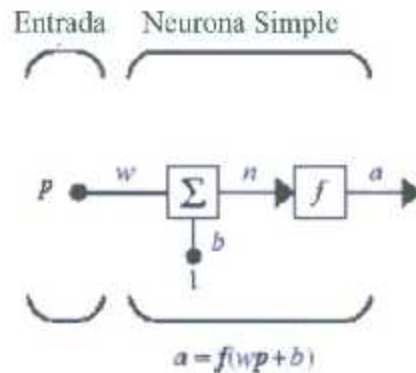


Figura 4.1 Neurona de una entrada

La salida de la neurona será:

$$a = f(wp + b) \tag{4.1}$$

La salida dependerá de la función de transferencia que se elija. La *polarización* es semejante al *peso* excepto que tiene una entrada constante. Tanto w como b son parámetros escalares ajustables de la neurona. El diseñador normalmente escoge la función de

transferencia y luego los parámetros mencionados se ajustaran por medio de alguna regla de aprendizaje, de tal forma que la relación entrada/salida de la neurona iguale alguna meta específica.

4.5.2 Funciones de transferencia.

La función de transferencia calcula el estado de actividad; transformando la entrada global en un valor (estado) de activación, cuyo rango normalmente va de 0 a 1 o de -1 a 1. Esto es así, porque una neurona puede estar totalmente inactiva (0 o -1) o activa (1). La función de transferencia o función de activación, es una función de entrada global menos el umbral. A continuación se mencionan las funciones de transferencia más comúnmente utilizadas.

4.5.2.1 Función de transferencia Hard Limit o escalón.

Coloca a salida de la neurona en cero, si el argumento de la función es menor de cero, o en 1 si el argumento es mayor o igual a cero. Normalmente el uso de esta función se escoge cuando queremos crear neuronas que clasifiquen las entradas en dos categorías distintas.

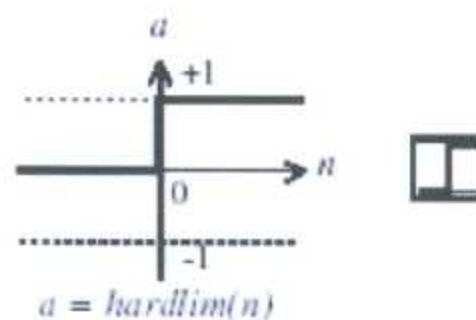


Figura 4.2 Función de transferencia Hard Limit o escalón

4.5.2.2 Función de transferencia *Lineal*.

En esta función de transferencia lineal, su salida es igual a su entrada, como se muestra en la figura siguiente:

$$a = n \quad (4.2)$$




Figura 4.3 Función de transferencia lineal

4.5.2.3 Función de transferencia *Log-Sigmoid*.

Esta función toma la entrada (la cual tiene un valor entre más y menos infinito) y ubica a su salida en el rango de cero a uno, de acuerdo a la expresión:

$$a = \frac{1}{1+e^{-n}} \quad (4.3)$$




Figura 4.4 Función de transferencia log-sigmoid

Esta función es utilizada normalmente en redes multicapas que son entrenadas por medio del algoritmo de *retropropagación*.

4.5.3 Neurona con múltiples entradas

En la figura 3.5 se muestra una neurona con R entradas. Las entradas individuales p_1, p_2, \dots, p están afectadas por el peso de los elementos correspondientes, w_1, w_2, \dots de la matriz W .

Entradas Neurona entradas múltiples




Figura 4.5 Neurona con múltiples entradas

La neurona tiene una polarización b que se suma a las entradas con el peso y da lugar a la entrada n a la red:

$$n = w_{1,1}p_1 + w_{1,2}p_2 + \dots + w_{1,R}p_R + b \quad (4.4)$$

Esta expresión puede escribirse en la forma matricial:

$$n = Wp + b \quad (4.5)$$

Y la matriz W tiene un solo renglón en el caso de una sola neurona.

La salida de la neurona puede expresarse como:

$$a = f(Wp + b) \quad (4.6)$$

La notación abreviada facilita la representación de redes neuronales con múltiples entradas.

A continuación se muestra una red con R entradas, utilizando esta notación:

Entrada Neurona de entradas múltiples




Figura 4.6 Neurona con R entradas. Notación abreviada

El vector de entrada p se representa por la barra vertical sólida. Las dimensiones de p se muestran bajo la variable como $R \times 1$, y eso indica que la entrada es un solo vector de R elementos. Estas entradas van a la matriz de pesos W la cual tiene R columnas y solo un renglón. Una constante de 1 va a la neurona como entrada y es multiplicada por el escalar b . la entrada a la función de transferencia f es n_i que es la suma de b y el producto de Wp . La salida de la neurona a es en este caso un escalar. Si tuviéramos más de una neurona, la salida sería un vector.

4.5.4 Arquitectura de redes.

Normalmente, no es suficiente una neurona, aun con múltiples entradas. Se requieren varias operando en paralelo, y esto recibe el nombre de *capa*.

4.5.4.1 Capa de neuronas.

En la siguiente figura se muestra una red de una sola capa y de S neuronas. La matriz de pesos tiene ahora S renglones.




Figura 4.7 Capa de S neuronas

Incluidos en la capa, están: la matriz de pesos, los sumadores, el vector \mathbf{b} , los bloques de las funciones de transferencia y el vector de salida \mathbf{a} . cada elemento del vector de entrada \mathbf{p} está conectado a cada neurona a través de la matriz de pesos \mathbf{W} . cada neurona tiene una polarización \mathbf{b} , un sumador, una función de transferencia f , y una salida a . en conjunto las salidas forman el vector de salida \mathbf{a} . En notación abreviada se muestra en la siguiente figura una red de S neuronas, R entradas y una capa.

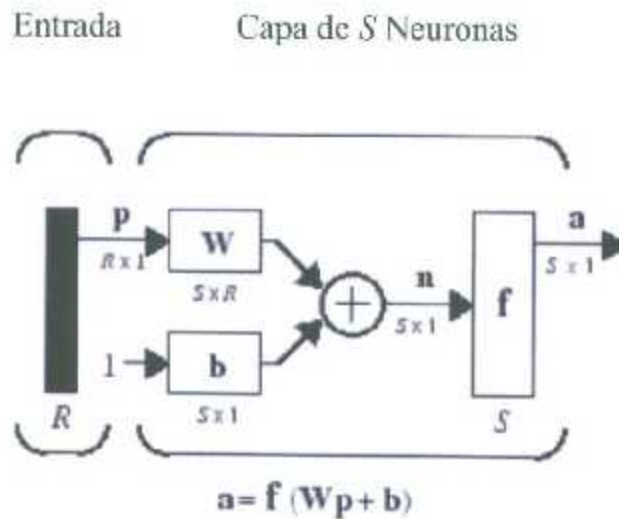


Figura 4.8 Capa de S neuronas. Notación abreviada

4.5.4.2 Neuronas de capas múltiples.

En este caso, cada capa posee su propia matriz de pesos \mathbf{W} , su propio vector de polarización \mathbf{b} , un vector \mathbf{n} de entradas a la red y un vector de salidas \mathbf{a} . el número de la capa se indica por su número correspondiente utilizado en la parte superior de los nombres de cada variable.

En la figura siguiente se muestra una red de tres capas:

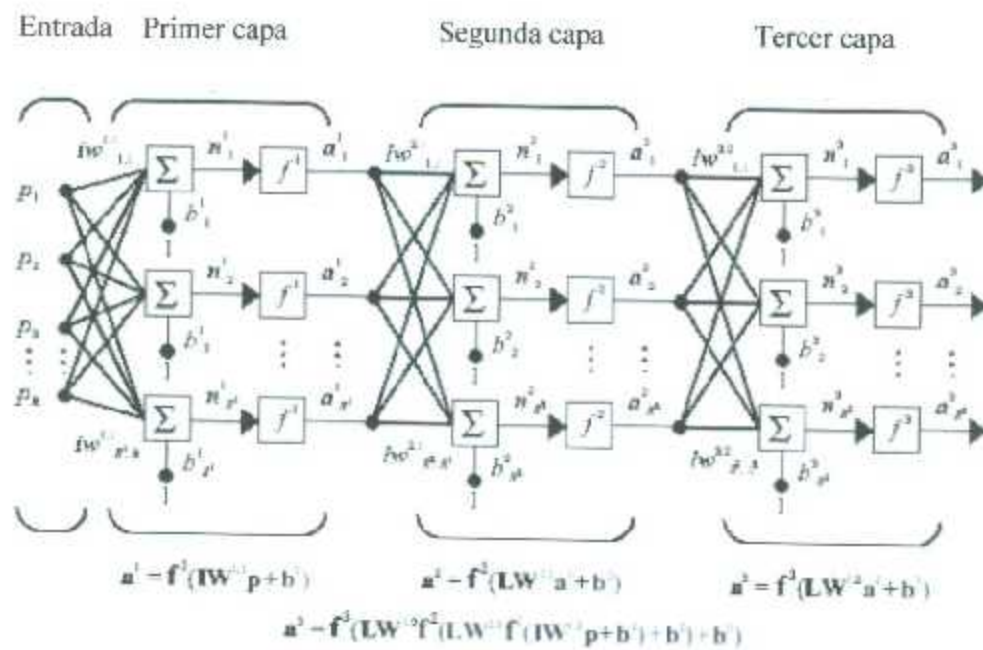


Figura 4.9 Red de tres capas

En la figura siguiente se muestra la misma red de tres capas, pero en forma de notación abreviada:

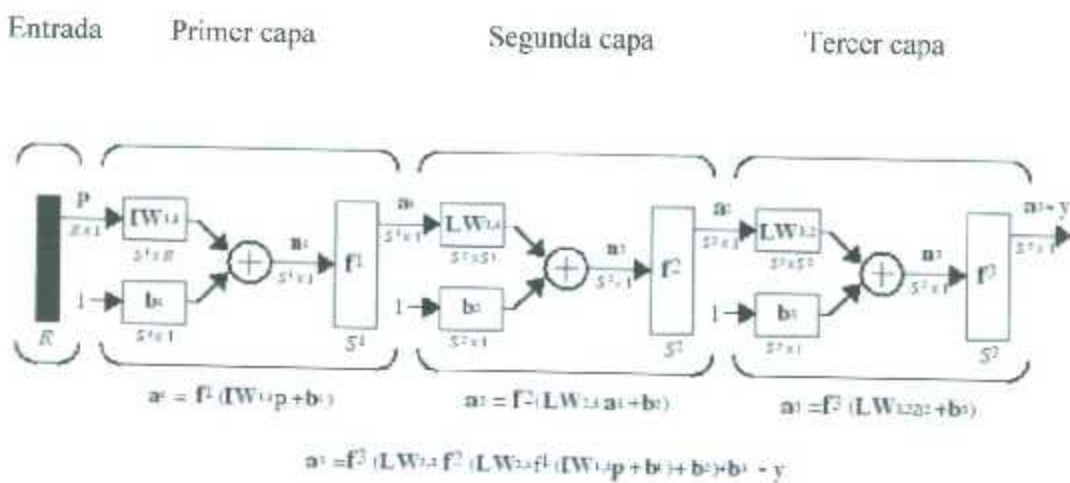


Figura 4.10 Red de tres capas. Notación abreviada

Cuando la salida de una capa es la salida de red, a esa capa se le denomina *capa de salida*. a las demás capas se les llama *capas ocultas*. Las redes de capas múltiples son más poderosas que las de una sola capa. La mayor parte de las redes prácticas, tienen solo dos o tres capas. Las neuronas se pueden seleccionar con o sin *bias*. Sin embargo, las redes con *bias* tienen mayor capacidad de desempeño.

4.5.5 Red neuronal de retropropagación.

El nombre *retropropagación* se refiere a la forma en la cual el gradiente es calculado en las redes no lineales de capas múltiples. Las redes *Retropropagación* adecuadamente entrenadas, dan respuestas razonables cuando se les alimentan entradas con las cuales nunca han tenido contacto anteriormente. Generalmente una nueva entrada llevara a la red hacia un tipo de salida igual correcta que corresponde a vectores de entrada usados en el entrenamiento y que son similares a la nueva entrada que se presenta.

Los vectores de entrada y los vectores de salida correspondientes, entrenan a una red hasta que esta pueda aproximar una función, asocie vectores de entrada con vectores de salida específicos o clasifique vectores de entrada en una forma apropiada y previamente definida. La retropropagación estándar, se basa en un algoritmo de gradiente descendiente.

4.5.5.1 Algoritmo de retropropagación.

En las redes de múltiples capas, la salida de una se convierte en la entrada de la capa siguiente. Esta operación la describen las siguientes ecuaciones:

$$a^{m+1} = f^{m+1}(w^{m+1}a^m + b^{m+1}) \text{ Para } m=0,1,\dots, M-1 \quad (4.7)$$

Para $m= 0,1,\dots, M-1$

donde M es el número de capas en la red.

En la primera capa, las neuronas reciben entradas externas:

$$a^0 = P \quad (4.8)$$

Lo que representa el punto de partida de la primera ecuación.

En la última capa, las salidas de las neuronas, se consideran las salidas de la red:

$$a = a^M \quad (4.9)$$

El algoritmo de *Retropropagación* utiliza el *error cuadrático medio* como índice de funcionamiento.

Al algoritmo se le provee con una serie de ejemplos de comportamientos adecuados de la red:

$$\{p_1, t_1\}, \{p_2, t_2\}, \dots, \{p_Q, t_Q\}, \quad (4.10)$$

donde p_Q es una entrada a la red, t_Q Es el objetivo correspondiente de salida.

A medida que cada entrada es aplicada a la red, la salida de la red es comparada con el objetivo.

El algoritmo debe ajustar los parámetros de la red en sentido tal de minimizar el *error cuadrático medio*:

$$F(x) = E[e^2] = E[(t - a)^2] \quad (4.11)$$

donde X es el vector de pesos y bias.

Con salidas múltiples lo anterior se generaliza:

$$F(x) = E[e^T e] = E[(t - a)^T (t - a)] \quad (4.12)$$

Se hace una aproximación del error cuadrático medio por medio de:

$$\hat{F}(x) = (t(k) - a(k))^T (t(k) - a(k)) = e^T(k)e(k) \quad (4.13)$$

El algoritmo descendiente para la aproximación del error cuadrático medio es:

$$w_{i,j}^m(k+1) = w_{i,j}^m(k) - \alpha \frac{\partial \hat{F}}{\partial w_{i,j}^m} \quad (4.14)$$

$$b_i^m(k+1) = b_i^m(k) - \alpha \frac{\partial \hat{F}}{\partial b_i^m} \quad (4.15)$$

Donde α es la razón de aprendizaje.

En el caso de redes de capas múltiples, el error no es una función explícita, sino indirecta de los pesos en las capas ocultas, siendo esa la razón por la que estas derivadas no pueden ser procesadas tan fácilmente.

Utilizando la regla de cadena para el cálculo de las derivadas de las ecuaciones anteriores:

$$\frac{\partial \hat{F}}{\partial w_{i,j}^m} = \frac{\partial \hat{F}}{\partial n_i^m} \chi \frac{\partial n_i^m}{\partial w_{i,j}^m}, \quad (4.16)$$

$$\frac{\partial \hat{F}}{\partial b_i^m} = \frac{\partial \hat{F}}{\partial n_i^m} \chi \frac{\partial n_i^m}{\partial b_i^m}. \quad (4.17)$$

Puesto que la entrada de la red a la capa m es una función explícita de los pesos y bias en esa capa, los segundos términos de las ecuaciones anteriores pueden ser procesados de manera más sencilla:

$$n_i^m = \sum_{j=1}^{s^{m-1}} w_{i,j}^m a_j^{m-1} + b_i^m \quad (4.18)$$

Así se tiene:

$$\frac{\partial n_i^m}{\partial w_{i,j}^m} = a_j^{m-1}, \quad \frac{\partial n_i^m}{\partial b_i^m} = 1. \quad (4.19)$$

Si se define:

$$s_i^m = \frac{\partial \hat{F}}{\partial n_i^m}, \quad (4.20)$$

Que representa la sensibilidad de \hat{F} a cambios en el i th elemento de la entrada de la red en la capa m , entonces las ecuaciones pueden simplificarse a:

$$\frac{\partial \hat{F}}{\partial w_{i,j}^m} = s_i^m a_j^{m-1}, \quad (4.21)$$

$$\frac{\partial \hat{F}}{\partial b_i^m} = s_i^m, \quad (4.22)$$

Así pues, ahora podemos expresar la aproximación del *algoritmo descendiente* como:

$$w_{i,j}^m(k+1) = w_{i,j}^m(k) - \alpha s_i^m a_j^{m-1} \quad (4.23)$$

$$b_i^m(k+1) = b_i^m(k) - \alpha s_i^m \quad (4.24)$$

en forma matricial sería:

$$W^m(k+1) = W^m(k) - \alpha s^m (a^{m-1})^T \quad (4.25)$$

$$b^m(k+1) = b^m(k) - \alpha s^m \quad (4.26)$$

donde:

$$s^m = \frac{\partial F}{\partial n^m} = \begin{bmatrix} \frac{\partial F}{\partial n_1^m} \\ \frac{\partial F}{\partial n_2^m} \\ \vdots \\ \frac{\partial F}{\partial n_{s^m}^m} \end{bmatrix} \quad (4.27)$$

El siguiente paso es propagar en sentido inverso las sensibilidades a lo largo de toda la red:

$$s^M = -2F^M(n^M)(t - a), \quad (4.28)$$

$$s^m = F^m(n^m)(W^{m+1})^T s^{m+1},$$

para

$$m=M-1, \dots, 2, 1. \quad (4.29)$$

Finalmente se actualizan los pesos y las bias:

$$w^m = (k + 1) = W^m(k) - \alpha s^m (a^{m-1})^T \quad (4.30)$$

$$b^m(k + 1) = b^m(k) - \alpha s^m \quad (4.31)$$

Capítulo 5

Métodos de estimación del estado de carga de baterías.

5.1. Introducción

La determinación del estado de carga (SOC por sus siglas en inglés State of Charge) se convierte en un tema cada vez más importante en todas las aplicaciones que incluyan una batería. Estrategias antiguas de operación usaban únicamente límites de voltaje para proteger la batería contra descargas profundas y sobrecargas. Actualmente, la operación de la batería está cambiando que puede ser llamada administración de batería que simplifica la protección. Para este control de batería mejorado, el SOC de la batería es un factor clave.

Muchos trabajos de investigación se han realizado en recientes años para mejorar la determinación del estado de carga [20]. Las condiciones de operación difieren dependiendo de su aplicación, por ejemplo aplicaciones fotovoltaicas, vehículos eléctricos y vehículos híbridos o telecomunicaciones. Por lo tanto, un método dado para calcular el SOC sería más adecuado para cierta aplicación que para otra. Los autores introducen métodos comúnmente usados para determinar el estado de carga y establecen una relación entre las ventajas de los diferentes métodos y las más comunes aplicaciones.

En muchos sistemas que usan batería, un punto importante es el conocimiento del estado de carga de la batería o más simple ¿Cuánto tiempo tengo hasta que mi dispositivo deje de funcionar?, el conocimiento de la capacidad remanente de la batería es muy importante para su administración. Actualmente muchos sistemas son sensibles a las descargas profundas o sobrecargas porque estos estados de muy alto o muy bajo SOC pueden llevar a un daño irreversible en la batería.

5.2. Definición de estado de carga

Técnicamente no existe una definición única para el estado de carga (SOC), en consecuencia, podemos encontrar varias en la literatura por ejemplo, el SOC está definido como el porcentaje de la máxima carga posible que está presente en el interior de una batería recargable. Hay diferentes definiciones para el estado de carga (SOC) que puede ser que simboliza la capacidad residual de la batería y es escrita como el porciento de la capacidad residual por la capacidad nominal. También puede ser la relación entre la diferencia de la capacidad nominal y la cantidad neta de carga descargada de la batería desde el ultimo SOC a 100 % por una parte y la capacidad nominal por otro lado, también una forma más simple de definir el estado de carga es la relación entre la energía almacenada en la batería y toda la energía que pueda ser almacenada en ella [20]. La estimación del estado de carga no es una tarea fácil y depende del tipo de batería y sus aplicaciones, generalmente hay dos categorías para la estimación del estado de carga de las baterías que son métodos directos y métodos indirectos. En el método directo, el SOC es estimado de las propiedades físicas de la batería, tales como densidad de ácido o pulsos catódicos galvanostáticos. Estas estimaciones necesitan mediciones precisas y tiene varias limitaciones en la práctica. Una de las mediciones de forma indirecta es la medición del voltaje de circuito abierto de la batería. En este método la batería debe de estar relajada por un tiempo para permitir su voltaje de circuito abierto para llegar a una condición de estado estacionario. Por lo tanto este método no es práctico para aplicaciones donde en la batería no se permite que se abra el circuito eléctrico. En otros métodos el SOC es estimado usando la descarga del voltaje de la batería. La impedancia estroboscópica es un método indirecto comúnmente usado para procesos electroquímicos tales como la batería. Este método no es usado únicamente para la estimación del SOC sino también para la estimación del SOH (estado de salud de la batería por sus siglas en inglés state of health). Sin embargo estos enfoques requieren de algunas mediciones adicionales que las hacen adecuadas para pruebas de laboratorio [21].

Entre los métodos directos la estimación del SOC se encuentra la técnica de conteo de Amperios-hora. Este método necesita de un valor inicial de estado de carga, cálculo de los consumos internos de la batería, y sensores de corriente exactos. Las redes neuronales artificiales también han sido utilizadas por algunos investigadores como estimación directa

del estado de carga de la batería. En estos métodos existe la necesidad de datos de entrada y salida para entrenar la red, los cuales son obtenidos por algunos otros métodos de estimación. Entrenar la red puede ser usada para estimar el estado de carga SOC [22].

A continuación establecemos algunas de las ecuaciones en las que se describe el estado de carga en las diferentes literaturas:

$$S(t) = S(0) - \int_0^t \frac{\eta I(t)}{C_n} dt, \quad (34)$$

donde $S(t)$ es el estado de carga en el instante de tiempo t , $S(0)$ es el estado de carga inicial, C_n es la capacidad nominal, y $I(t)$ es la corriente en el tiempo t . La corriente es positiva mientras se descarga y negativa mientras carga. η es la eficiencia coulombica. Usualmente, $\eta = 1$ para descargas y $\eta < 1$ para cargas bajo condiciones estándares [23].

Otra tradicional definición del estado de carga (SOC) es:

$$SOC(t) = 100 \left(\frac{Q_c - \int_0^t I_d(\tau) d\tau}{Q_c} \right) \quad (35)$$

Donde la batería se asume que ha sido cargada totalmente (SOC= 100%) en $t = 0$, y donde Q_c es la capacidad de corriente en coulombs [24].

Otra de las ecuaciones del estado de carga más comúnmente utilizada es:

$$SOC = 1 - \frac{\int i dt}{C_n} \quad (36)$$

Donde i es la corriente, y C_n es la capacidad máxima que la batería puede mantener. El SOC refleja la cantidad de carga restante que está disponible en la batería. Y se utiliza para determinar la distancia restante de conducción en vehículos eléctricos [25].

Para realizar el control de carga de baterías de manera eficiente, es necesario contar con un medio que permita determinar con precisión el estado de carga de las baterías. Este es un

tema complicado que se investiga en diferentes centros alrededor del mundo [26], [27], [28]. A continuación se describen brevemente las principales técnicas para determinar el estado de carga.

5.3 Métodos de determinación del estado de carga

La determinación del estado de carga puede ser un problema más o menos complejo dependiendo del tipo de batería y en la aplicación en la cual la batería va a ser usada. Los métodos para determinar el SOC están descritos explícitamente para sistemas de batería de ácido plomo, pero aplican parcialmente también para otros sistemas electroquímicos.

5.3.1 Prueba de descarga

Es la más confiable prueba para determinar el estado de carga, la prueba consiste en carga y descarga de la batería bajo condiciones controladas, tal prueba, la cual requiere recargas consecutivas, consume demasiado tiempo para ser considerada en muchas aplicaciones y como segundo inconveniente durante la prueba la función del sistema es interrumpido.

5.3.2 Conteo de amperios hora

Esta es la técnica más común para calcular el SOC. Así la carga y la descarga son directamente relacionadas con la corriente de descarga y la corriente de carga, la idea de un balance de corriente es evidente. Es decir, contando el número de Amperios-hora (Ah) que se suministran a la batería y compararlos contra el número de Ah que la batería ha suministrado. En este balance se deben tomar en cuenta las pérdidas por disipación de potencia y en las reacciones químicas que tienen lugar en el interior de la batería. Esta técnica se puede afinar si además de las corrientes se miden también el voltaje de la batería y la temperatura.

$$SOC = SOC_0 + \frac{1}{c_n} \int_{t_0}^t (I_{bat} - I_{perd}) dt \quad (37)$$

donde C_n es la capacidad nominal, I_{bat} es la corriente de la batería, I_{perd} es la corriente consumida por las pérdidas de las reacciones.

Dos complicaciones principales surgen con este método: primero, medición incorrecta de la corriente podría llevarnos a un gran error y la medición precisa de la corriente es costosa. En segundo, no toda la corriente suministrada por la batería es consumida por la carga y las pérdidas correspondientes tienen que ser tomadas en cuenta.

5.3.3 Medición de las propiedades físicas del electrolito

En las baterías plomo-ácido el electrolito es un ácido diluido en agua, a través del cual se llevan a cabo las reacciones químicas durante la carga y la descarga. Existe una relación lineal entre la concentración de ácido en el electrolito y el estado de carga de una batería. Este método es factible con baterías de ácido-plomo ventiladas. La densidad es medida directamente o indirectamente por concentración de ion, conductividad, índice refractivo, viscosidad, ultrasónicos.

Los problemas relacionados con esta técnica son ocurrencia de la estratificación del ácido, pérdidas de agua, y la estabilidad a largo plazo de sensores. Las dos primeras pueden ser evitadas por circulación de electrolito y un sistema de abastecimiento de agua automático. Además, las mediciones de las propiedades físicas no pueden ser hechas en los poros de los electrodos donde el ácido ya está consumido o producido. Esto significa que durante los procesos de altas corrientes, la difusión lenta del electrolito es una fuente de error para esta técnica.

5.3.4 Voltaje de circuito abierto

Parecido a la medición de la densidad de ácido, el voltaje de circuito abierto tiene una relación lineal con el estado de carga como se muestra en la Fig. 5.1. Obtenida de 4 baterías VRLA 12 V., 52 Ah (C/5). En aplicaciones donde existen largos periodos de descanso, este método es prometedor. En aplicaciones más dinámicas, el voltaje de circuito

abierto se usa para complementar alguna otra técnica que determine el estado de carga [20]. Las características del método se muestran en la tabla 5.1.

Tabla 5.1: Resumen método de voltaje de circuito abierto

Aplicación	Todo tipo de baterías
Principio de funcionamiento	Se basa en la existencia de una relación entre el VOC y el SOC.
Aplicación	Sistemas donde la batería tenga largos periodos de descanso
ventajas	Fácil aplicación, combinado con otras técnicas permite estimación continua del SOC
desventajas	Por si solo no es posible ser aplicado en tiempo real. Es afectado por la temperatura, e historia de la batería.

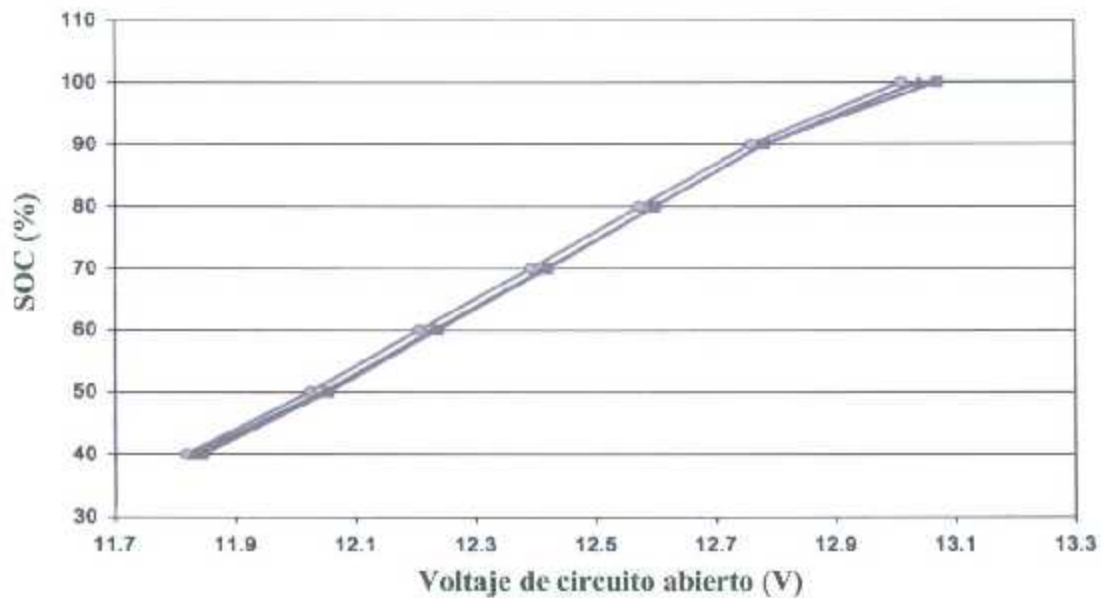


Figura 5.1 dependencia del estado de carga (SOC) y el voltaje de circuito abierto

Como se comentó anteriormente hay una relación lineal entre el SOC y el voltaje de circuito abierto de las baterías de ácido plomo que está dada por:

$$V_{oc}(t) = a_1 X SOC(t) + a_0 \quad (38)$$

donde $SOC(t)$ es el SOC de la batería en t , a_0 es el voltaje en terminales de la batería cuando el $SOC = 0\%$, y a_1 se obtiene de conocer el valor de a_0 y $V_{oc}(t)$ con el $SOC = 100\%$. Para (38), la estimación del SOC es equivalente a la estimación de su Voltaje de circuito abierto. El método de voltaje de circuito abierto está basado en el voltaje de circuito abierto de baterías es proporcional a su estado de carga cuando están desconectadas de la carga por un periodo mayor de 2 horas. Sin embargo tan prolongado tiempo de desconexión puede ser demasiado tiempo para ser implementado para baterías [30].

5.3.5 Interpretación heurísticas de mediciones

La siguiente técnica infiere el estado de carga de una batería a partir de la interpretación de sus curvas de carga y descarga. Esta técnica parte del supuesto de que analizando las partes de las curvas que se consideran significativas, se puede estimar el estado de carga de una batería.

5.3.6 Coup de fouet

La llamada región de coup de fouet es usada no para calcular exactamente el SOC si no la capacidad que puede ser entregada después de una recarga completa a una corriente y temperatura dada. La expresión francesa *coup de fouet* significa literalmente *latigazo*. En el contexto de las baterías plomo-ácido se refiere a la pequeña caída de voltaje que ocurre al inicio de la primera descarga después de una carga completa. Se ha encontrado que en particular dos parámetros del *coup de fouet* presentan una relación lineal con el estado de carga: el voltaje mínimo que se alcanza durante el *coup de fouet* y el voltaje estable que se alcanza al final del mismo. Este método se puede aplicar cuando se alcanza con frecuencia la carga completa de la batería.

5.3.7 *Modelo lineal*

Es una relación lineal establecida entre la variación del SOC y las mediciones eléctricas intermedias en la batería y el valor previo de SOC.

$$\begin{aligned}\Delta Q(i) &= \beta_0 + \beta_1 U(i) + \beta_2 I(i) + \beta_3 Q(i-1), \\ Q(i) &= Q(i-1) + \Delta Q(i)\end{aligned}\tag{39}$$

donde $Q(i)$ es el estado de carga, $\Delta Q(i)$ es la diferencia de SOC, U es el voltaje, I son las mediciones de corrientes.

Los factores β_0, \dots, β_3 son determinados a partir de datos de referencia por calculados estadísticos. El modelo fue desarrollado para aplicaciones de celdas fotovoltaicas, es decir para bajas corrientes y bajos cambios de SOC, y está caracterizado por su gran robustez en relación a los errores de medición y errores en las condiciones iniciales.

Es importante notar que los factores β no describen parámetros físicos.

El modelo lineal puede ser aplicado a varios tipos de baterías y en baterías en diferentes etapas de su tiempo de vida. Sin embargo mejores resultados se han logrado si los datos de referencia son del mismo tipo de batería usados para calcular los factores β [20].

5.3.8 *Redes neuronales artificiales*

Una red neuronal artificial establece una relación entre datos de entradas y salidas de cualquier tipo que pueden ser utilizados para todos los sistemas de baterías y para todas las aplicaciones, que prevé que los datos de entrenamiento para la red están disponibles. Si una red neuronal artificial adaptable es aplicada, otros métodos para determinar el estado de carga son usados para proveer datos de entrenamiento en estados seleccionados de operación. Los errores dependen fuertemente de los datos de entrenamiento y de los métodos de entrenamiento. La calidad de los resultados entregados por la red está en relación directa con la calidad de los datos de entrenamiento.

Como las baterías son dispositivos no lineales, la propiedad de no linealidad de las redes Neuronales es algo muy ventajoso, así como su aprendizaje adaptable ya que las Condiciones en las que se encuentran las baterías no son siempre predecibles. Es decir, una De las principales ventajas de las redes neuronales es su habilidad de aprender de su medio Ambiente y que mediante un proceso de entrenamiento pueden “descubrir” la correlación Que existe entre variables de entrada y salida sin recurrir a los métodos tradicionales. Esta Capacidad les permite proporcionar el valor de salida que corresponde a un conjunto de Entradas que no se utilizaron durante el entrenamiento de la red. Otra característica Importante de las redes neuronales es su fácil inserción dentro de casi cualquier tecnología. Se han reportado trabajos relacionados con el cálculo del estado de carga de baterías Utilizando redes neuronales, uno de los cuales presenta un método para la estimación de la Capacidad remanente de baterías selladas de tipo plomo-ácido, con un error máximo del 10% y error promedio de 3% [20].

5.3.9 Impedancia estroboscópica

Muchos trabajos de investigación han sido realizados con el método de impedancia estroboscópica. Este método es una técnica de medición común para investigar procesos electroquímicos y han sido estudiado para todos los sistemas de batería no únicamente para SOC sino también para determinación del estado de salud de la batería (SOH por sus siglas en inglés state of health).

Sorpresivamente, a pesar de la cantidad de artículos escritos sobre este tema, la impedancia estroboscópica rara vez es implementada para la determinación práctica del estado de carga y permanece siendo un tema de debate [27], [28], [29].

5.3.10 Resistencia interna

Relacionado con la impedancia estroboscópica es el cálculo de la resistencia interna de la batería, la caída de voltaje dividida por la corriente de carga durante el mismo (corto) intervalo de tiempo. El valor de la resistencia depende fuertemente del intervalo de tiempo seleccionado. Para un intervalo de tiempo más pequeño que 10 ms, únicamente efectos

Ohmicos son medidos. Si el intervalo es extendido otros efectos tales como las reacciones de transferencia o difusión de ácido son involucrados y la resistencia llega a ser compleja. En este caso sería mejor usar la previamente descrita impedancia estroboscópica en vez del voltaje y corriente nominales. Para baterías de ácido plomo el cambio en la resistencia interna (Ohmica) entre SOC completo y el SOC=0, y únicamente algunos miliohms por celda. Este tipo de mediciones es más usado para brindar información sobre el estado de salud de las baterías. Y esto puede brindar algo de información acerca del estado de carga SOC que nos dice que la batería no está totalmente cargada.

5.3.11 Filtro de Kalman

El filtro de Kalman es un algoritmo para estimar los estados dinámicos internos de un sistema. En nuestro caso la batería es un sistema dinámico y uno de los estados internos es el estado de carga SOC. La estimación está basada en un modelo de un sistema dinámico.

Resumiendo los diferentes métodos de determinación del estado de carga de baterías y sus Aplicaciones obtenemos la tabla 5.2 [20].

Tabla 5.2: Resumen de las diferentes técnicas de determinación de estado de carga de baterías.

Técnica	Campo de aplicación.	Ventajas	Desventajas
Prueba de descarga	Todos los sistemas de Baterías.	Fácil y exacto, independiente del estado de salud.	Fuera de línea, mucho tiempo, modifica el estado de la batería, pérdida de energía.
Conteo de Amperios-hora	Todos los sistemas de baterías mayoría de sus aplicaciones.	En línea, fácil, exacto si existen suficientes puntos de recalibración y si existe una buena medición de corriente.	Necesita un modelo para las perdidas, sensible a las reacciones parasitas, costo elevado para medición de corriente exacta.
Medición de las propiedades físicas del electrolito	Plomo, Litio, Zn/Br y Va.	En línea, proporciona información del estado de salud.	Errores si el ácido esta estratificado. Baja dinámica. Problemas de estabilidad en los sensores del electrolito. Sensible a la temperatura y a las impurezas.
Voltaje de circuito abierto	Plomo, Litio, Zn/Br y Va.	En línea, económico.	Baja dinámica y errores si el ácido esta estratificado, y largos periodos de descanso para los sistemas de ácido. Problemas de reacciones parasitas.
Modelo lineal	Plomo en aplicaciones de sistemas fotovoltaicos.	En línea, fácil.	Necesidad de datos de referencia para parámetro de ajuste.
Redes neuronales artificiales	Todos los sistemas de batería.	En línea.	Necesidad de datos de entrenamiento de baterías similares.
Impedancia estroboscópica	Todos los sistemas.	Da información acerca del estado de salud y calidad, posibilidad de medición en línea.	Sensible a la temperatura y costoso.
Resistencia interna C.D.	Plomo, Ni/Cd.	Da información acerca del SOH, barato, posibilidad de medir en línea.	Buena precisión, pero únicamente para bajos SOC.
Filtro de Kalman	Todos los sistemas de baterías, aplicaciones dinámicas y aplicaciones de sistemas fotovoltaicos.	En línea, dinámico.	Necesidad de gran capacidad computacional. Necesidad de modelo adecuado de batería. Problemas para determinar parámetros iniciales.

Capítulo 6

Diseño y simulación de un algoritmo de estimador del estado de carga para baterías de ciclo profundo con redes neuronales

6.1 Introducción

En este capítulo se presenta la simulación y la implementación de un convertidor reductor-elevador empleado como cargador de baterías, con un sistema de control basado en seguimiento del punto de máxima transferencia de potencia (MPPT), y con una fuente de alimentación de un sistema fotovoltaico.

También se presenta la simulación del convertidor reductor-elevador con un sistema de control de 3 etapas en las cuales se involucran lazos cerrados de control PI (proporcional integral) en corriente y en voltaje, aplicado como cargador de baterías. Cabe mencionar que este modelo quedó solo en simulación ya que la fuente de alimentación para nuestro circuito es un módulo fotovoltaico de corriente limitada. Y no alcanza el nivel de corriente de carga recomendado por el fabricante.

Finalmente se muestran los resultados de las simulaciones del estimador de estado de carga con el método de redes neuronales artificiales, en modo de carga y descarga de una batería de 6 volts, 225 Ah. Con los datos de entrada de voltaje de circuito abierto, corriente de batería y temperatura, así como se hizo la simulación con 3 y 4 entradas en donde agregamos el tiempo como una variable de entrada más para el entrenamiento de la red y como es una red supervisada los objetivos fueron trazados a partir de la estimación del estado de carga de acuerdo al método de voltaje de circuito abierto.

6.2 Sistemas fotovoltaicos

Con la aceleración de la utilización de fuentes de energía renovables, la generación de potencia con sistemas fotovoltaicos está siendo empleada en muchas aplicaciones.

Convencionalmente, los sistemas fotovoltaicos consisten de arreglos de celdas fotovoltaicas y convertidores eléctricos [31]. Además, la creciente demanda de energía, junto con la posibilidad de reducción en el suministro de combustibles convencionales, como lo demuestra la crisis del petróleo, junto con la creciente preocupación por la conservación del medio ambiente. Han impulsado la investigación y el desarrollo de fuentes alternativas de energía más limpias, renovables y producir poco impacto ambiental. Entre las fuentes alternativas, la energía eléctrica a partir de celdas fotovoltaicas es actualmente considerada como una fuente de energía natural que es más útil, ya que es libre, abundante, limpia, y distribuida sobre toda la tierra. Por otra parte, a pesar de los fenómenos de reflexión y de absorción de la luz solar por la atmósfera, se estima que la energía solar incidente en la superficie de la tierra es del orden de diez mil veces mayor que el consumo de energía en el mundo. Una gran ventaja de las celdas es la reducción de las emisiones de dióxido de carbono. Para el año 2030, la reducción anual de dióxido de carbono debido al uso de sistemas fotovoltaicos puede ser alrededor de 1Gton/año, lo cual es equivalente a la cantidad total de emisiones de la India en el año 2004 o las emisiones de 300 plantas de carbón. De acuerdo a los expertos, la energía obtenida de celdas solares llegara a ser una importante alternativa en las fuentes de energía renovables hasta 2040. A pesar de todas las desventajas presentadas por la generación de energía a través de celdas fotovoltaicas, la eficiencia de la conversión de energía se encuentra actualmente baja, y los costos iniciales para su implementación continúan considerándose altos [32].

El potencial de la energía solar en la superficie de la tierra es estupendo. La potencia de la irradiación solar por unidad de área es superior a 1000 W/m^2 . Hay que destacar que su potencial es renovable y además, es inagotable. Los sistemas fotovoltaicos operan sobre la base de conversión directa de energía solar en los materiales semiconductores. Una celda fotovoltaica es básicamente un diodo semiconductor cuya unión p-n está expuesta a la luz. Las celdas fotovoltaicas están hechas de varios tipos de semiconductores usando diferentes tipos de manufactura. Las celdas de silicio monocristalino y policristalino son las únicas encontradas en escala comercial en tiempos actuales. Las celdas fotovoltaicas de silicio están compuestas de una fina capa de grueso Silicio o de una película delgada conectada en terminales eléctricas. Uno de los lados de la capa de Silicio se dopa para formar la unión p-

n. Una rejilla metálica delgada se coloca en la superficie del semiconductor orientada hacia el sol.

La incidencia de la luz genera en la celda portadores de carga que originan corriente eléctrica si la celda está en cortocircuito. Cargas son generadas cuando la energía del fotón es suficiente para separar los electrones covalentes del semiconductor, este fenómeno depende del material del semiconductor y de la longitud de onda incidente de luz. Básicamente, el fenómeno fotovoltaico puede ser descrito como la absorción de radiación solar, la generación y la transportación de portadores en la unión p-n, y la colección de estas cargas eléctricas en las terminales del dispositivo fotovoltaico. La generación de portadores depende del flujo de luz incidente y la capacidad de absorción del semiconductor. La capacidad de absorción depende principalmente del intervalo de banda del semiconductor, en la reflectancia de la superficie de la celda (que depende de la forma y del tratamiento de la superficie), en la concentración intrínseca de los portadores del semiconductor, en la movilidad electrónica, en la temperatura y de otros varios más factores.

La radiación solar está compuesta de fotones de diferentes energías. Los fotones con energías inferiores a las del intervalo de banda de la celda fotovoltaica son inútiles y no generan voltaje o corriente eléctrica. Los fotones con energía superior al intervalo de banda generaran electricidad, pero únicamente se utiliza la energía correspondiente al intervalo de banda, la energía remanente es disipada como calor en el cuerpo de la celda fotovoltaica [33] [34].

6.2.1 Modelo matemático de modulo fotovoltaico

La radiación electromagnética de la energía solar puede ser directamente convertida en electricidad a través del efecto fotovoltaico. Siendo expuesto a la luz solar, los fotones con mayor energía que la energía del intervalo de banda de los semiconductores crea algunos pares de huecos proporcionales a la incidencia de irradiación.

El circuito equivalente de una celda fotovoltaica se muestra en la figura 6.1.




Figura 6.1 Modelo de celda fotovoltaica de un diodo.

La metodología de modelado de sistemas de energía solar fotovoltaica se describe a continuación, la fuente de corriente I_{ph} representa la fotocorriente de la celda. R_{sh} y R_s son las resistencias shunt intrínseca y la resistencia serie de la celda, respectivamente. Usualmente el valor de R_{sh} es muy grande y el valor de R_s es muy pequeño, por lo tanto, esta se puede despreciar para simplificar el análisis [35] [36].

Los paneles solares pueden ser modelados matemáticamente como se indica en las ecuaciones (6.1-6.4).

Fotocorriente de módulo:

$$I_{ph} = [I_{scr} + K_i(T - 298)] * \lambda / 1000 \quad (6.1)$$

donde. I_{scr} es la corriente de corto-circuito a 25° C, y K_i es el coeficiente de temperatura de la corriente de corto-circuito a $I_{scr}=0.0017 \text{ A/}^\circ\text{C}$, T es la temperatura de operación del módulo en grados Kelvin, λ es la iluminación del módulo PV (W/m^2)= 1000W/m^2 .

Corriente de saturación de reversa:

$$I_{rs} = I_{scr} / [\exp\left(\frac{qV_{oc}}{N_s k A T}\right) - 1] \quad (6.2)$$

donde, q es la carga del electrón= 1.6×10^{-19} C, V_{oc} es el voltaje de circuito abierto de la celda, N_s es el número de celdas conectada en serie, K es la constante Boltzman= 1.3805×10^{-23} J/K, $A = B$ es el factor de idealidad y tiene un valor de 1.6.

La corriente de saturación del modulo I_0 varia con la temperatura de la celda, la cual está dada por:

$$I_0 = I_{rs} \left[\frac{T}{T_r}\right]^3 \exp\left[\frac{q * E_{g0}}{B k} \left\{\frac{T}{T_r} - \frac{1}{T_r}\right\}\right] \quad (6.3)$$

donde, T_r es la temperatura de referencia= 298 K, E_{g0} es el intervalo de banda del silicio= 1.1 eV, B es el factor de idealidad = 1.6.

La corriente de salida del módulo es:

$$I_{pv} = N_p * I_{ph} - N_p * I_0 \left[\exp\left\{\frac{q * (V_{pv} + I_{pv} R_s)}{N_s A k T}\right\} - 1 \right] \quad (6.4)$$

donde, $V_{pv} = V_{oc}$, $N_p = 1$ y $N_s = 36$, V_{pv} es el voltaje de salida del módulo PV (V), I_{pv} es la corriente de salida del módulo PV (A).

El modelo del módulo PV para la simulación en MATLAB/simulink se hizo de acuerdo a los datos de la tabla 6.1.

Tabla 6.1 Datos de características eléctricas de módulo solar fotovoltaico SOLKAR 36 W.

Potencia nominal	37.08 W
Voltaje a máxima potencia (V_{mp})	16.56 V
Corriente a máxima potencia (I_{mp})	2.25 A
Voltaje de circuito abierto (V_{oc})	21.24 V
Corriente de cortocircuito (I_{scr})	2.55 A
Número total de celdas en serie (N_s)	36
Número total de celdas en paralelo (N_p)	1

En la figura 6.2 se muestra el modelo del módulo PV elaborado en MATLAB/simulink.




Figura 6.2 Modelo de panel fotovoltaico en MATLAB/Simulink

Las curvas características de voltaje-corriente y voltaje-potencia se muestran en las figuras 6.3 y 6.4 y han sido obtenidas por simulación a través de MATLAB/simulink.




Figura 6.3 Curva característica V-I de modelo de panel fotovoltaico de MATLAB/simulink a 1000 W/m^2 .




Figura 6.4 Curva característica P-V de modelo de panel fotovoltaico de MATLAB/simulink a 1000 W/m^2

6.2.2 Panel fotovoltaico utilizado

El módulo fotovoltaico con el que se realizaron las pruebas del convertidor reductor-elevador empleado como cargador, fue con las características de celda marca Siemens que se muestran en la tabla 6.2. Este módulo fotovoltaico se encuentra en las instalaciones del

Instituto Tecnológico de la Laguna como se muestra en la Fig. 6.5. En los módulos se hizo un arreglo serie-paralelo para lograr el nivel de voltaje y corriente necesarios para las pruebas con el convertidor y la batería de ciclo profundo.

Tabla 6.2 Datos de características eléctricas de modulo solar fotovoltaico marca SIEMENS de 53 W

Potencia Máxima (P_{max})	53 Watts
Corriente de cortocircuito (I_{sc})	3.35 Amps
Corriente a máxima potencia (I_{mp})	3.05 Amps
Voltaje de circuito abierto (V_{oc})	21.7 Volts
Voltaje a máxima potencia (V_{mp})	17.4 Volts



Figura 6.5 Panel fotovoltaico empleado

Las siguientes curvas de la Fig. 6.6 fueron obtenidas del módulo fotovoltaico marca Siemens a distintas irradiaciones en el transcurso del día para obtener la característica P-V del panel solar.

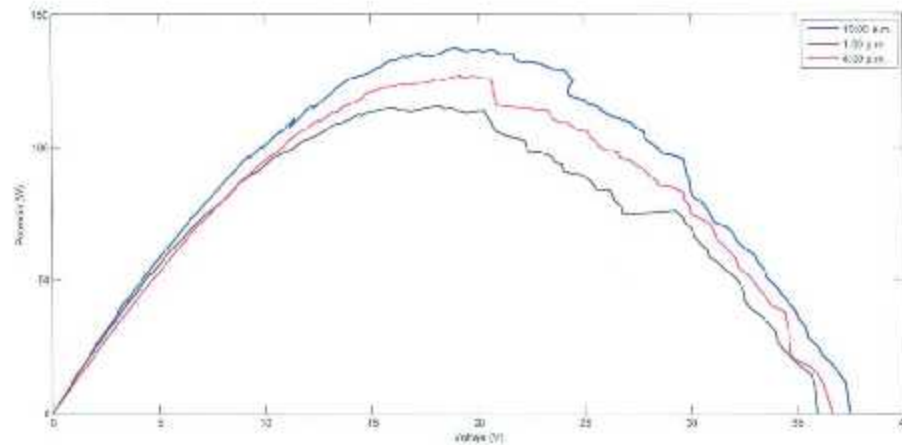


Figura 6.6 Gráfica de la curva P-V de panel solar Siemens 53 W con diferentes irradiaciones

6.3 Algoritmo de seguimiento de punto de máxima de potencia (MPPT)

El valor práctico de aplicaciones fotovoltaicas es cada vez más importante. Bajo la influencia de su carga, intensidad solar, temperatura y otros factores, las características de salida de las celdas solares muestran no-linealidad y relativamente fuerte variabilidad. Para maximizar el uso de la energía solar, un seguimiento de punto de máxima transferencia de potencia es necesario. En la actualidad, los algoritmos más comúnmente usados son el método de perturbar y observar (P&O) y el método de conductancia incremental (INC). El método P&O nos lleva fácilmente a juicios erróneos y a la oscilación en torno al punto de máxima potencia, este generalmente necesita combinar una

o varias mejoras para su uso normal [37]. Los algoritmos de P&O son ampliamente usados por su estructura simple y las pocas variables que se precisan medir, el algoritmo opera perturbando periódicamente (incrementando o decrementando) la tensión en las terminales del sistema FV (fotovoltaico) por medio del ciclo de trabajo del convertidor y luego comparando la potencia de salida del sistema FV, con la potencia del ciclo previo de perturbación. Si la potencia actual medida es mayor que la del ciclo anterior, la perturbación continuara en la misma dirección en el próximo ciclo, caso contrario la dirección de la perturbación se invertirá en el próximo ciclo. Esto significa que la tensión en las terminales del sistema FV se ve perturbada en cada ciclo a intervalos, por lo tanto, una vez alcanzado el punto máximo de potencia, el algoritmo de P&O oscilara alrededor de este punto resultando una pérdida de potencia del sistema FV, especialmente en casos donde las condiciones atmosféricas son constantes o varían con lentitud. Por otro lado, cuando las condiciones del entorno cambian rápidamente, por ejemplo como resultado del movimiento de las nubes, se verifica el algoritmo de P&O se desvía del punto de máxima potencia. Este algoritmo puede operar equivocadamente en estos casos debido al hecho de que no es capaz de distinguir las variaciones de la potencia de salida del sistema FV causadas por el ciclo de trabajo de aquellas causadas por la desviación de la radiación solar.

Con el propósito de solucionar los problemas mencionados anteriormente del método de P&O, el algoritmo de Conductancia incremental, el cual sigue el punto de máxima potencia del sistema FV usando un procedimiento diferente. El método se basa en el hecho de que en el punto de máxima potencia, la derivada de la potencia de salida del sistema FV con respecto a la tensión es cero. Así, la tensión del sistema FV puede ser regulada cercana a la tensión en el punto de máxima potencia midiendo la conductancia incremental, dI/dV , y la conductancia I/V [38] [39].

El método de la conductancia incremental se obtiene a partir de la derivación de la potencia del panel fotovoltaico; esta derivada se iguala a cero para obtener el punto de máxima potencia (MPP), tal y como se muestra en la ec. (6.4):

$$\frac{dP}{dV} = \frac{d(VI)}{dV} = I \frac{dV}{dV} + V \frac{dI}{dV} = I + V \frac{dI}{dV} \quad (6.4)$$

donde P es potencia, V es voltaje, e I es corriente del panel fotovoltaico.

El MPP será encontrado cuando:

$$\frac{dP}{dV} = 0; I + V \frac{dI}{dV} = 0; -\frac{I}{V} = \frac{dI}{dV} \quad (6.5)$$

donde $\frac{I}{V}$ representa la conductancia instantánea del panel fotovoltaico y $\frac{dI}{dV}$ es la conductancia incremental. En este algoritmo se busca que ambas cantidades sean iguales en magnitud para asegurar la operación en el punto de máxima transferencia de potencia.

De esta ecuación se pueden deducir las siguientes condiciones, las cuales son utilizadas para alcanzar el punto de máxima potencia:

$$\begin{aligned} \frac{dI}{dV} &= -\frac{I}{V}; \left(\frac{dP}{dV} = 0\right) \\ \frac{dI}{dV} &> -\frac{I}{V}; \left(\frac{dP}{dV} > 0\right) \\ \frac{dI}{dV} &< -\frac{I}{V}; \left(\frac{dP}{dV} < 0\right) \end{aligned} \quad (6.6)$$

Estas condiciones sirven para determinar la dirección en la que se deben dar los pasos de carga para lograr convergencia con el punto MPPT. El algoritmo de conductancia incremental se muestra en la Fig.6.7.

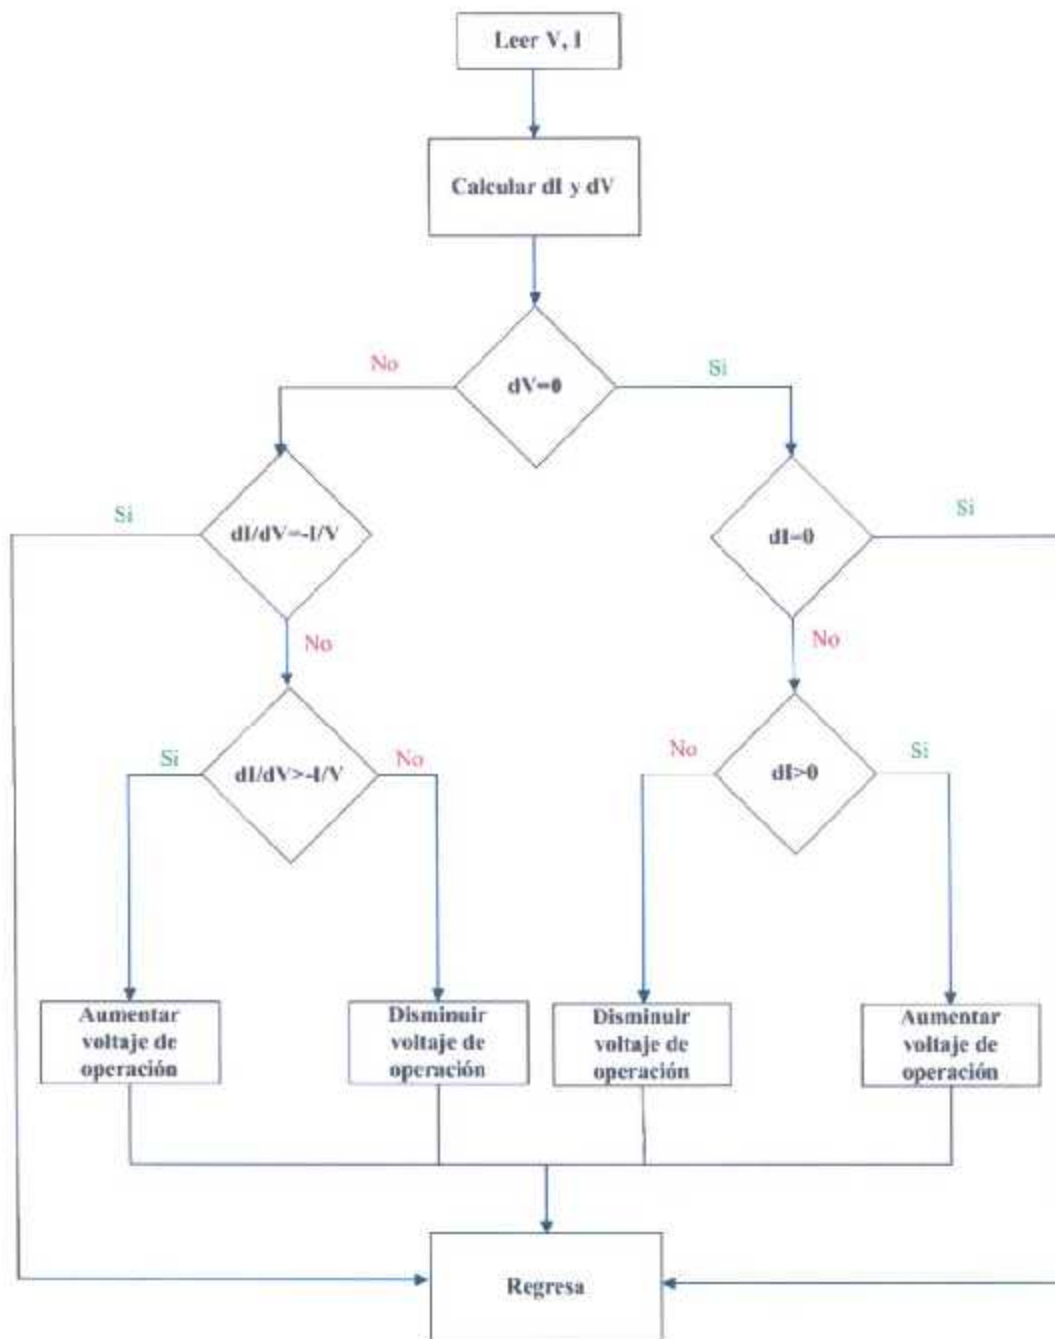


Figura 6.7 Algoritmo de conductancia incremental

La principal ventaja que ofrece este método consiste en que el algoritmo de conductancia incremental puede determinar el momento en que se ha alcanzado el punto de máxima

potencia, esto no ocurre en el método de perturbación y observación. Esto se logra sin necesidad de desconectar el panel fotovoltaico de la carga que esta alimentado. Una ventaja adicional consiste en la presencia de transiciones en las condiciones atmosféricas no existe la posibilidad de que el método comience a rastrear en la dirección opuesta al punto de máxima potencia. Por lo antes mencionado se tomó la decisión de utilizar este algoritmo para nuestro panel fotovoltaico.

La tabla 6.3 muestra una comparación detallada de las principales características para los métodos de MPPT, con un enfoque en la velocidad de la convergencia, la complejidad de la implementación, la fiabilidad para detectar el punto de máxima potencia con diferentes condiciones climáticas y el método de implementación preferido [40].

Tabla 6.3 Comparación de los métodos más comunes de MPPT

Técnica de MPPT	Velocidad	Complejidad	Confiabilidad	Implementación
Fraccionario I_{sc}	Media	Media	Baja	Digital/Análoga
Fraccionario V_{oc}	Media	Baja	Baja	Digital/Análoga
Conductancia Inc.	Varia	Media	Media	Digital
Hill Climbing	Varia	Baja	Media	Digital/Análoga
Lógica Difusa	Rápida	Alta	Media	Digital
Redes Neuronales	Rápida	Alta	Media	Digital

En la figura 6.8 se muestra el diagrama de bloques del algoritmo de MPPT conductancia incremental diseñado en Simulink.

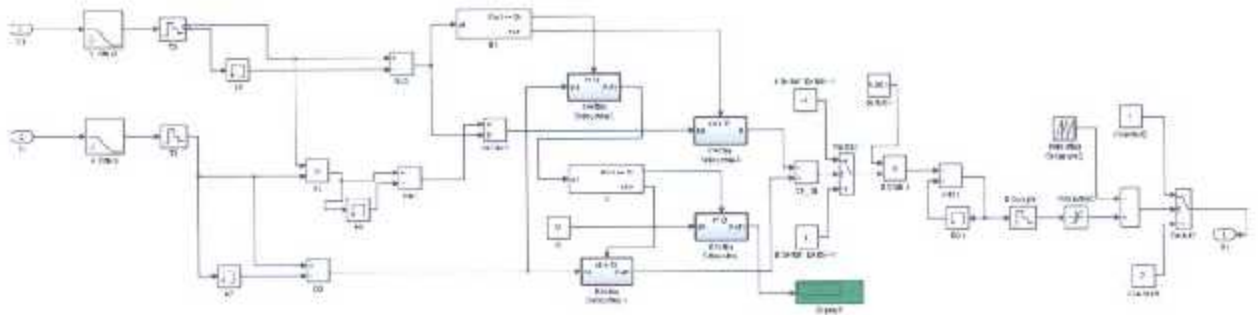


Figura 6.8 Diagrama de bloques de MPPT conductancia incremental

6.4 Calculo de inductancia y capacitancia de convertidor reductor-elevador

Para obtener los datos en modo carga para el entrenamiento de la red neuronal para nuestro estimador de estado de carga necesitamos un cargador de batería, el convertidor reductor-elevador combina las propiedades del convertidor elevador y el reductor. Es decir, es capaz de transformar un voltaje de entrada a cualquier nivel de voltaje de salida, esto es necesario de acuerdo a la aplicación que tengamos en diferentes niveles de voltaje de baterías. A continuación se muestran las ecuaciones de diseño para obtener el valor de la inductancia y capacitancia que se obtuvieron en el capítulo #3 que son las siguientes ecuaciones (3.17):

A partir de la corriente de rizo de pico a pico obtenemos:

$$\Delta I = \frac{V_s k}{fL}$$

donde, $\Delta I = 0.85 A$, $V_s = 36 V$, $k = 0.55$, $f = 20000 Hz$.

Despejando L obtenemos:

$$L = \frac{V_s k}{f \Delta I} = \frac{(36)(0.55)}{(20000)(0.85)} = 1.16 mH$$

Para el cálculo de la capacitancia, a partir del voltaje de pico de rizo pico a pico (3.18) se obtiene:

$$\Delta V_c = \frac{I_a k}{f C}$$

donde, $\Delta V_c = 0.5 V$, $I_a = 9 A$, $k = 0.55$, $f = 20000 hz$.

Despejando C obtenemos:

$$C = \frac{I_a k}{f \Delta V_c} = \frac{(9)(0.55)}{(20000)(0.5)} = 330 \mu F$$

Ya con estos valores se diseña la bobina del inductor con la siguiente ec.

$$L = N^2 A_L \tag{6.7}$$

donde, L es inductancia en nanohenrios, N es número de vueltas, A_L es el índice inductivo en $nH/vuelta^2$.

Así despejando N se tiene:

$$N = \sqrt{\frac{L}{A_L}} \tag{6.8}$$

donde, $L = 1.16 \times 10^6 nH/vueltas^2$, $A_L = 450 nH/vueltas^2$ Valor obtenido de tablas de acuerdo a dimensiones y color de la ferrita [4].

$$N = \sqrt{\frac{1,16 \times 10^6}{450}} = 50,77 \text{ vueltas}$$

Para determinar el calibre del conductor empleamos la fórmula de la densidad de corriente como sigue:

$$S = \frac{I}{J} \tag{6.9}$$

donde, $I = 9 \text{ A}$, $J = 5 \text{ A/mm}^2$.

$$S = \frac{9}{5} = 1,8 \text{ mm}^2$$

Para un calibre 15 de alambre para la construcción de la bobina.

6.5 Simulación de convertidor reductor-elevador empleado como cargador de baterías de tres etapas.

Dentro del periodo de tesis se diseñó un convertidor reductor-elevador empleado como cargador de baterías con el propósito de utilizarlo para nuestras pruebas de carga. Sin embargo, con la limitación de la fuente de alimentación que es un panel fotovoltaico, se tomó la decisión de dejarlo solo en simulación y no llevarlo a la implementación. Se realizaron simulaciones de prueba de lazo abierto, lazo cerrado y de cada una de las etapas por separado para llegar al diseño de este cargador. Por lo tanto, el cargador tiene 3 etapas de carga, las cuales son: corriente constante-voltaje constante-corriente constante (CC-VC-CC). Los cargadores deben proporcionar las siguientes funciones: 1) entrega de carga a la batería; 2) optimización de velocidad de carga; y 3) terminar el proceso de carga. La carga debe ser entregada a la batería a través de diferentes esquemas de carga basados en la química de la batería. Muchos métodos de carga de baterías han sido propuestos tales como corriente constante (CC), voltaje constante (VC), método de CC-VC, método de CC-

VC-CC que es el método aplicado al convertidor reductor-elevador [42]. El método de carga de CC está basado en ajustar una corriente de carga para la batería. El método de carga es simple y fácil de implementar y las corrientes de carga son iguales para cada batería en conexión en serie. Sin embargo, la principal desventaja del método de carga de corriente constante es su dificultad para conseguir un mecanismo preciso que detecte el 100 % de estado de carga (SOC). Por lo tanto, una sobre descarga y una sobrecarga tendrá lugar en la estrategia de corriente lo cual disminuirá su desempeño. Por otro lado, el método de carga de voltaje constante VC simplemente una tensión constante que proporciona a las baterías. Se necesita limitar la corriente de carga en el método de voltaje constante para evitar una corriente de sobrecarga, la cual reduciría la vida útil de la batería por el aumento de la temperatura [43]. Actualmente, la combinación de los métodos de carga CC y VC para las baterías se ha convertido en un enfoque convencional. Primero se aplica el método de CC para un bajo estado de carga (SOC) hasta que el voltaje se acerque a un valor preestablecido, el cual es determinado por las características de la batería. Entonces, un voltaje constante se mantiene para continuar con la carga de la batería para permitir cargar en forma completa la batería. Existe también el método de 3 etapas el cual es el que se simula en esta sección que consiste de empezar con una corriente constante CC, después continuar con un voltaje constante VC, y finalmente con una corriente constante. Esta estrategia puede eficientemente aumentar la velocidad de carga y evitar sobrecarga [44].

Los lazos de control de corriente constante y de voltaje constante fueron simulados con bloques de MATLAB/Simulink los controles PI (Proporcional-Integral) en lazo cerrado, a continuación se muestra un poco de historia de los sistemas de control.

6.5.1 Sistemas de control en lazo cerrado

Los sistemas de control realimentado se denominan también sistemas de *control en lazo cerrado*. En la práctica, los términos control realimentado y control en lazo cerrado se usan indistintamente. En un sistema de control en lazo cerrado, se alimenta al controlador la señal de error de actuación, que es la diferencia entre la señal de entrada y la señal de realimentación (que puede ser la propia señal de salida o una función de la señal de salida y sus derivadas y/o integrales), con el fin de reducir el error y llevar la salida del sistema a

un valor deseado. El termino control en lazo cerrado siempre implica el uso de una acción de control realimentado para reducir el error del sistema.

6.5.2 Sistemas de control en lazo abierto

Los sistemas en los cuales la salida no tiene efecto sobre la acción de control se denomina sistemas de control en lazo abierto. En otras palabras, en un sistema de control de lazo abierto no se mide la salida ni se realimenta para compararla con la entrada. Cada entrada de referencia le corresponde una condición de operación fija; como resultado de ello, la precisión del sistema depende de la calibración. Ante la presencia de perturbaciones, un sistema de control en lazo abierto no realiza la tarea deseada.

6.5.3 Sistemas de control en lazo cerrado en comparación con sistemas en lazo abierto

Una ventaja del sistema de control en lazo cerrado es que el uso de la realimentación vuelve la respuesta del sistema relativamente insensible a las perturbaciones externas y a las variaciones internas en los parámetros de los sistemas. Desde el punto de vista de estabilidad, el sistema de control en lazo abierto es más fácil de desarrollar, porque la estabilidad del sistema no es un problema importante. Por otra parte, la estabilidad si es un gran problema en el sistema de lazo cerrado, que puede conducir a corregir en exceso errores que producen oscilaciones de amplitud constante cambiante.

Las ventajas fundamentales de los sistemas de control en lazo abierto son las siguientes:

1. Construcción simple y facilidad de mantenimiento.
2. Menos costosos que el correspondiente sistema en lazo cerrado.
3. No hay problemas de estabilidad.
4. Convenientes cuando la salida es difícil de medir o cuando medir la salida de manera precisa no es económicamente viable.

Las desventajas fundamentales de los sistemas de control en lazo abierto son las siguientes:

1. Las perturbaciones y los cambios en la calibración originan errores, y la salida puede ser diferente de lo que se desea.
2. Para mantener la calidad requerida en la salida, es necesaria la recalibración de vez en cuando.

Un controlador automático compara el valor real de la salida de una planta con la entrada de referencia (el valor deseado), determina la desviación y produce una señal de control que reduce la desviación a cero o a un valor pequeño, la manera en la cual el controlador automático produce la señal de control se denomina acción de control. La figura 6.9 es un diagrama de bloques de un sistema de control industrial que consiste en un controlador automático, un actuador, una planta y un sensor (elemento de medición). El controlador detecta la señal de error, que por lo general, está en un nivel de potencia muy bajo, y la amplifica a un nivel lo suficientemente alto. El sensor o el elemento de medición, es un dispositivo que convierte la variable de salida en otra variable manejable, como un desplazamiento, una presión o un voltaje que pueda usarse para comparar la salida con la señal de entrada de referencia [45].

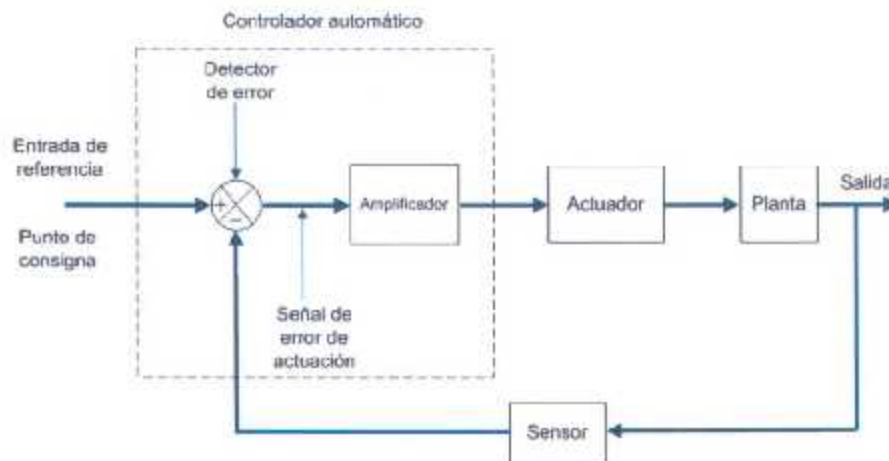


Figura 6.9 Diagrama de bloques de un sistema de control industrial

Clasificación de los controladores. Los controladores industriales se clasifican, de acuerdo con sus acciones de control, como:

1. De dos posiciones o controladores on-off
2. Controladores proporcionales
3. Controladores integrales
4. Controladores proporcionales-integrales
5. Controladores proporcionales-derivativos
6. Controladores proporcionales-integrales-derivativos

Acción de control proporcional.- Para un controlador con acción de control proporcional, la relación entre la salida del controlador $u(t)$ y la señal de error $e(t)$ es:

$$u(t) = K_p e(t) \quad (6.10)$$

Acción de control integral.- es un controlador con acción de control integral, el valor de la salida del controlador $u(t)$ se cambia a una razón proporcional a la señal de error $e(t)$. Es decir:

$$\frac{du(t)}{dt} = K_i e(t) \quad (6.11)$$

o bien

$$u(t) = K_i \int_0^t e(t) dt \quad (6.12)$$

La acción de control proporcional-integral.- Es de control de un controlador proporcional-integral (PI) se define mediante:

$$u(t) = K_p e(t) + \frac{K_p}{T_i} \int_0^t e(t) dt \quad (6.13)$$

donde: $u(t)$ = Salida del controlador, K_p = Ganancia proporcional, $e(t)$ = la señal de error

T_i = tiempo integral

En la figura 6.10 se muestra el cargador de baterías de 3 etapas simulado en MATLAB/Simulink.

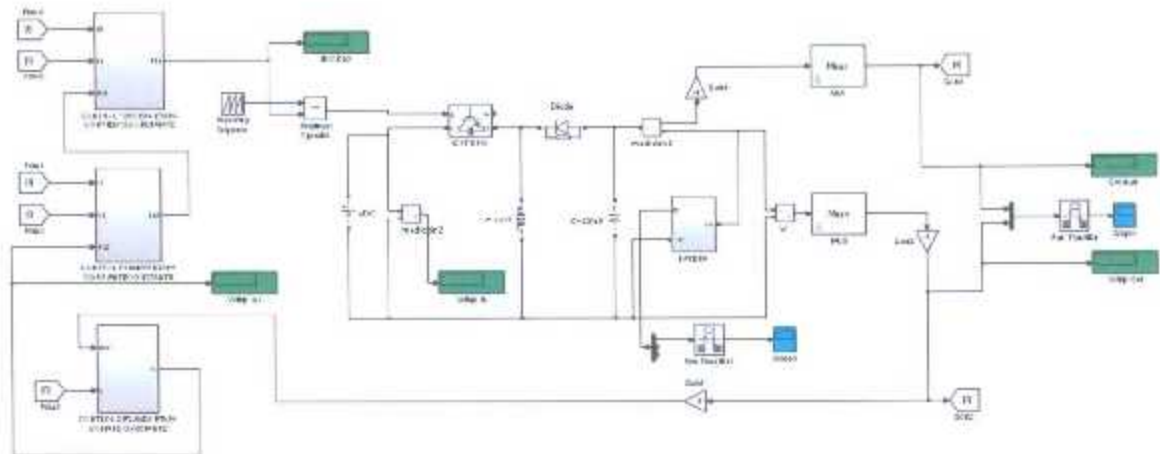


Figura 6.10 Circuito de convertidor reductor-elevador empleado como cargador de 3 etapas

Los parámetros del circuito son:

Fuente de alimentación= 36 vcd

Inductancia=1mH

Capacitancia=330uH

IGBT y diodo de marcha libre

Carga=batería de 36 volts, 225 A-h

Como se mencionó anteriormente el perfil de carga consiste en que al inicio de la carga, se empieza con el método de corriente constante, después, al incrementar el nivel de voltaje al deseado se cambia al método de voltaje constante para lograr que el nivel de corriente disminuya conforme la carga de la batería se va incrementando, hasta lograr un valor deseado de corriente y por ultimo entra el método de corriente constante otra vez para finalizar la carga total de la batería. La ecualización es una sobrecarga llevada a cabo en las

baterías de electrolito líquido luego de que estas se han cargado por completo. Se recomienda la equalización solo cuando las baterías tenga una gravedad específica baja, menor a 1.250, o un rango amplio de valores mayor a 0.030 puntos entre baterías después de haberlas cargado por completo.

En la figura 6.11 se muestran las tres etapas de carga de la batería de ciclo profundo, las cuales consisten en: se inicia la carga con un voltaje de 5.98 V, el cual representa un estado de carga de 40 %. Comienza la carga con la etapa de corriente constante (CC) de 29 A, hasta alcanzar un nivel de voltaje de 7.05 V, cuando se alcanza este nivel de voltaje comienza la segunda etapa de carga la cual es a voltaje constante (VC), hasta que la corriente alcance un valor de 10 A, para que inicie la tercera etapa y última etapa con el método de corriente constante (CC) hasta alcanzar un nivel de voltaje de 8.1 V, que equivale a un 100 % de estado de carga de acuerdo a tablas del fabricante y estos valores de voltaje son obtenidos por el método de voltaje de circuito abierto. Con este último valor de voltaje se completa todo el perfil de carga recomendado según fabricantes en baterías de ácido plomo de ciclo profundo con electrolito líquido.




Figura 6.11 Gráfica de voltaje (rojo) y corriente (verde) de carga de batería con el convertidor reductor-elevador en tres etapas de CC-VC-CC

Un convertidor reductor-elevador empleado como cargador de baterías de tres etapas se diseñó en cada una de las etapas con un lazo cerrado PI (proporcional-integral), dos de corriente y uno de voltaje de acuerdo a cada etapa según el perfil de carga del fabricante para una óptima carga de las baterías de ciclo profundo. El convertidor resultó, según simulaciones, una buena aplicación para cargadores de baterías por su rango amplio de voltaje para diferentes aplicaciones de sistemas de almacenamiento de energía y excelente control de corriente para evitar que la batería sea sobrecargada y así reducir su vida útil por calentamiento interno.

6.6 Simulación de convertidor reductor-elevador con batería y fuente de alimentación de panel fotovoltaico y MPPT.

Para llegar a la simulación del convertidor reductor-elevador con la carga de una batería y con la fuente de alimentación del panel solar, fue un proceso progresivo semana tras semana, en el cual comenzamos simulando las tres principales topologías de los convertidores de CD-CD. Las cuales son el reductor (Buck), el elevador (Boost), y por último el reductor-elevador que fue el que se seleccionó para nuestra aplicación por su amplio rango de niveles de voltaje, ya que puede reducir o elevar el nivel de voltaje de su fuente de alimentación, y con esto se puede aplicar a diferentes sistemas de almacenamiento de energía con variados niveles de voltaje.

En primer lugar la simulación se llevó a cabo con un resistencia de carga, para observar el comportamiento de las variables del circuito, como son la corriente de salida, voltaje de salida, corriente de entrada, corriente de inductor, corriente de capacitor, corriente de IGBT, corriente en el diodo.

Los parámetros del circuito fueron los mismos que se utilizaron para el circuito del convertidor reductor-elevador empleado como cargador. En la figura 6.12 se muestra la gráfica de eficiencia del convertidor con respecto al ciclo de carga. La cual muestra como se va incrementando la eficiencia del convertidor, conforme vamos aumentando el ciclo de

trabajo, empieza baja la eficiencia pero se va recuperando de acuerdo al incremento del ciclo hasta que llega a la máxima eficiencia de salida.




Figura 6.12 Gráfica de Eficiencia vs Ciclo de trabajo de convertidor reductor-elevador

Después se continuó con la simulación del convertidor pero ahora con una batería como carga y una fuente de alimentación de CD, para observar el comportamiento del circuito con esta carga. El circuito se comportó muy bien cargando la batería a niveles de voltaje que necesitábamos. Después, integramos al circuito el modelo de panel fotovoltaico mostrado al principio de este capítulo con los datos de la tabla 6.1, primero simulamos el convertidor reductor-elevador con el panel fotovoltaico y una resistencia de carga, para determinar corrientes y voltaje de panel fotovoltaico y carga. Obteniendo una buena respuesta del circuito.

A continuación se le integro al sistema el modelo de MPPT mostrado anteriormente en figura 6.8, se le obtuvo la gráfica P-V al convertidor reductor-elevador con MPPT y con el panel fotovoltaico como se muestra en la figura 6.13. Con tres diferentes niveles de irradiación, demostrando el buen funcionamiento de todo el sistema panel fotovoltaico, convertidor reductor-elevador y MPPT, cabe mencionar que fue con una carga resistiva la simulación para graficar la curva P-V.




Figura 6.13 Gráfica de convertidor reductor-elevador con panel fotovoltaico y MPPT con tres irradiancias diferentes

A continuación se muestra en la figura 6.14 el circuito completo de simulación del convertidor reductor-elevador con fuente de alimentación panel fotovoltaico y MPPT empleado como cargador para cargar una batería de ácido-plomo de 6 V, 70 Ah.




Figura 6.14 Diagrama de bloques de circuito de convertidor reductor-elevador con panel fotovoltaico y MPPT empleado como cargador de baterías

Se simuló el circuito del convertidor reductor-elevador con panel fotovoltaico y MPPT con una batería de 6 V. a 70 Ah para lograr la carga de la batería por el nivel de Amperaje que maneja el circuito del convertidor. Que es de 9.5 A. la gráfica de la parte de abajo muestra el comportamiento de la corriente y voltaje de carga en la batería.




Figura 6.15 Gráfica de corriente de carga en batería de circuito de convertidor reductor-elevador con panel fotovoltaico y MPPT




Figura 6.16 Gráfica de voltaje de carga en batería de circuito de convertidor reductor-elevador con panel fotovoltaico y MPPT

La simulación se inició con un estado de carga de un 40 % que es equivalente a 5.98 V. de acuerdo a tablas del fabricante para determinar el estado de carga según su voltaje de circuito abierto. Y se cargó la batería hasta un nivel de voltaje de 8.1 V. como marca la gráfica de carga de batería para un valor estimado de carga en circuito abierto de 100 %.

6.7 Implementación de convertidor reductor-elevador

En esta sección se presenta la implementación del convertidor reductor-elevador con MPPT y la carga de la batería, el convertidor fue construido con el diseño de la bobina que mencionamos anteriormente en la sección 6.4 con un valor de 1.1 mH, el capacitor fue un tipo polarizado electrolito de 330 μF , el diodo de marcha libre fue del tipo 150EBU04, un IGBT tipo G4PC30KD, el panel fotovoltaico utilizado como fuente de alimentación fue el mostrado en la figura 6.5 y con los datos de tabla 6.2, el control para la implementación del MPPT fue a través de un DsPIC 30F3011, además de un IR2121, y un LM324 dentro de la etapa de control del convertidor mostrada en la figura 6.15 y la etapa de potencia se muestra en la figura 6.16.




Figura 6.17 Etapa de control implementada en convertidor reductor-elevador




Figura 6.18 Etapa de potencia implementada en convertidor reductor-elevador

Las pruebas de carga del convertidor fueron realizadas primeramente en lazo abierto como carga una resistencia de 5.5 ohm, se probaron IGBT's con diodo y sin diodo para determinar la mejor eficiencia del convertidor como se muestra en la figura 6.17, y gráfica de eficiencia contra corriente de salida como se muestra en la figura 6.18. Además de otras más pruebas de corriente en inductancia contra eficiencia, se probó el convertidor con varios valores de inductancia para ver su funcionamiento. Sin embargo, se llegó a la conclusión de que los valores antes mencionados eran los de mejor desempeño para el convertidor reductor-elevador en la aplicación de cargador de baterías de ciclo profundo.




Figura 6.19 Gráficas de eficiencia vs corriente de carga y corriente de IGBT con interruptor IGBT con diodo y sin diodo.




Figura 6.20 Gráficas de eficiencia vs corriente de carga de convertidor reductor-elevador implementado

6.8 Prueba de carga de batería con convertidor reductor-elevador con modulo fotovoltaico y MPPT.

Se realizó la carga de una batería de 6 V., 225 Ah de las que utiliza el carro eléctrico de taller de potencia, para probar el convertidor como cargador. La prueba se empezó a las 10: a.m. y se terminó a las 5:30 p.m. se empezó con un estado de carga de la batería de un 80% equivalente a 6.25 volts. Se inició la prueba con una corriente de 9.8 A. y se incrementó el nivel de voltaje a 7.1 V. después, la corriente se mantuvo en un nivel de 9 hasta las 12:30 p.m. y el voltaje llegó a 7.75 V. Después de esa hora la corriente se mantuvo constante en 8.5 A. hasta las 5:10 p.m. que bajo a 6 A. ya a las 5:30 p.m. la corriente estaba en 2 A. el nivel de voltaje llegó en el nivel más alto a 8 V. que de acuerdo a fabricantes de baterías, una batería de 6 V. al 100% de carga debería de llegar en modo carga a 8.1 V. al terminar la carga de la batería por falta de potencia en las celdas el voltaje en batería se quedó en 7.02 V. se determinó cargar la batería con ese nivel de estado de carga por el hecho que prácticamente íbamos a empezar la carga de la batería en la última etapa de carga que es la de corriente constante con alrededor de 8 A. ya que el panel fotovoltaico no entrega más de 9 A. y la corriente es constante por el tipo de control que es el MPPT, obteniendo la

máxima potencia del panel solar. Cabe mencionar que durante la carga de la batería hubo bajas de corriente en la carga por efecto de las nubes que bajaban la potencia del panel fotovoltaico. En las figuras 6.19 y 6.20 se muestran corriente de batería, voltaje de batería.



Figura 6.21 Corriente de batería en modo carga con convertidor reductor-elevador, panel fotovoltaico y MPPT



Figura 6.22 Voltaje de batería en modo carga con convertidor reductor-elevador, panel fotovoltaico y MPPT

6.9 Simulación de algoritmo de estimador de estado de carga con datos de descarga de batería.

Se tomaron los datos de descarga de una batería de 6 V. y un banco de resistencia como carga para obtener una corriente de 7.5 A. al principio y después se incrementó la corriente de descarga a 12.5 A. la prueba se inició con un voltaje de batería de 6.357 V. equivalente a 98 % de estado de carga la prueba de descarga tuvo una duración de 6 horas, quedando el nivel de voltaje de la batería en 5.97 V. equivalente a 42 % de estado de carga. La prueba se realizó de la siguiente manera; se conectaba la carga a la batería por un tiempo de 10 minutos transcurrido ese tiempo se desconectaba la carga, se esperaba 50 segundos para dejar pasar el régimen de descarga de la batería y se estabilizara el voltaje, entonces se tomaba la lectura de voltaje de circuito abierto en la batería y se anotaba el registro y así sucesivamente las 6 horas transcurridas. El nivel de voltaje alcanzado de 5.97 V. fue un estado de carga prudente para no descargar tanto la batería y así no sobre descargarla y afectar su vida útil. Con los datos obtenidos de voltaje, corriente, temperatura y tiempo como entradas a la red neuronal y como salida el voltaje interno de la batería pero ya convertido a porciento con la fórmula que relaciona el voltaje de circuito abierto y el estado de carga de la batería de plomo-acido obtenida de formula (6.14).

$$V_{oc}(t) = a_1 S(t) + a_0$$

$$S(t) = \frac{V_{oc}(t) - a_0}{a_1} \quad (6.14)$$

donde $S(t)$ es el estado de carga de la batería SOC (%), a_0 es el voltaje en terminales de la batería cuando $S(t) = 0\%$, y a_1 se obtiene de conocer el valor de a_0 y V_{oc} cuando $S(t) = 100\%$. La estimación del estado de carga es equivalente a la estimación de su voltaje de circuito abierto [46]. En la siguiente figura 6.21, se muestra una comparativa entre el estado de carga y el voltaje de circuito abierto con datos obtenidos tablas del fabricante y la obtención del SOC con la ecuación (6.14), esto para darle mayor validez a la ecuación.




Figura 6.23 Gráfica comparativa de SOC vs V_{OC} entre datos de tabla de fabricante y ecuación

6.9.1 Simulación de la red neuronal de retroalimentación con 4 entradas datos de descarga

Una vez que se tienen estos 4 datos de entrada (temperatura, corriente, voltaje, y tiempo) y 1 dato de salida (porcentaje de estado de carga) obtenidos. La red tiene 1 capa oculta con 4 neuronas y 1 capa de salida con 1 neurona. Se procedió a ingresar los datos a la red neuronal arrojándonos los siguientes resultados como se muestra en las siguientes figuras.




Figura 6.24 Arquitectura de la red neuronal del estimador del estado de carga con 4 entradas




Figura 6.25 Gráfica de desempeño del estimador de estado de carga

En la gráfica 6.25 se muestra el desempeño del estimador, el error cuadrático medio evalúa la diferencia entre el estimador y el valor real de la cantidad que se quiere calcular, el MSE mide el promedio del cuadrado del error, siendo el error el valor en la que el estimador difiere de la cantidad a ser estimada. Podemos ver en la gráfica como el error es muy pequeño en el valor de 0.0080 en 42 épocas. En la siguiente figura 6.24 se muestra el comportamiento de la regresión, que no es más que la manera de encontrar la relación entre dos o más variables. Es decir, se utiliza para predecir una medida basándose en el conocimiento de otra.

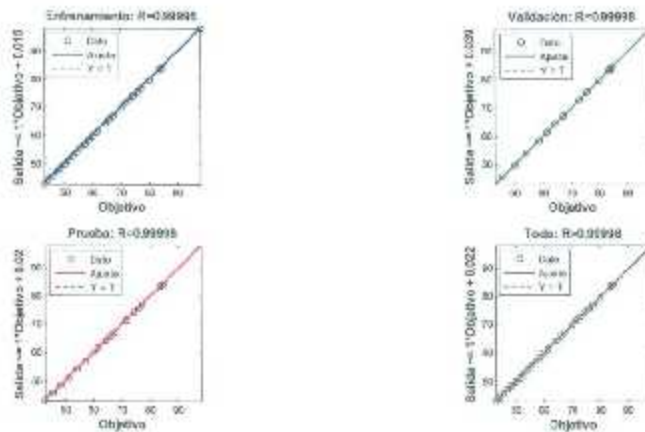


Figura 6.26 Gráfica de Regresión del entrenamiento de la red neuronal

En la gráfica de la figura 6.25 se muestra el comportamiento de la salida del estimador con respecto a los objetivos señalados en la red neuronal de retropropagación, se puede apreciar la precisión del algoritmo, como los valores del estimador son casi iguales entre las salida y los objetivos que se le trazaron al algoritmo de la red neuronal, para que alcanzara después del entrenamiento.




Figura 6.27 Gráfica de aproximación de salidas con respecto a objetivos de red neuronal

6.9.2 Simulación de la red neuronal de retroalimentación con 3 entradas datos de descarga

También se entrenó la red neuronal con 3 datos de entrada que fueron: Temperatura, corriente, y voltaje en terminales y 1 datos de salida (porcentaje de carga). A continuación se muestra en las siguientes figuras 6.26 y 6.27 la arquitectura de la red neuronal con 3 entradas y la gráfica del mejor desempeño de la validación del estimador del estado de carga.




Figura 6.28 Arquitectura de la red neuronal del estimador con 3 entradas




Figura 6.29 Gráfica de desempeño del estimador de estado de carga

Se puede apreciar en la gráfica anterior que el error es muy pequeño de un valor de 0.032 en 70 épocas.




Figura 6.30 Gráfica de Regresión del entrenamiento de la red neuronal

En la gráfica 6.30 podemos ver el comportamiento de la regresión del estimador, se aprecia muy bien el ajuste correcto entre las variables.




Figura 6.31 Gráfica de aproximación de salidas con respecto a objetivos de red neuronal

6.10 Simulación de algoritmo de estimador de estado de carga con datos de carga de batería.

Se cargó una batería de 6 V, 225 Ah, que se inició con un estado de carga de 20%, es decir, 5.83 V, con un rectificador trifásico y el Variac y siguiendo el perfil de carga del fabricante. El procedimiento que seguimos fue el siguiente, aprox. cada media hora se detenía la carga de la batería y se dejaba estabilizar el voltaje por 3 minutos y a continuación se le media el voltaje de circuito abierto a la batería, después, se continuaba cargando hasta que obtuviéramos un estado de carga de 100 % en circuito abierto. Se hicieron mediciones de corriente, voltaje de circuito abierto y temperatura de batería para los datos para la red neuronal en la figura 6.30 se muestra la tabla de valores obtenidos de la carga de la batería.

TIEMPO (min)	VOC BATERIA (V)	CORRIENTE BATERIA (A)	TEMPERATURA BATERIA (°C)	PORCENTO DE CARGA (%)
08:30:00 a. m.	5.83	29.00	21.10	22.86
09:00:00 a. m.	6.08	29.00	22.30	58.57
09:30:00 a. m.	6.10	20.00	22.70	61.43
10:00:00 a. m.	6.13	20.00	23.10	65.71
10:30:00 a. m.	6.15	19.90	23.10	68.57
11:00:00 a. m.	6.19	18.50	23.40	74.29
11:30:00 a. m.	6.21	17.00	23.60	77.14
12:00:00 p. m.	6.24	17.70	24.30	81.43
12:30:00 p. m.	6.26	16.00	24.30	84.29
01:00:00 p. m.	6.28	15.90	24.40	87.14
01:30:00 p. m.	6.31	14.40	24.60	91.43
02:00:00 p. m.	6.32	13.50	24.80	92.86
02:30:00 p. m.	6.33	13.10	24.90	94.29
03:00:00 p. m.	6.34	13.50	25.10	95.71
03:30:00 p. m.	6.35	12.20	25.10	97.14
04:00:00 p. m.	6.36	11.30	25.30	98.57
04:30:00 p. m.	6.37	9.80	25.40	100.00

Figura 6.32 Tabla de datos obtenidos de procedimiento de carga de batería de 6 V.

Estos datos se ingresaron a la red neuronal en MATLAB para el entrenamiento de la misma, también se simuló con 3 y 4 entradas que a continuación se presentan a continuación.

6.10.1 Simulación de la red neuronal de retroalimentación con 4 entradas de datos de carga

Como en la simulación de los datos de descarga las variables de entrada fueron la temperatura, el voltaje de circuito abierto, la corriente, y el tiempo. Y la salida el porcentaje de estado de carga obtenido de la ecuación (6.14). Del procedimiento del estimador de voltaje de circuito abierto. Primero se muestra en la figura 6.31 la arquitectura de la red neuronal.




Figura 6.33 Arquitectura de la red neuronal con 4 entradas para los datos de carga




Figura 6.34 Gráfica de desempeño del estimador de estado de carga

En la figura anterior podemos ver el resultado del entrenamiento de la red, como el error es muy pequeño de 0.013 en 70 iteraciones, a continuación se muestra la gráfica de regresión de los datos de carga y su comportamiento.




Figura 6.35 Gráfica de regresión del entrenamiento de la red neuronal




Figura 6.36 Gráfica de aproximación de salidas con respecto a objetivos de red neuronal

En la figura anterior podemos apreciar el buen comportamiento entre la salida y los objetivos en la red neuronal, es decir, el buen funcionamiento del estimador de estado de carga, ya que nos da una aproximación muy buena en la salida.

6.10.2 Simulación de la red neuronal de retroalimentación con 3 entradas de datos de carga

También se entrenó la red neuronal con 3 datos de entrada que fueron: Temperatura, corriente, y voltaje en terminales y 1 datos de salida (porciento de carga), obtenido a través de la ecuación (6.14) del método de voltaje de circuito abierto. A continuación se muestra en las siguientes figuras. La arquitectura de la red neuronal con 3 entradas y la gráfica del mejor desempeño de la validación del estimador del estado de carga, la regresión y las salidas con respecto a los objetivos.




Figura 6.37 Arquitectura de la red neuronal con 3 entradas




Figura 6.38 Gráfica de desempeño del estimador de estado de carga

En la figura anterior podemos ver el resultado del entrenamiento de la red, como el error es de 0.029 en 40 épocas prácticamente cero el valor del error, a continuación se muestra la gráfica de regresión de los datos de carga y su comportamiento con 3 entradas.




Figura 6.39 Gráfica de regresión del entrenamiento de la red neuronal




Figura 6.40 Gráfica de aproximación de salidas con respecto a objetivos de red neuronal

Podemos ver en la figura anterior, como el ajuste entre las dos curvas tiene una muy buena aproximación y con esto comprobamos el buen funcionamiento de la red neuronal con 3 entradas, para determinar como adecuado el estimador de estado de carga

Capítulo 7

Conclusiones

7.1 Conclusiones

Las baterías juegan un papel muy importante como fuentes de alimentación de la tecnología moderna, desde bienes de consumo hasta vehículos eléctricos y sistemas de energía renovable. Es importante que la batería sea confiable y capaz de suministrar potencia y energía cuando se requiere. La determinación del estado de carga (SOC) es una cuestión cada vez más importante en las tecnologías de las baterías, en términos de tanto extender la vida de la batería y la visualización de lo utilizable. Una determinación exacta del SOC nos permite administrar la batería a su potencial óptimo. Estados extremadamente alto o bajos del SOC pueden conducir a un daño irreversible en la batería. En esta sección se presentan las conclusiones del trabajo presentado en capítulos anteriores.

En este trabajo se presentó el diseño y simulación de un cargador de baterías de 3 etapas con una configuración de convertidor de cd-cd, tipo reductor-elevador. El cual fue construido con 3 sistemas de control de lazo cerrado tipo PI para cada etapa de carga y fue simulado en Simulink/MATLAB con una batería de plomo-acido como carga obteniendo buenos resultados en el sentido de elevación de voltaje de batería. El modelo se quedó en simulación debido a la corriente que necesitan las baterías con las que contamos aquí en el laboratorio de potencia, las cuales en su perfil de carga inician con una corriente de 29 A, siendo muy difícil obtener ese nivel de corriente de la fuente de alimentación que en nuestro caso sería un panel fotovoltaico.

También se diseñó, simuló e implementó un cargador de baterías a partir de la topología del convertidor de cd-cd tipo reductor-elevador con una fuente de alimentación de un panel fotovoltaico y un sistema de control MPPT. Se hicieron pruebas satisfactorias de corriente y voltaje con resistencia de carga y después con batería de ciclo profundo. La única limitante del diseño fue la corriente del convertidor ya que fue diseñado para una corriente de 9 A, y por consiguiente el diseño quedó limitado para utilizarlo en la carga de la batería de 6 V, 225 Ah, por el nivel de corriente que maneja en la primera etapa de perfil de carga

de acuerdo a fabricantes. Otro inconveniente sería que el suministro de corriente sería constante, es decir, con una sola etapa de carga.

Como resultado de esta tesis se obtuvo una red neuronal que permite estimar el estado de carga de una batería de plomo ácido marca Trojan de 6 V. 225 Ah. La red neuronal fue entrenada utilizando datos proporcionados por la carga de la batería, a través de un rectificador trifásico y un Variac. Los datos de entrada a la red fueron: temperatura, corriente de batería y voltaje de circuito abierto, y el tiempo. Para los datos de descarga se utilizó una resistencia de carga y se tomaron valores de voltaje, corriente, y temperatura de batería cada cierto tiempo.

La topología feedforward y el algoritmo de entrenamiento de retropropagación seleccionados para el desarrollo de la red neuronal resultó ser muy conveniente ya que fue muy eficiente para el entrenamiento y simulación de la red neuronal. Esta topología es muy eficiente en MATLAB para el diseño de redes neuronales.

Por tratarse de una red neuronal supervisada los objetivos de la red fueron determinados a partir del método de voltaje de circuito abierto, para el entrenamiento de la red y así lograr la mejor aproximación entre los objetivos trazados y la salida de estimador.

7.2 Trabajos futuros

El estado de carga (SOC) mide la energía que queda en la batería, y este es crítico para el modelado y el desempeño de las baterías, desarrollar algoritmos preciso permanece siendo un problema desafiante. Entre los trabajos futuros serían:

- Probar el algoritmo del estimador de estado de carga con las mismas entradas, pero los objetivos con otro método de estimación para determinar la exactitud de la red neuronal.
- Profundizar más en el estudio de las redes neuronales para la implementación en aplicaciones futuras.
- Implementación del algoritmo del estimador de estado de carga en dsPIC para la estimación del estado de carga.

- En lo que concierne al convertidor de CD-CD empleado como cargador de baterías de tres etapas, sería la implementación del modelo en una micro red para que nos pueda sustentar la corriente necesaria para cargar las baterías de 225 Ah, de acuerdo al perfil de carga del fabricante.
- En lo referente al prototipo del convertidor reductor-elevador empleado como cargador de baterías con alimentación del panel fotovoltaico y control MPPT. Sería Diseñar e implementar un convertidor que soporte una corriente mayor para la carga de la batería de acuerdo a la capacidad de la misma y evaluar el costo de la vida útil de la batería al ser cargada por una corriente constante del cargador y no seguir el perfil de carga recomendado por el fabricante y el costo del ahorro de energía al obtener la mayor potencia del panel fotovoltaico por acción del MPPT.

Referencias

- [1] Lezhang Liu, Le Y. Wang, Caisheng Wang, Feng Lin, Hongbin Wang, "Integrated system identification and state of charge estimation of battery systems", IEEE Transactions on Energy Conversion, Vol. 28, No. 1, pp. 12-23, March 2013.
- [2] W. Guoliang, L. Rengui, Z. Chunbo, C. C. Chan, "State of charge estimation for NiMH battery based on electromotive force method", presented at the Vehicle Power and Propulsion Conference, Harbin, China, Sept 2008.
- [3] S. Santhanagopalan, R. E. White, "State of charge estimation for electrical vehicle batteries", presented at the 17th International Conference on control applications, San Antonio, Texas, USA, Sept 2008.
- [4] Wen-Yeau Chang, "The state of charge estimating methods for battery: a review", ISRN Applied Mathematics, Volume 2013 (2013), Article ID 953792, p.p.1-7.
- [5] Miguel A. Cristin Valdez, Jaime A. Orozco Valera, Ma. Jojutla O. Pacheco Arteaga, "Estimating SOC in lead-acid batteries using neural network in a microcontroller-based charge-controller", 2006 International joint conference on neural networks, july 16-21, 2006.
- [6] R. M. Dell y D. A. Rand, "Understanding batteries", Cambridge, Royal society of chemistry, 2001.
- [7] Juan Carlos Viera Pérez, Tesis "Carga Rápida de Baterías de Ni-Cd y Ni-MH de Media y Gran Capacidad. Análisis, Síntesis y Comparación de Nuevos Métodos", Universidad de Oviedo, España, 2003.
- [8] B. Severino, «Modelación de un sistema fotovoltaico y un banco de baterías de plomo ácido como elementos de una micro-red,» Memoria de título para optar al grado de ingeniero civil electricista, Universidad de Chile, Santiago, Chile, 2011.
- [9] O. A. Petri, B. B. Damaskin, "Fundamentos de la electroquímica teórica". Editorial MIR. 1981.

- [10] Boris Tsenter, Menahem Anderman, "Common vessel monoblock design for sealed nickel-cadmium batteries", *Journal of Power Sources*, 1996.
- [11] D. Berndt. John Wiley & Sons Inc., "Maintenance-free batteries". Second edition. 1997.
- [12] Robert Rynkiewicz, "Discharge and charge modeling of lead acid batteries", *APEC'99*, 1999.
- [13] David Linden and Thomas B. Reddy. McGraw-Hill Handbooks, *Handbook of batteries*". Third edition. 2002.
- [14] H. Rashid, Muhammad. "Electrónica de Potencia, circuitos, dispositivos y aplicaciones", 3^a ed., Prentice Hall., 2004.
- [15] Daniel U. Campos-Delgado "Experimentos en Teoría de Control: Convertidores CD-CD", Facultad de Ciencias (UASLP),
- [16] Robert W. Erickson, "DC-DC Power Converters", *Wiley Encyclopedia of Electrical and Electronics Engineering*.
- [17] José Luis Gamboa Quesada, "Guía de Diseño y Análisis de Convertidores Conmutados de Alta Frecuencia", Universidad de Costa Rica, Facultad de Ingeniería Eléctrica, 2008.
- [18] S. Haykin, *Neural Networks a Comprehensive Foundation*, Second Edition, Pearson, 1999, ISBN 81-7808-300-0.
- [19] The Mathworks, "MATLAB. Neural Networks Toolbox".
- [20] Piller S., Perrin M., Jossen A., "Methods for State-of-Charge Determination and Their Applications", *J. of Power Sources*, Vol.96, 2001, p.p.113-120.
- [21] Wu G, Lu R., Zhu Ch, C.C. Chan, "State of Charge Estimation for NiMH Battery Based on Electromotive Force Method", *IEEE Vehicle Power and Propulsion Conference (VPPC)*, September 3-5, 2008, Harbin, China.

- [22] Mohammad Ch., Mohammad F., "State of Charge Estimation for Lithium-Ion Batteries using Neural Networks and EKF", *IEEE Transactions on Industrial Electronics*, vol. 57, No. 12, December 2010
- [23] Junping W., Binggang C., Quanshi Ch., Feng W., "Combined state of charge estimator for electric vehicle battery pack", *Control Engineering Practice* 15 (2007), p.p. 1569–1576.
- [24] Shu P., Jay F., Jie D., Matthew B., "Battery State-of-Charge Estimation", *Proceedings of the American Control Conference*, Arlington, VA June 25-27, 2001.
- [25] Yinjiao X., Eden W.M., Kwok L., Michael P., "Battery Management Systems in Electric and Hybrid Vehicles", *Energies* 2011, 4, p.p.1840-1857; doi:10.3390/en4111840.
- [26] Ehret C., Piller S., Schroer W. and Jossen A., "State-of-Charge determination for lead acid batteries in PV-applications", in *Procs. 16th European Photovoltaic Solar Energy Conference*, Glasgow, May 2000, p.p. 2486-2489.
- [27] Salkind A., Fennie C., Singh P., Atwater T. and Reisner D., "Determination of state-of-charge and state-of-health of batteries by fuzzy logic methodology", *J. of Power Sources*, Vol.80, 1999, p.p. 293-300.
- [28] Wagner R., Sauer D., "Charge strategies for valve-regulated lead/acid batteries in solar Power applications", *J. of Power Sources*, Vol.95, 2001, p.p. 141-152.
- [29] F. Huet, "A review of impedance measurement for determination of the state of charge or state of health of secondary batteries", *journal of power sources* 70 (1998) p.p. 59-69.
- [30] Wen-Yeou Chang, "The State of Charge Estimation Methods for Battery: A Review", *ISRN Applied Mathematics*, Volume 2013, Article ID 953792, p.p.1-7.
- [31] K. Ding, X. Bian, H. Liu, T. Peng, "A MATLAB-Simulink-Based PV Module Model and Its Application Under conditions of Nonuniform Irradiance", *Energy Conversion, IEEE Transactions*, Vol.27, Issue:4, 2012, p.p. 864-872.

- [32] de Brito, M.A.G., Galotto, L., Sampaio, L.P., de Azevedo e Melo, G., Canesian, C.A. " Evaluation of the Main MPPT Techniques for Photovoltaic Applications", *Industrial Electronics, IEEE Transactions*, Vol.60, Issue:3, 2013, p.p. 1156-1167.
- [33] Karabanov, S., Kukhmistrov, Y., Miedzinski, B., Okraszewski, Z. " Photovoltaic Systems", *Modern electric Power Systems, Proceeding of the International Symposium*, 2010, p.p. 1-5.
- [34] Villalva, M.G., Gazoli, J.R., Filho, E.R. "Comprehensive Approach to Modeling and Simulation of Photovoltaic Arrays", *Power Electronics, IEEE Transactions*, Vol. 24, Issue: 5, 2009, p.p. 1198-1208.
- [35] Pandiarajan, N., Muthu, R. "Mathematical modeling of photovoltaic module with Simulink", *Electrical energy Systems (ICEES)*, 2011, p.p. 258-263.
- [36] Manju, B.S., Ramaprabha, R., Mathur, B.L., "Modelling and control of standalone solar photovoltaic charging system", *Emerging Trends in electrical and Computer Technology (ICETECT)*, 2011, p.p. 78-81.
- [37] Wang P., Ding H., Diao Ch., Qi S., "An improved MPPT algorithm based on traditional incremental conductance method", *Power Electronics Systems and Applications*, 2011, p.p. 1-4.
- [38] F. A. Ramírez "Controladores Electrónicos Basados en Espacios Vectoriales PWM para Sistemas Fotovoltaicos y Eólicos", *Tesis de Maestría, Instituto Tecnológico de la Laguna, Torreón Coah*, 2010.
- [39] M.G. Molina, P.E. Mercado, P.E. Wierncs, "Análisis y simulación de algoritmos de Control para el Seguimiento del Punto de Máxima Potencia de sistemas Solares Fotovoltaicos Conectados a la Red eléctrica", *avances en energías renovables y medio ambiente*, Vol.11, 2007.
- [40] Safari, A., Mekhilef, S., "Simulation and hardware implementation of incremental conductance MPPT with direct control method using cuk converter", *Industrial electronics*, Vol.58, 2011, p.p. 1154-1161.

- [41] Luis Sánchez Pérez, "Núcleos toroidales", EA4-NH, Aparado 421, Toledo.
- [42] A. A.-H. Hussain and I. Batarseh, "A review of charging algorithms for nickel and lithium battery chargers," *IEEE Trans. Veh. Technol.*, vol. 60, no. 3, p.p. 830-838, Mar.2011.
- [43] A. A.-H. Hussain and I. Batarseh, "A study of control of lead-acid battery for electric vehicles," in *Proc. IEEE ISIE, 2000*, vol. 1, p.p. 135-140.
- [44] F. J. Lin, M. S. Huang, P.Y. Yeh, H. Ch. Tsai, Ch. H. Kuan, "DSP-Based Probabilistic Fuzzy Neural Network control for Li-ion battery charger," *IEEE Trans. Power Electronics* 2012, vol. 27, p.p. 3782-3794.
- [45] Katsuhiko Ogata, *Ingeniería de control moderna*, 5ª edición, Ribera del Loira, 28042 Madrid España, PEARSON, 2010.
- [46] Chiasson J., Vairamohan B., "Estimating the state of charge of a battery", *IEEE Transactions, Control systems Technology*, Vol. 13, Issue 3, mayo 2005 p.p. 465-470.