



**INSTITUTO LATINO-AMERICANO DE
TECNOLOGIA, INFRAESTRUTURA E
TERRITORIO (ILATIT)**

INGENIERIA DE ENERGIA

APLICACIÓN DE REDES NEURONALES EN CONTROLADORES DE BATERÍAS

Norah Nadia Sánchez Torres

Foz de Iguazú
2019



**INSTITUTO LATINO-AMERICANO DE
TECNOLOGIA, INFRAESTRUTURA E
TERRITORIO (ILATIT)**

INGENIERIA DE ENERGIA

APLICACIÓN DE REDES NEURONALES EN CONTROLADORES DE BATERÍAS

Norah Nadia Sánchez Torres

Trabajo de final de Curso presentado al Instituto Latino-Americano de Tecnología, Infraestructura y Territorio de la Universidad Federal de Integración Latinoamericana, como requisito para obtener el título de Bachiller en Ingeniería de Energías.

Orientador: Dr. Jorge Javier Gimenez Ledesma

Coorientador: Dr. Oswaldo Hideo Ando Junior

Foz de Iguazú
2019

NORAH NADIA SANCHEZ TORRES

APLICACIÓN DE REDES NEURONALES EN CONTROLADORES DE BATERÍAS

Trabajo de final de Curso presentado al Instituto Latino-Americano de Tecnología, Infraestructura y Territorio de la Universidad Federal de Integración Latinoamericana, como requisito para obtener el título de Bachiller en Ingeniería de Energías.

BANCA EXAMINADORA

Orientador: Prof. Dr. Jorge Javier Gimenez Ledesma
UNILA

Orientador: Prof. Dr. Oswaldo Hideo Ando Junior
UNILA

Ing. Dr. Helton Fernando Scherer
(FPTI)

Prof. Ms. Larissa Andreia Wagner Machado
UNILA

Prof. Dr. José Ricardo Cezar Salgado
UNILA

Foz de Iguazú, ____ de _____ del ____.

Dedico este trabajo a los que dieron todo por mí y me dejaron antes de tiempo.

AGRADECIMIENTO

A mi orientador y coorientador por su paciencia, comprensión, calidez, cariño, incentivo, por su lectura cuidadosa y sus excelentes aportes para el desarrollo de este trabajo y a lo largo de este ciclo universitario.

A todas aquellas personas que me acompañaron en este arduo camino pero que por circunstancias de la vida se adelantaron, mi madre, mis abuelos, por su esfuerzo, confianza, dedicación, apoyo incondicional en cada proyecto y por ser mi fuente de inspiración.

A mi padre y hermana, por sus consejos, su fortaleza, por ser mis pilares para seguir cada día.

A mi madre adoptiva Tania, por sus consejos, por no dejarme caer nunca, por guiarme, por acompañarme en cada alegría y cada fracaso.

A mi familia, por su apoyo, por incentivar me a realizar mis sueños.

A Karen, por su cariño, compañía y apoyo incondicional.

A mis amigos, Nayda, Silvana, Ana, Leticia, Carolina, Sebastián, Lorena, Isnel, Glenda, Marialejandra, por compartir conmigo cada paso y por su constante apoyo en este proceso.

A mis compatriotas Yoseline, Elvis, Vilma, Javier por su compañía en el inicio de este gran sueño fuera de casa.

A los jotitas, por el apoyo desde el inicio de este gran sueño.

A la familia Ferreiras y a la familia Hell's Dogs Motorcycle, por la oportunidad laboral a pesar de ser extranjera y unilera, por su ayuda y su comprensión en el final de este proyecto.

A los profesores y profesoras del curso de Ingeniería de energías, por las enriquecedoras discusiones, por enseñarnos que nada es imposible en este camino, por su esfuerzo y dedicación en hacer de nosotros excelentes profesionales.

Al Parque Tecnológico de Itaipu, en especial el proyecto de baterías por la oportunidad de trabajar con ellos.

Al Ingeniero Helton Fernando Scherer, por su comprensión en las prácticas, paciencia, por su disponibilidad para evaluar mi trabajo, por sus acertados aportes y sugerencias para la finalización de este trabajo de investigación.

A la Universidad Federal de Integración Latinoamericana, por la oportunidad de continuar mi formación y la oportunidad de vivir momentos inolvidables.

Finalmente a todas las personas que se cruzaron en este camino y que me dieron palabras de aliento, enseñándome a entender la diversidad de nuestro territorio latinoamericano.

*Hay alguien especial para cada uno de nosotros. A menudo, nos están destinados dos, tres o hasta cuatro seres. **Bryan Weiss***

SÁNCHEZ TORRES, Norah Nadia. APLICACIÓN DE REDES NEURONALES EN CONTROLADORES DE BATERÍAS. 2019. Número de Páginas: 60. Documento de Conclusión de Curso de Ingeniería de Energías – Universidad Federal de Integración Latinoamericana, Foz do Iguazú, 2019.

RESUMEN

El presente estudio tiene como objetivo aplicar el uso de redes neuronales artificiales, que tiene como una de sus aplicaciones operar como un aproximador universal de funciones, mapeando la relación funcional entre las variables de un sistema a partir de un conjunto conocido de valores muestreados. En este contexto, este trabajo aborda un método para predecir el estado de carga de las baterías utilizando técnicas de redes neuronales artificiales a través de una base de datos y modelos de la curva de carga de las baterías de cloruro de sodio y níquel; y así analizar el comportamiento del sistema de gestión de baterías, a través de los modelos encontrados en las curvas de salida. Así este estudio en principio presenta una breve introducción del mercado de energía, seguido de la justificativa y motivación que llevaron a desarrollar el mismo. En seguida, se presenta la metodología empleada, en el software MATLAB, paso a paso para la obtención de las curvas de carga. Seguido de una breve descripción de los sistemas de almacenamiento de energía, baterías. Continuando con una descripción del sistema de gerenciamiento de baterías, funcionalidades y aplicaciones. Y por fin, una descripción de redes neuronales, clasificación arquitectura y aplicaciones en ingeniería; que, para el caso, el método propuestos utiliza una red neuronal artificial Perceptron multicapa, una arquitectura de avance (*feedforward*) con algoritmo de entrenamiento de retropropagación. Con todo esto, finalmente, los resultados indican la capacidad del método para indicar el estado de carga de la batería, así como el análisis de los errores estipulados. Concluyendo que, la configuración utilizada tiene un mejor rendimiento al ajustar el número de capas, y puede ser aplicado en otras baterías, como es el caso de la batería de litio; con los errores y percances encontrados a lo largo de este estudio se presenta algunos trabajos a futuro.

Palabras claves: Estado de carga, redes neuronales artificiales, funcionalidad.

SÁNCHEZ TORRES, Norah Nadia. APPLICATION OF NEURONAL NETWORKS IN BATTERY CONTROLLERS. 2019. Number of pages: 60. Conclusion Paper on Energy Engineering - Federal University of Latin American Integration, Foz do Iguazú, 2019.

ABSTRACT

The present study aims to apply the use of artificial neural networks, which has as one of its applications to operate as a universal approximator of functions, mapping the functional relationship between the variables of a system from a known set of sampled values. In this context, this work addresses a method to predict the state of charge of batteries using artificial neural network techniques through a database and models of the charge curve of batteries of sodium chloride and nickel; and thus analyze the behavior of the battery management system, through the models found in the output curves. Thus, this study in principle presents a brief introduction to the energy market, followed by the justification and motivation that led to its development. Next, the methodology used is presented, in the MATLAB software, step by step to obtain the load curves. Followed by a brief description of the energy storage systems, batteries. Continuing with a description of the battery management system, features and applications. And finally, a description of neural networks, architectural classification and applications in engineering; that, for that matter, the proposed method uses a multilayer Perceptron artificial neural network, a feedforward architecture with backpropagation training algorithm. With all this, finally, the results indicate the ability of the method to indicate the state of charge of the battery, as well as the analysis of the stipulated errors. Concluding that, the configuration used has a better performance when adjusting the number of layers, and can be applied in other batteries, as in the case of the lithium battery; With the errors and mishaps found throughout this study, some future work is presented.

Keywords: Charge status, artificial neural networks, functionality

LISTA DE FIGURAS

Figura 1: Diagrama de modelo experimental	7
Figura 2: Modelo de red <i>Perceptron</i> usada para el entrenamiento.....	8
Figura 3: Entrenamiento de la red	9
Figura 4: Clasificación de Baterías según su reacción electroquímica	11
Figura 5: Aplicaciones de Baterías	13
Figura 6: Principios Físicos de una Batería	15
Figura 7: Clasificación del Sistema de Gestión de Baterías	19
Figura 8: Sistemas Interconectados al BMS.....	21
Figura 9: Funcionalidad del BMS	22
Figura 10: Neurona Artificial	26
Figura 11: Partes una red neuronal	27
Figura 12: Clasificación de Redes Neuronales.....	28
Figura 13: Aprendizaje	29
Figura 14: Arquitectura de Redes Neuronales Artificiales.....	30
Figura 15: Arquitecturas	31
Figura 16: Ejemplo de red feedforward de múltiples capas	32
Figura 17: Regresión Descartada.....	36
Figura 18: Entrenamiento con un aumento del número de neuronas.	37
Figura 19: Número de neuronas y función de transferencia modificados.	38
Figura 20: Regresión para el entrenamiento.....	38
Figura 21: Regresión para la validación.	39
Figura 22: Regresión para los testes	39
Figura 23: Curva de entrenamiento	40
Figura 24: Modelo de Curvas Seleccionadas	40
Figura 25: Modelo descartado con 10 neuronas	42
Figura 26: Entrenamiento con 28 neuronas	43

LISTA DE TABLAS

Tabla 1: Cantidad de datos utilizados en la red.....	34
Tabla 2: Datos de entrenamiento.....	34
Tabla 3: Datos en PU para el entrenamiento.....	35
Tabla 4: Datos en PU para pila de litio.....	35
Tabla 5: Errores del modelo seleccionado.....	41
Tabla 6: Errores del modelo descartado.....	42
Tabla 7: Errores del modelo descartado a 28 neuronas.....	43

LISTA DE CUADROS

Cuadro 1: Comparación del mejoramiento de parámetros de batería de litio y sodio.....	17
Cuadro 2: Características de las topologías de BMS.....	20
Cuadro 3: Métodos para encontrar el estado de carga (SOC) de una batería.....	24

LISTA DE ABREVIATURAS

ANN	<i>Artificial Neural Networks</i>
BMS	<i>Battery Management Systems</i>
FIAMM	<i>Acumulatori Motocarri Fabbrica Montecchio Italiana</i>
MLP	<i>Perceptron</i> de multicasas
MTep	Unidad de medida de energía equivalente a 10^6 toneladas de petróleo
OCV	Voltaje a Circuito Abierto
RBF	Redes de Base Radial
SOC	State Of Charge
SOH	State of Health

SUMARIO

1	INTRODUCCIÓN.....	1
1.1	JUSTIFICATIVA.....	2
1.2	MOTIVACIÓN.....	3
1.3	OBJETIVOS.....	4
1.4	ESTRUCTURA DEL TRABAJO.....	4
2	METODOLOGIA.....	6
3	SISTEMAS DE ALMACENAMIENTO DE ENERGÍA: BATERÍAS.....	10
3.1	PRINCIPALES CARACTERÍSTICAS Y APLICACIONES.....	11
3.2	BATERÍAS DE CLORURO DE SODIO – NÍQUEL.....	12
3.3	BATERÍAS DE LITIO.....	15
4	SISTEMA DE GESTIÓN DE BATERÍAS.....	18
4.1	TIPOS DE BMS.....	18
4.2	FUNCIONALIDAD DEL SISTEMA DE GESTIÓN DE BATERÍAS.....	20
4.3	APLICACIONES.....	23
5	REDES NEURONALES ARTIFICIALES.....	24
5.1	DEFINICIÓN.....	25
5.2	CLASIFICACIÓN DE REDES NEURONALES ARTIFICIALES.....	27
5.3	ARQUITECTURA DE REDES NEURONALES ARTIFICIALES.....	29
5.4	APLICACIONES EN INGENIERÍA.....	33
6	RESULTADOS OBTENIDOS.....	34
6.1	PARÁMETROS USADOS.....	34
6.2	RENDIMIENTO DE LA RED.....	36
6.3	CURVAS Y ERROS DO MODELO.....	39
7	CONCLUSIONES.....	45
	REFERENCIAS BIBLIOGRÁFICAS.....	46

1 INTRODUCCIÓN

En la actualidad, con la constante demanda de energía eléctrica, en Brasil en el 2018 la energía total disponible llego a 288,4 Mtep, registrando un crecimiento de 1,7% en relación al año anterior. En el caso de la energía eléctrica se verifico un avance en la oferta interna 10,7 TWh (1,7%) en relación al año anterior. Debido a las condiciones hidrológicas favorables, creció un 4,1% la energía hidráulica disponible en relación al 2017. La participación de las energías renovables en la matriz eléctrica llego al 83,3% en el 2018. La generación eólica llego a 48,5 TWh con un crecimiento de un 14,4%, y la potencia eólica alcanzo 14 390 MW, se expandió 17,2%, según se informó en el balance energético del 2019. (EMPRESA DE PESQUISA ENERGÉTICA, 2019).

No solo Brasil, otros países adoptaron políticas que aumentan la participación de fuentes de energía renovable en los últimos años y con la cúspide de los dispositivos electrónicos y la generación de energía, está creciendo la necesidad de sistemas de almacenamiento de la misma, con gran capacidad, bajo costo y peso reducido, además de siempre obtener equipos que nos permitan reducir los contaminantes para el medio ambiente. Estos sistemas pueden eliminar variaciones de potencia, aumentar la flexibilidad de sistemas eléctricos, permitir el almacenamiento de despacho de energía eléctrica generada por fuentes renovables.

Uno de los sistemas de almacenamiento de energía más usados son las baterías, las cuales transforman energía química almacenada en energía eléctrica, vienen siendo usadas en aplicaciones vehiculares y en sistemas de almacenamiento estacionarios. En la actualidad las baterías que mejor se adecuan y que mejores características proponen al mercado son las de litio, mientras que a pesar de ser contaminantes las baterías de plomo continúan siendo las más baratas en el mercado, pero a la fecha nuevas baterías vienen siendo desarrolladas y es el caso de las baterías de sodio, que tienen características como rendimiento constante y vida útil en un amplio rango de temperatura ambiente de -40 °C a + 60°C en operación, un alto rendimiento en aplicaciones de ciclos pesado >3 000 ciclos al 80% de profundidad de carga, un ventajoso costo total de propiedad a lo largo de los años y una tecnología verde sin plomo y otros aditivos nocivos. (ELECTRILABS (PTY) LTD, 2018).

Pero hoy en día quien no busca que los dispositivos electrónicos sean más duraderos, y que soporten grandes temperaturas, pero se ha visto que grandes empresas del área de telefonía móvil han tenido problemas con la inflación o explosión en las baterías, lo cual requieren de un sistemas de seguridad, este dispositivo de seguridad más conocido por sus siglas

en inglés como *Battery Management Systems* (BMS), que ayuda a proteger la seguridad del operador, detectar las condiciones de funcionamiento y responder a ellas, además de proteger la vida de la batería, manteniendo la misma en un estado en el que puede cumplir sus requisitos de diseño funcional y controla que la carga y descarga de la batería se realice en forma adecuada.

El BMS además informa al controlador como hacer un mejor uso del paquete, es muy utilizado para aplicaciones vehiculares, como en vehículos eléctricos, híbridos eléctricos, entre otros; y en aplicaciones de gran escala, para el almacenamiento en red y copia de seguridad.

El BMS está interconectado con las celdas, los sistemas de refrigeración y el sistema de medición de la batería y a su vez conectado con el controlador del vehículo, por ellos se describirá brevemente su funcionalidad, las cuales se pueden dividir según su detección y control de alto voltaje, midiendo así los cambios de temperatura, voltaje, corriente, aislamiento y control térmico. Según su protección, interfaz, gestión de rendimiento y diagnóstico, en los que se estudia los estados de carga, salud y vida de la batería. (PLETT, 2015).

Es por ello que en este presente trabajo se pretende aplicar las redes neuronales artificiales; más conocido por su nombre en inglés como Artificial Neural Networks (ANN); de tipo red *Perceptron* con arquitectura *feedforward*, para modelar la estimación del estado de carga, más conocido por sus siglas en inglés *State Of Charge* (SOC), y observar el comportamiento del BMS, con diferentes parámetros de entrada de la batería, en este caso corriente, tensión y temperatura.

Además, con el software MATLAB, se obtendrá las curvas de salida, el error en la salida de la curva de carga y por último realizar las respectivas comparaciones con otras baterías y observar si es viable su aplicación o no.

1.1 JUSTIFICATIVA

La importancia de este trabajo, está en la necesidad aplicar el uso de redes neuronales artificiales (ANN) para predecir el comportamiento de la curva de carga en baterías de sodio, y así poder modelar el comportamiento del BMS.

Las ANN, son un algoritmo preciso y práctico para la obtención de la estimativa del SOC. Existen diferentes modelos para estimar el SOC, ya que estos no pueden ser obtenidos directamente de los terminales de la batería, por lo que es necesario el desarrollo en algoritmos de estimación que utilicen variables eléctricas como el voltaje, corriente y la temperatura. (JULIÁN *et al.*, 2015).

Por otro lado, el BMS es esencial para la seguridad ya que la gran mayoría de baterías pueden llegar a encenderse y explotar cuando se sobrecarga. El BMS está formada por un software y hardware que controlan la carga y descarga de la batería al mismo tiempo que garantizan un funcionamiento confiable y seguro, además el BMS también controla el equilibrio celular y la gestión térmica de la batería. (CHATURVEDI *et al.*, 2010; MEISSNER; RICHTER, 2003).

El BMS tiene varias características para controlar y monitorear el estado operativo de la batería en diferentes niveles de células, módulos y paquetes de baterías, las cuales nos proporcionan una estimación SOC y de vida (SOH), así como el control de carga de la batería. (RAHIMI-EICHI *et al.*, 2013).

Por lo cual el monitoreo y control, son dos aspectos operativos importantes del BMS, no se pueden separar durante la operación. Para garantizar un control adecuado de los procesos de carga y descarga de la batería, se requiere de un sistema de monitoreo rápido, preciso y exacto. El BMS examina los parámetros operativos de voltaje, corriente y la temperatura interna de la batería durante la carga y descarga para estimar el SOC y de salud (SOH), y así proteger la batería de daños. (HAQ *et al.*, 2014).

Es esencial la implementación de las ANN para la estimación de la curva de carga en baterías de sodio, ya que va a permitir su aplicación en otras baterías, por ejemplo: baterías de litio, plomo, etc., por lo que se requieren grandes datos de entrenamiento y un estudio minucioso de los ajustes, arquitecturas y tipos de redes en el entrenamiento. Después de esto, poder estudiar los errores y el comportamiento de las curvas de salida.

1.2 MOTIVACIÓN

La motivación que llevo a realizar este trabajo, fue la importancia que tiene la carga en las baterías y la dificultad que presenta para medir la curva de carga.

El estado de carga, en la mayoría de los dispositivos electrónicos es uno de los factores que más preocupa a los clientes, por lo cual el estudio de la influencia de factores como temperatura, corriente y tensión pueden modificar el estado de carga e/o descarga de la batería, es esencial para la medición de la curva.

Hoy en día, para su medición se aplican métodos convencionales que necesitan de parámetros variables, otros exigen equilibrio en el estado de la batería, acceso al electrolito, entre otras dificultades. Es por ello, que se requieren métodos innovadores, como ANN para su medición y el estudio de los errores en la salida de la curva.

1.3 OBJETIVOS

Considerando la importancia que tiene el sistema de gestión de baterías para el rendimiento, la seguridad y la vida útil de la batería, es así, que el estudio del estado de carga de baterías es de gran envergadura, por lo que el objetivo principal y específicos de este presente trabajo se muestra a continuación.

1.3.1 Objetivo General:

1. Aplicar el uso de redes neuronales para predecir el comportamiento de una curva de carga en una batería de sodio, y así analizar el comportamiento del sistema de gestión de la batería, a través de los datos encontrados en la salida de la red neuronal.

1.3.2 Objetivos específicos:

1. Estudiar las baterías de sodio y litio, y sus aplicaciones.
2. Conocer el sistema de seguridad de la batería (BMS) y su funcionalidad.
3. Realizar las pruebas para encontrar los parámetros de entrada, usados en nuestra red neural.
4. Aplicar el estudio de redes neuronales en baterías.
5. Verificar si existe alguna diferencia de los sistemas de seguridad de otras baterías.
6. Estudiar el comportamiento de la curva de carga para proteger la batería.
7. Comparar las curvas y encontrar posibles diferencias o soluciones para una mejoría.

1.4 ESTRUCTURA DEL TRABAJO

El presente trabajo está estructurado de la siguiente forma:

En el capítulo 2, Con el uso de diagramas se muestra el método utilizado para el entrenamiento de la red, y con el software MATLAB, se describe el entrenamiento de la red neuronal, los parámetros, algoritmos, arquitecturas que se toman en cuenta para modelar el comportamiento de la curva de carga.

En seguida en el capítulo 3, es detallado uno de los sistemas de almacenamiento de energía más usados como es la batería. Su respectiva clasificación según su reacción electroquímica, además de sus principales características y aplicaciones no solo en la industria sino también en la medicina. En este caso se describirá brevemente las baterías de litio que es la más comercial y la batería de sodio-níquel que es estudio de nuestro trabajo. Para finalizar, un cuadro comparativo de los parámetros de ambas baterías.

Siguiendo con el desarrollo en el capítulo 4, se abordará el estudio del BMS, las funciones de estos, así como también una breve descripción de los tipos de BMS según su clasificación en uso comercial y por su topología, se mostrará un cuadro comparativo de las características. Además de mostrar las funciones que tienen el BMS para la batería de estudio, SONICK. Por último, haciendo uso de diagramas se mostrará la funcionalidad del BMS y sus respectivas aplicaciones.

Continuando, en el capítulo 5, es mostrado con la ayuda de un cuadro de datos las ventajas y desventajas de los posibles métodos para la determinación del SOC, lo que permitió elegir las ANN. Seguido de los conceptos de ANN, cuantas partes se compone una ANN, así como la clasificación de la misma según su topología o estructura de red y su aprendizaje. Con el uso de diagramas se mostrará una breve descripción de cada aprendizaje y sus aplicaciones. Después se describirá la arquitectura, que también con el uso de diagramas se muestra sus aplicaciones y las redes donde son utilizadas estas arquitecturas. Y para concluir las potenciales áreas de aplicaciones tanto en ingeniería como en ciencias.

Ya en el capítulo 6, se muestra las curvas de carga, así como los resultados obtenidos, el error en la curva de carga, y las discusiones del porqué de algunos parámetros escogidos para el entrenamiento de la red, así como curvas descartadas en el transcurso del entrenamiento.

Para finalizar en el capítulo 7, se muestra las conclusiones y trabajos a futuro después de esta investigación. Referencias consultadas para el estudio y entendimiento de este presente trabajo.

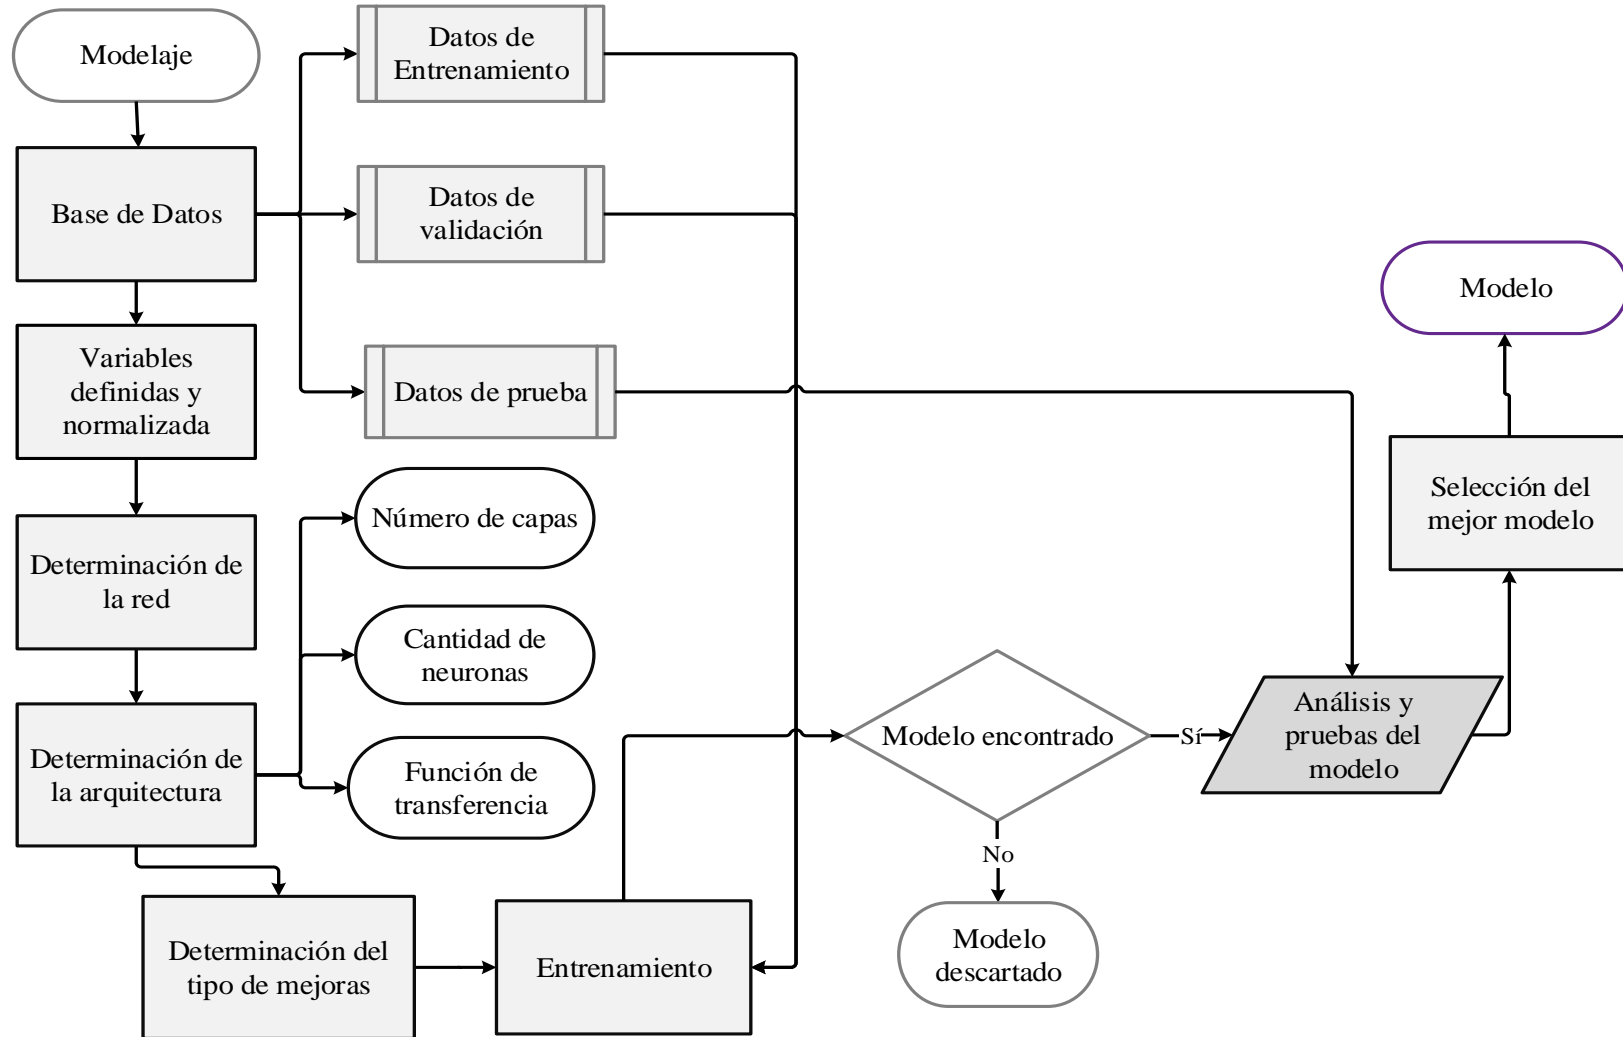
2 METODOLOGIA

En este capítulo se detallará, mediante un diagrama de flujo el proceso paso a paso para llegar al modelo de curva de carga. Con la ayuda del software MATLAB e de la herramienta Toolbox Neural Network/Data Manager (nntool) se encontrará las curvas y datos de salida.


Para la determinación del modelo experimental, se siguieron algunos pasos, como es descrito en la Figura 1,

- A. Base de datos:** La base de datos fue obtenida de la batería de sodio y litio, de donde se tomaron valores de corriente, voltaje y temperatura, la batería de sodio cuenta con 10 celdas. De esta base de datos se tomará para el entrenamiento, validación y teste.
- B. Variables definidas y normalizadas:** como la base de datos se encuentran en diferentes unidades, se convierte a PU, como se explica en el capítulo 6.
- C. Determinación de la red:** para nuestro caso se utilizó ANN de tipo *Perceptron*, más conocida por su nombre en inglés como *Multilayer Perceptron* (MLP), como se muestra en la Figura 2, una explicación más detallada se muestra en la sección 5.3.1 de esta investigación.
- D. Determinación de la Arquitectura:** con una arquitectura *Feedforward*, de múltiples capas, más detallada en la sección 5.3. Aquí se va a definir el número de capas, la cantidad de neuronas y la función de transferencia.
- E. Determinación del tipo de mejoras:** Se selecciona el tipo de mejoras que para el caso será a Levenberg – Marquardt, una descripción de este tipo de mejoras se muestra al final de esta sección.
- F. Entrenamiento:** se entrenó las curvas de carga, teniendo en cuenta algunos parámetros y algoritmos usados, El algoritmo de aprendizaje aplicado en el transcurso del proceso de entrenamiento es denominado backpropagation o algoritmo de retropropagación del error, una descripción más detallada del algoritmo se muestra al final de esta sección. Se optó por tres parámetros, ya que la salida depende de ellos.
- G. Modelo encontrado:** es obtenido el modelo después del entrenamiento, en el cual se espera sea acorde a la salida, y si no sucede eso se descarta hasta encontrar el mejor.
- H. Análisis y prueba del modelo:** después de encontrado el modelo, se analiza y prueban con otros datos de entrada, para obtener la curva de salida.
- I. Selección del mejor modelo:** después de obtenido el mejor modelo, se grafica los datos de salida y se calculan los errores.

Figura 1: Diagrama de modelo experimental



Fuente: Elaboración propia

Figura 2: Modelo de red *Perceptron* usada para el entrenamiento

Fuente: Adaptado de (HAYKIN, 2009).

Siguiendo el diagrama, para el entrenamiento el algoritmo de retropropagación del error o *backpropagation* comúnmente realizado mediante las aplicaciones sucesivas de dos fases bien específicas: fase *forward* y fase *backward*, las cuales hacen que los pesos sinápticos y umbrales de las neuronas se ajusten automáticamente en cada interacción. La fase de propagación por delante (*forward*), permite obtener las respuestas de la red, llevando en consideración los valores actuales de pesos sinápticos y umbrales de sus neuronas, los cuales permanecerán inalterados durante cada ejecución de esta fase. (SILVA; SPATTI; FLAUZINO, 2010).

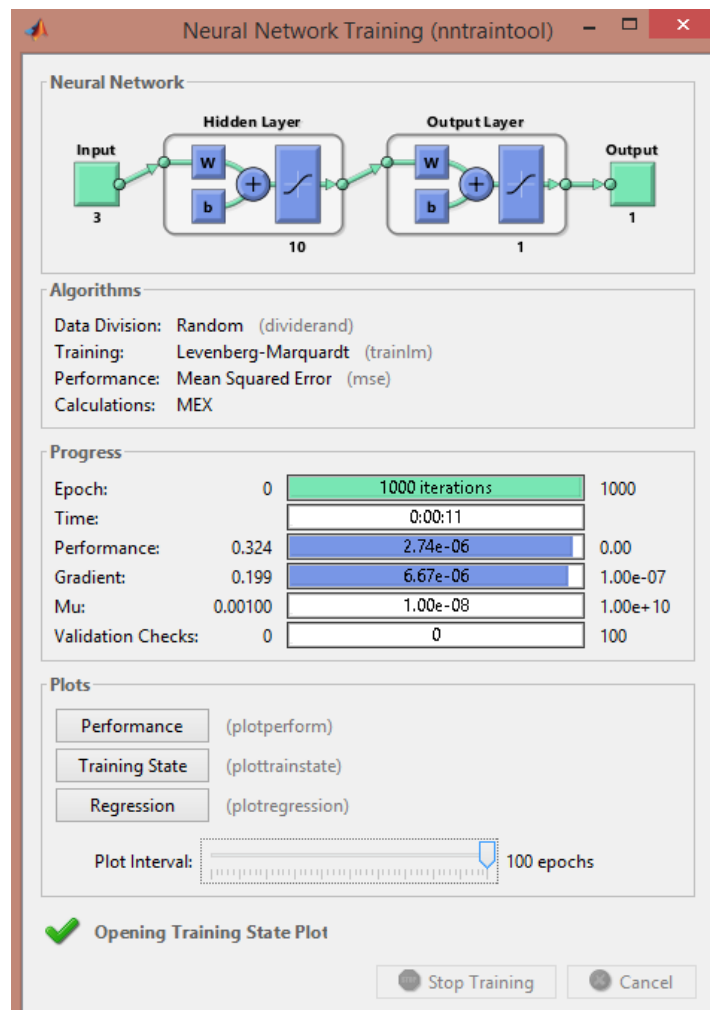
Existen diversas variaciones del método de *backpropagation* que son propuestos con el objetivo de realizar el proceso de convergencia más eficiente. Entre estos métodos de mejoras tenemos el Levenberg – Marquardt (BENATTI, 2017; GAVIN, 2019; SINGH, 2012), que ayuda a una convergencia más rápida ya que el algoritmo tiende a ajustar los valores de las matrices de pesos de la red MLP en relación a la dirección opuesta del error cuadrático de la función de gradiente, lo que hace que la convergencia sea más lenta y por consiguiente exija un mayor esfuerzo computacional, este es otro parámetro para crear nuestra red neuronal, lo encontramos como función de entrenamiento TRAINLM.

Después de lo expresado y siguiendo el diagrama de flujo, en el entrenamiento de la red trabajaremos con el error cuadrático medio, más conocido por su nombre en inglés como

Mean Squared Error (MSE), que nos va a permitir medir la evaluación del desempeño global del algoritmo.

Como se puede apreciar en la Figura 3, el número de capas es de dos y el número de pesos sinápticos para este entrenamiento será de diez, mientras que la función de activación será utilizada es la función TANSIG o tangente hiperbólica, que como toda función de transferencia calculan la salida de una capa a partir de su entrada neta. Después de creada la red, pasamos entrenar.

Figura 3: Entrenamiento de la red



Fuente: Imagen adquirida por Matlab R2018a.

Finalizado el entrenamiento y la validación de los datos, se realiza el análisis y prueba del modelo junto con los datos de teste y es encontrado los resultados y errores proporcionados por la red, los cuales serán discutidos en el capítulo 6.

3 SISTEMAS DE ALMACENAMIENTO DE ENERGÍA: BATERÍAS

En este capítulo se mostrará una breve descripción uno de los principales sistemas de almacenamiento de energía, baterías, sus principales características y aplicaciones; así como la definición de dos grandes tipos de baterías, las baterías de litio que son las más usadas en la actualidad y baterías de sodio que es el foco de estudio y para finalizar un cuadro comparativo de los parámetros de ambas baterías.

Conceptualmente, en este trabajo se asume que la batería es un acumulador de electricidad, un dispositivo electro-químico, es decir transforma energía química almacenada en energía eléctrica.

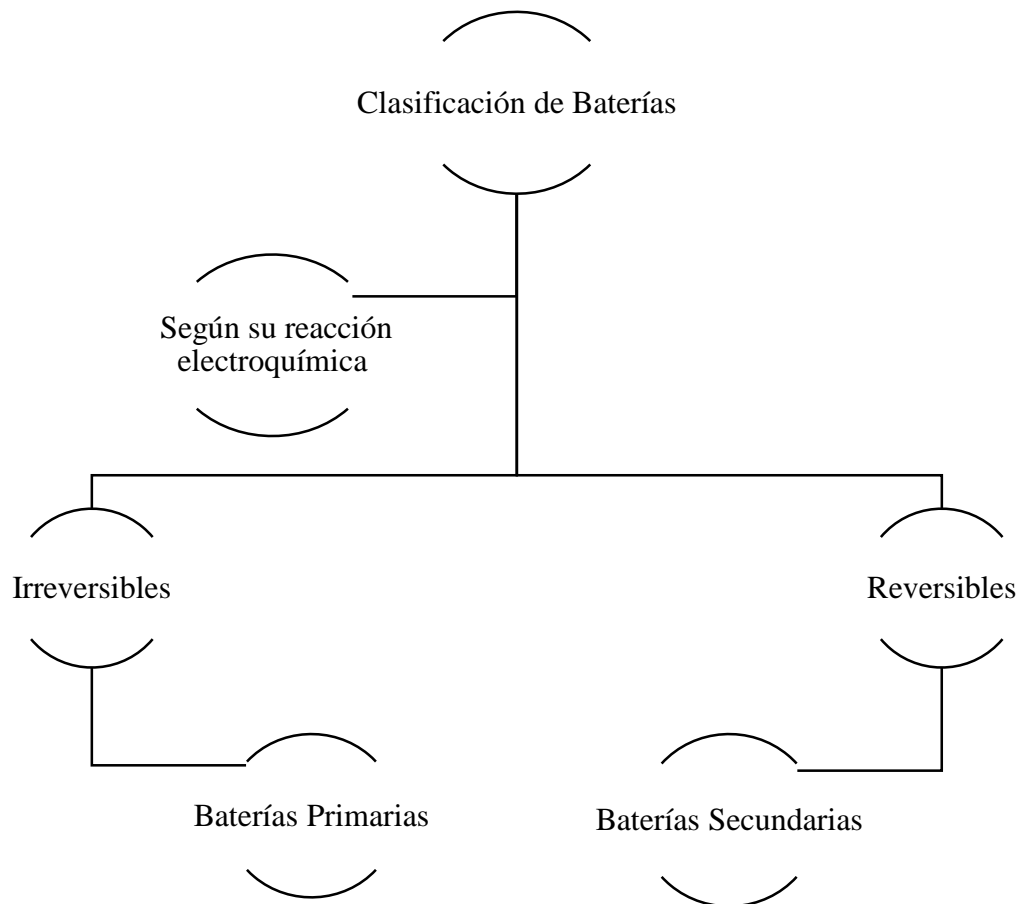
El funcionamiento de una batería se basa en una celda electroquímica que tiene dos electrodos, el ánodo y el catodo. En el ánodo se lleva a cabo la oxidación y en el cátodo se efectúa la reducción, o sea uno gana y el otro pierde electrones. Es mediante esta pérdida y ganancia de electrones de los elementos que forman la batería que se genera la diferencia de potencial en sus bordes y así, al conectar un circuito a ellos, se produce el paso de corriente. (MARTÍNEZ BERTRAN, 2017).

Todas las baterías son similares en su construcción y están formadas por un número de celdas compuestas de electrodos positivos y negativos, separadores y de electrolito. El tamaño, el diseño interno y los materiales utilizados controlan la cantidad de energía disponible de cada celda. Los electrodos pueden ser de cualquier material siempre que sea un buen conductor eléctrico, como es el caso de metales y semiconductores.

Se pueden clasificar según su reacción electroquímica en reversibles e irreversibles, como se muestra en la Figura 4.

- A. **Batería primaria:** es irreversibles, o sea una vez que la batería se descarga no se puede volver a cargar. Siendo que muchas veces son fabricadas con el mismo tipo de material activo que las secundarias, ellas son construidas de tal forma que solamente una descarga intermitente o continua puede ser obtenida antes que los reactivos químicos colocados durante la fabricación sean consumidos. Así la batería primaria descargada debe ser sustituida.
- B. **Batería secundaria:** es reversibles, o sea una vez que la batería se descarga si se puede volver a cargar, inyectándole corriente continua desde una fuente externa. Cuando una corriente de carga fluye a través de sus terminales en una dirección opuesta al flujo de corriente durante la descarga, los materiales activos retornan a su condición original, aproximadamente. (FILHO, 2007).

Figura 4: Clasificación de Baterías según su reacción electroquímica



Fuente: Elaboración Propia

3.1 PRINCIPALES CARACTERÍSTICAS Y APLICACIONES

Las baterías en general tienen características comunes que son las principales que se pueden ver a la hora de elegir una batería, según Jiménez López, (2018), las características pueden ser:

- A. Resistencia interna:** Formada por la resistencia óhmica de sus componentes (terminales, electrodos, soportes y electrolito) y por una resistencia virtual variable en función del estado de carga y de las distintas polarizaciones y concentraciones
- B. Rendimiento:** Es la relación entre la energía suministrada durante la descarga y la que se necesita para cargar plenamente la batería.
- C. Velocidad de carga y descarga:** Las corrientes de carga y descarga a menudo se especifican con unos términos que indican la descarga completa en un período continuo de una hora.
- D. Vida útil:** La vida útil de una batería no se mide en años, sino por la cantidad de ciclos de carga - descarga que es capaz de realizar.

Las aplicaciones de las baterías van a depender de sus características, del material que están hecho y muchas pueden ser elegidas por su bajo costo, a continuación se muestra algunas aplicaciones en la Figura 5.

Es utilizado para aplicaciones de tracción, en uso vehiculares, como vehículos eléctricos, o híbridos; en el área de robótica; en el área de salud, por ejemplo, para audífonos que utilizan baterías pequeñas; en áreas industriales, baterías para sistemas fotovoltaicos; en automoción, es usado baterías de plomo en barco y en una gran variedad de aplicaciones a nivel mundial, incluso en los dispositivos electrónicos que se utilizan a diario.

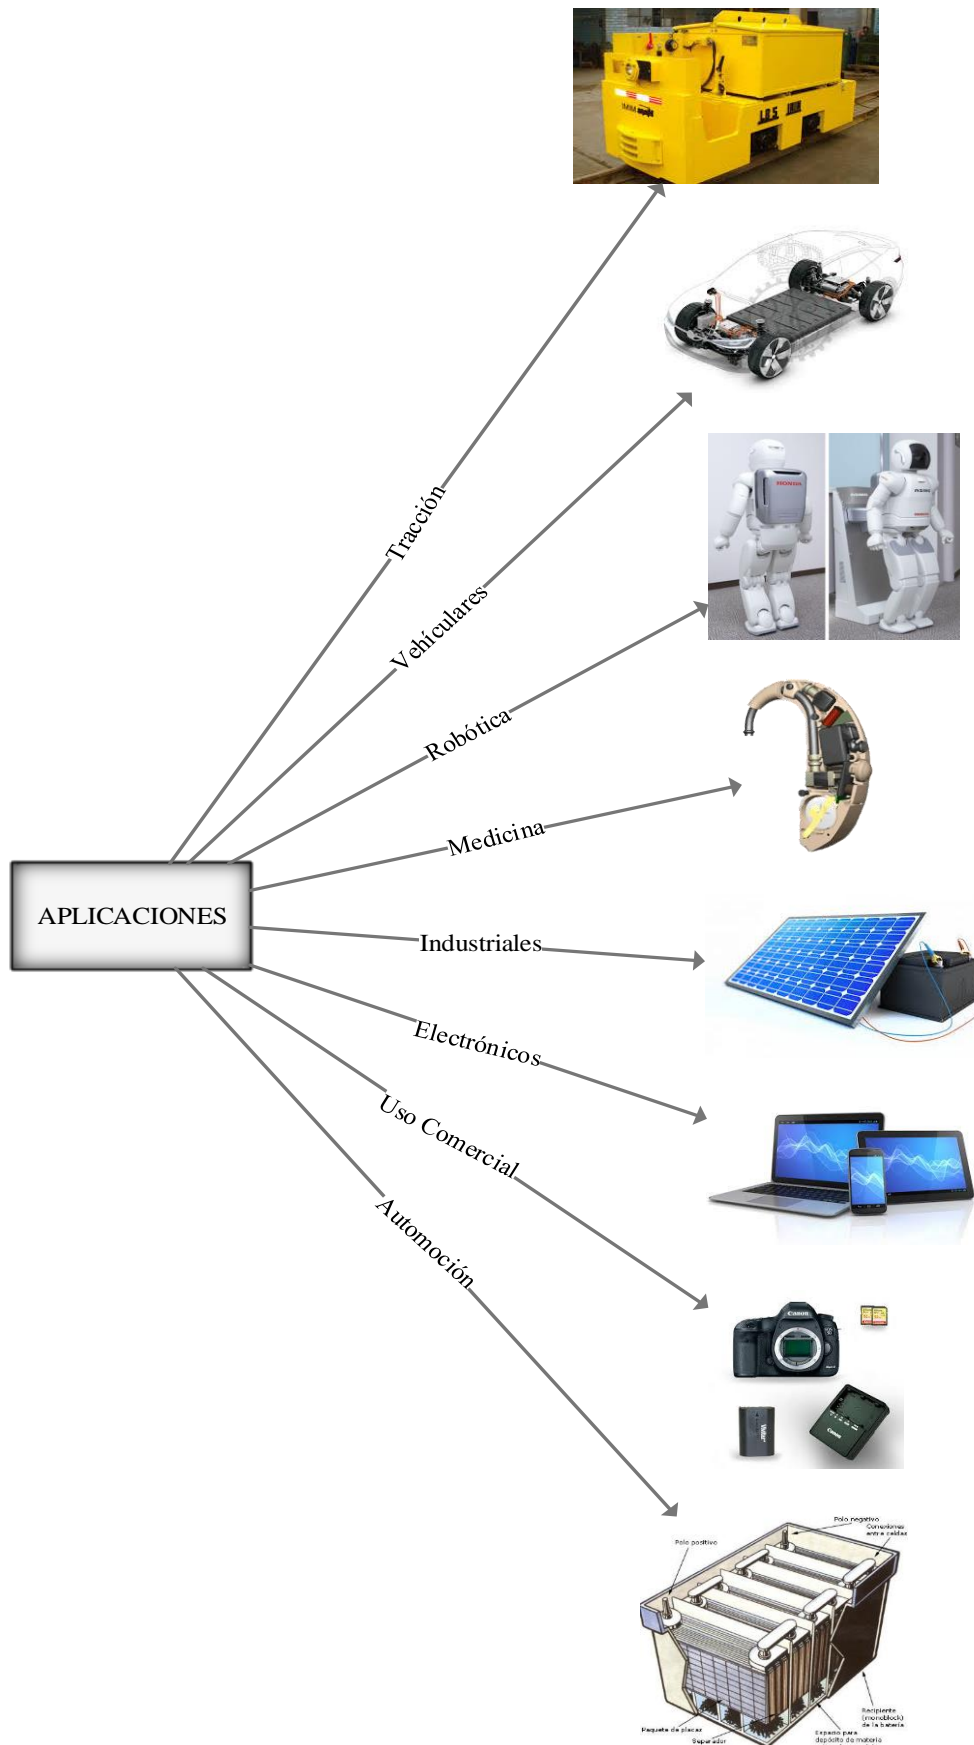
Entre las baterías más comunes comercialmente y las más innovadoras en el mercado tenemos: la batería de litio, es usada en la mayoría de dispositivos electrónicos, siendo el litio una de los recursos con mayores reservas localizadas en Sudamérica.

Para el estudio se trabajará con baterías de sodio-níquel, siendo que la en la actualidad vienen siendo una de las novedades en el mercado por poseer componentes reciclables, como el níquel, hierro, sal común y cerámica fácil de reutilizar o de desechar, y muchos de estos son usados para uso en carreteras. Además, estas baterías de sodio-níquel tienen mayores parámetros de temperatura, lo que garantiza un alto rendimiento y durabilidad, al inicio aplicadas para vehículos eléctricos, pero hoy en día muestran grandes resultados en el almacenamiento de energía y en grandes centrales eléctricas de energía renovables.

3.2 BATERÍAS DE CLORURO DE SODIO – NÍQUEL

La batería de cloruro de sodio – níquel se desarrolló por primera vez en la década de los 70, con el uso de materiales activos como cloruro de sodio, níquel y con un electrolito cerámico sólido. En 1985 la empresa *Zeolite Battery Research Africa* (ZEBRA) comienza el proyecto Zeolita para la investigación de estas baterías en África (BOBBY, 2014). Mientras que su comercialización comienza desde la década de 1990 (SCHROEDER; GATTIGLIO, 2015), y su aplicación originalmente comenzó en los vehículos eléctricos y los vehículos eléctricos híbridos, como autobuses, camiones, furgonetas. Hoy en día muestra grandes resultados en el almacenamiento de energía, aplicaciones marinas, aplicaciones industriales, mercado de telecomunicaciones y de respaldo, grandes centrales eléctricas de energía renovables, micro red de conexión a la red y fuera de la red.

Figura 5: Aplicaciones de Baterías



Fuente: Elaboración propia

Es un sistema de almacenamiento de energía basado en las reacciones de carga / descargas electroquímicas que se producen entre un electrodo positivo (cátodo) que consiste principalmente de níquel (Ni) y cloruro de sodio (NaCl) y un electrodo negativo (ánodo) que típicamente está hecha de sodio (Na), como se muestra más adelante en la Figura 6. Los electrodos están separados por una pared cerámica de beta-alúmina que es conductora de los iones de sodio, pero un aislador para los electrones. Esta cerámica de beta-alúmina actúa como un electrolito y permite la conducción de iones de sodio entre el ánodo y el cátodo de las células. (EASE, 2019).

Las baterías de cloruro de níquel y sodio son producidas en Europa por la compañía del grupo *Acumulatori Motocarri Fabbrica Montecchio italiana* (FIAMM). (FIAMM, 2014).


La batería de cloruro de sodio-níquel se basa en cadenas de celdas cerradas en un acero inoxidable, con una caja completa con aislamiento térmico. La temperatura de la batería se mantiene entre 240 ° C y 330 ° C para mantener los electrodos en un estado fundido, esto quiere decir calentadores independientes son parte del sistema de la batería. (EASE, 2019).

Los componentes principales de la batería son: célula elemental compuesta de electrodos, electrolito, módulos separadores, sistemas de baterías compuestas por un gran conjunto de módulos, un sistema de control y un sistema de conversión de energía. Son baterías de alta capacidad (más pequeñas y más livianas que las tradicionales), fiables a altas temperaturas, larga vida, sin mantenimiento y no tiene materiales peligrosos, ya sea en fabricación o uso.

Debido al electrolito de cerámica la batería no tiene auto-descarga electroquímica, y dependiendo de las condiciones de operación, la pérdida térmica es equilibrada por la pérdida eléctrica interna que se convierte en calor de manera que la eficiencia general varía entorno de 80-95%. Estas baterías son de alta temperatura, que garantizan un alto rendimiento y durabilidad, independientemente de la temperatura ambiente. En su funcionamiento, la temperatura interna del módulo de la batería se mantendrá dentro de la gama de temperatura operativa y no afectará su capacidad y duración, incluso si la temperatura ambiente exterior varía en gran medida. Tanto la operación de carga y descarga son independientes de la temperatura exterior, incluso durante las condiciones térmicas más severas.

Las baterías de cloruro de sodio-níquel son reciclables ya que sus componentes como níquel, hierro, sal común y cerámica son fáciles de reutilizar o de desechar, muchos de estos componentes con usos para asfalto en la construcción de carreteras. (GRIDEDGE, 2017).

Figura 6: Principios Físicos de una Batería



Fuente: Adaptado de (BECK, 2019).

3.3 BATERÍAS DE LITIO

Las baterías recargables utilizando iones de litio surgieron por primera vez en 1991, fabricadas por SONY. (KAUFFMANN, 2008). Las baterías son muy ligeras, pero tienen una densidad de energía más alta y, en el mercado actual, tienen las densidades de potencia más altas, son fabricadas con materiales inflamables, siendo que a grandes temperaturas pueden llegar a explotar es por ellos que necesitan de un circuito eléctrico adicional, que monitoreen el estado de la batería, los BMS; el mercado en la actualidad es dominado por fabricantes asiáticos.

Son capaces de un rendimiento increíble y son la opción estándar para muchos productos de consumo electrónico, como teléfonos móviles, agendas electrónicas, ordenadores portátiles, entre otras tecnologías; se están convirtiendo rápidamente en una elección de paquetes de tracción en vehículos.

La batería de ion-litio lleva este nombre porque el agente responsable por la oxidación y reducción de los electrodos es de ion litio (Li^+). Una batería provee corriente eléctrica para un sistema cuando los iones de litio son intercalados o de electrodos intercalados.

Las baterías de ion-litio tienen efecto memoria y pueden cargarse sin estar completamente descargadas, esto no reduce su vida útil, mientras que si se le impone una sobrecarga a la batería más del 50% de iones de litio dejarán el electrodo, y este va a sufrir una transformación irreversible que daña la batería.

Otro problema ocurre cuando se aplica un exceso de descarga, o sea, se realiza una descarga profunda, esto ocasiona una corrosión en el electrodo de grafito el cual pierde masa, perdiendo capacidad de carga. La vida se reduce si la descarga se realiza a una corriente muy alta o si la carga se realiza muy rápida, la célula puede resultar dañada también si se producen pulsos de corriente durante más de unos pocos segundos o si se baja de ciertos valores de voltaje.

El rango de temperatura de funcionamiento en descarga es de -20 a 60°C y de 0 a 40°C en carga. (VALDIVIA MIRANDA, 2018). Dependiendo del valor de la temperatura, el electrolito a base de solvente orgánico puede deteriorarse y perder las características deseables para un buen electrolito. (KAUFFMANN, 2008).

Para que las baterías de litio obtengan un máximo rendimiento, es necesario que tengan la misma tensión, de lo contrario algunas baterías llegarán al tope de su capacidad mientras que las otras no.

Para el mejoramiento de las baterías en la industria vehicular, los fabricantes se han concentrado en el aumento de la densidad de energía y la potencia de las baterías de iones de litio, lo que mejorará su rendimiento en sistemas de propulsión híbridas y electrificadas, y el aumento de la gama de conducción general de los vehículos eléctricos.

Los costos de la batería de iones de litio continuarán disminuyendo significativamente durante los próximos años. Esto debido a mejoras de células y reducción de los costos de embalaje, siendo que estos costos se reducirán en un 70% a los actuales.

Para un mejor rendimiento, vida y la reducción de costes de las baterías, estas tecnologías se están mejorando en parámetros como densidad de energía, densidad de poder, ciclo de vida, o rendimiento, como se muestra en la Cuadro 1.

Cuadro 1: Comparación del mejoramiento de parámetros de batería de litio y sodio

	Baterías de Sodio	Baterías de Litio
Densidad de Energía	A través de la optimización de la composición del cátodo.	Mediante el desarrollo de materiales de electrodo con una alta capacidad específica, o por celular en desarrollo que utilizan la química de voltaje más alto.
Densidad de Poder	A través de la reducción de las pérdidas óhmicas debido al mejoramiento del diseño y los materiales en los componentes de la célula.	Mediante un diseño optimizado, La mejora de la fabricación, Colectores de corriente de alto rendimiento.
Duración de la batería	Con sistemas de refrigeración para la parte térmica, La gestión de la energía, La nueva composición del cátodo, Incluso la introducción de un nuevo BMS con características avanzadas, mejorara la fiabilidad general de baterías de cloruro de sodio-níquel.	En el sistema de gestión térmica de la batería, lo que asegura que las células se mantienen en intervalos óptimos de temperatura, con esto se espera que las células de vehículos eléctricos van a lograr una vida útil de 10 -15 años en 2030.

Fuente: Adaptado de (SCHROEDER; GATTIGLIO, 2015).

4 SISTEMA DE GESTIÓN DE BATERÍAS

En este capítulo se abordará una descripción del sistema de gestión de baterías; más conocido por sus siglas en inglés como: *Battery Management System* (BMS) y en el recorrer del presente trabajo se adoptará como BMS para referirse al controlador; así como sus funciones, sus tipos, un cuadro de comparación de los tipos de BMS's, una breve descripción del BMS que acompaña a la batería de sodio - níquel en estudio, su funcionalidad y sus respectivas aplicaciones.

Conceptualmente en este trabajo el BMS es un dispositivo que ayuda a mejorar la seguridad, el rendimiento y la vida útil de una batería. Se fabrican de forma general para que funcionen con la mayoría de tipos de celdas y muchos no llegan a ayudar en el rendimiento de las celdas, pero como medida de seguridad verifica constantemente el estado de las celdas y garantiza que no exceda de los límites establecidos.

Las funciones de los BMS's son:

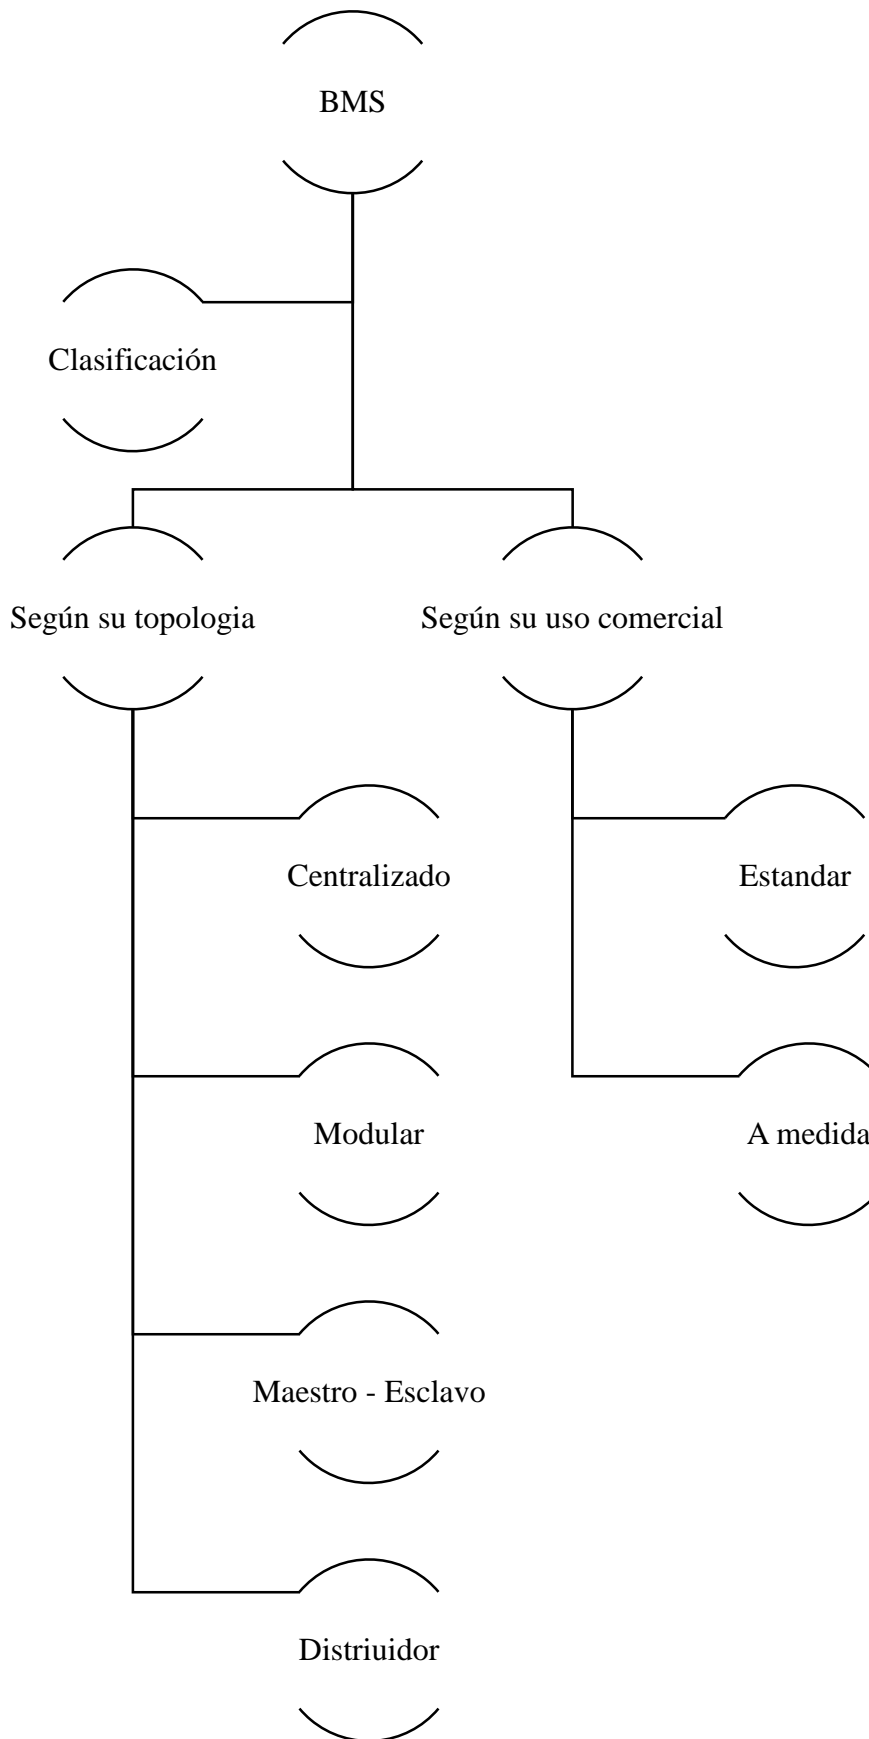
- A. Procesar de forma adecuada todos los valores de temperatura, voltajes, corrientes, etc.
- B. Proteger a la batería, impidiendo que el voltaje de las celdas exceda los límites, deteniendo la carga y descarga; así mismo evitar que la temperatura de las celdas exceda los límites, deteniendo el sistema o enfriándolo e impedir que la corriente exceda los límites, tanto en la carga como en la descarga, cortando la corriente o limitándola.
- C. Verificar el estado en el que se encuentra la batería, calculando el estado de carga (SOC) y el estado de salud (SOH).
- D. Realizar el balanceo adecuado en las células, para garantizar un nivel de carga óptimo en todas las celdas.
- E. Mantener un histórico de la batería, mediante la consulta de voltaje, corriente, temperaturas, etc.

4.1 TIPOS DE BMS

Según Valdivia (2018), los BMS's se clasifican por su uso comercial y por su topología, como se muestra en la Figura 7.

En el Cuadro 2, podemos observar que el BMS con topología distribuida es uno de los mejores en calidad de las medidas, seguridad, costo de componentes y versatilidad, seguido por la topología modular y maestro – esclavo, y por último la topología centralizada. Ya según su uso comercial, los BMS varían de acuerdo a los tamaños que el usuario desea ya sean estándar o a una medida en específico.

Figura 7: Clasificación del Sistema de Gestión de Baterías



Fuente: Adaptado de (VALDIVIA MIRANDA, 2018)

Cuadro 2: Características de las topologías de BMS

Topología	Centralizada	Modular	Maestro - Esclavo	Distribuida
Excelente	Inmunidad al ruido	Inmunidad al ruido, Coste de componentes	Inmunidad al ruido, Coste de componentes	Calidad de las medidas, Versatilidad, Seguridad Coste de componentes
Muy bueno	Calidad de las medidas. Coste de montaje	Calidad de las medidas Versatilidad Coste de montaje	Calidad de las medidas, Versatilidad, Coste de montaje.	Inmunidad al ruido, Coste de mantenimiento,
Bueno	Versatilidad Seguridad Coste de componentes	Seguridad Coste de mantenimiento	Seguridad, Coste de mantenimiento.	Coste de montaje

Fuente: Adaptado de (VALDIVIA MIRANDA, 2018).

Para la batería SoNick el BMS tiene las siguientes funciones (LINDA, 2017):

- A. Monitorear la temperatura de la batería.
- B. Carga de la batería una vez que ha alcanzado la temperatura de funcionamiento requerida.
- C. Regulación de los parámetros de carga de la batería (voltaje y corriente) para obtener el mejor rendimiento de carga de la batería.
- D. Demostrar detalles sobre el estado de carga o la profundidad de descarga (DOD), para indicar el nivel de carga de la batería.
- E. Proteger la batería contra sobrecarga o sobre descarga.
- F. Medición continua de todos los parámetros de la batería, tales como voltajes, corrientes, temperaturas, niveles de aislamiento que proporcionan un monitoreo continuo de las condiciones de operación.

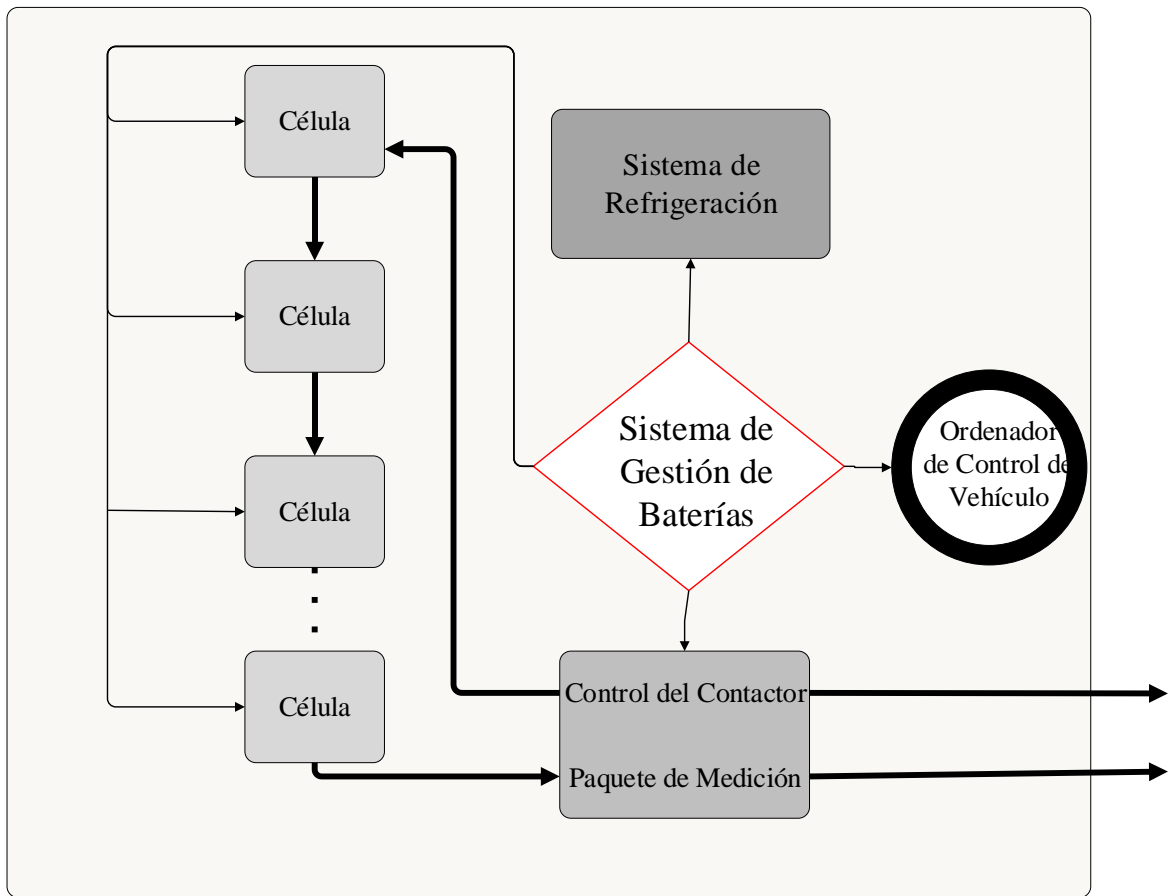
4.2 FUNCIONALIDAD DEL SISTEMA DE GESTIÓN DE BATERÍAS

En esta sección con el uso de diagramas se mostrará la funcionalidad del BMS, así como una breve descripción de la estimación de carga, que es parte del sistema de gestión de rendimiento, el cual es el foco en nuestro trabajo.

BMS está interconectado con todos los componentes del paquete de baterías y con el ordenador de control, como se muestra en la Figura 8.

Su funcionalidad se puede dividir en varias categorías, por ejemplo, detección de control y de alto voltaje, protección, interfaz, gestión de rendimiento y diagnósticos, que se muestran en la Figura 9.

Figura 8: Sistemas Interconectados al BMS



Fuente: Adaptado de (PLETT, 2015)

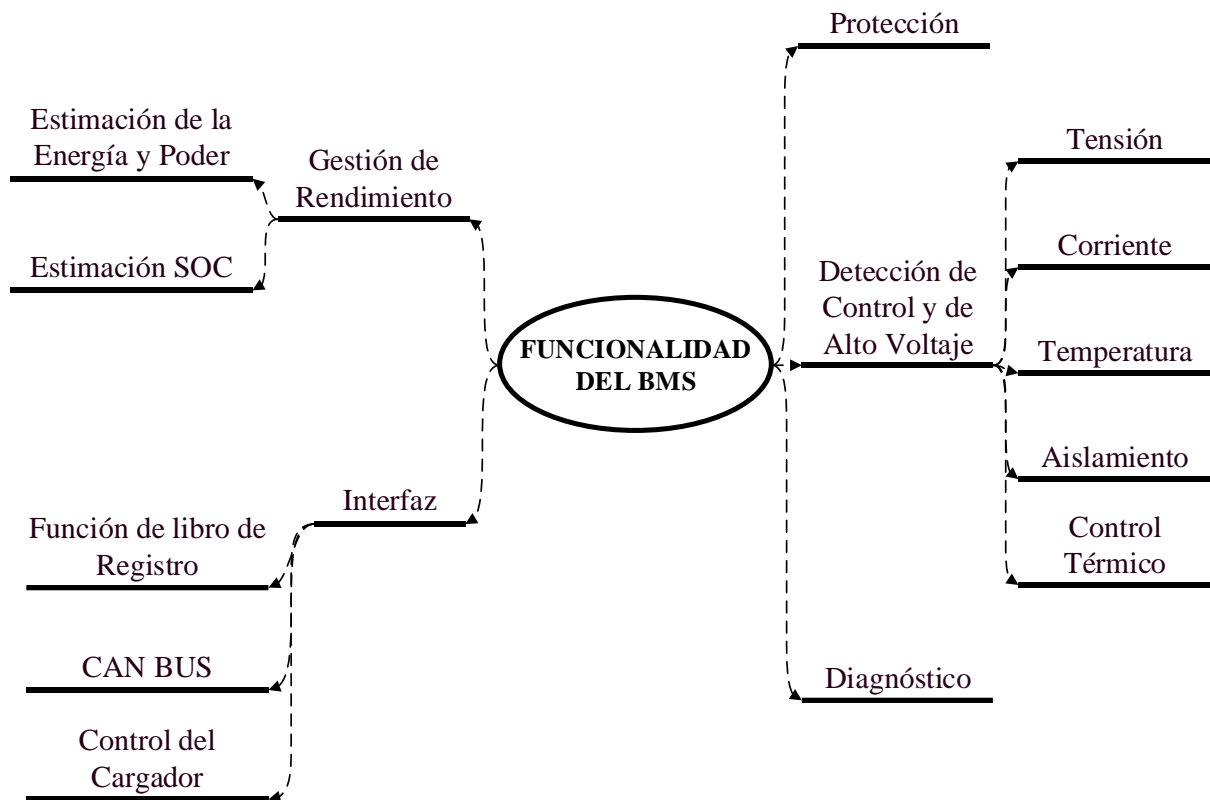
Para la investigación la funcionalidad de gestión de rendimiento, es una de las características más importantes ya que a través de estimación de estado de carga, predice en que momento la batería deja de cargar y ya está lista, así como nos muestra los límites que el voltaje y corriente alcanzan, no solo es usada para aplicaciones en sistemas estacionarios, sino también en usos vehiculares, una descripción más detallada de la estimativa del estado de carga se muestra en el siguiente subcapítulo.

4.2.1 Estimación del estado de carga

Los xEVs (referente a los tipos de vehículos eléctricos), necesitan saber dos cantidades de batería, la cantidad de energía que está disponible en la batería y la cantidad de energía disponible en el futuro inmediato.

Para lo EV una estimación de la energía es más importante porque la energía nos dice hasta donde puedo conducir. Mientras que para lo HEV la estimación de energía es importante porque indica si se puede acelerar o aceptar la carga de frenado. Para calcular la energía, hay que saber todos los estados de carga celular, resistencias y capacitancias.

Figura 9: Funcionalidad del BMS



Fuente: Adaptado de (PLETT, 2015).

La carga de una célula de litio se mueve desde el positivo al negativo del electrodo de la célula, en la descarga hace lo contrario. Electroquímicamente, el SOC de la célula se relaciona con la concentración promedio de litio en las partículas sólidas del electrodo negativo.

El voltaje de la célula depende de la temperatura y de las concentraciones de la superficie de la partícula del electrodo, pero el SOC depende de las concentraciones promedio de las partículas, las concentraciones superficiales y promedio generalmente no serán las mismas. Además, el reposo de la célula y el cambio de la temperatura cambian el voltaje de la célula, pero no las concentraciones promedio, por lo que no cambia el SOC; el historial de uso de células cambia la concentración de la superficie en estado estable frente a la concentración promedio (histéresis).

En conclusión, SOC cambia solo debido al paso de la corriente, ya sea cargando o descargando la célula debido a circuitos externos, o debido a auto-descarga dentro de la célula, entonces, encontraremos el voltaje útil como un indicador indirecto de SOC, pero no como una edición directa de SOC.

4.3 APLICACIONES

Después de conocer sus funcionalidades los BMS pueden ser aplicados en:

- A.** Para el caso de vehículos eléctricos, el BMS se encarga de controlar parámetros específicos, por ejemplo, la frenada regenerativa.
- B.** Usado en almacenamiento de red y la copia de seguridad.
- C.** Protección celular: por ejemplo, es necesario un sistema de gestión o de seguridad (BMS) para la protección de la batería cuando se sobrecargan, ya que pueden dañarse y causar sobrecalentamiento e incluso explosiones o llamas, en este caso es utilizado el BMS, para que brinde protección contra sobretensiones.
- D.** Descarga: por ejemplo, si la batería se descarga por debajo de aproximadamente 5% de la capacidad total, su capacidad puede reducirse permanentemente, por lo que para estos casos el BMS tiene un dispositivo de protección llamado protector de iones de litio.
- E.** Administración de energía: un ejemplo de administración de energía es el medidor de energía de la batería de una computadora, no solo nos dicen cuanto de carga tenemos, si no también cual es la tasa de consumo y cuánto tiempo le queda para usar antes de que la batería se descargue, un BMS rastrea esta capacidad.
- F.** Si en un sistema de almacenamiento tenemos un desbalance de voltaje en las baterías, el BMS evita seguir mandando carga a una batería cuando ya ha llegado a un nivel máximo. O lo desconecta cuando ya alcanzo su carga más alta y protege a las otras baterías de sobrecarga. Mantiene tanto los valores de voltaje y corriente, para que no pasen de sus límites, que sirve para la aplicación de la estimativa de carga, así como no comienza a cargar si no alcanza la temperatura de operación dada. Estos límites son esenciales para una buena estimativa de carga y así poder tener un mejor rendimiento.

5 REDES NEURONALES ARTIFICIALES

En este capítulo se abordará el porqué es utilizado el método de ANN con ayuda de un cuadro comparativo, además de la definición, la clasificación, arquitecturas de ANN y aplicaciones en ingeniería, que servirá para conocer y poder escoger una red neuronal artificial y poner en práctica en los BMS.

El SOC de la batería según Zong-You Hou et al., (2017), puede ser claramente definido como la capacidad residual en la batería con respecto a la capacidad nominal. El SOC proporciona información sobre la capacidad de retención cuando la batería está cargada o descargada, esta información puede respaldar la decisión correcta de iniciar y detener el proceso de carga y descarga para así evitar fallas en la batería, como sobre carga y descarga.

Hoy en día algunos investigadores aplican métodos convencionales y otros sistemas inteligentes como redes neuronales artificiales. En los métodos convencionales tenemos métodos como: medida directa, medida de la gravedad específica, en base a la intensidad, voltaje a circuito abierto (OCV). (CHAQUI; IBE-EKEOCHA, 2017; MARTÍNEZ BERTRAN, 2017).

Cuadro 3: Métodos para encontrar el estado de carga (SOC) de una batería

MÉTODO	VENTAJAS	DESVENTAJAS
MEDIDA DIRECTA	Método teórico e hipotético. Hipótesis de una corriente de descarga constante.	Inviabile en la práctica. La corriente de descarga es variable.
MEDIDA DE LA GRAVEDAD ESPECIFICA	Conocido como medida de densidad relativa. Método bastante preciso	No es capaz de determinar la capacidad total de la batería. Es necesario obtener acceso al electrolito líquido interno de la batería.
EN BASE A LA INTENSIDAD (COULOMB COUTING)	Consiste en la integración de la carga medida de la batería y las corrientes de descarga a través del tiempo. Es considerado el método más preciso	Es limitado por que es propenso a desviaciones a largo plazo que podrían surgir de una calibración ineficiente del sensor de corriente.
VOLTAJE A CIRCUITO ABIERTO (OCV)	Se basa en la existencia de una relación directa entre el voltaje actual de la batería y la capacidad de la misma.	Poco preciso debido al comportamiento no lineal de muchos tipos de baterías. Para EV, este método es extraño ya que la batería debe estar en estado de equilibrio, ni carga ni descarga, para una estimación relativamente precisa.
REDES NEURONALES ARTIFICIALES (ANN)	Mediante un proceso de entrenamiento pueden descubrir la correlación que existe entre variables de entrada y salida.	Necesita de datos de entrenamiento de baterías similares.

Fuente: Adaptado de (CHAQUI; IBE-EKEOCHA, 2017; MARTÍNEZ BERTRAN, 2017).

Debido a lo comentado en el Cuadro 3, y a la fácil inserción dentro de cualquier tecnología, las ANN, será el método utilizado para la determinación de SOC de la batería.

El cerebro humano es compuesto por billones de neuronas y trillones de sinapsis, que son unidades estructurales y funcionales elementales que modelan las interacciones entre las neuronas.

En 1943 los primeros en definir las redes neuronales fueron McCulloch y Pitts, cuyos estudios fueron publicados en un artículo clásico denominado “*a logical calculus of the ideas immanent in nervous activity*”. (MCCULLOCH; PITTS, 1943). El estudio envolvía el análisis de comportamiento biológico de una neurona, su objetivo era crear un modelo matemático que simule el comportamiento de una neurona. La teoría fundamental era que todo fenómeno psicológico puede ser analizado y comprendido en términos de la actividad en una red de dispositivos lógicos de dos estados.

El modelo de McCulloch y Pitts, matemáticamente puede ser expresado por la siguiente ecuación (1):

$$x_i(n+1) = f\left(\sum_j^n w_{ij} x_j(n) - \theta_i\right) \quad (1)$$

Donde:

x_i	Estado de i -ésima neurona ($i = 1, \dots, n$)
f	Función señal
n	Tiempo
w_{ij}	Eficiencia de la conexión
θ_i	Umbral de funcionamiento

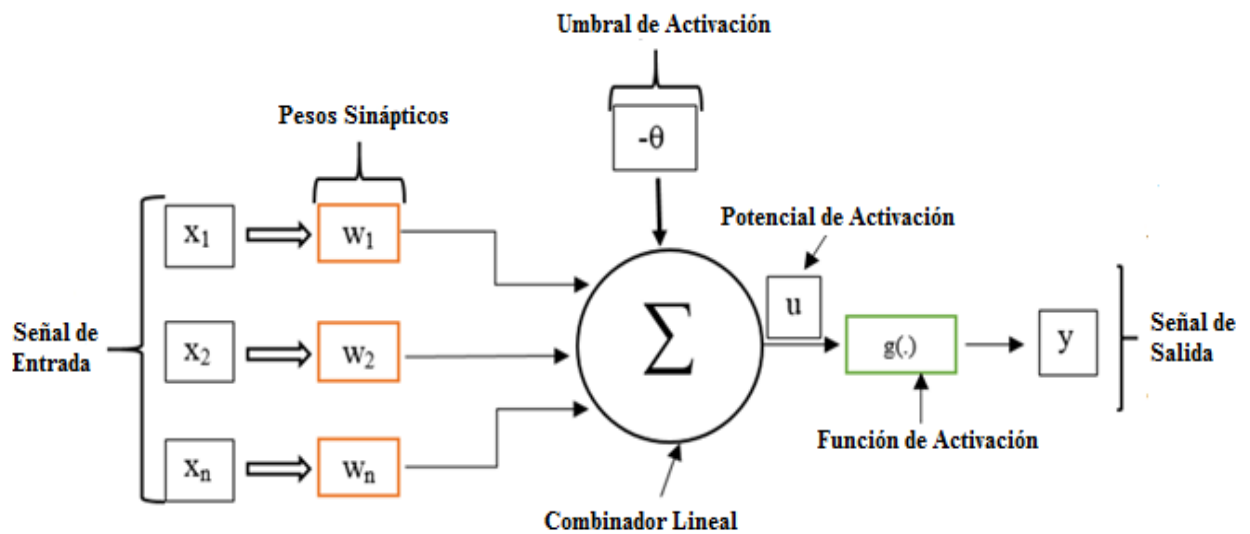
Así como se muestra en la Figura 10, se ve que la neurona artificial es constituida por siete elementos básicos.

En la actualidad, son numerosos los trabajos que se realizan y publican cada año, las aplicaciones nuevas que surgen (sobre todo en el área de control) y las empresas que lanzan al mercado productos nuevos, tanto hardware como software (sobre todo para simulación).

5.1 DEFINICIÓN

Según Ruiz (2015), ANN son redes interconectadas masivamente en paralelo de elementos simples (usualmente adaptativos) y con organización jerárquica, las cuales intentan interactuar con los objetos del mundo real del mismo modo que lo hace el sistema nervioso biológico.

Figura 10: Neurona Artificial



Fuente: Adaptado de (HAYKIN, 2009).

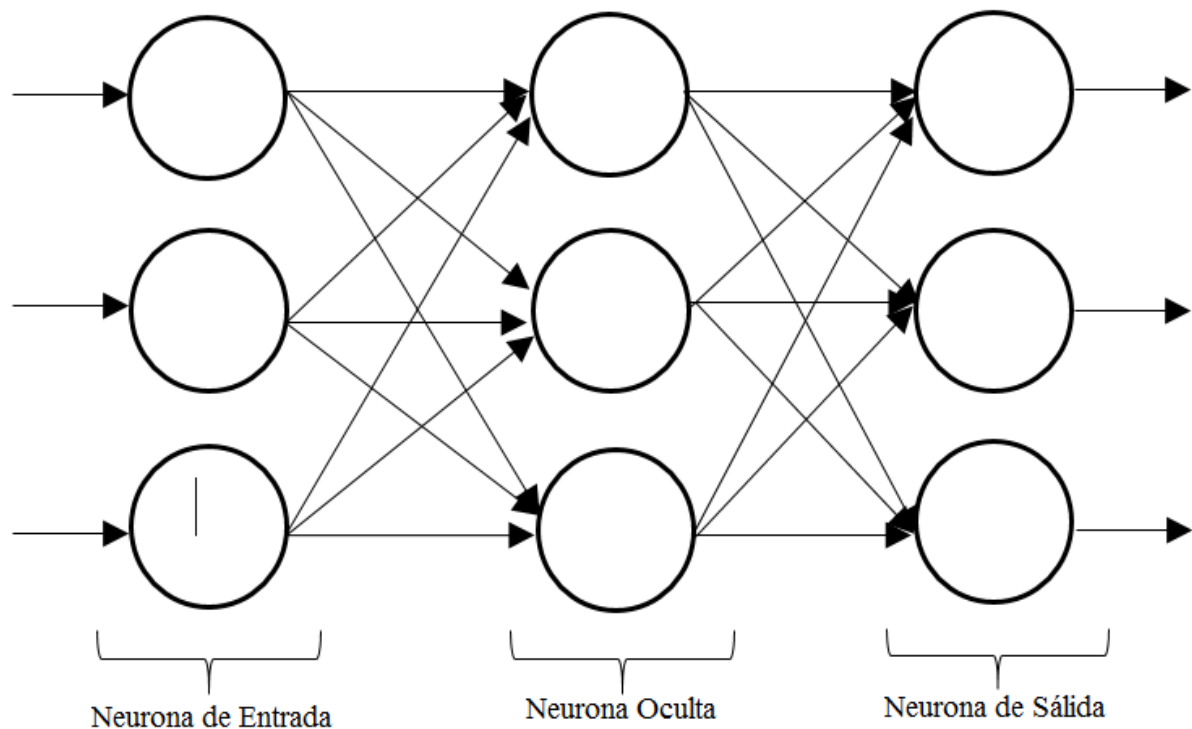
Para Tepán (2013), una red está compuesta por un conjunto de neuronas artificiales, dispositivos simples de cálculo que a partir de un vector de entrada generan una respuesta única y se pueden distinguir en:

- A. **Neuronas de entrada:** reciben señales del entorno ya sea de otras partes del sistema o de sensores.
- B. **Neuronas de salida:** emiten una salida fuera del sistema una vez que ha finalizado el tratamiento de la información.
- C. **Neuronas ocultas:** reciben estímulos y emiten dentro del sistema, es decir no tienen ningún contacto con el exterior; son las encargadas de realizar el procesamiento de la información.

Al igual que Tepán, Silva (2010), divide la ANN en tres partes, denominándolas capas, como se muestra en la Figura 11.

Las características más importantes de estas ANN son sus elevadas habilidades en mapear sistemas no lineales. En la actualidad el modelo propuesto por McCulloch y Pitts (1943), sigue siendo el modelo más utilizado en las diferentes arquitecturas de ANN.

Figura 11: Partes una red neuronal



Fuente: Adaptado de (RUIZ; BASUALDO; MATICH, 2015).

5.2 CLASIFICACIÓN DE REDES NEURONALES ARTIFICIALES

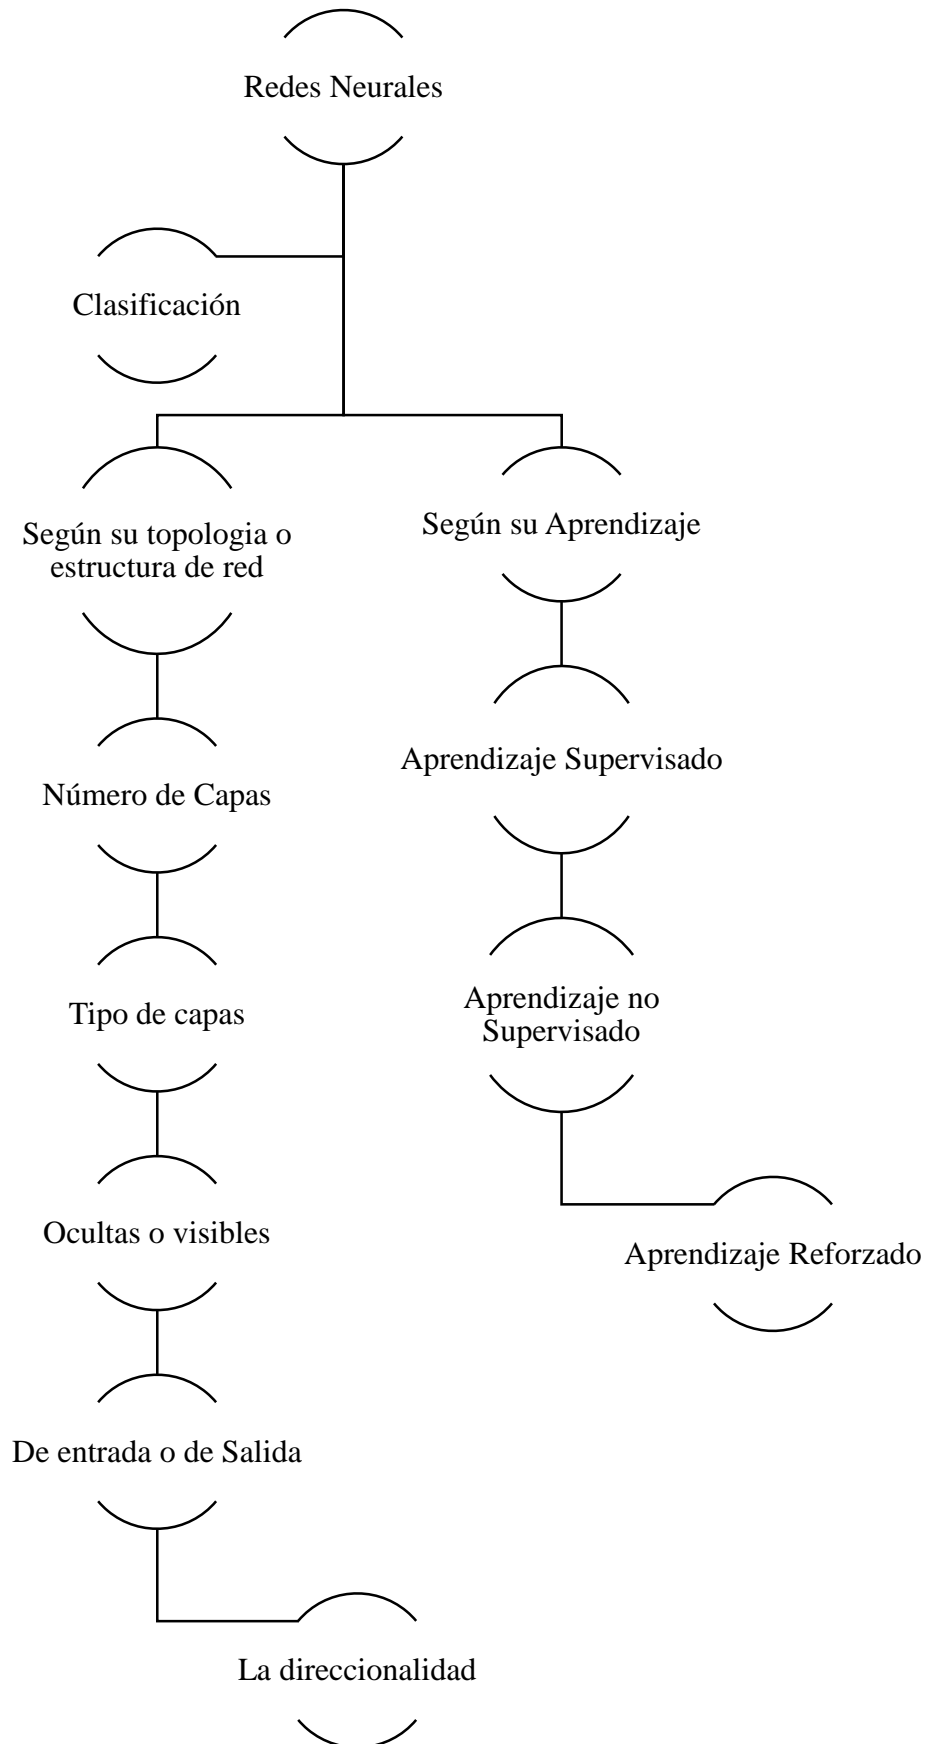
La clasificación de las ANN como se muestra en la Figura 12, se puede dar en función de sus características más importantes como: topología y aprendizaje, de ellas se pueden especificar según el número de capas, tipos de capas, ocultas, visibles, con aprendizaje supervisado, no supervisado, entre otras. (BALLESTEROS GONZÁLES, 2006).

El entrenamiento de una ANN consiste en la aplicación de pasos ordenados que sean necesario para la sintonización de los pesos sinápticos y umbrales de sus neuronas, el conjunto de estos pasos ordenados destinados a capacitar la red es denominado de algoritmo de aprendizaje.

Un aspecto importante respecto al aprendizaje de las ANN es el conocer cómo se 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 una nueva información. (RUIZ; BASUALDO; MATICH, 2015).

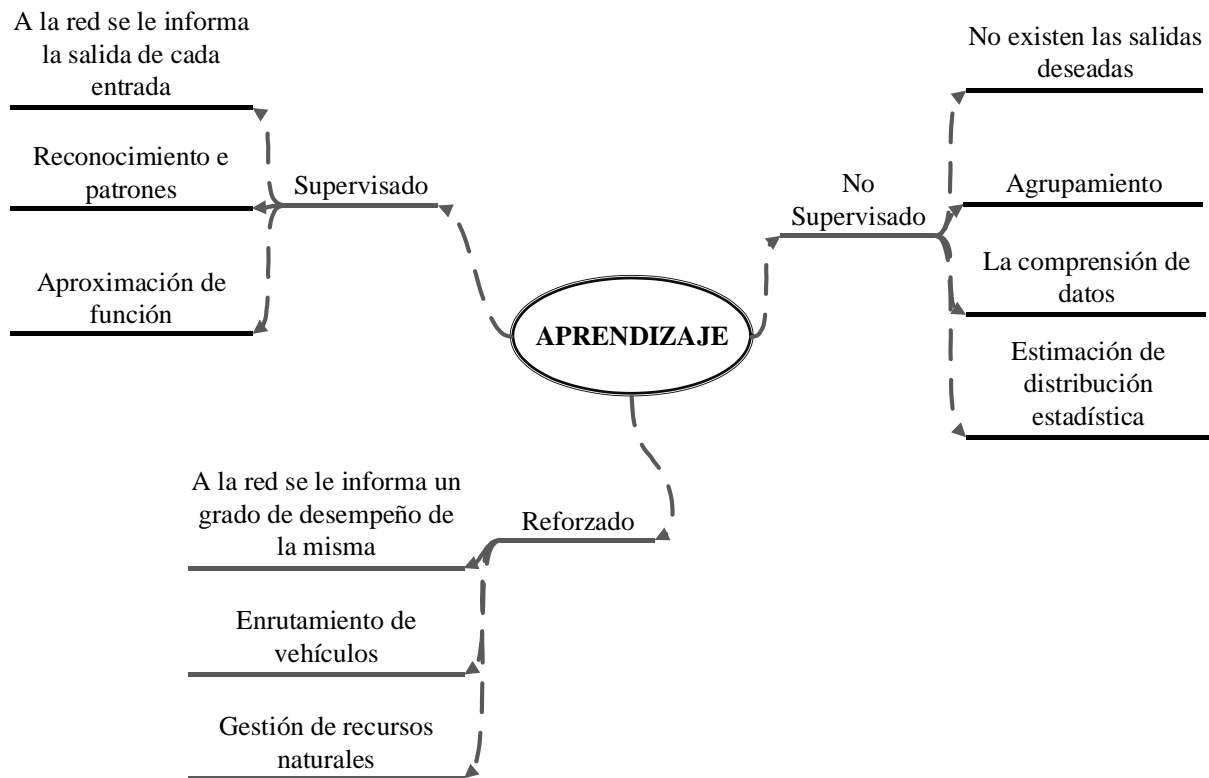
Estos aprendizajes pueden ser: supervisados, no supervisado y reforzado, que se muestra en la Figura 13, con sus respectivas aplicaciones, para el estudio de esta red se trabajara según su aprendizaje, en nuestro caso aprendizaje supervisado que es aplicado en aproximación de funciones, para predecir la curva de carga.

Figura 12: Clasificación de Redes Neuronales



Fuente: Adaptado de (BALLESTEROS GONZÁLES, 2006)

Figura 13: Aprendizaje



Fuente: Adaptado de (SILVA; SPATTI; FLAUZINO, 2010).

Otro de los aspectos importantes para las ANN es la arquitectura de la red, las cuales pueden ser de una sola capa o de múltiples capas, así como con un avance adelante o para atrás, un detalle de estas arquitecturas se muestra en el siguiente subcapítulo.

5.3 ARQUITECTURA DE REDES NEURONALES ARTIFICIALES

La arquitectura de una ANN define la forma como las diversas neuronas se encuentran arregladas, o preparadas, unas en relación a las otras. La topología de una red neuronal, considerando una determinada arquitectura, puede ser definida como siendo las diferentes formas de composiciones estructurales que puede asumir.

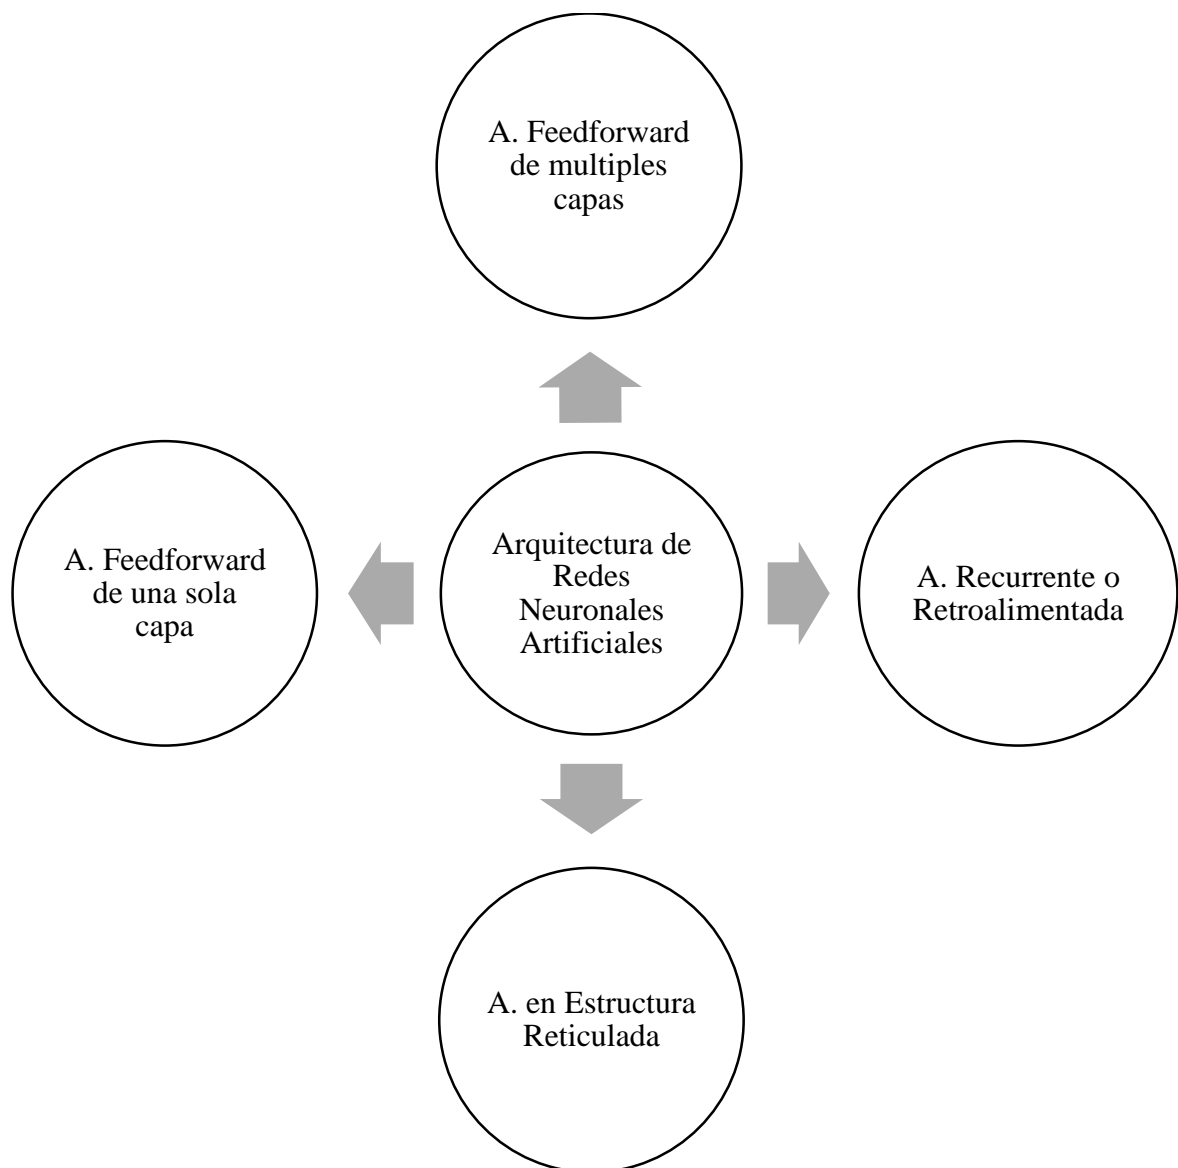
Las principales arquitecturas de ANN, considerando la disposición de sus neuronas, así como sus formas de interconexión entre ellos y la constitución de sus capas, pueden ser divididas como: redes *feedforward* de una sola capa y de múltiples capas, redes recurrentes y redes reticuladas, como se muestra en la Figura 14.

Para fines de este trabajo se optó por la arquitectura *feedforward* de Múltiples Capas. Se optó por esta arquitectura, ya que la fase de entrenamiento de difusión hacia adelante (*forward*), en el cual los valores son insertados en la entrada de la red y se difunden capa a capa

hasta la producción de las respectivas salidas, por lo que la aplicación de esta fase tiene como objetivo obtener la respuesta de la red.

Para esta investigación contamos con los datos de entrada (°C, A, V) y la salida esperada de la red es la curva de carga, donde se puede observar el comportamiento de los parámetros y como actúa el BMS, además más pesos y más capas ocultas tenga se optimizará mejor nuestra red. Una breve descripción de la arquitectura empleada se muestra en el siguiente subcapítulo.

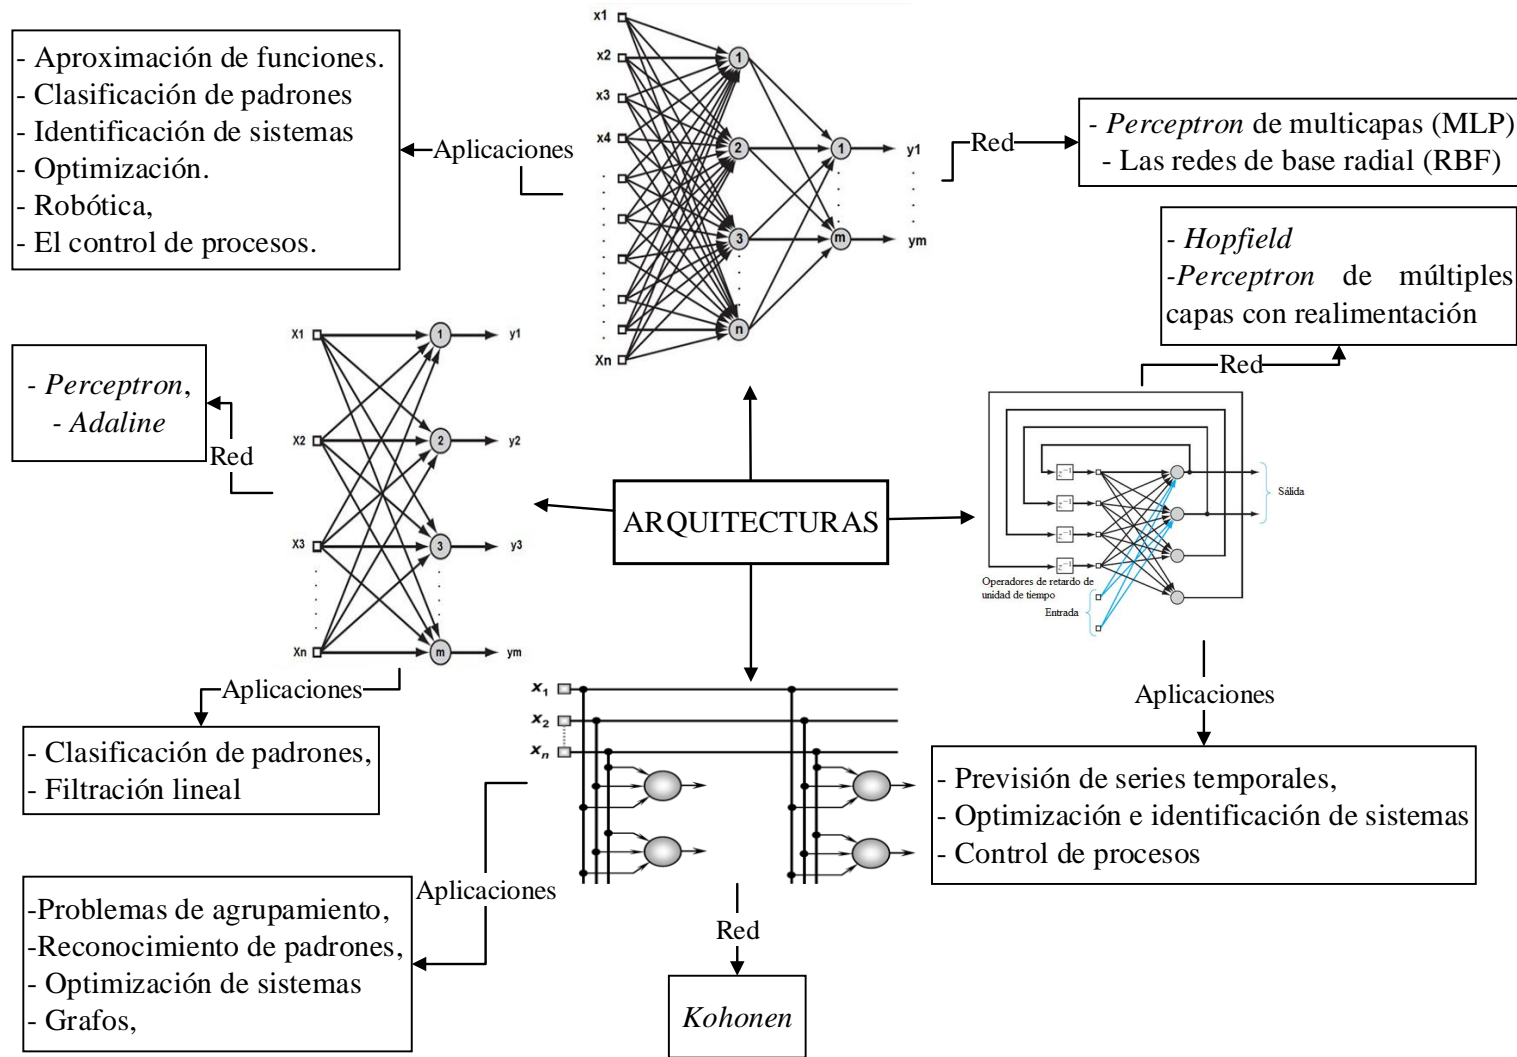
Figura 14: Arquitectura de Redes Neuronales Artificiales



Fuente: Adaptado de (SILVA; SPATTI; FLAUZINO, 2010).

Sus principales aplicaciones y tipos de red que pueden emplear estas arquitecturas se muestran en la Figura 15.

Figura 15: Arquitecturas




Fuente: Adaptado de (HAYKIN, 2009).

5.3.1 Arquitectura *Feedforward* De Múltiples Capas

A diferencia de la arquitectura de una capa, estas presentan una o más capas escondidas de neuronas, como se puede ver en la Figura 16. Al agregar una o más capas ocultas, la red está habilitada para extraer estadísticas de orden superior de su entrada.

Son empleadas en la solución de diversos tipos de problemas como la aproximación de funciones que es la aplicación de nuestra investigación donde se predice el comportamiento de la curva de carga; clasificación de padrones, identificación de sistemas, optimización, robótica, el control de procesos, etc. Los tipos de redes relacionadas con esta arquitectura son *Multilayer Perceptron* (MLP) y las *Radial Basis Function Networks* (RBF).

Figura 16: Ejemplo de red feedforward de múltiples capas



Fuente: Adaptado de (HAYKIN, 2009).

Ya que los dos únicos tipos de redes asociados tanto a la arquitectura multicapas son *Perceptron* y RBF, para nuestra investigación se optó por la red *Perceptron* multicapas, ya que cuentan con por lo menos una capa oculta, lo que va a permitir un mejor rendimiento en la salida, además de caracterizarse por tener elevadas posibilidades de aplicaciones en diversos problemas, por ejemplo: en aproximación de funciones para predecir la curva de carga. Y además con el aprendizaje supervisado y la arquitectura esta red es más afectiva

5.4 APLICACIONES EN INGENIERÍA

Las potenciales áreas de aplicación según Silva (2010), tanto en ingenierías y ciencias pueden ser:

- A.** Aproximación de funciones universales: mapear el relacionamiento funcional entre las variables de un sistema a partir de un conjunto conocido de sus valores representativos. Por ejemplo, es bastante utilizado para predecir el comportamiento de una curva de carga, como es el caso de nuestro estudio, esto se realiza mediante las variables de los parámetros de entrada, donde el BMS controla sus límites y así se puede observar el comportamiento de dicho controlador, esto puede ser aplicado con diferentes temperaturas o a corrientes constantes diferentes.
- B.** Control de procesos: identificar acciones de control que permiten el alcance de los requisitos de calidad, eficiencia y seguridad del proceso. Se destacan los controles empleados en robótica, aeronaves, elevadores, satélites, etc.
- C.** Reconocimiento/clasificación de patrones: consiste en asociar un patrón de entrada para una de las clases previamente definidas como ocurre en el reconocimiento de imágenes, voz, escrita, etc.
- D.** Agrupación de datos (agrupamiento): consiste en la identificación y detección de similitudes y particularidades entre los diversos patrones de entrada a fin de posibilitar su agrupamiento. Por ejemplo, en sistemas radar, reconocimiento facial, análisis de datos aplicados a conductas adictivas, etc.
- E.** Sistemas de previsión: consiste en estimar valores futuros de un proceso teniendo en cuenta varias medidas anteriores observadas en su dominio. Se destacan los sistemas de previsiones climáticas, financieras, etc.
- F.** Optimización de sistemas: consiste en minimizar o maximizar una función costo obedeciendo también eventuales restricciones que son impuestas para el correcto mapeamiento del problema. Por ejemplo, optimizando sistemas multi-respuesta para determinar parámetros que influyen en la mejora de la calidad de productos y servicios
- G.** Recuerdos asociativos: consiste en recuperar patrones correctos mismos si sus elementos constituyentes son presentados de forma incierta o imprecisa. Se destacan el procesamiento de imágenes, la transmisión de señales, identificación de caracteres manuscritos, etc.

6 RESULTADOS OBTENIDOS

Continuando con el desarrollo del diagrama de flujo mostrado en el capítulo anterior, para la obtención de resultados de esta investigación, es modificado los parámetros reales, y es ajustado la función de entrenamiento para un mejor rendimiento, y al final es comparado el error entre el entrenamiento valido y el descartado.

6.1 PARÁMETROS USADOS

La cantidad de datos utilizado para el entrenamiento, así como los datos usados para los diferentes testes se muestra en la Tabla 1, siendo que los datos de entrenamiento fueron de una batería de sodio a 3,8 A, ya que es la única de la que hemos tenido acceso a más datos, además de ser la utilizada en vehículos eléctricos y que motivo de realización de esta investigación por ser una de las baterías innovadoras en la actualidad.

Tabla 1: Cantidad de datos utilizados en la red.

Modo de Entrada en la red	Datos
Entrenamiento y Objetivo_3,8 A	9 110,00
Teste_3A	10 282,00
Teste_7,6A_	7 273,00
Teste_11,4A	7 484,00
Teste_Litio_0,520 A	10 479,00

Fuente: Elaboración propia.

Los parámetros iniciales de nuestro entrenamiento y de los datos de teste tanto en litio como en sodio, están en el sistema internacional de unidades, para temperatura, corriente y tensión (°C, A, V), como se muestra en la Tabla 2, donde tenemos algunos datos iniciales; por lo cual se convirtió todos los datos a PU.

Tabla 2: Datos de entrenamiento

%SOC	T (°C)	I BAT(A)	V BAT(V)
9,989	269,561	3,8	24,501
10,003	269,55	3,8	24,505
10,017	269,542	3,8	24,511
10,031	269,531	3,8	24,515
10,045	269,522	3,8	24,519
10,059	269,512	3,8	24,523
10,073	269,501	3,8	24,525
10,086	269,492	3,8	24,529
10,100	269,482	3,8	24,533

Fuente: Elaboración propia.

Los valores mostrados, fueron convertidos a PU, para un mejor entrenamiento y teste de los datos, siguiendo la ecuación (2). Para convertir los valores a PU, será necesario los valores nominales de la batería, para el caso de la batería de sodio la tensión nominal es de 25,8V para 10 células, la capacidad nominal es de 38 Ah, la temperatura es de 270°C y el %SOC considerado es de 100%.

$$pu = \frac{\text{Valor de Parámetro}}{\text{Valor Nominal de Cada Parámetro}} \tag{2}$$

En la Tabla 3, se muestra algunos de los datos en PU, usados para el entrenamiento de la batería de sodio. El mismo procedimiento se realizó para los datos usados para el teste a 3 A, a 7,6 A y 11,4 A.

Tabla 3: Datos en PU para el entrenamiento

%SOC	T (°C)	I BAT (A)	V BAT (V)
0,09989	0,99837	0,4	0,94965
0,10003	0,99833	0,4	0,94981
0,10017	0,99830	0,4	0,95004
0,10031	0,99826	0,4	0,95019
0,10045	0,99823	0,4	0,95035
0,10059	0,99819	0,4	0,95050
0,10073	0,99815	0,4	0,95058
0,10086	0,99812	0,4	0,95074
0,10100	0,99808	0,4	0,95089

Fuente: Elaboración propia.

Siguiendo el mismo raciocinio usado en sodio, se convirtió en PU los datos de la pila de litio usados para el teste; los valores nominales para la batería de litio convertir a PU serán: corriente nominal 0,520 A, voltaje nominal de 3,7 V, temperatura a 60 °C, y %SOC a 100%; como se muestra en la Tabla 4, así no se tendrá problemas al graficar y simular los datos de salida.

Tabla 4: Datos en PU para pila de litio

%SOC	T (°C)	I BAT (A)	V BAT (V)
0,02816	0,46667	1,00385	0,98027
0,02816	0,46667	1,00385	0,98027
0,02816	0,46667	1,00385	0,98027
0,02816	0,46667	1,00385	0,98027
0,02944	0,46667	1,00385	0,98054
0,02944	0,46667	1,00385	0,98054
0,02944	0,46667	1,00385	0,98054
0,02944	0,46667	1,00385	0,98054
0,02816	0,46667	1,00385	0,98027

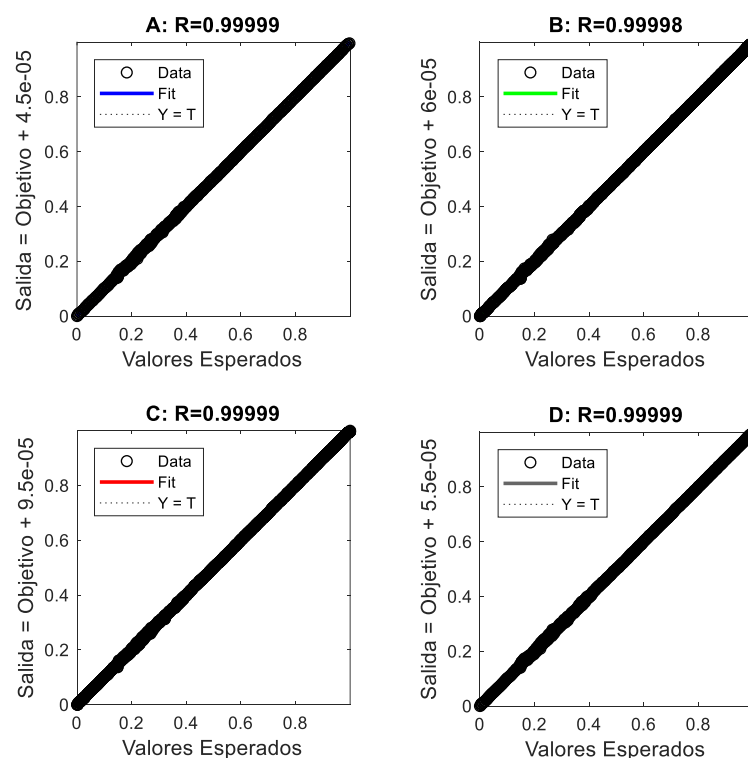
Fuente: Elaboración propia.

Hay que tener en cuenta para los datos de entrenamiento de sodio, el primer dato es negativo, esto se debe a errores acumulativos, se escogió la batería a 3,8 A ya que es la que comienza a cargar casi desde cero y alcanza valores de carga hasta 99,99%. Para los testes, a mayor corriente el %SOC es más rápido, por lo cual se tomaron como referencias 3A y 7,6A, ya para 11,4 A, siendo que vamos a encontrar que a corrientes mayores la red cambia. Para el litio, como es una pila más pequeña al poner a cargar, se descartaron algunos valores donde la corriente aún se encontraba en cero y no comenzaba a cargar, para un mejor modelo.

6.2 RENDIMIENTO DE LA RED

Siguiendo con el diagrama de flujo, con la obtención de los datos ya convertidos a PU, y el tipo de arquitectura elegida, se empieza a entrenar la red, con datos de entrenamiento a 3,8 A, y se observa la regresión, como se muestra en la Figura 17. Esta imagen cuenta con 4 graficas, tanto para la curva de entrenamiento (A), validación (B), teste (C) y una gráfica general (D). Se muestra las curvas después del entrenamiento, validación y teste, variando la salida en función del objetivo (target), en cada salida se le agrega el valor del error. Estas graficas muestran la precisión del modelo y del esperado, mientras estos valores de la regresión (R), sean más cercanos a 1 mejor será el rendimiento de nuestra red, para ello se necesita entrenar varias veces la red hasta alcanzar valores cercanos a la unidad.

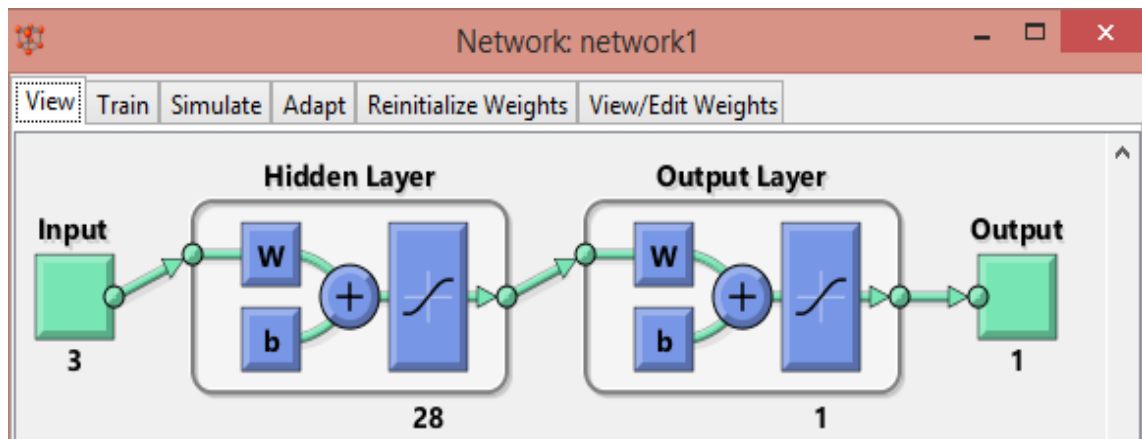
Figura 17: Regresión Descartada



Fuente: Elaboración propia.

Al finalizar el entrenamiento, el modelo de curva de salida, no era la esperada ya que presenta ligeros picos en el transcurso de la curva, como se explicará más adelante, estos errores pueden ser debido a ajustes, o la función de transferencia en las capas ocultas y de salida. Por lo que se dispuso aumentar el número de neuronas a 28 como se muestra en la Figura 18, conservando la misma función de transferencia y después entrenar la red, en la cual también encontramos errores de gran magnitud los que serán explicados y graficados más adelante.

Figura 18: Entrenamiento con un aumento del número de neuronas.



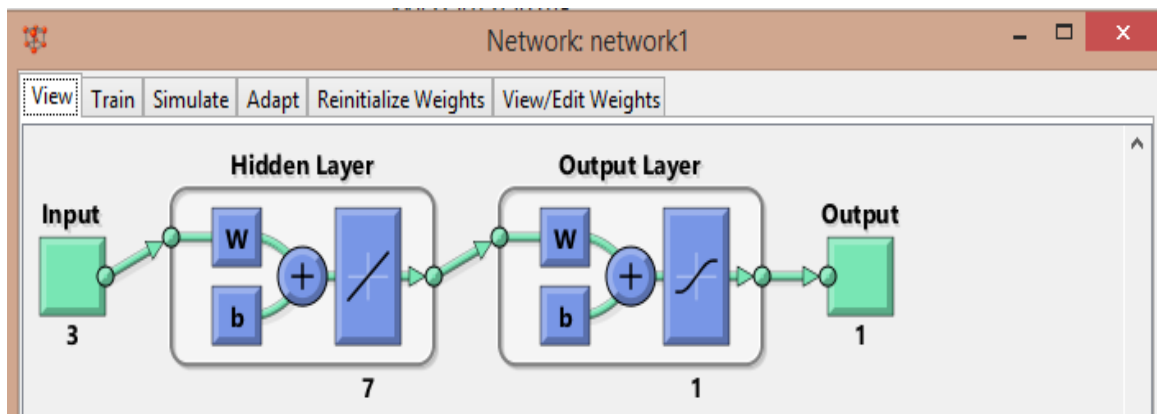
Fuente: Elaboración propia.

Entonces para eso, hay que tener en cuenta que existen diferentes formas de ajustar la red y al cambiar la función de transferencia o función de activación, para la capa oculta se muestra una función lineal, que nos va a proporcionar resultados de salida idénticos a los valores, y para la capa de salida la función tangente hiperbólica, el resultado de salida va asumir valores entre -1 y 1, siendo que la carga de salida entrenada en la red es constante al inicio y después realiza una pequeña curva al final de la carga, que será próximo a la unidad, ya que los datos están en PU.

Como se muestra en la Figura 19, la red funciona mejor para problemas de ajuste de funciones que en problemas de reconocimiento de patrones. Además de ser la más rápida para la función de entrenamiento predeterminada. La topología *Perceptron* multicapas seleccionada para el tratamiento de la red neuronal es muy conveniente ya que simplifica el diseño de la red, así como su entrenamiento, simulación e implementación.

Además, en el recorrer del entrenamiento encontramos que al ajustar el número de neuronas para 7, encontramos el mejor modelo de curva para testar los datos, siempre se espera mientras que cuanto mayor número de neuronas tenga las capas, mejor es el rendimiento de la salida, pero en nuestro caso se disminuyó para encontrar el objetivo.

Figura 19: Número de neuronas y función de transferencia modificados.

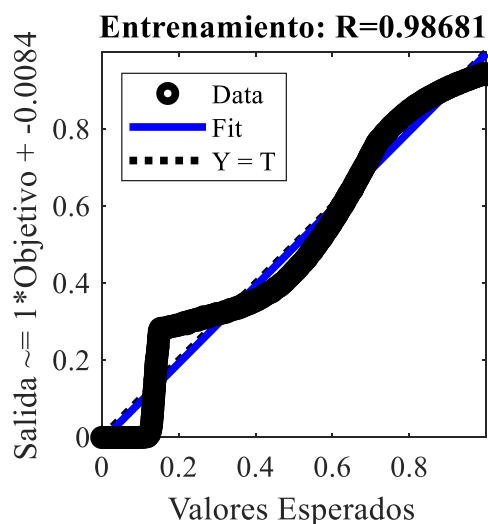


Fuente: Elaboración propia.

Al ajustar la red nuestra grafica de regresión cambio, siendo que los valores de regresión no son cercanos a la unidad, como es esperado, pero el modelo de curva de salida fue la más cercana al objetivo.

- A. **Entrenamiento:** muestra la precisión de la curva de salida en función del objetivo deseado, mientras la regresión sea más próxima de 1 el rendimiento es mejor, la línea azul nos muestra el ajuste que debe seguir nuestros datos, no están muy lejanos ya que la curva en el color negro, que son los datos de entrenamiento sigue de alguna forma la línea recta, como se muestra en la Figura 20.

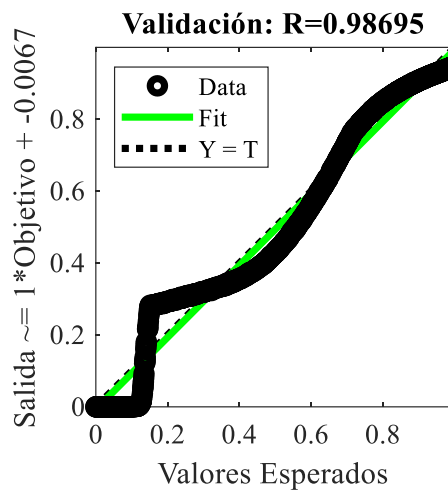
Figura 20: Regresión para el entrenamiento



Fuente: Elaboración propia

- B. **Validación:** muestra la precisión que tiene nuestros datos validados, pero en este caso la regresión es la segunda mejor, como se muestra en la Figura 21, por lo tanto, mientras más entrenamiento, o una forma más rápida de entrenar tendrá una mejor regresión, al inicio los valores de salida son cero, pero después crece lentamente.

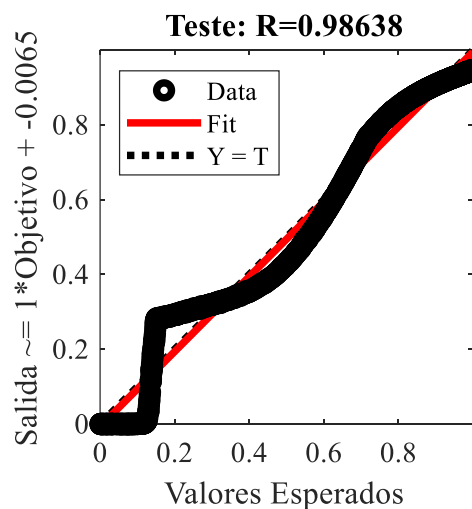
Figura 21: Regresión para la validación.



Fuente: Elaboración propia

- C. **Teste:** para la curva de salida la regresión es la más lejana a 1, pero con el transcurso del entrenamiento se espera siempre que tenga mejores valores, mismo así las curvas encontradas son de alguna forma cercanas al objetivo. Se muestra en la Figura 22.

Figura 22: Regresión para los testes



Fuente: Elaboración propia.

Para la discusión de las curvas, no solo se tienen que tomar en cuenta estos datos y ajustes, sino también los datos reales al inicio, ya que como se expresó pueden tener errores acumulativos, o datos en torno de cero.


6.3 CURVAS Y ERROS DO MODELO

Para entender un poco como funciona la carga en los datos de entrenamiento y observar después el comportamiento en las curvas de salida encontrada, se muestra la Figura 23, el comportamiento de la curva de carga de salida entrenada para el modelo deseado, siendo que estos valores están en función del tiempo. Como se observa la carga en toda batería a una

corriente mayor crece más rápido que a tensión constante, después de alcanzar el 100% de carga los valores de tensión y corriente caen a cero.

Como se sabe el BMS tiene por característica que la corriente y tensión no excedan los límites y a su vez monitorear el estado de temperatura de operación.


Figura 23: Curva de entrenamiento



Fuente: Elaboración propia.

Después de entrenada la red, se simularon los datos de teste, de cada una de las redes requeridas, para 3 A, 7,6 A, 11,4 A y la pila de litio a 0,52 A y seguidamente se graficaron los datos de salida. La grafica obtenida después de evaluar y probar los datos, se muestra en la Figura 24. Se puede observar que, en la curva de salida de sodio, se aprecia que al inicio es cargado de manera rápida, como se explicó esto debido a la corriente y al final más lento a tensión constante. Para la curva a 11,4 A y 7,6 A se nota un crecimiento rápido de carga en relación las otras dos, y cuando se empieza a carga a tensión constante las curvas no varían mucho una con la otra. Ambas curvas a corriente más grande que la de entrenamiento tiene casi el 100% de carga cuando la curva azul de 3 A recién está en un 75 % de carga.

Figura 24: Modelo de Curvas Seleccionadas



Fuente: Elaboración propia.

En las curvas de sodio tienen un leve pico, lo que se interpreta que hasta ese momento fue cargado el fierro, para después cargar el níquel, es de interés para curvas de descargar el momento en el que el BMS detecta que se descargó todo el níquel y está en la franja de fierro que es el límite para las descargar en las baterías, y rara vez se deja descargar hasta el final.

Por otro lado, analizando los datos de la pila de litio, carga un 60% a corriente constante, por lo cual su curva es más lenta que en comparación al sodio, después cuando el voltaje alcanza su límite, tiende a cargar más lento a una tensión constante y por consecuencia la corriente comienza a caer hasta cero, hasta que la pila este 100% cargada. Otro de los factores que se debe tener en cuenta es la temperatura, que en el caso de la batería de litio es casi temperatura ambiente, mientras que en la de sodio los valores son de tres cifras. Pero en ambas curvas los valores de temperatura variaron entorno de un grado o decimales.

Luego de encontrada las curvas, se procede a exportar los errores a través del error cuadrático medio, el cual se muestra en la siguiente Tabla 5, para hallar el error se utilizó la ecuación (3):

$$\%E = \left(\frac{\text{Datos de salida} - \text{Datos de referencia}}{\text{Datos de referencia}} \right) * 100 \tag{3}$$

Tabla 5: Errores del modelo seleccionado

<i>RED</i>	<i>%E</i>
Teste_3A	4,53
Teste a 7,6 A	4,80
Teste a 11,4 A	5,93
Teste_litio_0,520A	4,96

Fuente: Elaboración propia.


El error de la batería de 3 A es la menor, siendo que los datos son más cercanos al entrenamiento, con una curva con un 95% de rendimiento; ya los otros las corrientes tienen valores más grandes y hay una gran variación y por lo tanto más error respecto a la curva de salida del entrenamiento.

Para la curva de litio el rendimiento de la curva es de 95%, hay que tener en cuenta los parámetros para la carga de esta curva, así como el número de datos y otros factores que influncian en esta batería, pero en lo general va de acuerdo con lo esperado en una curva de litio.

Estos datos analizados corresponden al modelo esperado, ahora para las curvas descartadas, que se muestra en la Figura 25, se observó que cuando la red es entrenada con 10 neuronas y con una sola función de transferencia, tangente hiperbólica, tanto en la capa oculta

como en la salida, se aprecia un pico cuando la curva deja de ser cargada a corriente y pasa a tensión constante, lo cual no ocurre en la carga normalmente, por lo que se descartó.

Figura 25: Modelo descartado con 10 neuronas



Fuente: Elaboración propia.

Para corrientes más grandes el pico de carga bajo al momento de dejar de cargar el fierro y comenzar a cargar el níquel, y para cargas de 3 A en azul, apareció un pico creciente y después se estabilizo cuando empezó a cargar a tensión constante.

Al igual que en el modelo deseado el error para este modelo se presenta en la Tabla 6, el cual como se apreció tiene errores más significativos en relación a nuestros objetivo, pero no deja de ser una alternativa para otras aplicaciones. Los errores como mencionado anteriormente pueden ser debido a ajustes, datos, o incluso la cantidad de veces entrenada, entre otras.

Tabla 6: Errores del modelo descartado

<i>Red Descartada</i>	%E
Teste_3A	6,79
Teste a 7,6 A	8,37
Teste a 11,4 A	8,50
Teste_litio_0,520A	8,52

Fuente: Elaboración propia

Ahora para la misma red, pero con el número de neuronas modificado para 28, se puede apreciar en la Figura 26, que cuenta con picos hacia abajo. Para la curva azul a 3 A en el momento de cambia de un parámetro a otro el pico es más significativo que a 10 neuronas, que no es acorde con la forma de cargar del entrenamiento.


Para las curvas a corriente mayor, el comportamiento en la curva de 7,6 A se divide en dos líneas al inicio y después crece de forma recta paralela al eje “y”, cuando cambian a cargar a voltaje constantes es una línea recta, al igual que para una corriente de 11,4 A, por lo mismo expresado no van acorde a lo esperado.

Para la curva litio en casi toda la carga a corriente constante se observa unos pequeños picos de oscilación y cuando carga a tensión constante ya en el final de la carga se observa una línea recta paralela el eje “y” y después vuelve a la línea recta, lo que no va de acuerdo a lo esperado. Todos esos errores se pueden deber a diferentes factores.

Así como estas salidas, muchas otras fueron descartadas en el transcurso del entrenamiento, lo que hace parte de la investigación para llegar a un modelo parecido al ideal, muchos factores como el número de neuronas, la función de transferencia que puede ser lineales, hiperbólica, logarítmica, etc.; el tipo de arquitectura, la cantidad de valores, son ajustes que hace que las curvas de salida sean mejor de acuerdo a lo esperado.

Al igual que las curvas, los errores se encuentran en la Tabla 7, son demasiado grandes en relación al teste inicial con 10 neuronas, se debe al comportamiento que tiene la curva y que no va de acuerdo con las funciones asignadas para cada capa.

Figura 26: Entrenamiento con 28 neuronas



Fuente: Elaboración propia

Siendo que la curva más cerca es la de 3 A, tiene un error de 20%, lo que implica que la red tiene un rendimiento menor a 80 %, lo cual no va de acuerdo a nuestra curva.

Tabla 7: Errores del modelo descartado a 28 neuronas

<i>RED</i>	<i>%E</i>
Teste_3A	20,67
Teste a 7,6 A	26,11
Teste a 11,4 A	27,71
Teste_litio_0,520A	29,01

Fuente: Elaboración propia

Hay que tener en cuenta que estas curvas de salida están en función de la tensión y la corriente y no en función del tiempo, para estos entrenamientos el tiempo fue descartado ya que

no es un parámetro que va a influenciar en el comportamiento del BMS. Para el caso de la temperatura, es uno de los parámetros que debido a que no varío mucho, no influencia en las curvas cargas, pero si en el BMS, ya que él no comienza a cargar sino tiene la temperatura de operación requerida. Tanto para el sodio como para el litio los BMS son similares, pueden tener una que otra variación, pero cumplen la función de monitorear los limites tanto de tensión y corriente.

7 CONCLUSIONES

En conclusión, en este trabajo se mostró la implementación y el análisis de los resultados de una red neuronal artificial para la estimación del estado de carga de las baterías y así estudiar el comportamiento del BMS.

Los resultados muestran que, para el caso con corriente menor, 3 A, más cercano al modelo de entrenamiento, la curva de carga presenta un mejor comportamiento que en corrientes mayores. Es por ello, que es necesario más datos de entrada para el entrenamiento de la red, con más variaciones de corriente y temperatura para obtener un mejor análisis.

Por otro lado, hay que destacar que el mejor funcionamiento de la red, se dio al variar el número de neuronas en la capa oculta; lo que nos indica que una curva de carga es más eficiente al variar los ajustes en el entrenamiento.

Finalmente, el uso de redes neuronales para predecir aproximación de funciones, se puso en práctica y la red funciona para toda clase de baterías, como se puede apreciar en los resultados, fue generada la estimativa de carga para sodio y litio. Con todo, el BMS cumple con la característica de garantizar un mejor rendimiento y vida útil de la batería, al no dejar pasar los límites de corriente y tensión, así como empezar a cargar a una temperatura requerida.

Después de esta investigación, los trabajos futuros, basados en esta línea de investigación; como, por ejemplo:

- A. Trabajos con variaciones de temperaturas más grandes en operaciones.
- B. Modelaje de la capacidad de la batería en función de los ciclos, para encontrar el estado de vida de la batería.
- C. Estado de carga independiente del uso, por ejemplo, en vehículos eléctricos, para eliminar el error acumulativo por causa de interferencias, que hace que el BMS pare en un 100% de carga no real.
- D. Por último, reutilizar las baterías para sistemas estacionarios en el campo de las energías renovables y modelar las curvas en estas nuevas aplicaciones.

REFERENCIAS BIBLIOGRÁFICAS

- BALLESTEROS GONZÁLES, A. **Clasificación de las Redes Neuronales Artificiales**, 2006. Proyecto Final de Grado.
- BECK, R. F. **Baterias Tecnologias e Aplicaçao em GD**. 2019.
- BENATTI, K. A. **O Método de Levenberg-Marquardt para o Problema de Quadrados Mínimos não Linear**. Simpósio de Métodos Numéricos em Engenharia, n. 4, 2017.
- BOBBY. **What is a Sodium-nickel chloride Na-NiCl₂ battery?** 2014. *E-book*.
- CHAOUI, H; IBE-EKEOCHA, C. C. **State of Charge and State of Health Estimation for Lithium Batteries Using Recurrent Neural Networks**. IEEE Transactions on Vehicular Technology, v. 66, n. 10, p. 8773–8783, 2017.
- CHATURVEDI, N. A.; KLEIN, R.; CHRISTENSEN, J. *et al.* **Modeling, estimation, and control challenges for lithium-ion batteries**. In: 2010 AMERICAN CONTROL CONFERENCE (ACC 2010) 2010, Baltimore, MD. Proceedings of the 2010 American Control Conference. Baltimore, MD: IEEE, 2010. p. 1997–2002.
- EASE. **Sodium-nickel-chloride Battery Report**. p. 1–2, 2019.
- ELECTRILABS (PTY) LTD. **Sodium Nickel Batteries**. 2018. Disponível em: <https://www.electrilabs.co.za>
- EMPRESA DE PESQUISA ENERGÉTICA. **Relatório Síntese. BEN 2019 Ano Base 2018**. Rio de Janeiro: *Maio*, 2019. Informe Anual.
- FIAMM, Sonick. **Sodium Nickel Technology for Energy Storage Application**. Montecchio Maggiore, 2014.
- FILHO, T. T. **Influência da qualidade do pó de zinco na geração de hidrogênio em pilhas alcalinas**. 2007. Dissertação de Mestrado - Universidade Federal de Minas Gerais, Minas Gerais, 2007.
- GAVIN, H. P. **The Levenburg-Marquardt Algorithm For Nonlinear Least Squares Curve-Fitting Problems**. Duke University, p. 1–19, 2019.
- GRIDEDGE (org.). **Recycling of Sodium Nickel Batteries**. Australia: 2017.
- HAQ, I. N.; LEKSONO, E.; IQBAL, M.; et al. **Development of battery management system for cell monitoring and protection**. In: 2014, 2014 International Conference on Electrical Engineering and Computer Science (ICEECS). p. 203–208.
- HAYKIN, S. S. **Neural networks and learning machines**. 3rd ed. New York: Prentice Hall, 2009. *E-book*.
- JIMÉNEZ LÓPEZ, J. C. **Componentes de una Instalación Fotovoltaica**. In: La Energia Solar en Internet. 2018.

JULIÁN, D.; PATARROYO, R.; ALEXANDER, R.; et al. **Sistemas de gestión de baterías (BMS) y su importancia para los sistemas de almacenamiento de baterías (BESS)**. Tecnura, v. 19, p. 51–56, 2015.

KAUFFMANN, R. **BATERIAS ENERGIA DE IÓN LÍTIO**. Rio de Janeiro, 2008. Manual de Usuario.

LINDA. **SoNick battery BMS or Battery Management System**, 2017.

MARTÍNEZ BERTRAN, J. **Métodos de estimación del estado de carga de baterías electroquímicas**. 2017. Trabajo de Final de Grado - Escola Tècnica Superior d'Enginyeria Industrial de Barcelona, Bcelona, 2017.

MCCULLOCH, W. S.; PITTS, W. **A logical calculus of the ideas immanent in nervous activity**. The bulletin of mathematical biophysics, v. 5, n. 4, p. 115–133, 1943.

MEISSNER, E; RICHTER, G. **Battery Monitoring and Electrical Energy Management**. Journal of Power Sources, v. 116, n. 1–2, p. 79–98, 2003.

PLETT, G. L. **Battery Management Systems, Volume II: Equivalent-Circuit Methods** Artech House, 2015. (Artech House power engineering series). *E-book*.

RAHIMI-EICHI, H.; OJHA, U.; BARONTI, F.; et al. **Battery Management System: An Overview of Its Application in the Smart Grid and Electric Vehicles**. IEEE Industrial Electronics Magazine, v. 7, n. 2, p. 4–16, 2013.

RUIZ, C. A.; BASUALDO, M. S.; MATICH, D. J. **Redes Neuronales: Conceptos Básicos y Aplicaciones**. p. 55, 2015.

SCHROEDER, R.; GATTIGLIO, F. **Battery Technology For Vehicle Applications**. Eurobat - European Automotive and Industrial Battery Manufacturers, 2015.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas**. São Paulo: Artliber, 2010.

SINGH, S. **Backpropagation Learning Algorithm Based on Levenberg Marquardt Algorithm**. v. 2 *E-book*.

TEPÁN, A.; CRISTINA, E. **Estudio de los principales tipos de redes neuronales y las herramientas para su aplicación**. 2013. Graduación - Universidad Politécnica Salesiana, Cuenca, 2013.

VALDIVIA MIRANDA, C. **Diseño de un BMS para baterías de tecnología Li-ion**. 2018.

ZONG-YOU HOU; PANG-YEN LOU; WANG, C.-C. **State of charge, state of health, and state of function monitoring for EV BMS**. In: 2017 IEEE INTERNATIONAL CONFERENCE ON CONSUMER ELECTRONICS (ICCE) 2017, Las Vegas, NV, USA. 2017 IEEE International Conference on Consumer Electronics (ICCE). Las Vegas, NV, USA: IEEE, 2017. p. 310–311.