



Modelado computacional de acumuladores de energía según sus especificaciones técnicas basados en datos y circuitos equivalentes

Juan Carlos Martínez Torres

Universidad Magdalena

Facultad de Ingeniería

Programa de Ingeniería Electrónica

Santa Marta, Colombia

2023



Modelado de acumuladores de energía según sus especificaciones técnicas basados en datos y circuitos equivalentes

Juan Carlos Martínez Torres

Trabajo presentado como requisito parcial para optar al título de:
Ingeniero Electrónico

Director (a):

Magíster en Ingeniería, Víctor José Olivero Ortiz

Codirector (a):

Doctor en ciencias, Carlos Arturo Robles Algarín

Codirector (a):

Ingeniero Electrónico, Andrés Felipe Valle González

Grupo de Investigación

Magma Ingeniería

Universidad del Magdalena

Facultad de Ingeniería

Programa de Ingeniería Electrónica

Santa Marta, Colombia

2023

Nota de aceptación:

Aprobado por el Consejo de Programa
en cumplimiento de los requisitos
exigidos por la Universidad del
Magdalena para optar al título de
Ingeniero Electrónico

Jurado

Jurado

Santa Marta, ____ de ____ del _____

(Dedicatoria o lema)

De Juan:

*Dedicado especialmente a mis padres: Juan Carlos
Martínez Vargas y Yadira Isabel Torres Algarra.*

Agradecimientos

Primeramente, quiero empezar dando gracias a Dios por todo. Después de esto, agradecer a mis padres; Juan Carlos Martínez Vargas y Yadira Isabel Torres Algarra por ayudarme a cumplir una de mis metas apoyándome en todos los aspectos posibles, también agradecer a mi director de tesis: Ing. Víctor Jose Olivero Ortiz, quien me apoyo y confió en mí desde un principio y por consiguiente me ayudó a dar mis primeros pasos en el camino de la investigación, a los codirectores; Carlos Arturo Robles Algarín, Andrés Felipe Valle González y a todos los profesores que directa o indirectamente aportaron durante toda la carrera de pregrado para convertir un sueño en realidad, el cual consistía en conquistar la formación profesional de la carrera de Ingeniería Electrónica en la Universidad del Magdalena.

Resumen

Los acumuladores de energía son indispensables para los sistemas que requieren acumulación y suministro de energía eléctrica como: la movilidad eléctrica, sistemas de generación distribuida, dispositivos electrónicos portátiles, entre otros. De esta forma, cada día se requieren acumuladores de energía que soporten diferentes condiciones de operación. Por lo antes mencionado, este trabajo propone implementar modelos de circuito equivalente y basado en datos para acumuladores de energía de las tecnologías de Litio (Li) y Plomo (Pb) que puedan describir el comportamiento dinámico de la descarga bajo diferentes condiciones de operación. Para esto, se propone una forma de adquirir datos de voltaje, corriente y temperatura de los acumuladores de energía, valiéndose de una solución de bajo costo, pero que posee propiedades altamente confiables que garantizan la exactitud y el correcto almacenamiento de la información en una base de datos que ofrece flexibilidad para exportarlos a herramientas computacionales para el análisis y tratamiento de estos. Partiendo de los datos obtenidos, haciendo uso de las herramientas que brinda el software Matlab como Curve Fitting, se logra realizar un modelo de circuito equivalente basado en el modelo de polarización dual y con la herramienta Neural Net Fitting, modelos basados en datos ajustando redes neuronales, con los cuales se lograron buenos resultados comprobados por métricas estadísticas como el coeficiente de determinación y el error medio cuadrático.

Keywords: IOT, acumuladores de energía, protocolo MQTT, circuitos equivalentes, modelos basados en datos.

Contenido

	Pág.
Contenido	1
Objetivos	6
General.....	6
Específicos	6
Capítulo 1. Adquisición de datos de corriente, tensión y temperatura de los acumuladores de energía bajo diferentes condiciones de operación	7
Introducción	7
Descripción y características de los componentes.....	9
Procedimientos y resultados.....	14
Procedimiento para batería de Litio LifePO4.....	15
Procedimiento para la batería de Plomo (Pb)	16
Algoritmo de descarga.....	19
Resultados.....	21
Referencias	23
Capítulo 2: Selección de modelo de circuito equivalente y modelo basado en datos para los acumuladores de energía de las tecnologías de Litio y Plomo	26
Introducción	26
Modelo de circuito equivalente.....	28
Modelo computacional.....	28
Modelo analítico	31
Modelo basado en datos.....	34
Resultados.....	35
Referencias	48
Capítulo 3: Contraste de los modelos obtenidos por cada tecnología de acumulador	50
Introducción	50
Contraste del modelo de circuito equivalente.....	51
Contraste del modelo basado en datos.....	59
Referencias	66
Conclusión	68
Nota 68	
Anexos	69

Lista de figuras

	Pág.
Figura 1. Arquitectura del internet de las cosas (IOT) [1]	7
Figura 2. Sensor de voltaje FZ0430	10
Figura 3. Sensor de corriente WCS1800	11
Figura 4. Sensor de temperatura DS18B20.....	11
Figura 5. Módulo ADS1115.....	12
Figura 6. Gráfica del comportamiento de lectura de los puertos ADC de una ESP32 [8].....	12
Figura 7. Tarjeta de desarrollo ESP32.....	13
Figura 8. Raspberry Pi 3+.....	14
Figura 9. Conexión del sistema general para la adquisición y almacenamiento de los datos.....	14
Figura 10. Características del acumulador de energía de Litio (Li) entregadas por el fabricante [30]	15
Figura 11. Gráfica de las tasas de descarga para la batería de Litio (Li) entregadas por el fabricante [30]	16
Figura 12. Características del acumulador de energía de Plomo (Pb) entregadas por el fabricante [31]	17
Figura 13. Gráfica de las curvas de descarga para el acumulador de Plomo (Pb) entregada por el fabricante [31].....	18
Figura 14. Algoritmo para la adquisición de datos.....	20
Figura 14. A) Gráfica del voltaje, b) Gráfica de corriente y c) Gráfica de temperatura de la batería de LIFEP04 para 0.2C.....	21
Figura 15. A) Gráfica de voltaje, b) Gráfica de corriente y c) Gráfica de temperatura de la batería de LIFEP04 para 0.3C.....	21

Figura 16. A) Gráfica de voltaje, b) Gráfica de corriente y c) Gráfica de temperatura de la batería de LIFEP04 para 0.4C.....	22
Figura 17. A) Gráfica de voltaje, b) Gráfica corriente y c) Gráfica de temperatura del acumulador de Plomo NPD12-75AH para 0.2C.....	22
Figura 18. A) Gráfica de voltaje, b) Gráfica de corriente y c) Gráfica de temperatura del acumulador de Plomo NPD12-75AH para 0.3C	22
Figura 19. A) Gráfica de voltaje, b) Gráfica de corriente y c) Gráfica de temperatura del acumulador de Plomo NPD12-75AH para 0.4C	23
Figura 21. Modelos de acumuladores de energía [20].	27
Figura 21. Gráficas del ajuste exponencial a las curvas de tasas de descarga 0.2C, 0.3C y 0.4C en la batería de Litio.....	30
Figura 22. Graficas del ajuste exponencial para las curvas de tasas de descarga 0.2C, 0.3C y 0.4C respectivamente en la batería de Plomo.....	30
Figura 23. Modelo ECM de polarización dual o RC de 2do orden [15]......	32
Figura 24. Gráfica de una red neuronal en la app Neural Net Fitting de Matlab....	34
Figura 25. Gráfica de la red neuronal para la tasa de descarga 0.2C en el acumulador de Litio.....	36
Figura 26. Gráfica del ajuste por regresión en la tasa de descarga 0.2C en el acumulador de Litio.....	37
Figura 27. Gráfica de la red neuronal para la tasa de descarga 0.3C en la batería de Litio.....	38
Figura 28. Gráfica de la regresión para cada conjunto de datos en la tasa de descarga 0.3C	39
Figura 29. Gráfica de la red neuronal para la tasa de descarga 0.4C en el acumulador de Litio.....	40
Figura 30. Gráfica de regresión para el conjunto de datos en la tasa de descarga 0.4C en el acumulador de Litio	41
Figura 31. Red neuronal para la tasa de descarga 0.2C en la batería de Plomo ...	42
Figura 32. Gráfica de regresión para el conjunto de datos en la tasa de descarga 0.2C en el acumulador de Plomo	43
Figura 33. Red neuronal para la tasa de descarga 0.3C en la batería de Plomo ...	44
Figura 34. Gráfica de regresión para el conjunto de datos en la tasa de descarga 0.3C en el acumulador de Plomo	45
Figura 35. Red neuronal para la tasa de descarga 0.4C en la batería de Plomo ...	46
Figura 36. Gráfica de regresión para el conjunto de datos en la tasa de descarga 0.4C en el acumulador de Plomo.....	47

Figura 37. Gráfica de las tasas de descarga para el acumulador de energía de Litio	51
Figura 38. Gráfica de las tasas de descarga para el acumulador de energía de Plomo	52
Figura 39. Gráfica de la comparación de las tasas de descarga de 0.2C	53
Figura 40. Gráfica de la comparación de las tasas de descarga de 0.3C	53
Figura 41. Gráfica de la comparación de las tasas de descarga de 0.4C	54
Figura 42. Gráfica del ajuste exponencial a la curva de descarga 0.2C en la batería de Litio	55
Figura 43. Gráfica del ajuste exponencial a la curva de voltaje de 0.3C en la batería de Litio	55
Figura 44. Gráfica del ajuste exponencial para la curva de voltaje de 0.4C en la batería de Litio	56
Figura 45. Gráfica del ajuste exponencial para la curva de voltaje de 0.2C en la batería de Plomo.....	57
Figura 46. Gráfica del ajuste exponencial para la curva de voltaje de 0.3C en la batería de Plomo.....	57
Figura 47. Gráfica del ajuste exponencial para la curva de voltaje de 0.4C en la batería de Plomo.....	58
Figura 48. Gráfica de MSE vs épocas para la tasa de descarga de 0.2C en el acumulador de Litio.....	61
Figura 49. Gráfica de MSE vs épocas para la tasa de descarga de 0.3C en el acumulador de Litio.....	61
Figura 50. Gráfica de MSE vs épocas para la tasa de descarga de 0.4C en el acumulador de Litio.....	62
Figura 51. Gráfica de MSE vs épocas para la tasa de descarga de 0.2C en el acumulador de Plomo	63
Figura 52. Gráfica de MSE vs épocas para la tasa de descarga de 0.3C en el acumulador de Plomo	63
Figura 53. Gráfica de MSE vs épocas para la tasa de descarga de 0.4C en el acumulador de Plomo	64
Figura 54. Gráfica del modelo de caja negra [22]	65
Figura 56. Datos entregados por el fabricante del acumulador de Litio [30].....	70
Figura 57. Datos entregados por el fabricante del acumulador de Plomo [31]	71
Figura 58. Continuación de la información del fabricante del acumulador de Plomo [31]	72

Lista de tablas

	Pág.
Tabla 1. Valores de tasas de descargas para la batería de Litio (Li), corrientes en descargas y tiempo	16
Tabla 2. Valores de tasas de descarga para la batería de Plomo (Pb), corrientes en descarga y tiempos	18
Tabla 3. Valores de resistencias aproximados para consumir las diferentes corrientes para las tasas de descarga.	19
Tabla 4. Valores de a, b, c y d para cada tasa de descarga en el acumulador de energía correspondiente	30
Tabla 5. Valores de voltaje de circuito abierto y corriente de descarga para cada acumulador de energía.....	33
Tabla 6. Valores de las métricas de errores para la tasa de descarga 0.2C en el acumulador de Litio.....	36
Tabla 7. Valores de las métricas de errores para la tasa de descarga de 0.3C en la batería de Litio	38
Tabla 8. Valores de las métricas de errores para la tasa de descarga de 0.4C en la batería de Litio	40
Tabla 9. Valores de las métricas de errores para la tasa de descarga de 0.2C en la batería de Plomo.....	42
Tabla 10. Valores de las métricas de errores para la tasa de descarga de 0.3C en la batería de Plomo.....	44
Tabla 11. Valores de las métricas de errores para la tasa de descarga de 0.4C en la batería de Plomo.....	46
Tabla 12. Valores de las métricas de ajuste entregadas por Curve Fitting para ambos acumuladores de energía	59
Tabla 13. Comparación de las neuronas establecidas en cada red neuronal para cada tasa de descarga.....	60

Tabla 14. Ecuaciones que surgen del modelo de circuito equivalente y el modelo computacional 69

Objetivos

General

Modelar acumuladores de energía a partir de sus especificaciones técnicas utilizando modelos basados en datos, circuito equivalente y expresiones matemáticas en un ambiente de simulación asistido por computadora.

Específicos

1. Adquirir datos de corriente, tensión y temperatura para diferentes condiciones de operación de acumuladores de energía.
2. Seleccionar un modelo de circuito equivalente y un modelo orientado a datos para acumuladores de energía basados en Plomo (Pb) y Litio (Li).
3. Contrastar los datos obtenidos por cada análisis de las tecnologías de acumuladores de energía estudiadas.

Capítulo 1. Adquisición de datos de corriente, tensión y temperatura de los acumuladores de energía bajo diferentes condiciones de operación

Introducción

El internet de las cosas (IOT), se ha vuelto indispensable en los últimos años, gracias a que permite la comunicación entre dispositivos digitales y a su vez, la conexión de éstos con el entorno e interacción con los seres humanos. En la literatura se logran identificar dos tipos de arquitecturas que se usan según el tipo de aplicación. Éstas se pueden observar en la Figura 1 [1].

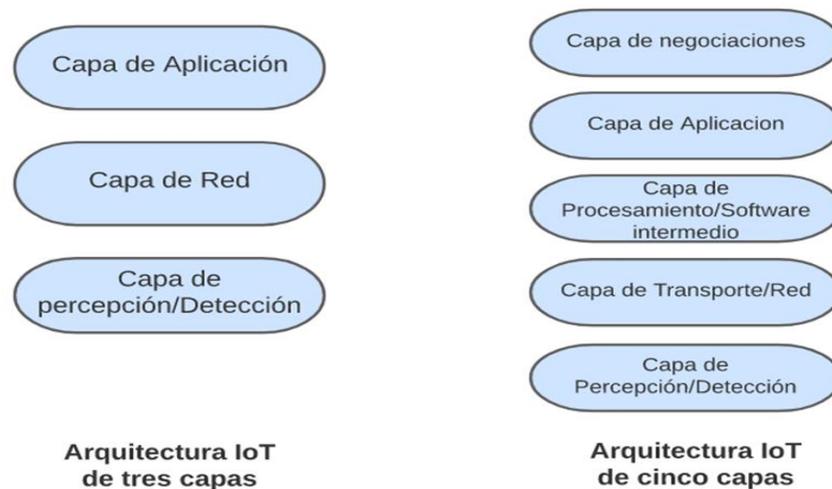


Figura 1. Arquitectura del internet de las cosas (IOT) [1]

En el año 2015, se contaba con alrededor de quince mil millones de dispositivos conectados a internet. Esto, contando con redes de dispositivos como puertas de enlace, servicios en la nube, actuadores y sensores interconectados entre sí, con el fin de ofrecer un servicio específico. Para el año 2020, la cantidad de elementos conectados creció

hasta llegar a alrededor de treinta mil millones de dispositivos y se espera que esta cantidad, se vuelva a incrementar exponencialmente para la década siguiente [2].

Por otro lado, los protocolos de comunicación o protocolos de mensajería son indispensables para una correcta transmisión y comunicación, entre los cuales se destacan Hypertext Transfer Protocol (HTTP), Advanced, Constrained Application Protocol (CoAP), Extensible Messaging and Presence Protocol (XMPP), Data Distribution Service (DDS), Message Queueing Protocol (AMQP), MQ Telemetry Transport (MQTT), entre otros. El protocolo MQTT, el cual traduce Transporte de Telemetría de Cola de Mensaje; es ampliamente utilizado con el servidor MQTT Mosquitto, el cual funciona bajo el paradigma publicador-subscriptor para la comunicación M2M (Machine To Machine) [3]. A este protocolo de comunicación se le ve un futuro prometedor para aplicación de IOT en las industrias debido a las virtudes en materia de eficiencia, flexibilidad, compatibilidad entre módulos, plataformas, máquinas, entre otras particularidades que éstos comparten [4].

Entre las tantas aplicaciones del internet de las cosas (IOT), está el monitorear sistemas de acumulación de energía (Paquetes de baterías); capturar los datos de corriente, voltaje y temperatura de estos dispositivos durante la carga y descarga a través de sensores, y recibirlos mediante tarjetas de desarrollo como lo es la ESP32 por sus puertos análogos y digitales y enviarlos por la tecnología incorporada en la ESP32, Bluetooth Low Energy (BLE), a un servidor MQTT instalado y configurado en una Raspberry Pi, cómo se implementa en [5].

Aparte, existen módulos conversores análogo-digital, los cuales facilitan la lectura y tratamiento de estas. Dentro de la variedad existente de ADC (Conversores Análogo-Digital) es oportuno mencionar el ADS1115, que cuenta con una resolución de hasta 16 bits, además utilizan protocolo I2C, lo que permite asignar direcciones únicas a los

diferentes sensores, por lo tanto, se utiliza un solo pin de datos de la tarjeta de desarrollo que se esté utilizando para la lectura. Por lo antes mencionado, los módulos ADS1115 ofrecen mejores prestaciones frente a los pines analógicos de las tarjetas de desarrollo como Arduino, ESP32, entre otras [6].

Hoy en día, con el necesario cambio de energías tradicionales a renovables se hace necesario el uso de sistemas que logren almacenar energía proveniente de sistemas eólicos, fotovoltaicos, entre otros de una forma eficiente[6]. Por lo antes mencionado desde hace tiempo se viene trabajando en modelos que ayuden a estudiar y apreciar el comportamiento de los diferentes parámetros y procesos que suceden en los acumuladores de energía.

Descripción y características de los componentes

En el mercado de componentes electrónicos y tecnológicos existe una gran variedad de sensores y tarjetas de desarrollo, entre otros componentes, que se destacan por ser soluciones eficientes a bajo costos. No obstante, dichos componentes deben ser seleccionados de manera que sus características funcionales favorezcan la aplicación que se desea implementar, como se aprecia en [7].

A partir del estudio de la hoja de especificaciones de sensores de corriente, voltaje, temperatura, y tarjetas de desarrollo, se seleccionaron los dispositivos que se describen a continuación, para la correcta captura y almacenamiento de los datos.

Para la lectura del voltaje en las terminales de los acumuladores de energía, se opta por usar el sensor FZ0430, el cual consta de un simple divisor de voltaje, con una relación 5:1. Este cuenta con un rango de lectura de 0 a 25v cuando cuenta con una alimentación de 5v, y hasta 16.5v cuando se alimenta con 3.3v. Este se puede apreciar en la figura 2.

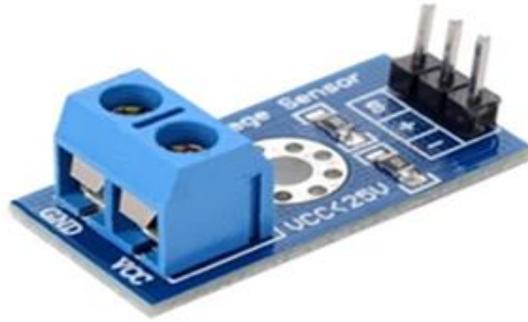


Figura 2. Sensor de voltaje FZ0430

Ahora, para capturar los datos de corriente que se está extrayendo de la batería, se utiliza un sensor que funciona bajo el efecto Hall, el cual permite medir corrientes DC de ± 35 A con una resolución de 60 mV/A. Esto quiere decir, que el sensor entrega un voltaje proporcional a la corriente que está pasando por el anillo del sensor.

El sensor WCS1800 cuenta con características importantes para esta investigación, la primera es que no es invasivo, es decir, que no necesita interrumpir el conductor para sensar la corriente que pasa por él, y, por otro lado, tiene un comportamiento lineal para el rango de corrientes que se van a manejar en este trabajo de investigación. Este sensor se puede apreciar en la figura 3.

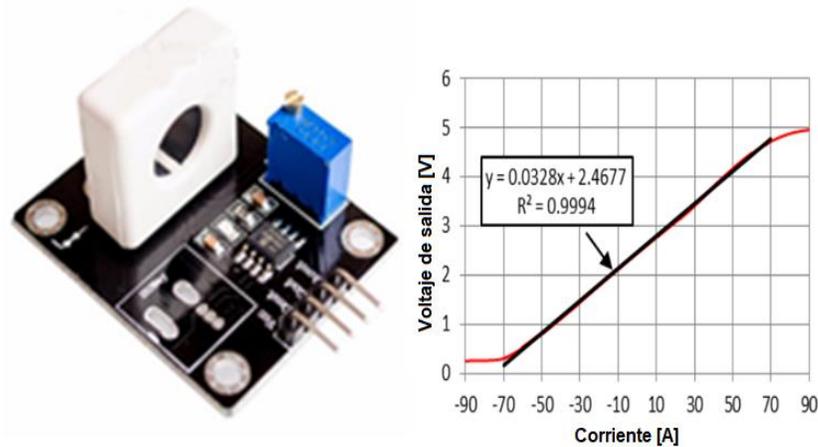


Figura 3. Sensor de corriente WCS1800

Por último, para obtener datos de la temperatura en la superficie de la batería, se unió el sensor en la parte superior del acumulador y se tomaron los datos durante todo el proceso del experimento. Para esto se usó del sensor de temperatura DS18B20, el cual logra medir un amplio rango de temperaturas que va desde -55°C hasta 125°C con un error de 0.5°C para temperaturas entre -10°C hasta 85°C . Este envía datos digitales de la temperatura mediante el protocolo One-wire con una resolución programable entre 9 a 12 bits. En la figura 4 se puede apreciar la imagen de este.



Figura 4. Sensor de temperatura DS18B20

Debido a inconvenientes de linealidad con los puertos análogo – digital de la ESP32, la cual se puede apreciar en la figura 6, se optó por utilizar el módulo ADS1115 (figura 5). Este es un conversor análogo-digital (ADC) con una resolución de 16 bits que se

comunica mediante el protocolo I2C. Este tendrá la función de leer los datos de los sensores de voltaje y corriente y enviarlos a la ESP32.



Figura 5. Módulo ADS1115

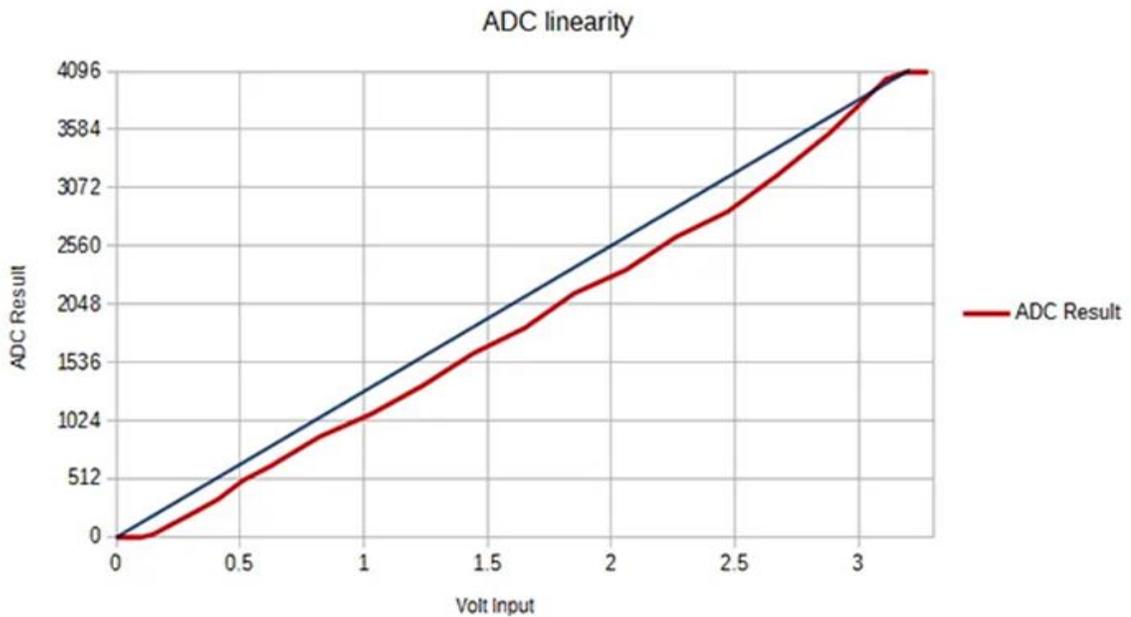


Figura 6. Gráfica del comportamiento de lectura de los puertos ADC de una ESP32 [8]

Ahora, para la adquisición de los datos suministrados por los sensores de corriente y voltaje a través del módulo ADS1115 mediante el protocolo I2C y el sensor de

temperatura, se utiliza una placa de desarrollo ESP32 (figura 7), la cual enviará los datos mediante el módulo Wifi con el que cuenta. Esta herramienta utiliza el protocolo MQTT en el rol de publicador para enviar estos datos al servidor del grupo de investigación Magma, en el cual se encuentra instalado el servidor MQTT. A este estarán conectados dos suscriptores, estos son la Raspberry Pi 3+ y una computadora portátil como respaldo. En los dos suscriptores se generan archivos Excel donde se almacenan los datos de los tópicos de voltaje, corriente y temperatura y fecha.



Figura 7. Tarjeta de desarrollo ESP32.

Como se ha mencionado antes, en una Raspberry Pi 3+, se encuentra previamente instalado un servidor MQTT Mosquitto, el cual se encarga de capturar los datos que son enviados por la esp32 (publicador) y almacenarlos en el servidor del grupo de investigación Magma para posteriormente enviarlos a clientes en modalidad de suscriptores (raspberry y pc) en un archivo .xls.



Figura 8. Raspberry Pi 3+

Cada uno de estos elementos se interconecta con el fin de crear un sistema para obtener y almacenar de forma correcta, los datos de corriente, tensión y temperatura para cada tasa de descarga que se extraerán de los acumuladores de energía, como se puede apreciar en la figura 9.

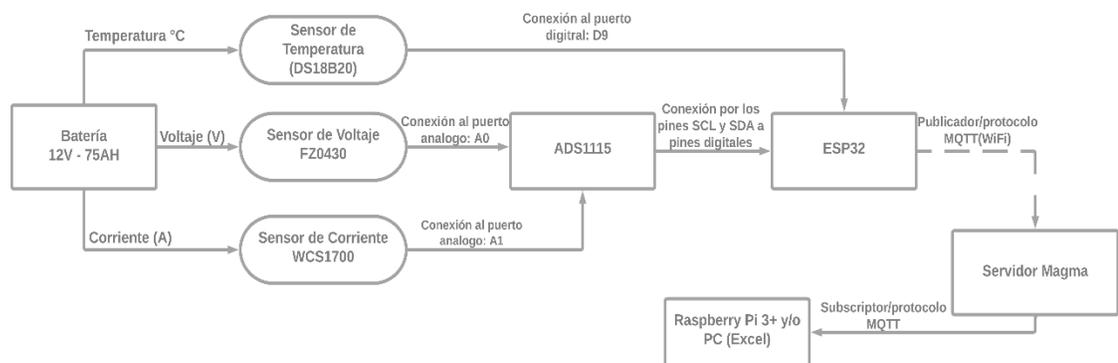


Figura 9. Conexión del sistema general para la adquisición y almacenamiento de los datos

Procedimientos y resultados

Para reconstruir las gráficas de las distintas curvas de descargas de las baterías de Litio y Plomo, se detallan los siguientes procedimientos para las diferentes tecnologías de acumuladores de energía, con el fin de obtener los datos que forman algunas de las

curvas de las tasas de descarga que se aprecian en las hojas de especificaciones entregadas por el fabricante, las cuales se detallan más adelante.

Procedimiento para batería de Litio LifePO4

Se toma para el primer procedimiento la batería de Litio con las siguientes características

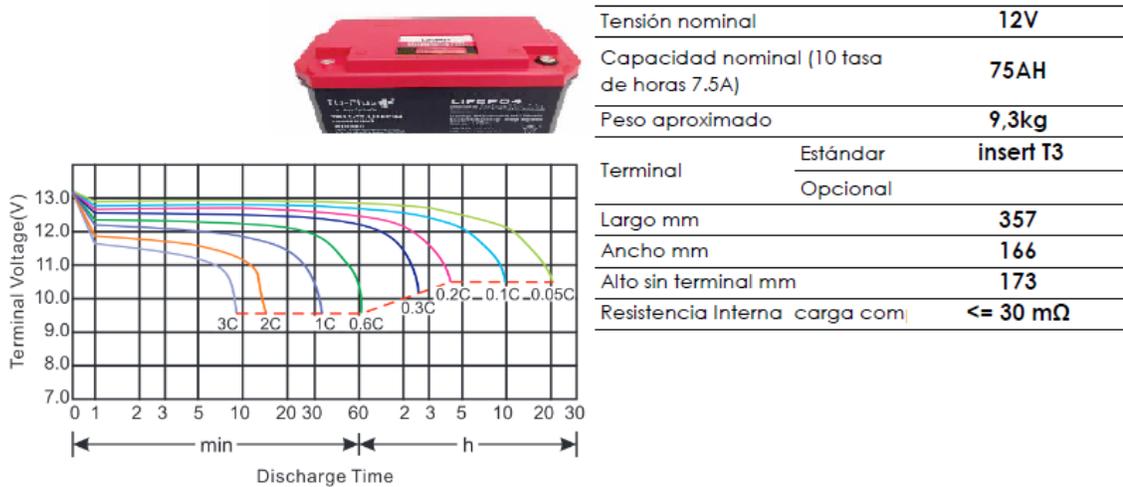


Figura 10. Características del acumulador de energía de Litio (Li) entregadas por el fabricante [30]

Para el procedimiento con el acumulador de energía de la tecnología Litio, se establecen los valores de corriente de descarga y tiempos que se necesitan para cada tasa de descarga. En la tabla 1, se logra apreciar el consumo de corriente que debe exigir la carga para cada tasa de descarga, calculada a partir de la ecuación 1 y el tiempo que dura cada una de ellas, el cual es estimado a partir de la figura 11.

$$I_u = I_n * C$$

Ecuación 1. Para calcular la corriente de descarga para las diferentes tasas de descarga [9]

Donde I_u , se refiere a la corriente de descarga o también conocida como la corriente en uso. I_n , es la capacidad nominal de la batería que para este caso es de 75 Ah y, por último, C es la tasa de descarga que se halla de la batería.

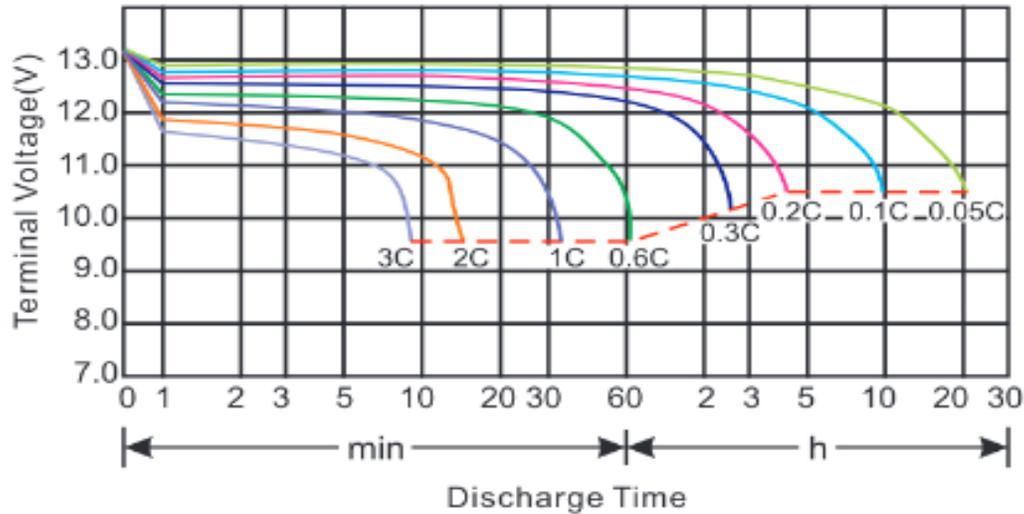


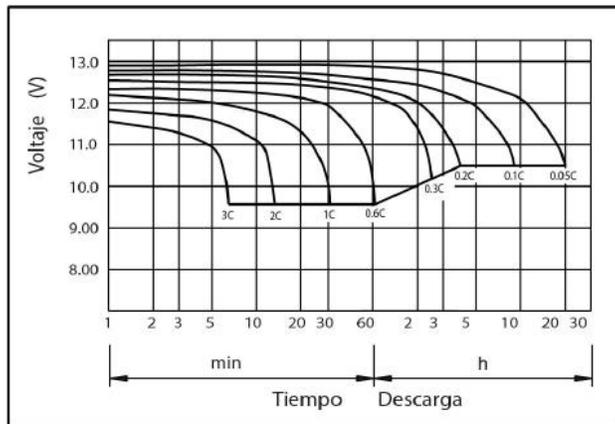
Figura 11. Gráfica de las tasas de descarga para la batería de Litio (Li) entregadas por el fabricante [30]

Tasa de descarga	Corriente en descarga (A)	Tiempo (Horas)
0.2	15.0 A	4h-40min
0.3	22.5 A	2h-40min
0.4	30.0 A	2h-20min

Tabla 1. Valores de tasas de descargas para la batería de Litio (Li), corrientes en descargas y tiempo

Procedimiento para la batería de Plomo (Pb)

Las características del acumulador de energía de tecnología de Plomo se pueden apreciar en la figura 12.



Voltaje Nominal		12 V
Capacidad Nominal (indice de 20 horas)		75 Ah
Dimensiones	Largo	260 ± 2 mm
	Ancho	168 ± 2 mm
	Altura	211 ± 2 mm
	Altura Total	215 ± 2 mm
Peso Aproximado		24.2kg (53.3lbs) ± 3%

Figura 12. Características del acumulador de energía de Plomo (Pb) entregadas por el fabricante [31]

Para el procedimiento con el acumulador de energía de Plomo, debido a que el voltaje y la capacidad nominal son las mismas que el caso de la batería de Litio, se establecen los mismos valores de corriente, pero los tiempos de descarga, para este procedimiento si varían. Estos se pueden estimar estudiando la gráfica de descarga que se encuentra en la figura 13, y en la tabla 2 se pueden apreciar los valores de corriente y tiempo para las tasas de descarga correspondientes.

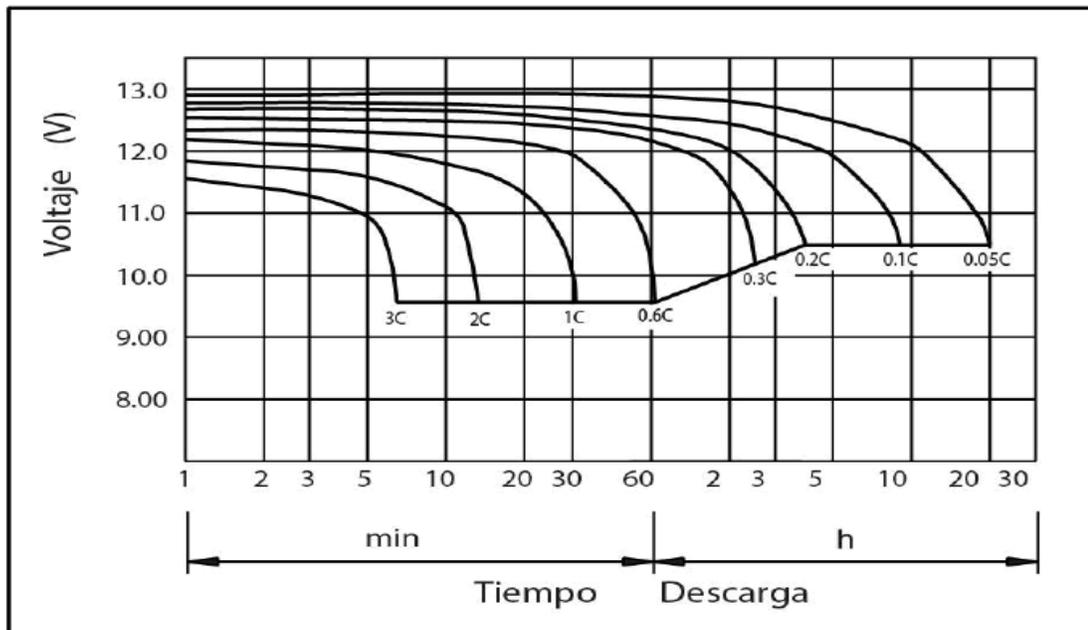


Figura 13. Gráfica de las curvas de descarga para el acumulador de Plomo (Pb) entregada por el fabricante [31]

Tasa de descarga	Corriente de descarga (A)	Tiempo (Horas)
0.2	15.0 A	4h-20min
0.3	22.5 A	2h-35min
0.4	30.0 A	1h-50min

Tabla 2. Valores de tasas de descarga para la batería de Plomo (Pb), corrientes en descarga y tiempos

Para el caso de los dos experimentos, debido a las limitaciones que genera el sensor de corriente, se opta por hacer las tasas de descarga de 0.2, 0.3 y 0.4. Como carga, se utiliza el Nicromo (carga resistiva), a este se le irá variando la longitud y, por ende, la resistencia. Esta se conecta a un inversor de onda pura de 600w, el cual se alimenta con un voltaje de 12Vdc que viene del acumulador de energía y tiene una salida 110Vac

donde se conecta la carga, para de esta forma, poder consumir las diferentes corrientes que se necesitan para cada tasa de descarga, esto se puede apreciar en la tabla 3.

Tasa de descarga	Consumo de corriente DC (A)	Consumo de corriente AC (A)	Resistencia (Ω)
0.2C	15.0 A(cd)	1.4835 A(ca)	75.1600 Ω
0.3C	22.5 A(cd)	2.2253 A(ca)	50.1056 Ω
0.4C	30.0 A(cd)	2.9670 A(ca)	37.5800 Ω

Tabla 3. Valores de resistencias aproximados para consumir las diferentes corrientes para las tasas de descarga.

Algoritmo de descarga

1. Inicio.
2. Configurar el banco de carga para la tasa de descarga correspondiente.
3. Verificar que la batería esté cargada.
4. Se conecta la tarjeta de adquisición de datos a la batería, de modo que, el sensor de voltaje. Pueda sensar el voltaje en las terminales y el sensor de temperatura registre los datos de temperatura del acumulador de energía y el sensor de corriente tome datos de la intensidad extraída de la batería.
5. Energizar la tarjeta de adquisición de datos (programada previamente para tomar datos cada 5 segundos durante el tiempo de descarga).
6. Se conecta el banco de cargas al inversor y el inversor a las terminales de la batería de manera que, el cable positivo pase a través del sensor de corriente.
7. Una vez terminado el tiempo de descarga de la batería, se desconecta el banco de cargas apagando el inversor.
8. Se toman datos del reposo del acumulador de energía.

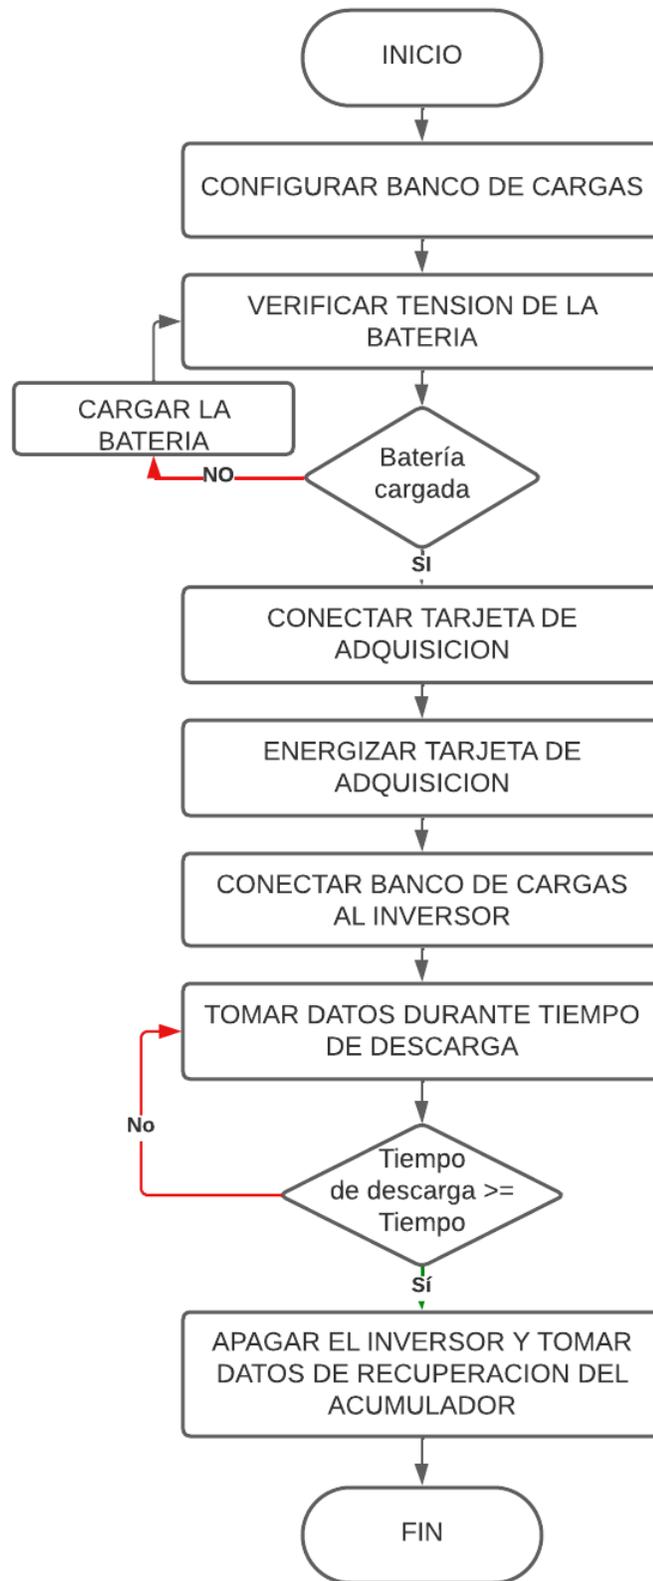


Figura 14. Algoritmo para la adquisición de datos

Resultados

Como resultado del experimento antes descrito con los acumuladores de energía, se crearon estructuras de datos .MAT en el software de ingeniería *MATLAB*[®] [10], los cuales contienen los valores registrados de voltaje en los bornes de la batería, corriente de descarga durante el tiempo del experimento y la temperatura, con los que se realizó la visualización del comportamiento de estos parámetros.

Por parte del acumulador de energía de Litio LIFEP04, se obtuvieron las gráficas que se aprecian a continuación en las figuras 14, 15 y 16.

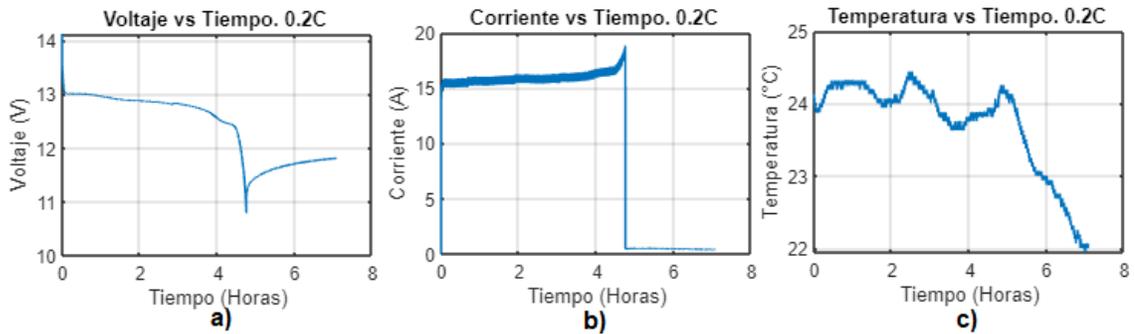


Figura 14. A) Gráfica del voltaje, b) Gráfica de corriente y c) Gráfica de temperatura de la batería de LIFEP04 para 0.2C

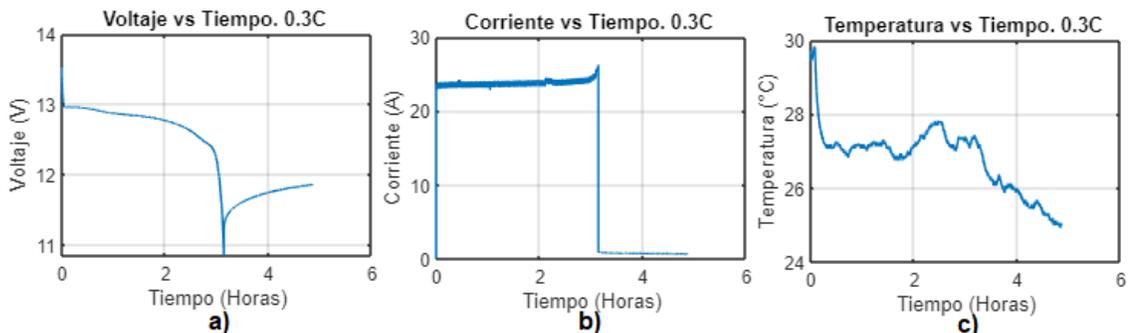


Figura 15. A) Gráfica de voltaje, b) Gráfica de corriente y c) Gráfica de temperatura de la batería de LIFEP04 para 0.3C

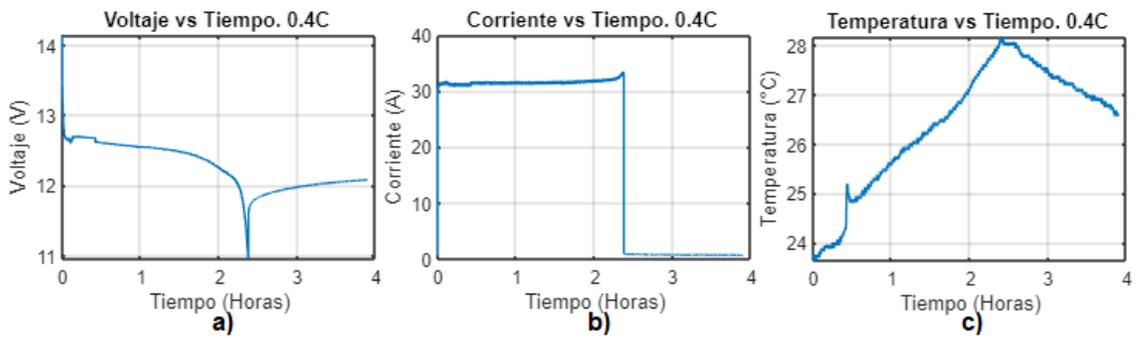


Figura 16. A) Gráfica de voltaje, b) Gráfica de corriente y c) Gráfica de temperatura de la batería de LIFEP04 para 0.4C

Ahora, por parte del acumulador de energía de Plomo NPD12-75AH, se obtuvieron las gráficas que se aprecian a continuación.

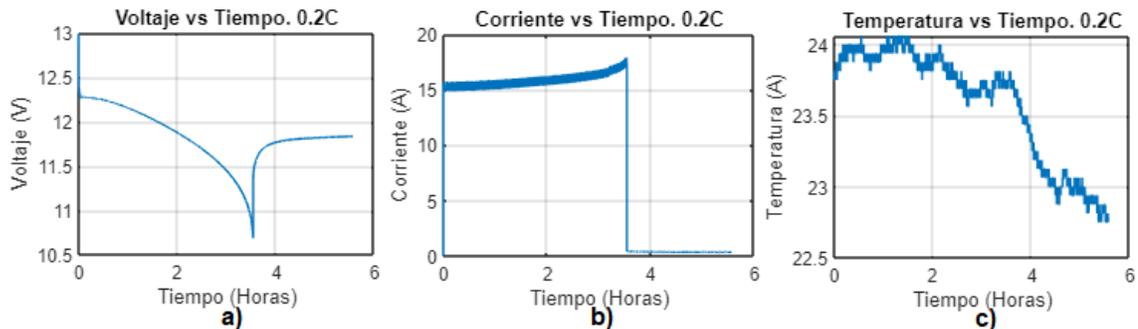


Figura 17. A) Gráfica de voltaje, b) Gráfica corriente y c) Gráfica de temperatura del acumulador de Plomo NPD12-75AH para 0.2C

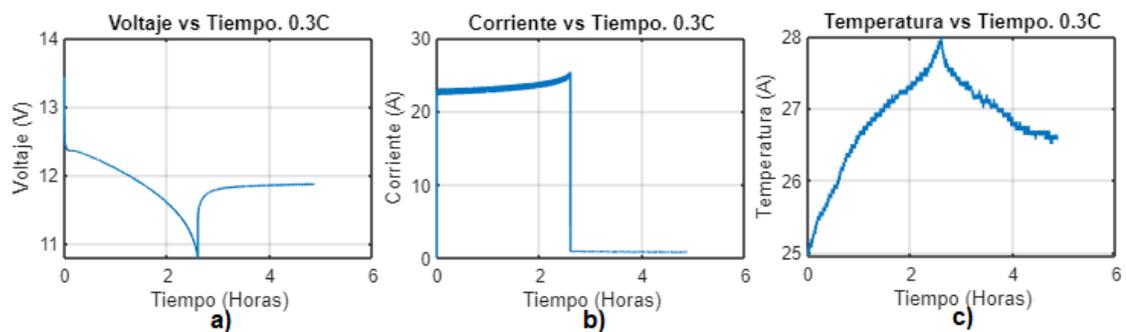


Figura 18. A) Gráfica de voltaje, b) Gráfica de corriente y c) Gráfica de temperatura del acumulador de Plomo NPD12-75AH para 0.3C

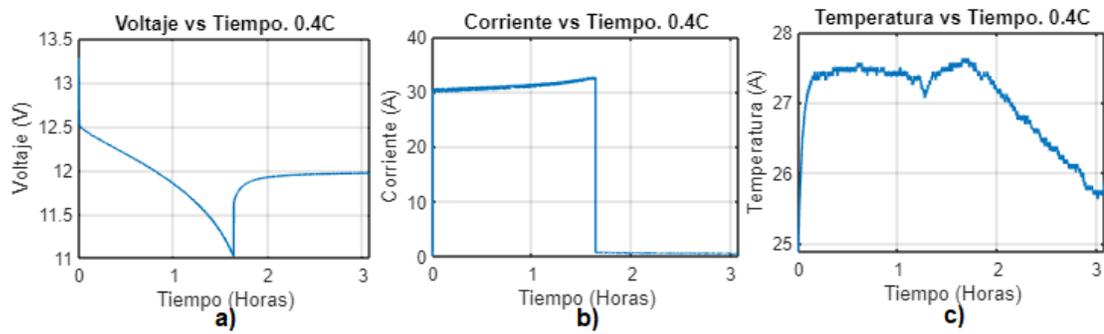


Figura 19. A) Gráfica de voltaje, b) Gráfica de corriente y c) Gráfica de temperatura del acumulador de Plomo NPD12-75AH para 0.4C

Referencias

- [1] P. Bellini, P. Nesi, and G. Pantaleo, "IoT-Enabled Smart Cities: A Review of Concepts, Frameworks and Key Technologies," *Appl. Sci.*, vol. 12, no. 3, 2022, doi: 10.3390/app12031607.
- [2] C. D'ortona, D. Tarchi, and C. Raffaelli, "Open-Source MQTT-Based End-to-End IoT System for Smart City Scenarios," *Futur. Internet*, vol. 14, no. 2, 2022, doi: 10.3390/fi14020057.
- [3] Y. Xiao, E. Pei, K. Wang, W. Zhou, and Y. Xiao, "Design and Research of M2M Message Transfer Mechanism of Looms for Information Transmission," *IEEE Access*, vol. 10, pp. 76136–76152, 2022, doi: 10.1109/ACCESS.2022.3189367.
- [4] Sagar B. S., B. Bairwa, K. K. Reddy, Jyothi V., Keerthana R., and Manasa R., "Design of IoT based battery monitoring system," *Int. Conf. Recent Trends Electr. Electron. Comput. Eng. Environ. Sustain. Dev. Icrteec-2021*, vol. 2461, p. 020005, 2022, doi: 10.1063/5.0094107.

- [5] R. M. Antosia, "Voltmeter Design Based on ADS1115 and Arduino Uno for DC Resistivity Measurement," *JTERA (Jurnal Teknol. Rekayasa)*, vol. 5, no. 1, p. 73, Jul. 2020, doi: 10.31544/jtera.v5.i1.2019.73-80.
- [6] V. V. Gavhane, M. R. Kshirsagar, G. M. Kale, S. Katangle, S. B. Deosarkar, and S. L. Nalbalwar, "IoT based Energy Meter with Smart Monitoring of Home Appliances," *2021 6th Int. Conf. Converg. Technol. I2CT 2021*, pp. 1–5, 2021, doi: 10.1109/I2CT51068.2021.9417886.
- [7] Deeksha Srivastava, Awanish Kesarwani, and Shivani Dubey, "Measurement of Temperature and Humidity by using Arduino Tool and DHT11 Measurement of Temperature and Humidity by using Arduino Tool and DHT11," *Int. Res. J. Eng. Technol.*, vol. 876, pp. 876–878, 2018, [Online]. Available: www.irjet.net.
- [8] A. Apps and N. T. C. Thermistor, "Using a Thermistor with Arduino and Unexpected ESP32 ADC Non-linearity," pp. 1–13, 2020, Accessed: Nov. 11, 2022. [Online]. Available: <https://www.e-tinkers.com/2019/10/using-a-thermistor-with-arduino-and-unexpected-esp32-adc-non-linearity/>
- [9] Ansys.com, "Building Better Batteries: Characterize Battery Parameters for Simulation," *ANSYS BLOG*, 2021. <https://www.ansys.com/blog/building-better-batteries> (accessed Dec. 20, 2022).
- [10] MathWorks, "Gráficas en dos y tres dimensiones - MATLAB & Simulink - MathWorks América Latina," *Gráficas en dos y tres dimensiones*, 2022. https://la.mathworks.com/help/matlab/learn_matlab/plots.html (accessed Dec. 20, 2022).

[11] M. Bouzguenda, S. Chtourou, M. Alarfaj, R. M. Sumsudeen, and M. Shwehdi, "Arduino Uno Wi-Fi DeMilitarized Zone-based monitoring of solar photovoltaic systems," *Meas. Control (United Kingdom)*, vol. 55, no. 3–4, pp. 136–145, 2022, doi: 10.1177/002029402

Capítulo 2: Selección de modelo de circuito equivalente y modelo basado en datos para los acumuladores de energía de las tecnologías de Litio y Plomo

Introducción

Hoy los acumuladores de energía eléctrica son indispensables para el desarrollo de la vida cotidiana debido a su gran importancia en diferentes industrias, por esto, diversas necesidades han hecho que se creen baterías con características requeridas [11]. Debido al reemplazo de combustibles fósiles por energía renovable, y la creciente participación de este tipo de tecnologías en la matriz energética, los acumuladores de energía han ganado un papel muy relevante hacia las energías renovables. Por consiguiente, estos sistemas requieren de acumuladores que sean fiables para un óptimo funcionamiento. Por esto, hoy en día las baterías de iones de Litio (Li-Ion) y Plomo ácido (Pb) son de uso común en aplicaciones estacionarias [12].

Los acumuladores que se utilizan en sistemas como la vehículos eléctricos, almacenamiento distribuido conectado a red, energías renovables, deben contar con un sistema de predicción precisa del comportamiento y/o rendimiento dinámico de estos dispositivos en tiempo real para de esta forma lograr alargar el tiempo de vida evitando que se sobrecargue o descargue y por lo tanto aumentar la confiabilidad, dado que, en general, estos acumuladores contribuyen en gran parte al costo final de la aplicación. Por esto, son necesarios los modelos que capturen el comportamiento dinámico de las baterías [13].

Al momento de modelar los acumuladores de energía, lo más importante es decidir el enfoque por el que se está modelando ya que en cada caso se necesitan enfoques o

parámetros levemente diferentes. Los modelos de baterías pueden pertenecer a más de una clase y por lo tanto no se pueden clasificar [11]. Unas de estas clases son: modelos electroquímicos, modelos basados en datos, modelos empíricos y modelos de circuito equivalente [14].

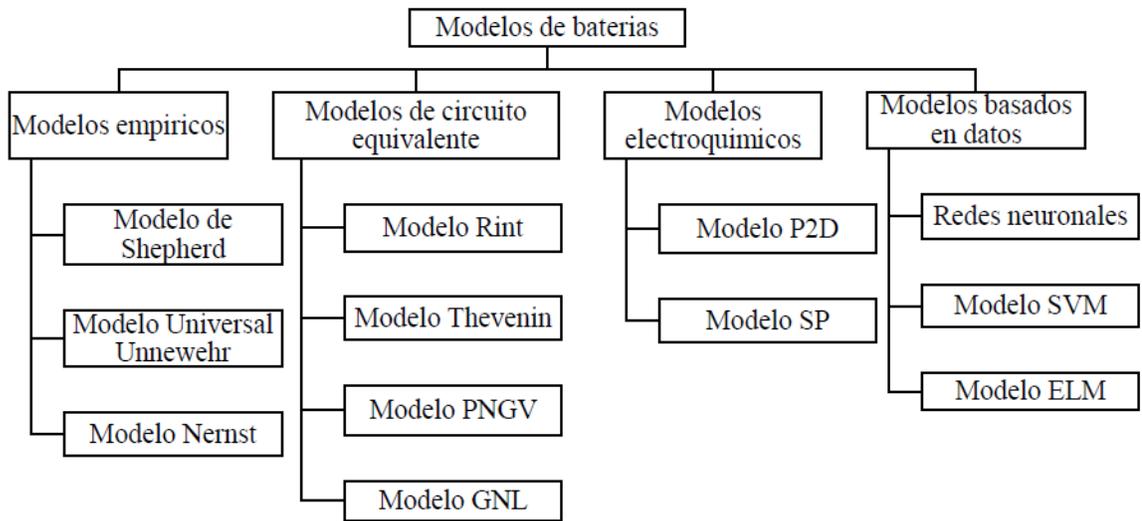


Figura 21. Modelos de acumuladores de energía [20].

Dentro de los modelos de circuito equivalente, se encuentran; el Modelo Rint, Modelo Thévenin, Modelo PNGV, Modelo GNL. Estos se pueden apreciar en la figura 20 y más adelante serán descritos. Estos son utilizados para simular la dinámica de los acumuladores de energía, puesto que, son capaces de modelar los efectos electroquímicos con el uso de elementos eléctricos sencillos como fuentes de tensión, resistencias y capacitores. Con estos elementos se pueden armar una o más ramas RC y es de esta forma que a través de constantes de tiempo se logra capturar sus parámetros más importantes ya que estos son los capaces de capturar la dinámica del material activo presente en la batería [14].

Para modelar el comportamiento de carga/descarga no lineal de estos dispositivos, también son utilizados modelos basados en datos a partir de la captura de parámetros como voltaje, corriente y temperatura durante los ciclos. En la figura 21, también se aprecian los modelos basados en datos. Para estos se utilizan técnicas de Machine Learning como máquinas de soporte vectorial (SVM por sus siglas en ingles), Redes neuronales y aprendizaje de máquinas extremas (ELM, por sus siglas en ingles).

Modelo de circuito equivalente

Modelo computacional

Para el modelo de circuito equivalente de los acumuladores de energía, en primer lugar, se plantea el uso de la caja de herramientas Curve Fitting del software Matlab. En esta herramienta se ejecuta un ajuste exponencial a la curva de tensión obtenida por el procedimiento experimental realizado en el capítulo anterior, este ajuste nos proporciona la ecuación que se puede apreciar a continuación.

$$V_{bat} = ae^{bt} + ce^{dt}$$

Ecuación 2. Ajuste exponencial del toolbox Curve Fitting

Donde la ecuación 2, corresponde a una ecuación general exponencial decreciente de dos términos [17]. Para cada curva de voltaje en cada tasa de descarga, se obtiene diferentes valores de a, b, c y d (tabla 4), además de un valor de R^2 y $RMSE$. Estos se pueden apreciar a partir del capítulo 3.

Para empezar, en la figura 21, se puede apreciar los modelos obtenidos por la herramienta antes nombrada utilizando la ecuación exponencial, donde la curva roja, corresponde al modelo y la curva azul, corresponde a la gráfica de los datos obtenidos

experimentalmente, así mismo se logra apreciar en la figura 22, las gráficas de los modelos para cada tasa de descarga del acumulador de energía de Plomo. Para el ajuste a las curvas experimentales, se hizo necesario el uso de métodos de robustes que nos brinda la herramienta de curve Fitting como lo es el método de ponderaciones bicuadradas (Robust Bisquare) el cual consiste en una serie de pasos con lo que se minimiza la suma de pesos cuadrados, donde la ponderación brindada a cada punto depende de lo lejos que este de la curva de ajuste, es decir, los puntos que más se acerquen a la curva de ajuste, obtienen una ponderación completa, los que no, obtienen una ponderación reducida, y los puntos que se salen de lo esperado obtienen una ponderación cero. También se utilizó el método de robustes de valores mínimos residuales absolutos (Robust LAR), este consiste en encontrar una curva que minimiza la diferencia residual absoluta en lugar de las diferencias cuadráticas, y, por consecuencia, los valores extremos tienen una menor influencia ya que los considera atípicos [18].

Los valores de las constantes a, b, c y d entregados por cada ajuste en la herramienta Curve Fitting reemplazables en la ecuación 2 para cada tasa de descarga en las diferentes tecnologías de los acumuladores, se pueden apreciar en la tabla 4.

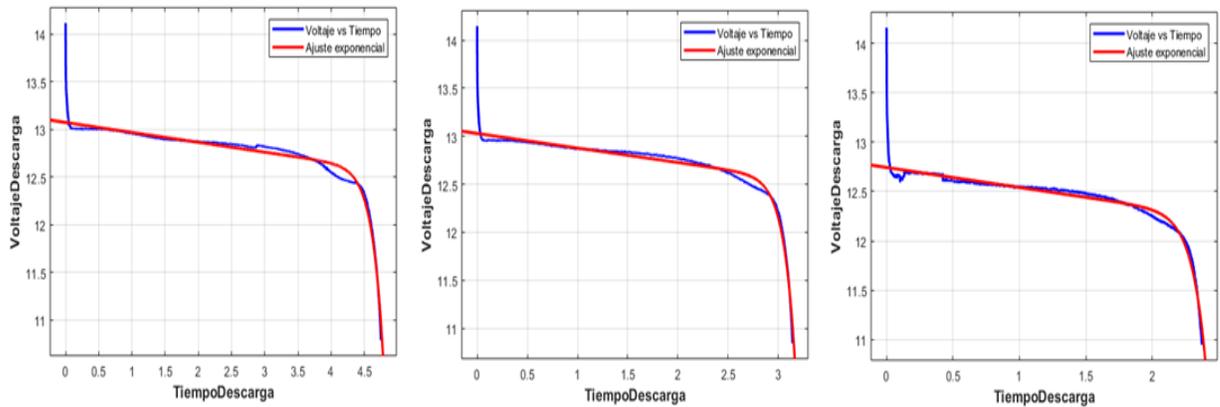


Figura 21. Gráficas del ajuste exponencial a las curvas de tasas de descarga 0.2C, 0.3C y 0.4C en la batería de Litio

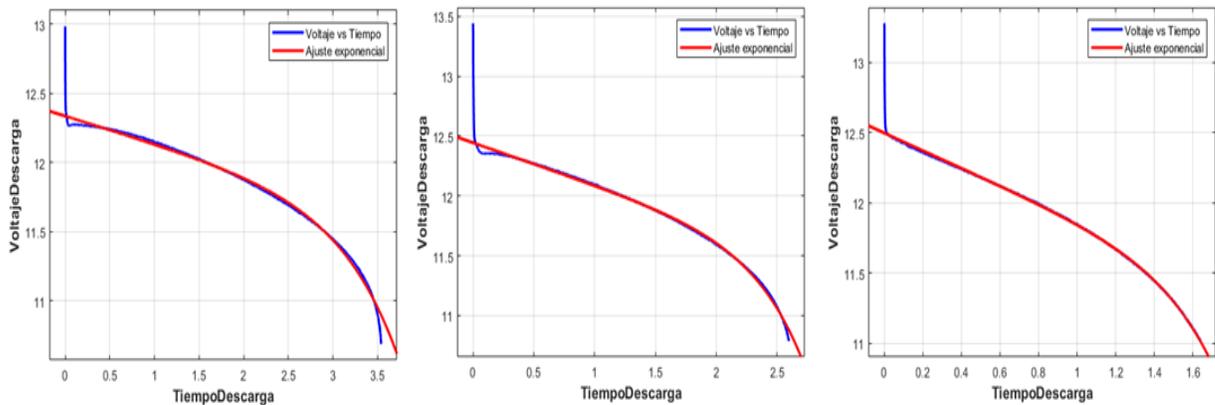


Figura 22. Graficas del ajuste exponencial para las curvas de tasas de descarga 0.2C, 0.3C y 0.4C respectivamente en la batería de Plomo

Constantes	Iones de Litio			Plomo ácido		
	0.2	0.3	0.4	0.2	0.3	0.4
a	-4.099e-07	-0.01634	-0.002552	-0.04654	-0.06506	0.02019
b	8.815	2.105	3.36	1.618	1.366	0.9999
c	12.84	12.84	12.52	12	12.04	0.9999
d	-0.008442	-0.005864	-0.007647	-0.01628	-0.01899	0.003163

Tabla 4. Valores de a, b, c y d para cada tasa de descarga en el acumulador de energía correspondiente

Modelo analítico

El modelo de polarización dual, como se puede ver en la figura 23, consta del modelo Thévenin con una rama de RC más, este modelo al contar con dos constantes de tiempo ayuda a describir mejor la respuesta transitoria del acumulador de energía ya sea durante el proceso de carga y/o descarga.

Utilizando las leyes de Kirchhoff en el circuito de la figura 28, se obtiene la ecuación 3, la cual establece las caídas de tensión en cada parte del circuito. Ahora, como V_1 y V_2 corresponden a los voltajes ramas RC_1 y RC_2 , estos se rigen bajo las ecuaciones diferenciales 4 y 5, correspondientemente.

$$V_{batt} = V_{oc} - V_1 - V_2 - R_o * i_{desc}$$

Ecuación 3. Voltaje en las terminales del acumulador en el ECM de polarización dual

$$\frac{dV_1}{dt} = \frac{V_1}{R_1 * C_1} + \frac{i_{desc}}{C_1}$$

Ecuación 4. Voltaje en la primera rama RC del modelo ECM de polarización dual

$$\frac{dV_2}{dt} = \frac{V_2}{R_2 * C_2} + \frac{i_{desc}}{C_2}$$

Ecuación 5. Voltaje en la segunda rama RC del modelo ECM de polarización dual

Donde él V_{batt} es el voltaje en las terminales de la batería, V_{oc} es el voltaje de circuito abierto, V_1 es el voltaje en el capacitor de la primera rama, V_2 el voltaje en el capacitor de la segunda rama y la resistencia interna está compuesto por R_o . Esta modela la caída de voltaje en el acumulador [15][16].

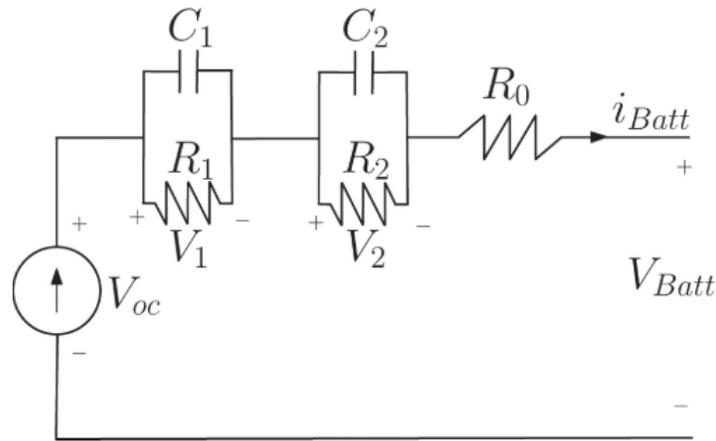


Figura 23. Modelo ECM de polarización dual o RC de 2do orden [15].

Ahora, para encontrar la ecuación que rige la descarga del acumulador de energía bajo diferentes tasas de descarga, se encuentran las soluciones para las ecuaciones diferenciales 4 y 5 ecuaciones para V_1 y V_2 . (Ecuación 6 y 7).

$$V_1 = I_{desc}R_1 + k_1 e^{-\frac{t}{R_1C_1}}$$

Ecuación 6. Solución de la ecuación 4

$$V_2 = I_{desc}R_1 + k_2 e^{-\frac{t}{R_2C_2}}$$

Ecuación 7. Solución de la ecuación 5

En las ecuaciones 6 y 7 podemos apreciar las soluciones para las ecuaciones 5 y 6 y al Reemplazar estas en la ecuación 3, obtenemos la siguiente ecuación

$$V_{batt} = V_{oc} - \left(I_{desc}R_1 + k_1 e^{-\frac{t}{R_1C_1}} \right) - \left(I_{batt}R_1 + k_2 e^{-\frac{t}{R_2C_2}} \right) - R_o * i_{batt}$$

Ecuación 8. Voltaje en las terminales del acumulador de energía mediante el circuito de polarización dual

Reacomodando la ecuación, obtenemos;

$$V_{batt} = V_{oc} - I_{desc}(R_1 + R_2 + R_o) - K_1 e^{-\frac{t}{R_1 C_1}} - K_2 e^{-\frac{t}{R_2 C_2}}$$

Ecuación 9. Ecuación simplificada del voltaje en las terminales del acumulador de energía mediante el circuito de polarización dual

Donde V_{oc} se refiere al voltaje de circuito abierto, I_{batt} a la corriente que se extrae de la batería, R_o a la resistencia interna, R_1 y R_2 a la resistencia de polarización de cada rama RC, K_1 al voltaje inicial del capacitor de la primera rama K_2 al voltaje inicial del capacitor de la segunda rama RC.

Ahora, comparando con la ecuación entregada por el toolbox Curve Fitting (ecuación 2), con la encontrada tras el proceso analítico, se aprecia que

$$a = K_1, b = -\frac{1}{R_1 C_1}, c = K_2 \text{ y } d = -\frac{1}{R_1 C_1}$$

Para cada tasa de descarga, el voltaje de circuito abierto y la corriente de descarga se consideran constantes, las cuales se pueden apreciar en la tabla 5.

Constante	Acumulador de Litio			Acumulador de Plomo		
	0.2C	0.3C	0.4C	0.2C	0.3C	0.4C
V_{oc}	14.12	14.15	14.16	12.99	13.44	13.28
I_{desc}	15.00	22.50	30.00	15.00	22.50	30.00

Tabla 5. Valores de voltaje de circuito abierto y corriente de descarga para cada acumulador de energía

Modelo basado en datos

Ahora, para la obtención de modelos basados en datos para los acumuladores estudiados en este trabajo de investigación, se hace uso del toolbox de Matlab Neural Net Fitting con la cual se busca que, a partir de los datos de entrada, se obtenga un ajuste a la salida, y, para esto, se utiliza la caja de herramientas Neural Net Fitting de Matlab. Esta utiliza redes prealimentadas de dos capas: en la capa oculta utiliza una función de activación sigmoide (ecuación 10), esta ayuda a introducir la no linealidad de los datos obtenidos, mientras que la capa de salida trabaja con una función de activación lineal (ecuación 11), esta ayuda a obtener una salida proporcional a la entrada debido que multiplica a las entradas por los pesos de cada neuronal, esto se puede apreciar en la figura 24 [20].

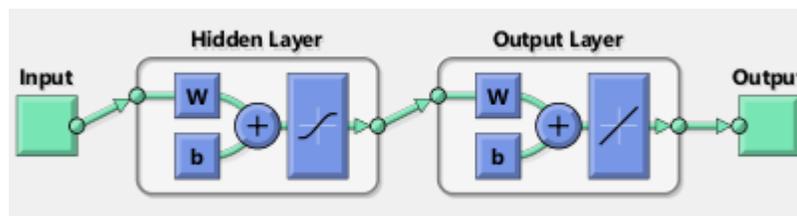


Figura 24. Gráfica de una red neuronal en la app Neural Net Fitting de Matlab

$$f(x) = \frac{1}{1 + e^{-x}}$$

Ecuación 10. Función de activación sigmoide

$$f(x) = x$$

Ecuación 11. Función de activación lineal

Como datos para alimentar el modelo se toman los parámetros de corriente y temperatura de cada experimento obtenidos en el capítulo uno, y, como objetivo o

salida, se requiere que estos se ajusten al voltaje en el período de descarga correspondiente, por lo tanto, serían un modelo con dos predictores o entradas y un objetivo o salida.

Para implementación de estos modelos se empezó con el acumulador de energía de Iones de Litio y seguido a este, la batería de Plomo.

Resultados

Para la primera tasa de descarga, correspondiente a la tasa de descarga de 0.2C, con 5866 como datos de entrada repartidos entre entrenamiento = 4106, validación = 880 y prueba = 880 en el acumulador de energía de Iones de Litio, para este ajuste se hizo necesario el uso de una sola neurona en la capa oculta (figura 25). Por consiguiente, se obtienen ajustes a los datos con un valor de $R^2 = 0.992388$ y un $MSE = 0.0015526$ para los datos de entrenamiento, para los datos de validación se obtuvo $R^2 = 0.989478$ con $MSE = 0.00229551$ y, por último, para los datos que se entregaron para la parte de prueba, se obtuvo $R^2 = 0.992521$ y 0.00136870 de MSE. Todos estos datos se pueden apreciar tabulados en la tabla 4, y, en la figura 26 se logra apreciar la regresión para los conjuntos de datos de entrenamiento, validación y prueba obtenidos como resultados del modelo.

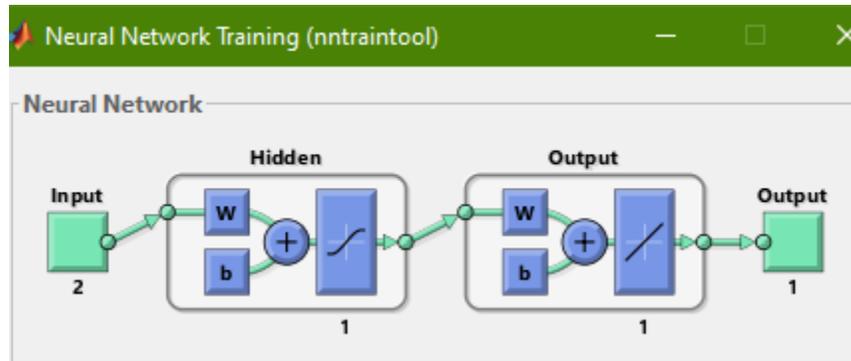


Figura 25. Gráfica de la red neuronal para la tasa de descarga 0.2C en el acumulador de Litio

MÉTRICA	TASA DE DESCARGA 0.2C EN LA BATERÍA DE LITIO	
	R ²	MSE
ENTRENAMIENTO	0.992388	0.0015526
VALIDACIÓN	0.989478	0.00229551
PRUEBA	0.992521	0.00136870

Tabla 6. Valores de las métricas de errores para la tasa de descarga 0.2C en el acumulador de Litio

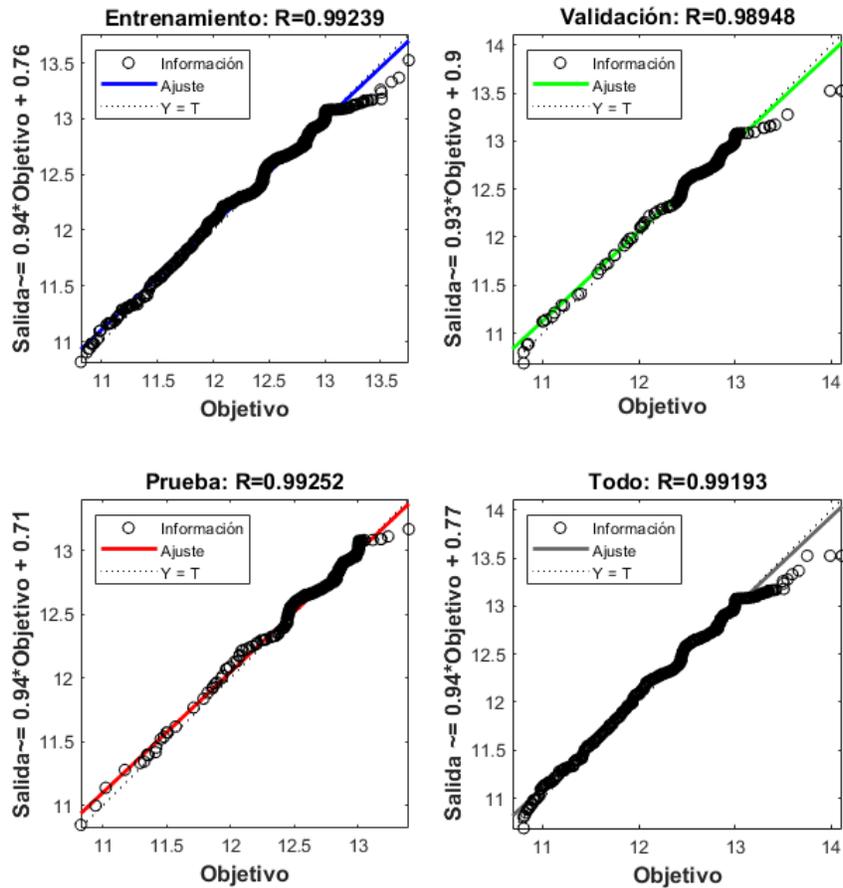


Figura 26. Gráfica del ajuste por regresión en la tasa de descarga 0.2C en el acumulador de Litio

Ahora para las tasas de descarga de 0.3C, se realizó una distribución de los 3879 datos, en entrenamiento = 2715 con un valor de $R^2 = 0.907009$ y $MSE = 0.0145439$, validación = 582 con $R^2 = 0.918571$ y $MSE = 0.0148684$ y prueba = 582 con $R^2 = 0.935425$ y $MSE = 0.0105955$, además para lograr unos buenos valores de regresión observables en la tabla 5, se hizo necesario el aumento de la cantidad de neuronas en la capa oculta a 20 (figura 27) y en la figura 28, se puede apreciar la gráfica de la regresión para cada conjunto de datos.

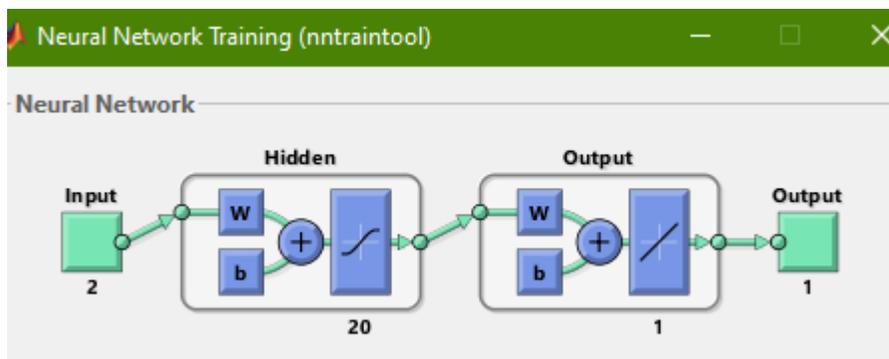


Figura 27. Gráfica de la red neuronal para la tasa de descarga 0.3C en la batería de Litio

MÉTRICA	TASA DE DESCARGA 0.3C EN LA BATERÍA DE LITIO	
	R^2	MSE
ENTRENAMIENTO	0.907009	0.0145439
VALIDACIÓN	0.918571	0.0148684
PRUEBA	0.935425	0.0105955

Tabla 7. Valores de las métricas de errores para la tasa de descarga de 0.3C en la batería de Litio

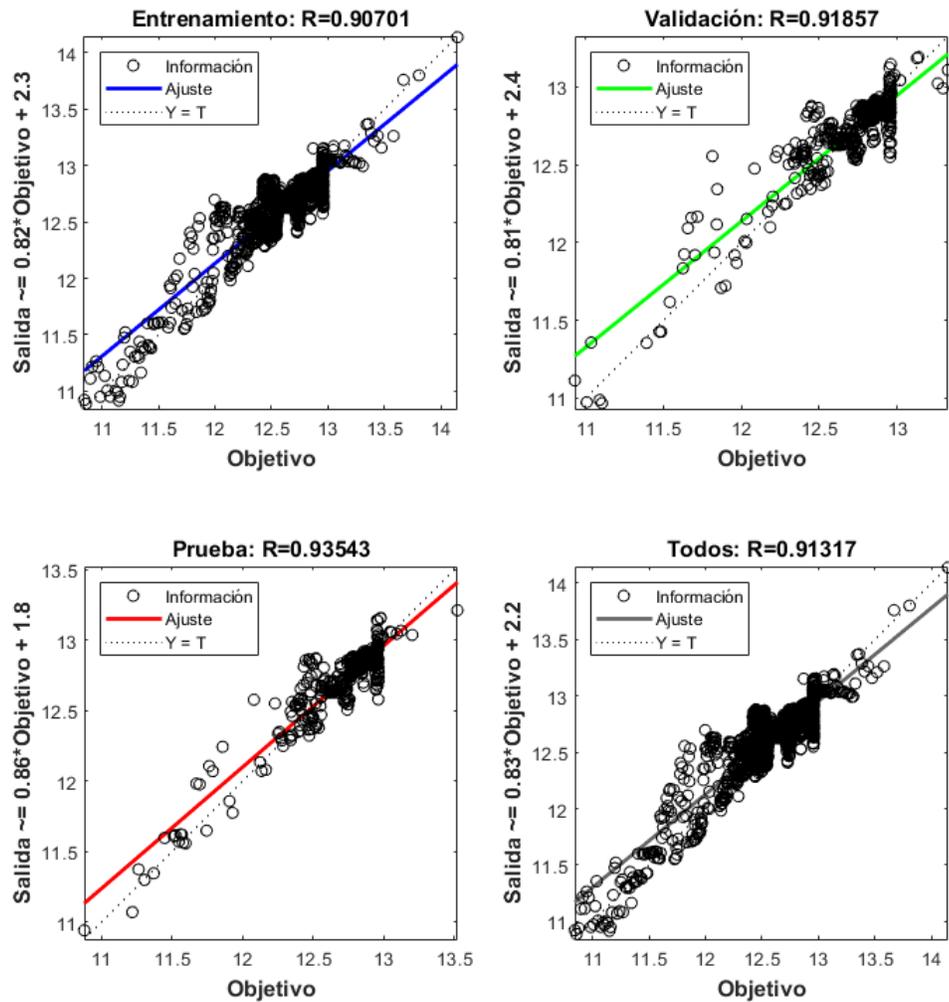


Figura 28. Gráfica de la regresión para cada conjunto de datos en la tasa de descarga 0.3C

Para el ajuste por regresión mediante redes neuronales, en la tasa de descarga 0.4C en el acumulador de Litio se hizo necesario utilizar 10 neuronas en la capa oculta como se puede apreciar en la figura 29, esto con el fin de obtener valores en las métricas de errores bastante aceptables, los cuales se pueden apreciar en la tabla 6, y, en la figura 30, la respectiva gráfica de regresión para cada conjunto de datos.

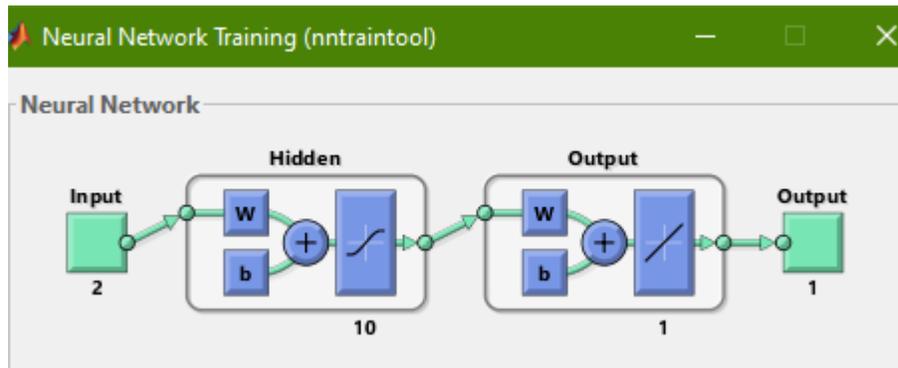


Figura 29. Gráfica de la red neuronal para la tasa de descarga 0.4C en el acumulador de Litio

MÉTRICA	TASA DE DESCARGA 0.4C EN LA BATERÍA DE LITIO	
	R^2	MSE
ENTRENAMIENTO	0.995412	0.000658958
VALIDACIÓN	0.996876	0.000483993
PRUEBA	0.987946	0.00154235

Tabla 8. Valores de las métricas de errores para la tasa de descarga de 0.4C en la batería de Litio

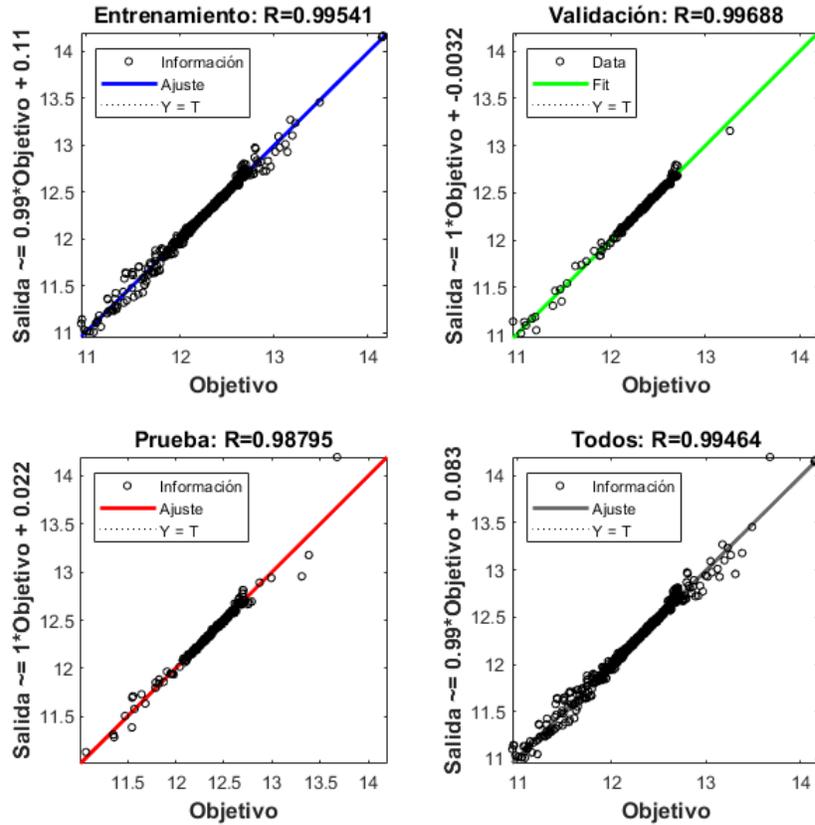


Figura 30. Gráfica de regresión para el conjunto de datos en la tasa de descarga 0.4C en el acumulador de Litio

Ahora, al hacer uso de las redes neuronales para el entrenamiento con los datos del acumulador de Plomo, se obtuvieron los siguientes resultados.

Para la tasa de descarga de 0.2C se obtuvieron 4351 datos, de los cuales, para el entrenamiento se tomaron 3059 y se obtuvo un valor de $R^2 = 0.924838$ y un $MSE = 0.0197614$, mientras para validación y prueba se tomaron 656 datos con unos valores de $R^2 = 0.921986$, $MSE = 0.0182361$ y $R^2 = 0.915619$ y $MSE = 0.0200588$ respectivamente como se puede apreciar en la tabla 9 y la grafica 31. Esto se logro aplicando una red con 1 neuronas en la Capa oculta como se ve en la figura 32.

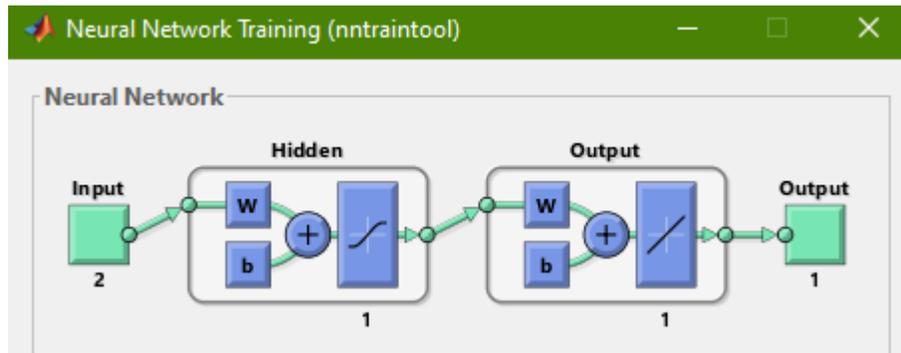


Figura 31. Red neuronal para la tasa de descarga 0.2C en la batería de Plomo

MÉTRICA	TASA DE DESCARGA 0.2C EN LA BATERÍA DE PLOMO	
	R ²	MSE
ENTRENAMIENTO	0.924838	0.0197614
VALIDACIÓN	0.921986	0.0182361
PRUEBA	0.915619	0.0200588

Tabla 9. Valores de las métricas de errores para la tasa de descarga de 0.2C en la batería de Plomo

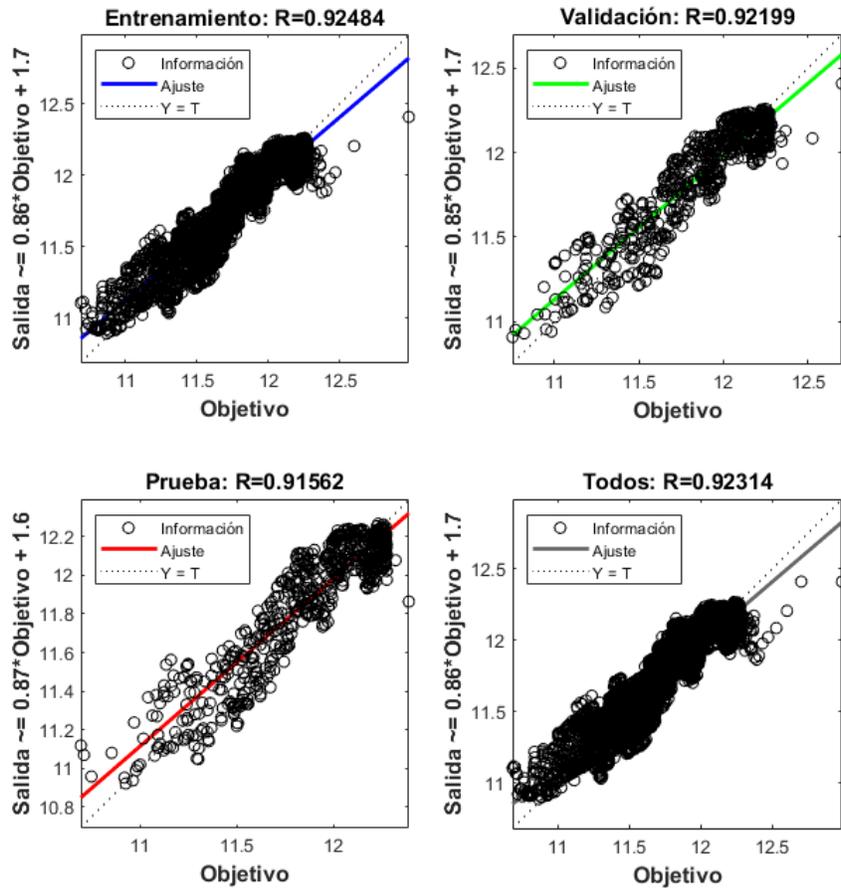


Figura 32. Gráfica de regresión para el conjunto de datos en la tasa de descarga 0.2C en el acumulador de Plomo

En el entrenamiento con los datos obtenidos por la descarga de 0.3C, se obtuvo un conjunto de datos de 3207, esto se separó en 2245 para el entrenamiento, 481 para la validación y 481 para la prueba. Bastó de una red neuronal con una sola neurona en la capa oculta (figura 33) para obtener los resultados que se logran apreciar en la tabla 10 y la figura 34.

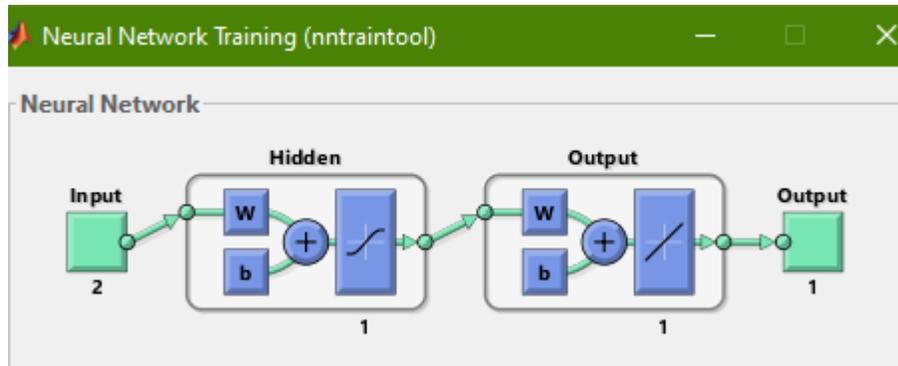


Figura 33. Red neuronal para la tasa de descarga 0.3C en la batería de Plomo

MÉTRICA	TASA DE DESCARGA 0.3C EN LA BATERÍA DE PLOMO	
	R^2	MSE
ENTRENAMIENTO	0.992318	0.00238611
VALIDACIÓN	0.997396	0.000831032
PRUEBA	0.987351	0.00388766

Tabla 10. Valores de las métricas de errores para la tasa de descarga de 0.3C en la batería de Plomo

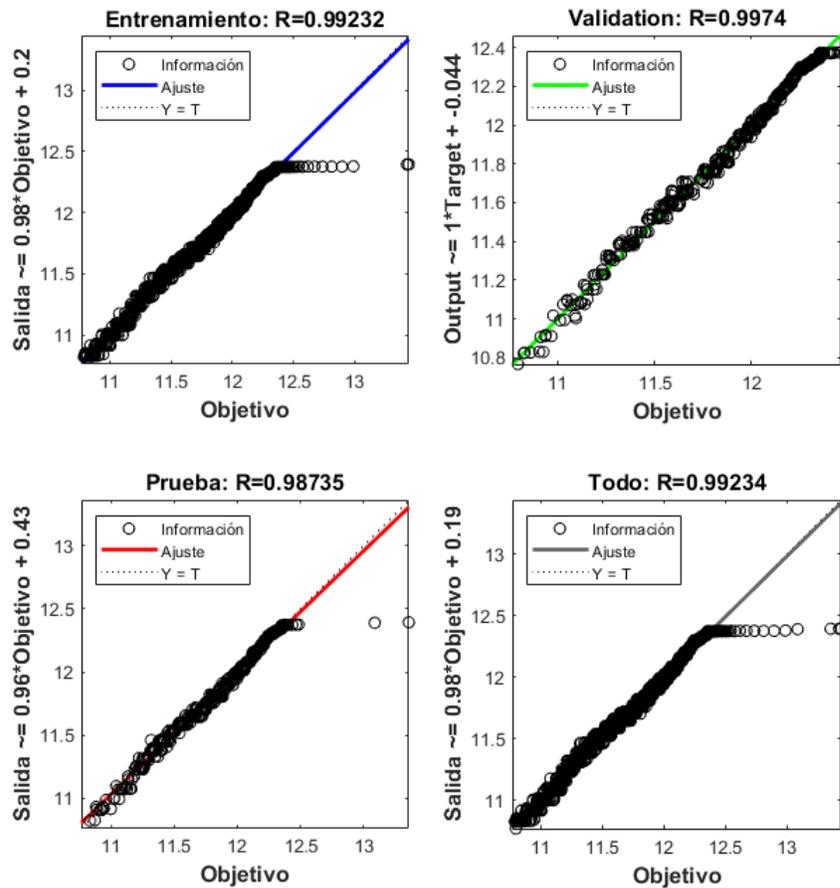


Figura 34. Gráfica de regresión para el conjunto de datos en la tasa de descarga 0.3C en el acumulador de Plomo

Por último, para la tasa de descarga de 0.4C, se contó con 2022 valores para los predictores y el objetivo, para este caso se distribuyeron 1416 datos para el entrenamiento, 303 para la validación y 303 para la prueba. Para la red se necesitaron dos neuronas en la capa oculta (figura 35) y con esto, se obtuvieron los resultados que se aprecian en la tabla 11 y la figura 36.

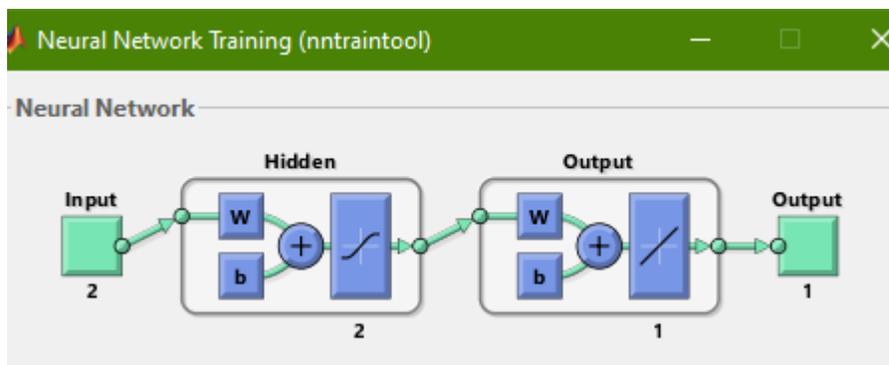


Figura 35. Red neuronal para la tasa de descarga 0.4C en la batería de Plomo

MÉTRICA	TASA DE DESCARGA 0.4C EN LA BATERÍA DE PLOMO	
	R ²	MSE
ENTRENAMIENTO	0.951894	0.0138534
VALIDACIÓN	0.955964	0.0129713
PRUEBA	0.953166	0.0145087

Tabla 11. Valores de las métricas de errores para la tasa de descarga de 0.4C en la batería de Plomo

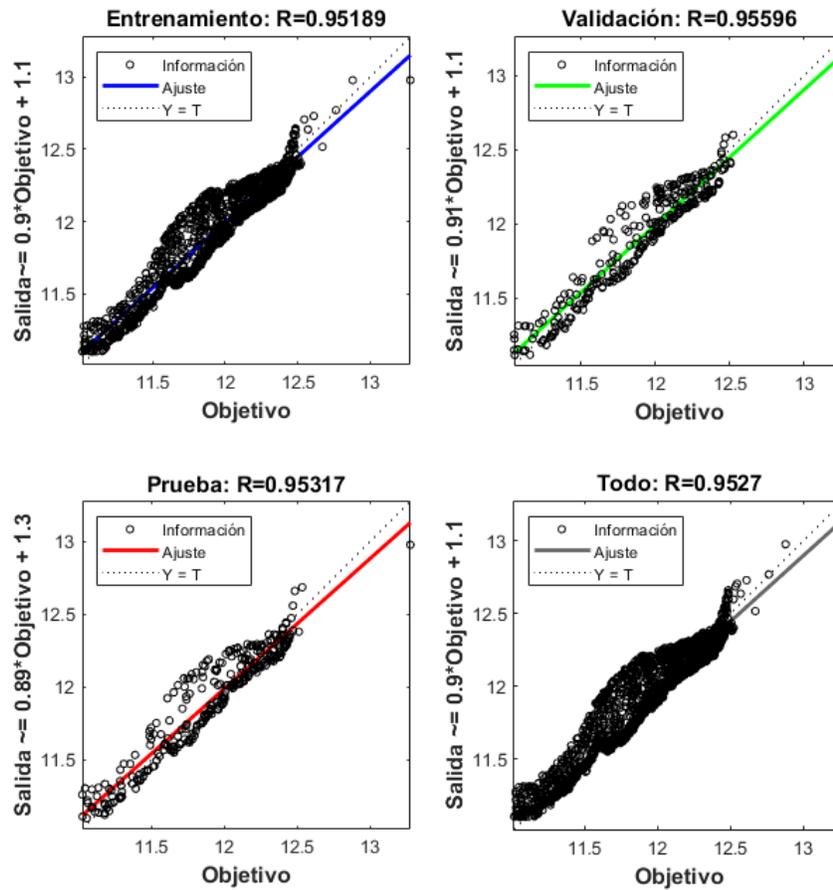


Figura 36. Gráfica de regresión para el conjunto de datos en la tasa de descarga 0.4C en el acumulador de Plomo

Referencias

- [11] M. Tomasov, M. Kajanova, P. Bracinik, and D. Motyka, "Overview of battery models for sustainable power and transport applications," *Transp. Res. Procedia*, vol. 40, pp. 548–555, 2019, doi: 10.1016/j.trpro.2019.07.079.
- [12] A. A. Kebede *et al.*, "Techno-economic analysis of lithium-ion and lead-acid batteries in stationary energy storage application," *J. Energy Storage*, vol. 40, no. November 2020, p. 102748, 2021, doi: 10.1016/j.est.2021.102748.
- [13] A. A. H. Hussein and I. Batarseh, "An overview of generic battery models," *IEEE Power Energy Soc. Gen. Meet.*, no. 4, pp. 4–9, 2011, doi: 10.1109/PES.2011.6039674.
- [14] O. V. Jose, "Diseño de un regulador electrónico para acumuladores de iones de Litio en condiciones de operación autónoma integrado a un sistema de generación híbrido solar-eólico," p. 6, 2021.
- [15] F. Eltoumi, A. Badji, M. Becherif, and H. S. Ramadan, "Experimental Identification using Equivalent Circuit Model for Lithium-Ion Battery," *Int. J. Emerg. Electr. Power Syst.*, vol. 19, no. 3, pp. 1–12, 2018, doi: 10.1515/ijeeps-2017-0210.
- [16] C. Pérez, "Tecnológico Nacional de México Tesis de Maestría Maestro en Ciencias en Ingeniería," 2019.
- [17] R. I. Valdés *et al.*, "Modelado y simulación de una batería de Ion-Litio comercial multicelda.," no. November 2016, pp. 464–469, 2015, [Online]. Available: https://www.researchgate.net/publication/234588217_MODELADO_Y_SIMULACION_DE_UNA_BATERIA_DE_ION-LITIO_COMERCIAL_MULTICELDA
- [18] "Ajuste por mínimos cuadrados - MATLAB & Simulink - MathWorks América

Latina.” https://la.mathworks.com/help/curvefit/least-squares-fitting.html#bq_5kr9-4
(accessed Mar. 07, 2023).

[19] H. He, R. Xiong, and J. Fan, “Evaluation of lithium-ion battery equivalent circuit models for state of charge estimation by an experimental approach,” *Energies*, vol. 4, no. 4, pp. 582–598, 2011, doi: 10.3390/en4040582.

[20] “Resolver un problema de ajuste utilizando redes prealimentadas de dos capas - MATLAB - MathWorks América Latina.” <https://la.mathworks.com/help/deeplearning/ref/neuralnetfitting-app.html> (accessed Mar. 16, 2023)

[21] T. Ahmad *et al.*, “Energetics Systems and artificial intelligence: Applications of industry 4.0,” *Energy Reports*, vol. 8, pp. 334–361, 2022, doi: 10.1016/j.egy.2021.11.256.

[22] W. Zhou, Y. Zheng, Z. Pan, and Q. Lu, “Review on the battery model and SOC estimation method,” *Processes*, vol. 9, no. 9, 2021, doi: 10.3390/pr9091685.

[23] J. Meng, G. Luo, M. Ricco, M. Swierczynski, D. I. Stroe, and R. Teodorescu, “Overview of Lithium-Ion battery modeling methods for state-of-charge estimation in electrical vehicles,” *Appl. Sci.*, vol. 8, no. 5, 2018, doi: 10.3390/app8050659.

Capítulo 3: Contraste de los modelos obtenidos por cada tecnología de acumulador

Introducción

Para el desarrollo de esta investigación, en primer lugar, se utilizó un acumulador de energía de la tecnología de Litio Fosfato Ferroso (LiFePO_4) con un voltaje nominal de 12V y una capacidad de 75 AH; en el que para la realización de los experimentos de descarga se tomó un tiempo de siete horas para 0.2C, cinco horas para 0.3C y cuatro horas para 0.4C. Esto se puede apreciar en las figuras 15, 16 y 17 respectivamente. Después se utilizó una batería de Plomo ácido con el mismo voltaje y capacidad nominal. Estos se sometieron a las tasas de descarga de 0.2C, 0.3C y 0.4C, las cuales tomaron tiempo de cinco horas con treinta minutos, cinco horas y tres horas, respectivamente. El procedimiento anterior se llevó a cabo con el fin de capturar los parámetros de voltaje, corriente y temperatura durante todo el experimento. Posteriormente, se utilizó el toolbox del software de ingeniería de Matlab como lo es Curve Fitting, el cual se adoptó para realizar modelos de circuito equivalente que se ajustaran a la curva de descarga de los acumuladores para las diferentes tasas de descarga y gracias a esto se obtuvieron buenos resultados de ajuste evidenciados por valores de métricas de errores como lo son: el coeficiente de determinación y el error medio cuadrático.

Por otro lado, se empleó la herramienta Neuronal Net Fitting también del software Matlab, el cual permite configurar redes neuronales que ayuden a ajustar unos datos de entrada a la salida esperada. Esto se puede apreciar como un modelo de caja negra en

el cual se establezcan unas entradas o predictores del modelo y debido a un proceso interno, se obtenga un ajuste en los pesos para obtener el objetivo esperado. Gracias a esta herramienta se realizaron modelos de redes neuronales para cada tasa de descarga de cada acumulador de energía. Como predictores, se usaron los parámetros de corriente y temperatura obtenidos en el primer capítulo y como objetivo se tomó el voltaje en descarga. En este modelo para verificar los resultados de cada modelo, también se utilizaron las métricas de errores de coeficiente de determinación también conocido como R^2 y el error medio cuadrático MSE.

Contraste del modelo de circuito equivalente

En el primer capítulo se registraron datos de voltaje en los bornes de los acumuladores de energía durante el proceso de descarga para las diferentes tasas de descarga. En la figura 37, se puede apreciar las curvas para las tasas de descarga de 0.2C, 0.3C y 0.4C de la batería de Litio y en la figura 38 para la batería de Plomo.

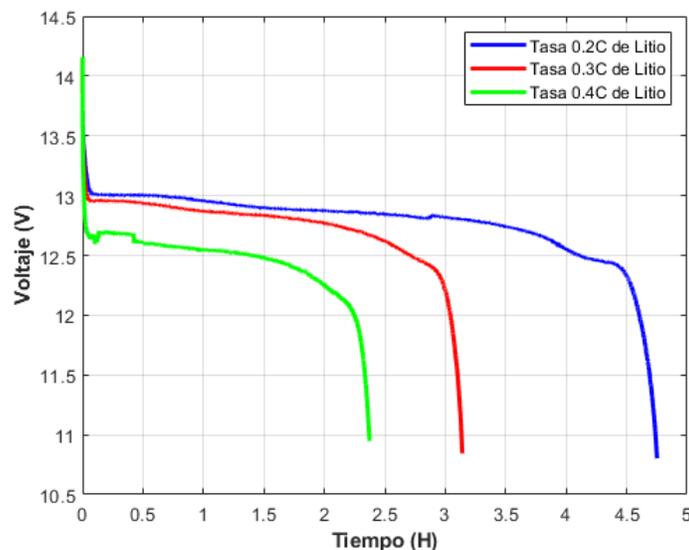


Figura 37. Gráfica de las tasas de descarga para el acumulador de energía de Litio

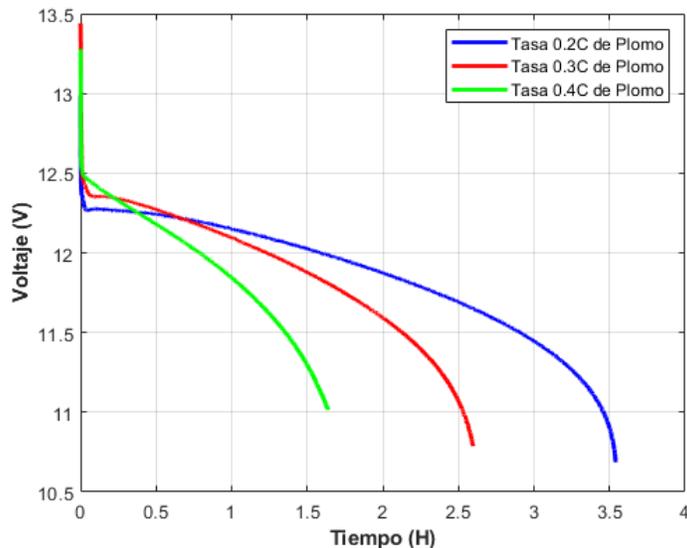


Figura 38. Gráfica de las tasas de descarga para el acumulador de energía de Plomo

Ahora, para apreciar el contraste entre las diferentes descargas que se hicieron en los dos acumuladores, se obtienen las gráficas por tasa de descarga las cuales se pueden apreciar en las figuras 39, 40 y 41. En primer lugar, se puede apreciar que los tiempos de descarga estimados en las tablas 1 y 2 obtenidos a partir de las curvas de descarga entregadas por el fabricante, se aproxima bastante en referencia a los tiempos que duraron los experimentos realizados para cada tasa de descarga. También se puede apreciar que la tecnología de Litio Fosfato Ferroso supera a la de Plomo ácido en referencia al tiempo que dura en descargarse dado que las tasas de descarga de la batería de Plomo tienen una curva más pronunciada.

También se puede apreciar que, aunque los dos acumuladores de energía tienen un voltaje nominal igual a 12V (dato entregado por el fabricante), la tensión en los bornes para la batería de Plomo se encuentra en el rango de 13.5V hasta 13V para el voltaje

de circuito abierto, mientras que el acumulador de energía de Litio se mantiene aproximadamente en los 14V.

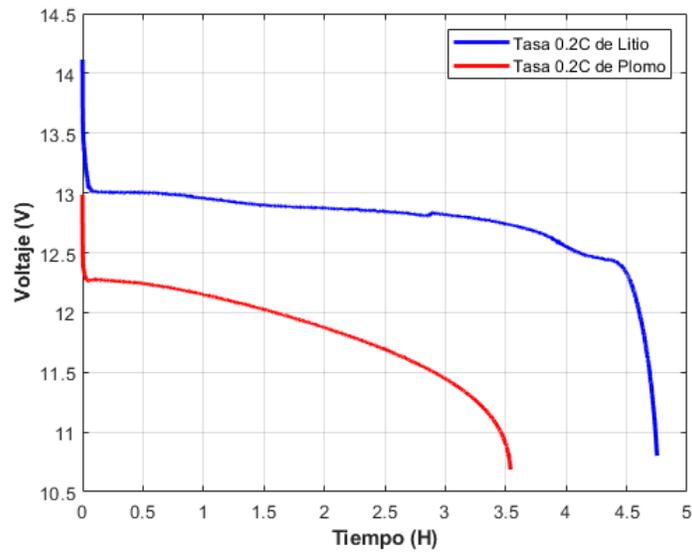


Figura 39. Gráfica de la comparación de las tasas de descarga de 0.2C

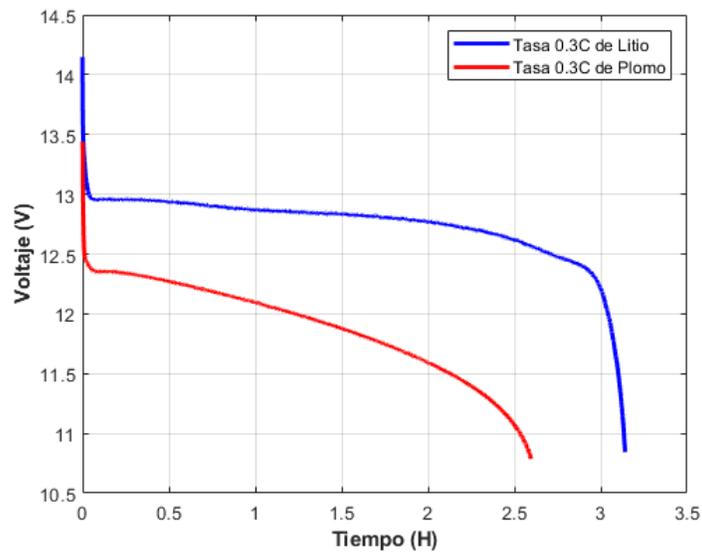


Figura 40. Gráfica de la comparación de las tasas de descarga de 0.3C

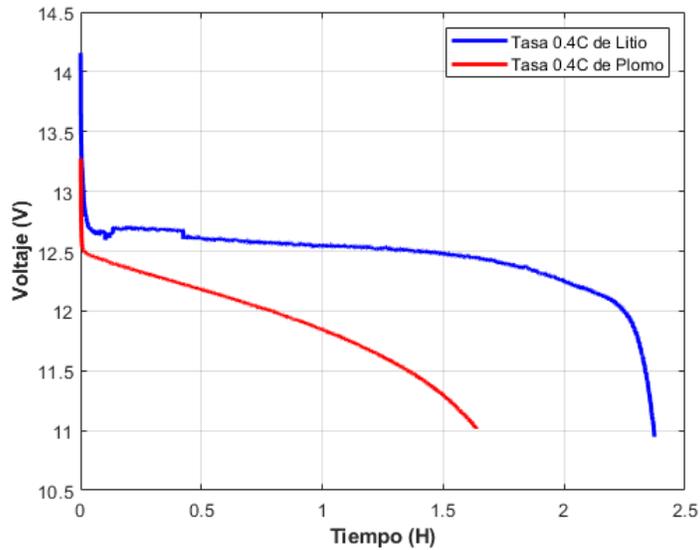


Figura 41. Gráfica de la comparación de las tasas de descarga de 0.4C

Ahora, en las gráficas 42, 43 y 44, se puede apreciar de mejor manera el ajuste del modelo obtenido por la herramienta curve Fitting a las curvas obtenidas por los datos experimentales del acumulador de energía de Litio. En el caso de los ajustes de las curvas de 0.2C (figura 47) y 0.3C (figura 48) utilizando el método de robustes de ponderaciones bicuadradas (Robust Bisquare) se obtuvo un ajuste de $R^2 = 0.997$ con un $RMSE = 0.01635$ para 0.2C y un $R^2 = 0.9986$ y $RMSE$ de 0.01086 para 0.3C. Mientras que para la tasa de descarga de 0.4C, el mejor ajuste se obtuvo utilizando el método de robustes de valores mínimos residuales absolutos (LAR) con $R^2 = 0.9982$ y $RMSE = 0.01124$

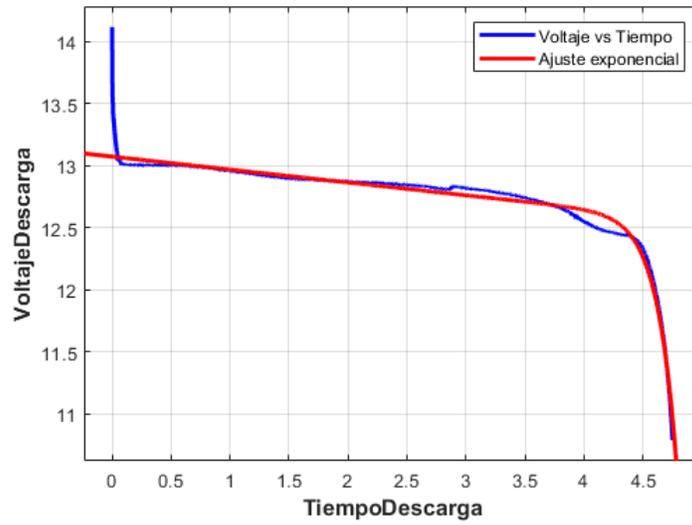


Figura 42. Gráfica del ajuste exponencial a la curva de descarga 0.2C en la batería de Litio

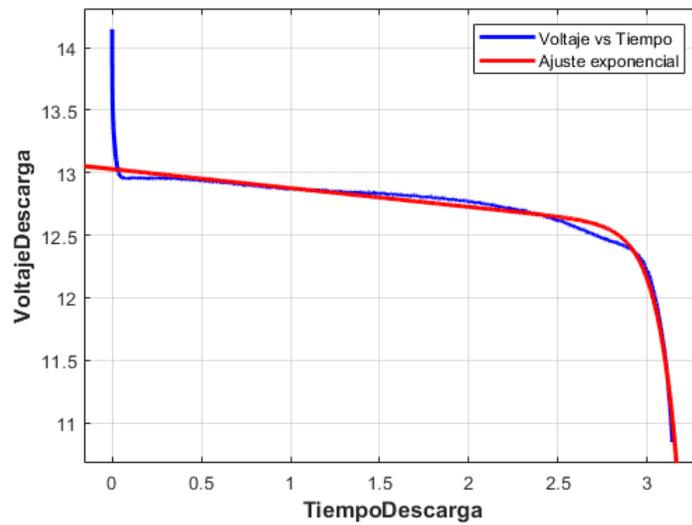


Figura 43. Gráfica del ajuste exponencial a la curva de voltaje de 0.3C en la batería de Litio

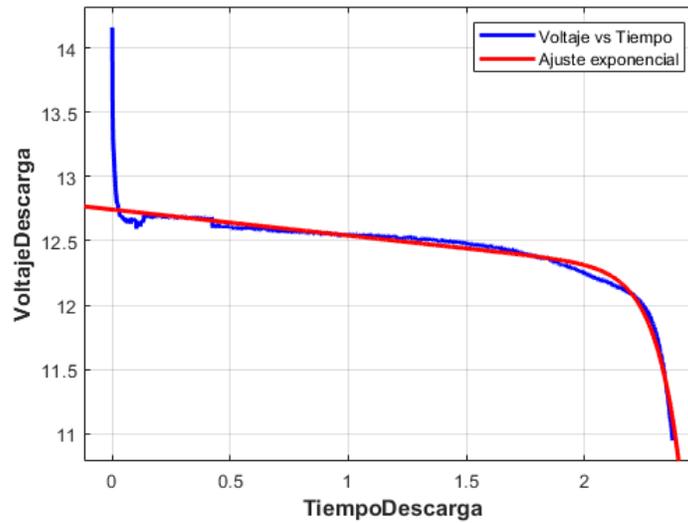


Figura 44. Gráfica del ajuste exponencial para la curva de voltaje de 0.4C en la batería de Litio

Ahora para el acumulador de energía de la tecnología de Plomo, se aprecia que para la tasa de descarga de 0.2C, el ajuste obtuvo un $R^2 = 0.9997$ y un $RMSE = 0.00623$ el cual fue el mejor ajuste sin necesidad de algún método de robustes mientras que para las tasas de descarga de 0.3C y 0.4C, se hizo necesario el método LAR, con el cual se obtuvo un $R^2 = 0.9999$ y $RMSE = 0.004102$ para 0.3C y $R^2 = 0.9999$ y $RMSE = 0.003163$

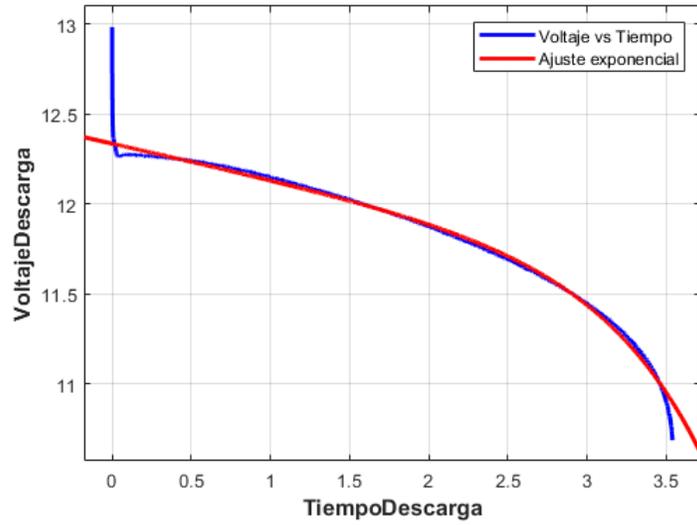


Figura 45. Gráfica del ajuste exponencial para la curva de voltaje de 0.2C en la batería de Plomo

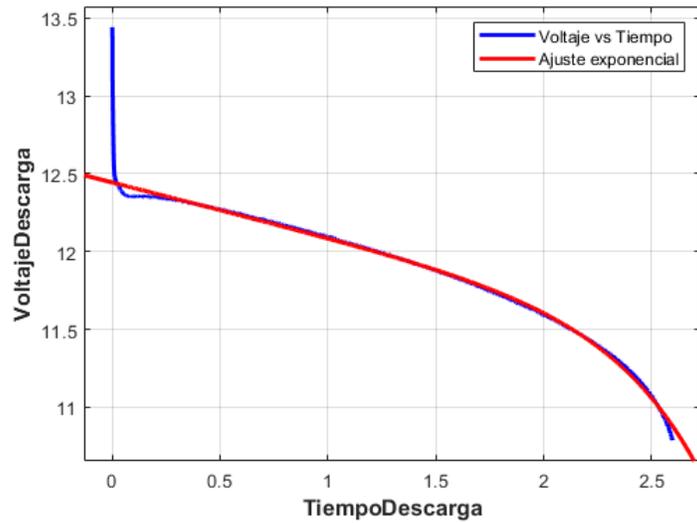


Figura 46. Gráfica del ajuste exponencial para la curva de voltaje de 0.3C en la batería de Plomo

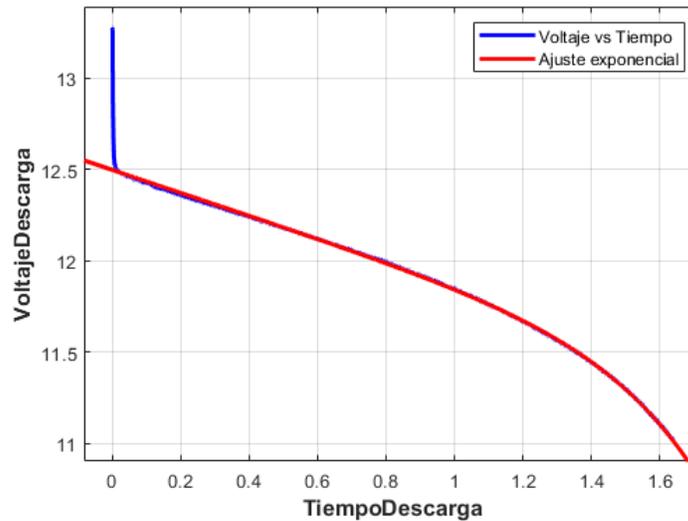


Figura 47. Gráfica del ajuste exponencial para la curva de voltaje de 0.4C en la batería de Plomo

Cabe resaltar que, en este trabajo de investigación, se trató de obtener los valores los parámetros de las resistencias, voltaje de circuito abierto y capacitores mediante ecuaciones descritas en otros documentos, y, debido a que en ellos ocupan métodos establecidos como HPPC [19] y pulsos de corriente constantes [13] no se logró un buen resultado ya que en este trabajo de investigación se utilizó un proceso de descarga constante en el cual se descarga el acumulador de energía desde el 100% hasta aproximadamente 0% sin interrupciones con una carga resistiva. A partir de esto, desde un proceso analítico utilizando teoría de circuitos, se obtuvo la ecuación que rige el voltaje a través del tiempo para los acumuladores según el modelo de polarización dual (ecuación 8), el cual se comparó con la ecuación exponencial que utiliza Curve Fitting (ecuación 2) para la parte del ajuste del modelo computacional, lo cual nos llevó a notar que, al igualar estas dos ecuaciones, tenemos que:

$$a = K_1, b = -\frac{1}{R_1 C_1}, c = K_2, d = -\frac{1}{R_1 C_1},$$

Ahora, revisando la tabla 12, la cual contiene los valores de las métricas según el ajuste de cada tasa de descarga, se puede apreciar que, en el caso del acumulador de Litio, el mejor caso se obtuvo en la tasa de descarga de 0.3C utilizando el método de robustes de ponderaciones bicuadradas, mientras que para el acumulador de Plomo ácido, el mejor ajuste se obtuvo en la tasa de descarga de 0.4C, utilizando el método de robustes de valores residuales mínimos absolutos, con lo cual se muestra que las tecnologías tienen sus diferencias debido a los compuestos químicos de los que están conformados.

Errores	Iones de Litio			Plomo Ácido		
	0.2	0.3	0.4	0.2	0.3	0.4
SSE	1.567	0.4572	0.3702	0.1695	0.05391	0.02019
R²	0.997	0.9986	0.9982	0.9997	0.9999	0.9999
RMSE	0.01635	0.01086	0.01124	0.00623	0.004102	0.003163
Robust	Bisquare	Bisquare	LAR	Ninguno	LAR	LAR

Tabla 12. Valores de las métricas de ajuste entregadas por Curve Fitting para ambos acumuladores de energía

Contraste del modelo basado en datos

Para el análisis de los resultados obtenidos por los modelos de redes neuronales utilizando la herramienta de Neuronal Net Fitting de Matlab, se tornan importantes las cantidades de datos obtenidos por cada tasa de descarga, los cuales abastecen las entradas (Corriente y temperatura) buscando una salida (voltaje). Para la tasa de descarga de Litio en la tasa de 0.2C, se obtuvieron 8656 datos de corriente, voltaje y temperatura, para la tasa de 0.3C, se obtuvieron 3879 y para la de 0.4C, se lograron obtener 2932 datos. Por otro lado, para el acumulador de Plomo ácido, para la tasa de descarga de 0.2C, se obtuvieron 4371 datos de los parámetros de corriente, voltaje y temperatura, para la tasa de 0.3C 3207 y, por último, para la tasa de 0.4C se obtuvieron 2022 datos. Con estos datos, se procede a alimentar las redes neuronales para cada

experimento y con ello se obtiene que, en el caso de algunas tasas de descarga, para obtener un resultado óptimo, es necesario contar con más neuronas en la capa oculta que en otras. Esto se puede apreciar en la tabla 13.

Tecnología de la batería	Batería de Litio			Batería de Plomo		
	0.2	0.3	0.4	0.2	0.3	0.4
Tasa de descarga						
Cantidad de neuronas en la capa oculta	1	20	10	1	1	2
Coefficiente de determinación (R^2)	0.99196	0.91317	0.99464	0.92314	0.99234	0.9527

Tabla 13. Comparación de las neuronas establecidas en cada red neuronal para cada tasa de descarga

Gracias a esta tabla, se puede notar que, para el caso del acumulador de Litio, se hizo necesario usar más neuronas que para el acumulador de Plomo y esto se puede asociar a que en los experimentos con la batería de Litio se recolectaron más datos de corriente, voltaje y temperatura debido a que estos duraron más tiempo (tabla 1 y 2). Para el caso del acumulador de Litio, en las figuras 48, 49 y 50, se logra evidenciar el número de épocas con los que las redes neuronales alcanzan su mejor valor de MSE para el entrenamiento, validación y prueba.

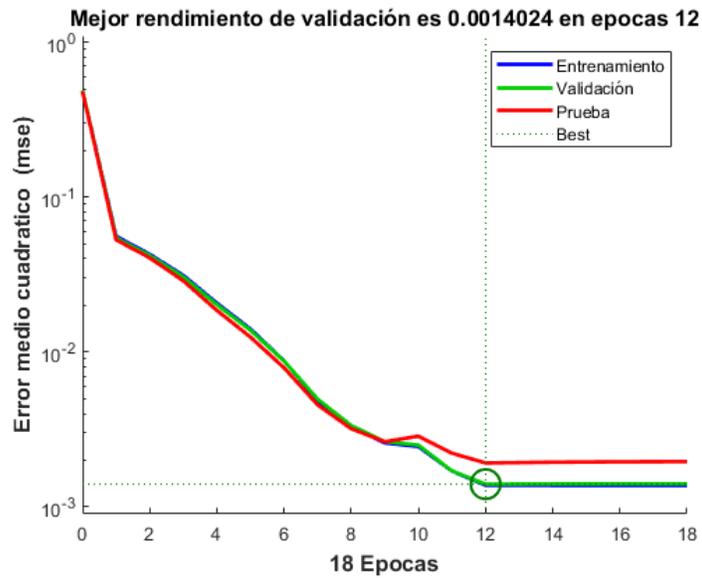


Figura 48. Gráfica de MSE vs épocas para la tasa de descarga de 0.2C en el acumulador de Litio

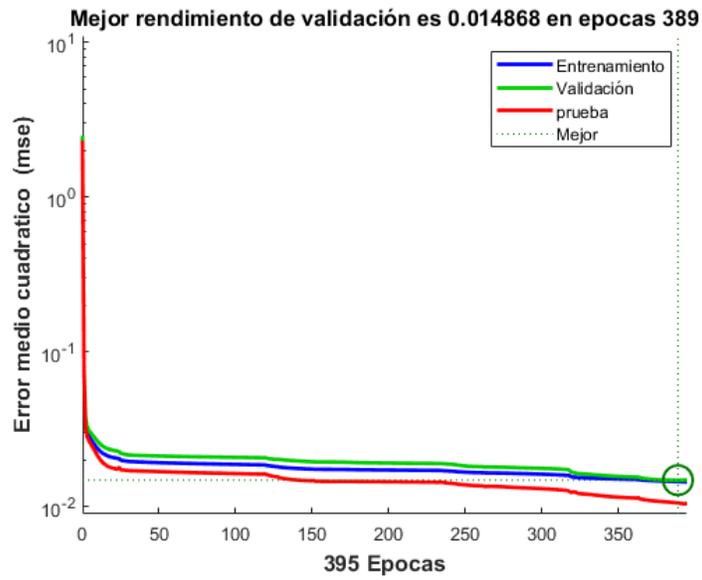


Figura 49. Gráfica de MSE vs épocas para la tasa de descarga de 0.3C en el acumulador de Litio

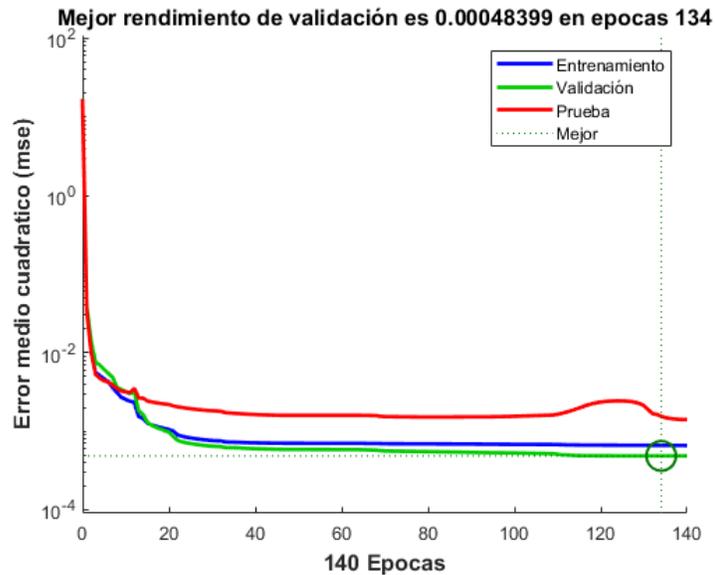


Figura 50. Gráfica de MSE vs épocas para la tasa de descarga de 0.4C en el acumulador de Litio

En la tasa de descarga de 0.2C, se obtuvo el mejor valor de error medio cuadrático de 0.0014024 al momento de completar 12 épocas, como se nota en la figura 47, mientras que para el experimento de 0.3C se tomó 389 épocas para lograr un buen ajuste en los datos de validación observados en la figura 48, con un error medio cuadrático de 0.014868, y, aunque fue el modelo que requirió más neuronas, no logró superar los valores de ajuste obtenidos en los otros dos modelos para el acumulador de Litio. En el modelo para la tasa de descarga de 0.4C, se obtuvo un MSE igual a 0.012971 alcanzado en 134 épocas.

Para el caso del acumulador de energía de Plomo, se obtuvo el mejor valor de MSE en 45 épocas, con un valor de 0.02038 para la tasa de descarga de 0.2C, el cual se aprecia en la figura 51. Mientras que para la tasa de descarga de 0.3C, se obtuvo un MSE de 0.00083103 en 16 épocas, apreciado en la figura 52, y, por último, para la tasa de descarga de 0.4C, se nota que el modelo alcanzó su mejor rendimiento en 150 épocas con un MSE de 0.012971 (figura 53).

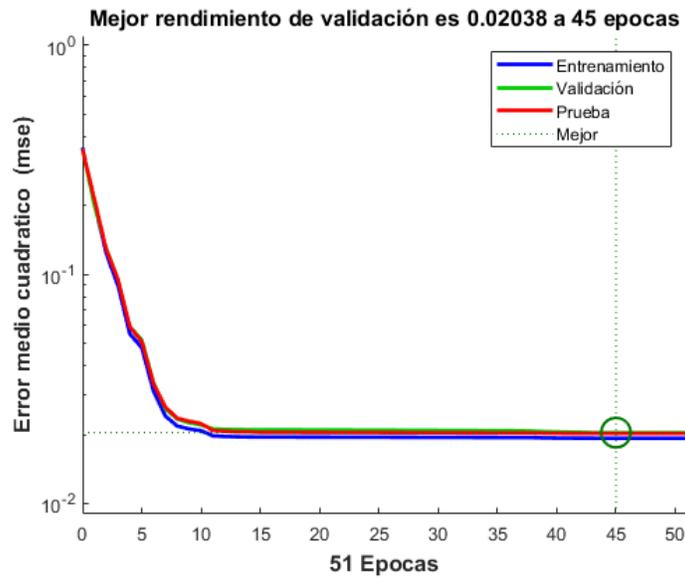


Figura 51. Gráfica de MSE vs épocas para la tasa de descarga de 0.2C en el acumulador de Plomo

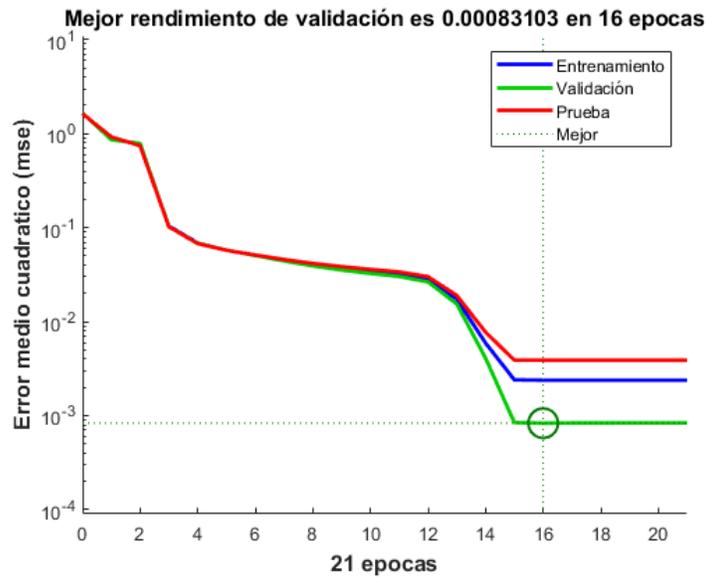


Figura 52. Gráfica de MSE vs épocas para la tasa de descarga de 0.3C en el acumulador de Plomo

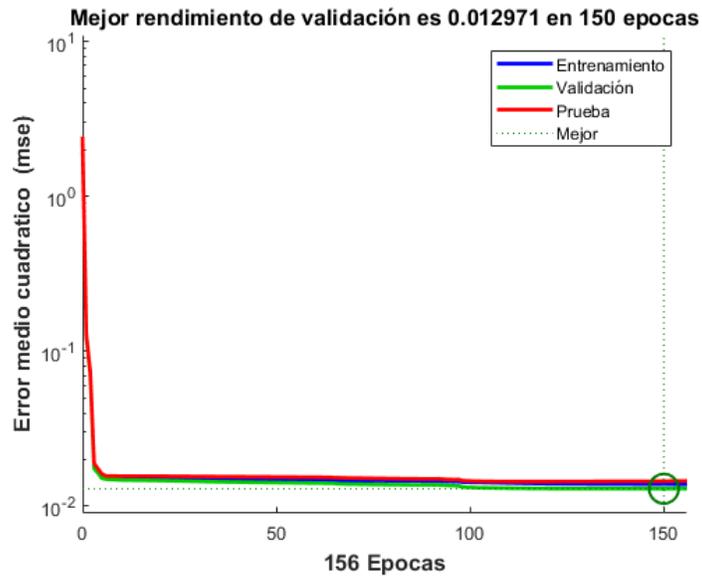


Figura 53. Gráfica de MSE vs épocas para la tasa de descarga de 0.4C en el acumulador de Plomo

Observando el modelo a base de datos como un modelo de caja negra (figura 54), el cual consiste en brindar unas entradas que en este caso son corriente y temperatura para obtener una salida esperada la cual es voltaje, sin tener en cuenta el proceso que se ejecuta en medio para la lograr dicho objetivo [22].

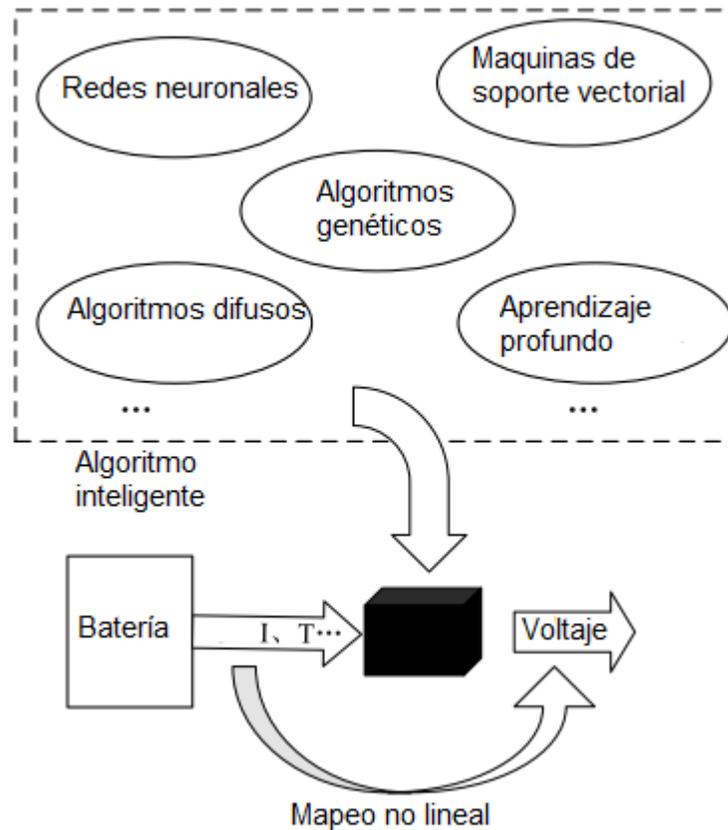


Figura 54. Gráfica del modelo de caja negra [22]

Gracias a esto, se utilizó una red neuronal para cada tasa de descarga, las cuales a partir de la descripción de las gráficas anteriores y la información vista en la tabla 13, permite contrastar los modelos obtenidos por cada tecnología de acumulador. En estos se logra apreciar que para la batería de Plomo, se necesitaron menos neuronas en contraste con los modelos para el acumulador de Litio para poder lograr un valor óptimo de ajuste a los datos experimentales, siendo el mayor para la tasa de descarga de 0.4C con 2 neuronas en la capa oculta y para las otras dos tasas de descarga, solo con una neurona fue suficiente, mientras que para el acumulador de Litio, en la red con más neuronas se necesitaron 20 y sin embargo, fue el procedimiento con el menor ajuste

para todos los experimentos. De la misma manera, el menor número de épocas que fueron necesarias para obtener el mejor MSE en cada caso, se obtuvo en las baterías de Plomo.

Referencias

- [24] Q. Q. Yu, R. Xiong, L. Y. Wang, and C. Lin, "A comparative study on open circuit voltage models for lithium-ion batteries," *Chinese J. Mech. Eng. (English Ed.)*, vol. 31, no. 4, pp. 0–7, 2018, doi: 10.1186/s10033-018-0268-8.
- [25] A. Aryal, M. J. Hossain, and K. Khalilpour, "A Comparative study on state of charge estimation techniques for Lithium-ion Batteries," *2021 IEEE PES Innov. Smart Grid Technol. - Asia, ISGT Asia 2021*, pp. 1–19, 2021, doi: 10.1109/ISGTASIA49270.2021.9715593.
- [26] E. Shangguan *et al.*, "A comparative study of structural and electrochemical properties of high-density aluminum substituted α -nickel hydroxide containing different interlayer anions," *J. Power Sources*, vol. 282, pp. 158–168, 2015, doi: 10.1016/j.jpowsour.2015.02.059.
- [27] A. I. Stan, M. Swierczynski, D. I. Stroe, R. Teodorescu, S. J. Andreasen, and K. Moth, "A comparative study of lithium ion to lead acid batteries for use in UPS applications," *INTELEC, Int. Telecommun. Energy Conf.*, vol. 2014-January, no. January, 2014, doi: 10.1109/intlec.2014.6972152.
- [28] J. Li, J. Klee Barillas, C. Guenther, and M. A. Danzer, "A comparative study of state of charge estimation algorithms for LiFePO₄ batteries used in electric vehicles," *J. Power Sources*, vol. 230, pp. 244–250, 2013, doi: 10.1016/j.jpowsour.2012.12.057.
- [29] P. Poopanya, K. Sivalertporn, and T. Phophongviwat, "A Comparative Study on the

Parameter Identification of an Equivalent Circuit Model for an Li-ion Battery Based on Different Discharge Tests,” *World Electr. Veh. J.*, vol. 13, no. 3, pp. 1–13, 2022, doi: 10.3390/wevj13030050.

[30] P. Tb, “Tb12-75 lifepo4 (12v75ah).”

[31] N.-Ó. Voltaje, “BATERIA-12V-75AH-CP-NETION.pdf.”

Conclusión

A partir de los experimentos de descarga continua, a los cual se sometieron los acumuladores de Litio y Plomo estudiados en este trabajo de investigación, para la tasa de descarga de 0.2C se obtuvieron 17598 datos sumando los datos de tensión, corriente y temperatura, para 0.3C, 11637 y, por último, para 0.4C, 8796 datos (figuras 14,15,16,17,18 y 19). Además, gracias a la caja de herramientas Curve Fitting y procesos analíticos utilizando teorías de circuitos, se logran obtener modelos de circuitos equivalentes, haciendo uso del modelo de polarización dual descrito en la literatura revisada que gracias a las métricas estadísticas como el coeficiente de determinación y el error medio cuadrático nos indican que se obtuvieron excelentes ajustes de los modelos como se logra apreciar en la tabla 12. Para el modelo basado en datos, se utilizaron redes neuronales con la caja de herramientas Neural Net Fitting, donde alimentando la red con los datos de corriente y temperatura, se logra obtener un ajuste al voltaje. Para cada tasa de descarga se utilizaron diferentes cantidades de neuronas en la capa oculta según se iba dando el ajuste de estas, intentando utilizar el menor número posible. Para este modelo también se obtuvieron resultados de las métricas estadísticas antes nombradas, donde se logra corroborar. Con lo antes mencionado, se logra concluir que se logró modelar los perfiles de descarga bajo la tasa de descarga de 0.2C, 0.3C y 0.4C para los acumuladores de energía de Litio y Plomo estudiados en modelos basados en datos y modelos de circuito equivalente satisfactoriamente.

Nota

Cabe resaltar que este proyecto de investigación contó con financiación del fondo Fonciencias de la universidad del Magdalena.

Anexos

ÍNDICE	NOMBRE	ECUACIÓN
1	Ecuación del modelo de polarización dual	$V_{batt} = V_{oc} - V_1 - V_2 - R_o * i_{desc}$
2	Ecuación diferencial para la primera rama RC del modelo de polarización dual	$\frac{dV_1}{dt} = \frac{V_1}{R_1 * C_1} + \frac{i_{desc}}{C_1}$
3	Ecuación diferencial para la primera rama RC del modelo de polarización dual	$\frac{dV_2}{dt} = \frac{V_2}{R_2 * C_2} + \frac{i_{desc}}{C_2}$
4	Solución de la ecuación diferencial de la primera rama RC del modelo de polarización dual	$V_1 = I_{desc}R_1 + k_1 e^{-\frac{t}{R_1C_1}}$
5	Solución de la ecuación diferencial de la segunda rama RC del modelo de polarización dual	$V_2 = I_{desc}R_2 + k_2 e^{-\frac{t}{R_2C_2}}$
6	Ecuación del modelo de polarización dual en términos de voltajes, resistencias y capacitores	$V_{batt} = V_{oc} - I_{desc}(R_1 + R_2 + R_o) - K_1 e^{-\frac{t}{R_1C_1}} - K_2 e^{-\frac{t}{R_2C_2}}$
8	Ecuación exponencial de dos términos entregada por Curve Fitting	$V_{bat} = ae^{bt} + ce^{dt}$
9	Comparación entre la ecuación del modelo de polarización dual y la entregada por curve fitting	$a = K_1, b = -\frac{1}{R_1C_1}, c = K_2 \text{ y } d = -\frac{1}{R_2C_2}$

Tabla 14. Ecuaciones que surgen del modelo de circuito equivalente y el modelo computacional

Referencia
ENERGY STORAGE LITHIUM BATTERY
TB12-75 LIFEPO4 (12V75AH)



Dimensiones y Características

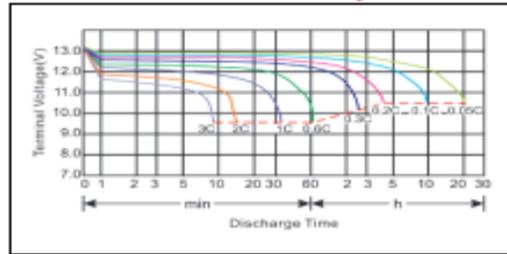


Tensión nominal	12V
Capacidad nominal (10 tasa de horas 7.5A)	75AH
Peso aproximado	9,3kg
Terminal	Estándar Insert T3 Opcional
Largo mm	357
Ancho mm	166
Alto sin terminal mm	173
Resistencia interna carga com	<= 30 mΩ

Especificación

Capacidad 25 C (77 F)	10 Tasa de horas (7.5A)	75AH
	3 Tasa de horas (18.7A)	58AH
	1 Tasa de horas (41.2A)	42AH
Capacidad afectada por la temperatura	40 C (104 F)	101%
	25 C (77 F)	100%
	0 C (32 F)	93%
Auto-descarga en 25 C (77 F) (Antes de recarga)	-15 C (5 F)	73%
	Cap. después de 3 meses	92%
	Cap. después de 6 meses	85%
Carga de tensión constante	Cap. después de 12 meses	67%
	Ciclo	Corriente de carga inicial <60A 14.4V - 15V at 25 C (77F)
En espera	13.6V - 13.8V at 25 C (77 F)	

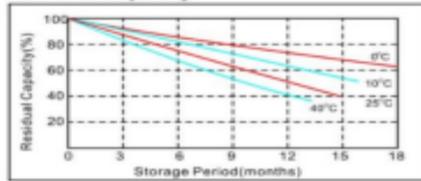
Características de descarga



Temperatura de funcionamiento

Battery Type	-20 °C	-10 °C	0 °C	5 °C	10 °C	20 °C	25 °C	30 °C	40 °C	45 °C
Li Battery	12V	73%	82%	93%	95%	97%	100%	100%	100%	102%

Residual Capacity



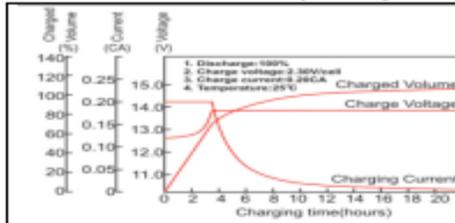
Características de descarga de corriente constante

F.V/Time	1,2h	3h	5h	10h	21h
10V	60	25	15	7.5	3.8

Características de descarga de potencia constante

F.V/Time	1,2h	3h	5h	10h	21h
10V	780	300	180	90.0	45.0

Características de Voltaje de Carga



Ciclo de vida en relación con la profundidad de Descarga

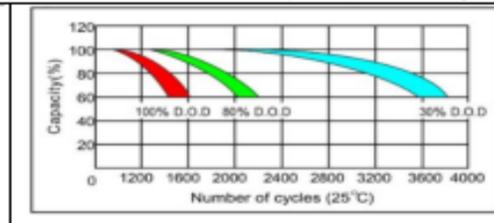


Figura 56. Datos entregados por el fabricante del acumulador de Litio [30]

NETION - Óptimo Voltaje

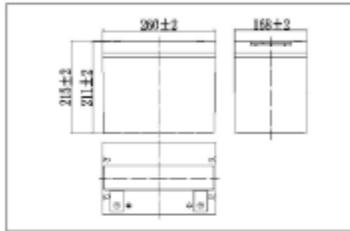


Batería Ciclo Profundo 12V 75Ah

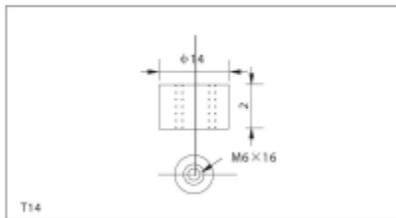
• Especificaciones

Voltaje Nominal	12 V	
Capacidad Nominal (Indice de 20 horas)	75 Ah	
Dimensiones	Largo	260 ± 2 mm
	Ancho	168 ± 2mm
	Altura	211 ± 2mm
	Altura Total	215 ± 2mm
Peso Aproximado	24.2kg(53.3lbs)±3%	

• Dimensiones Externas (mm)



• Tipo de Terminal (mm)



• Construcción

Componente	Placa Positiva	Placa Negativa	Contenedor	Cubierta	Separador	Electrolito	Válvula de Seguridad	Terminal
Materia Prima	Dióxido de Plomo	Plomo	ABS	ABS	AGM	Ácido sulfúrico	Caucho	Cobre

• Características de descarga de corriente constante : A (25 °C, 77 °F)

FV / Time	10 min	15 min	30 min	60 min	2 h	3 h	4 h	5 h	8 h	10 h	20 h
9.60V	170	131	78.4	48.2	28.5	20.5	16.4	14.0	9.63	794	4.21
9.90V	165	128	76.8	47.5	28.3	20.4	16.3	13.9	9.57	792	4.20
10.2V	158	123	74.6	46.3	28.1	20.3	16.2	13.8	9.50	790	4.19
10.5V	151	119	72.7	44.8	27.7	20.1	16.1	13.7	9.44	785	4.16
10.8V	143	113	70.0	43.4	27.0	19.5	15.6	13.3	9.15	780	4.13

• Características de descarga de potencia constante : W (25 °C, 77 °F)

FV / Time	10 min	15 min	30 min	60 min	2 h	3 h	4 h	5 h	8 h	10 h	20 h
9.60V	1836	1439	880	550	330	241	193	166	114	94.8	50.5
9.90V	1781	1404	862	541	328	240	192	165	114	94.6	50.4
10.2V	1708	1352	836	528	325	238	190	163	113	84.3	50.3
10.5V	1634	1306	815	511	311	237	189	162	112	93.8	50.0
10.8V	1543	1237	785	495	495	230	183	157	109	93.1	49.6

*Nota: Los datos de características anteriores pueden obtenerse dentro de tres ciclos de carga o descarga.

• Características

Capacidad (25 °C)	10 HR (10.8 V)	75 Ah
	3 HR (10.8V)	57 Ah
	1 HR (10.5 V)	43 Ah
Tipo de Terminal	T14	
Resistencia Interna Carga Completa (25 °C)	Aprox. 5.5m Ω	
Capacidad afectada por la temperatura (30 HR)	40 °C	102%
	25 °C	100%
	0 °C	85%
	-15 °C	65%
Auto descarga (25°C)	3 Meses	Capacidad Restante : 91%
	6 Meses	Capacidad Restante : 82%
	12 Meses	Capacidad Restante : 65%
Temperatura Nominal de Funcionamiento	25°C ± 3 °C (77 °F ± 5°F)	
Rango de Temperatura de Funcionamiento	Descarga	-15 °C-50 °C (5 °F -122 °F)
	Carga	-10 °C-50 °C (14°F -122 °F)
	Almacenamiento	-20 °C -50 °C (-4 °F - 122 °F)
Tensión de Carga de Mantenimiento (25 °C)	13.50 to 13.80V Compensación de Temperatura : -18 mV/°C	
Voltaje de carga ciclico (25 °C)	14.50 to 15.00 V Compensación de Temperatura : -30 mV/°C	
Corriente de Carga Máxima	22.5 A	
Corriente de Descarga Máxima	700 A (5 sec.)	
Vida Flotante Diseñada(20°C)	10 años	

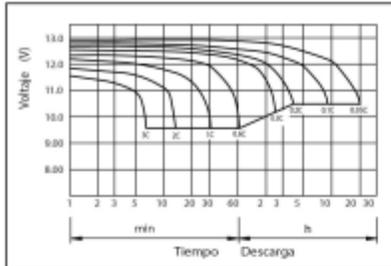


Figura 57. Datos entregados por el fabricante del acumulador de Plomo [31]

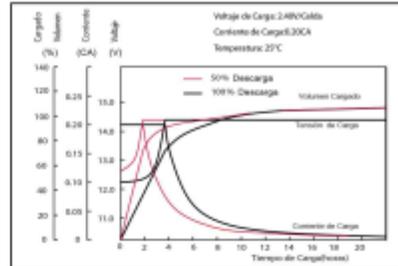
Batería Ciclo Profundo 12V 75Ah



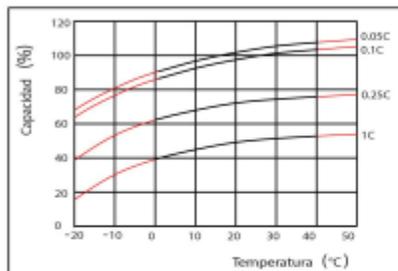
● Características de descarga (25°C)



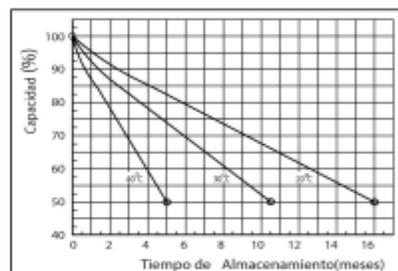
● Características de Carga (25°C)



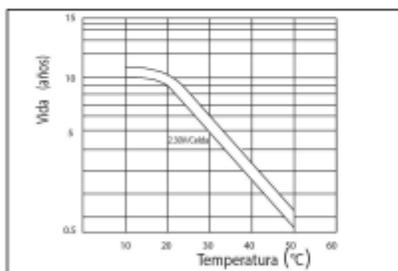
● Efectos de temperatura en la capacidad



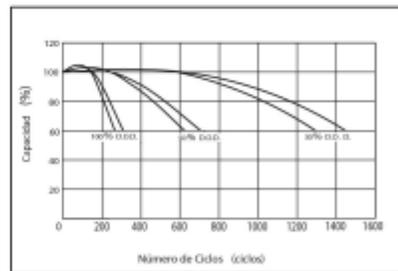
● Características de autodescarga



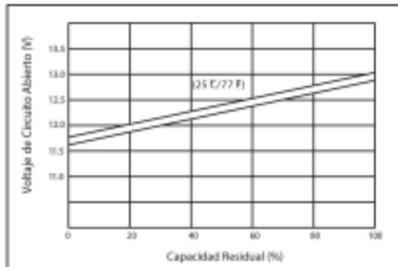
● Vida flotante en la temperatura



● Ciclo de vida en D.O.D (25°C)



● La relación para OCV y Capacidad (25°C)



● La relación de voltaje de carga y temperatura

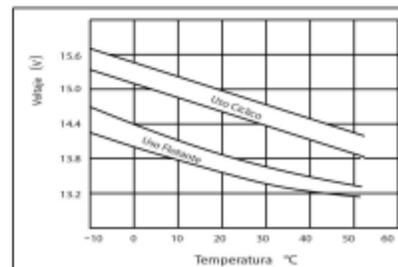


Figura 58. Continuación de la información del fabricante del acumulador de Plomo [31]