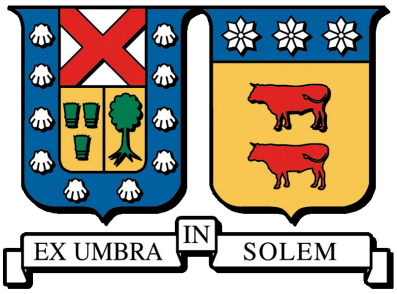
Universidad Técnica Federico Santa María
Departamento de Ingeniería Eléctrica
Santiago, Chile



Desarrollo y pruebas de simulación de nueva estrategia de control de energía para vehículos eléctricos compuestos por múltiples fuentes de almacenamiento

Angel Alejandro Silva Rivera

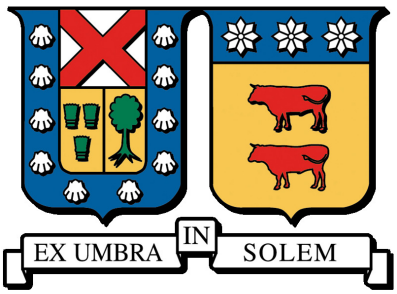
2024

Requisito parcial para obtener el título de:
Ingeniero Civil Electricista

Profesor Guía:
Dr. Antonio Sánchez
Comisión:
MS. Felipe Morales

Santiago, Agosto 2024.

Universidad Técnica Federico Santa María
Departamento de Ingeniería Eléctrica
Santiago, Chile



Desarrollo y pruebas de simulación de nueva estrategia de control de energía para vehículos eléctricos compuestos por múltiples fuentes de almacenamiento

Angel Alejandro Silva Rivera

2024

"Last but not least, I wanna thank me for believe in me"
— Snoop Dog

Agradecimientos

Escribir estos agradecimientos resultó un poco abrumador al pensar en todo el camino recorrido hasta ahora, hacer memoria de los momentos donde decidí estudiar esta carrera y luego pensar en todas aquellas personas con las que interactué en el camino.

Quisiera comenzar agradeciendo a mi abuelo Nano, quien si bien no está con nosotros y no pudo alcanzar a verme cerrar esta etapa, es una de las personas que más ha influenciado en mi, con sus valores, humildad e increíble fortaleza. Agradecer a mi Madre, que con sus dificultades logró construir un entorno donde pude concentrarme en mis estudios sin necesidades mayores.

Agradecer a los amigos que hice en este camino, donde quisiera destacar a Carlos (alias Omono), quien siempre estuvo abierto a que lo interrumpiera con mis divagaciones a deshoras de la noche, incluso cuando con eso le quitaba tiempo de estudio; Mackenzie, con quien compartí muchas horas los primeros años y me ayudó a relajarme respecto a las evaluaciones; Víctor, uno de mis primeros amigos en esta etapa hasta el día de hoy y una de las personas que más me han hecho reír; Álvaro, con quien no tuve mayor contacto durante los primero años, pero siempre ha sido una persona muy agradable con quien compartir, destaco su humor y preocupación; a Fabian, con quien compartí innumerables tardes de estudio, trasnochando haciendo trabajos, discutiendo de asuntos académicos, de música, de series, de la vida en general y que junto a Carlos me incluyeron en su grupo de amigos donde me hicieron sentir muy bien recibido. Agradezco también a Pablo, quien durante la finalización de esta etapa ha mostrado preocupación hacia mi persona y me ha incluido en su vida cotidiana.

No puedo pasar por alto el agradecer a mis profesores, especialmente al profesor Rodrigo Rozas, quien fue por muchos ramos una fuente de gran estrés, pero siento de quien aprendí mucho; También al profesor Antonio Sánchez, por su paciencia hacia mi persona a pesar de los errores cometidos tanto en aquellos incidentes de laboratorio como también durante el desarrollo de este trabajo.

Quisiera también darle un agradecimiento especial a Roser, quien probablemente estuvo presente en la redacción de muchos de los párrafos y simulaciones de esta memoria. Me has ayudado a ser mejor, aprender de más disciplinas, participar de proyectos, ampliar mi mundo y mis metas. Gracias por acompañarme en esta etapa.

Índice de Contenidos

Índice de Contenidos I

Índice de Figuras III

Índice de Tablas V

Resumen 1

1. Introducción 2

1.1. Objetivos . . . 3

1.1.1. Objetivo principal . . . 3

1.1.2. Objetivos específicos . . . 3

1.1.3. Alcance . . . 3

2. Estado del arte 4

2.1. Modelo de pila de combustible . . . 4

2.1.1. Celdas de Combustible PEM (PEMFC) . . . 5

2.1.2. Modelo Eléctrico de la PEMFC . . . 5

2.2. Modelo de batería . . . 6

2.2.1. Modelo eléctrico de batería . . . 7

2.3. Modelo de súpercondensador . . . 8

2.3.1. Modelo eléctrico de SC . . . 8

2.4. Topologías de circuito de potencias . . . 9

2.4.1. Full FCEV . . . 10

2.4.2. Hibridación FC con Batería . . . 10

2.4.3. Hibridación FC con Supercondensador (SC) . . . 10

2.4.4. Hibridación FC, Batería y SC . . . 10

2.5. Estrategias de control de energía . . . 11

2.5.1. Control basado en reglas . . . 12

2.5.2. Control basado en optimización . . . 12

2.5.3. Control basado en aprendizaje . . . 13

2.5.3.a. Aprendizaje por refuerzo . . . 15

2.5.3.b. Deep deterministic policy gradient (DDPG) 16
2.6. Discusión 17

3. Topología del circuito de potencia y control de convertidores. 19
3.1. Circuito de potencia 19
3.2. Control de convertidores. 20
3.2.1. Control de convertidor boost 21
3.2.1.a. Linealización 22
3.2.1.b. Lazo interno de corriente 22
3.2.1.c. Lazo externo de tensión 22
3.2.1.d. sintonización 22
3.2.2. Modelo promedio de convertidor boost 23

4. Estrategia de control de energía 25
4.1. Generalidades 25
4.1.1. Configuración de red neuronal 31
4.1.1.a. Red del crítico 32
4.1.1.b. Red del actor 32
4.2. Función de recompensa 33
4.3. Entrenamiento 35

5. Pruebas y resultados de simulación 38
5.1. Pruebas sobre ruta FTP-75 38
5.2. Aplicación de banda muerta 42

6. Conclusiones. 47

Apéndices 49

A. Anexos 49
A.1. Código para DDPG 49
A.2. Dispositivos 52
A.2.1. Pila de combustible HyPM-HD15 52
A.2.2. Batería LF105 53
A.2.2.a. Curva de polarización 54
A.3. Supercondensador LSUM 129R6C 0062F 55
A.3.1. Constantes modelo SC 56

B. Otro apéndice 57

Índice de Figuras

2.1. Modelo eléctrico simplificado de una celda de combustible PEMFC 6
2.2. Modelo eléctrico simplificado para una batería de ión-litio 7
2.3. Modelo eléctrico para SC 8
2.4. Topologías de vehículos eléctricos basados en pilas de combustible. Extraído de [11] 9
2.5. Ejemplo de red neuronal representada por medio de grafos 14

3.1. Circuito de potencia de topología completamente activa 20
3.2. Topología de convertidor boost. 21
3.3. Convertidor boost para $m = 1$ 21
3.4. Convertidor boost para $m = 0$ 21
3.5. Esquema de control anidado para convertidor boost 21
3.6. Esquema de modelo promedio de convertidor boost 23
3.7. Comparación a impacto de carga sobre convertidor promedio y conmutado 24

4.1. Diagrama de cuerpo libre para vehículo 25
4.2. Eficiencia de pila de combustible en función de la potencia entregada . . 28
4.3. Diagrama general de estrategia de control propuesto 30
4.4. Función de activación tangente hiperbólica 31
4.5. Red del crítico 32
4.6. Red del actor 33
4.7. Función campana de gauss 33
4.8. Etapas relevantes para proceso de entrenamiento y validación del Agente 35
4.9. Resultados de entrenamiento durante Etapa 2 36

5.1. Perfil de tensión y potencia demandada 38
5.2. Perfil de tensión y potencia demandada ante máxima demanda 38
5.3. Potencia entregada por las fuentes del FCHEV 39
5.4. Potencia entregada por las fuentes del FCHEV ante máxima demanda . . 39
5.5. Perfil de tensión y corriente de batería 39
5.6. Perfil de tensión y corriente de batería ante máxima demanda 39
5.7. Perfil de tensión y corriente de SC 40

5.8. Perfil de tensión y corriente de SC ante máxima demanda 40
5.9. Perfil de carga y tensión de batería y SC respectivamente. 41
5.10. Eficiencia de trabajo de la pila de combustible 41
5.11. Perfil de tensión y potencia demandada 42
5.12. Perfil de tensión y potencia demandada ante máxima demanda 42
5.13. Potencia entregada por las fuentes del FCHEV 43
5.14. Potencia entregada por las fuentes del FCHEV ante máxima demanda . . 43
5.15. Perfil de tensión y corriente de batería 43
5.16. Perfil de tensión y corriente de batería ante máxima demanda 43
5.17. Perfil de tensión y corriente de SC. 44
5.18. Perfil de tensión y corriente de SC ante máxima demanda 44
5.19. Perfil de carga y tensión de batería y SC respectivamente. 45
5.20. Eficiencia de trabajo de la pila de combustible 45

A.1. Configuración de banco de baterías 53
A.2. Curvas de polarización de batería 54

Índice de Tablas

4.1. Variables observadas por el Agente 29

5.1. Resumen estadístico de variables de interés. 42
5.2. Resumen estadístico de variables de interés. 46

A.1. Parámetros de pila de combustible 52
A.2. Parametros generales Batería LF105 53
A.3. Parámetros supercondensador LSUM 129R6C 0062F 55
A.4. Descripción de las variables en la ecuación del SC 56

Nomenclatura.

x	:	Valor temporal o variable de la cantidad x.
X	:	Valor medio de la cantidad x.
x^*	:	Valor de referencia para la cantidad x.
x_y	:	Valor de la cantidad x referida al secundario.
x_Y	:	Valor de la cantidad x referida al primario.
x_s	:	Variable referida a la entrada, p. ej.: ω_s frecuencia de entrada.
x_o	:	Variable referida a la salida, p. ej.: ω_o frecuencia de salida.
$a,\ b,\ c$	:	Sub-índices utilizados para variables de entrada.
$u,\ v,\ w$	:	Sub-índices utilizados para variables de salida.
N	:	Neutro de la alimentación.
n	:	Neutro de la carga.
o	:	Neutro del inversor.

Resumen

En este trabajo se ha desarrollado y evaluado una estrategia de control de energía para vehículos eléctricos alimentados por pilas de combustible, baterías y supercondensadores, enfocada en la eficiencia del uso del hidrógeno y la optimización del rendimiento del sistema. La estrategia implementada emplea técnicas avanzadas de aprendizaje automático, específicamente el algoritmo Deep Deterministic Policy Gradient (DDPG), para ajustar adaptativamente las contribuciones de cada fuente de energía en respuesta a las variaciones de demanda energética del vehículo.

El modelo de control propuesto ha demostrado ser efectivo para operar la pila de combustible en su punto de máxima eficiencia, aproximadamente el 48 %, incluso ante fluctuaciones significativas en la demanda de energía. Sin embargo, se identificó un comportamiento subóptimo relacionado con la operación continua de la pila de combustible en ausencia de demanda significativa, lo que provocaba una carga excesiva de la batería, potencialmente perjudicial para su vida útil.

Para abordar este problema, se implementó una banda muerta en la demanda de potencia que inactiva el control cuando la demanda es extremadamente baja, lo cual ayudó a evitar la carga innecesaria de la batería y mantener la eficiencia de la pila de combustible en niveles óptimos durante el funcionamiento necesario.

Los resultados obtenidos muestran que la estrategia de control basada en aprendizaje profundo es prometedora para la gestión de energía en vehículos eléctricos híbridos. Sin embargo, la investigación también reveló áreas para mejora futura, incluyendo la optimización del agente de control para equilibrar mejor la eficiencia de la pila de combustible con otros aspectos operativos como el mantenimiento del estado de carga de la batería.

Este estudio contribuye al desarrollo de sistemas de transporte más limpios y eficientes, ofreciendo un enfoque robusto y adaptable para la gestión de energía en vehículos eléctricos que utilizan múltiples fuentes de energía. Además, destaca la importancia de integrar técnicas de aprendizaje automático en aplicaciones de control energético.

Capítulo 1

Introducción

Para el presente trabajo, se ha considerado la tendencia mundial con respecto a la descarbonización de la matriz energética y al creciente interés en disminuir las emisiones de gases de efecto invernadero (GEI). Asimismo, se ha contemplado el ahorro y el buen uso de la energía, promoviendo nuevos estándares para el uso eficiente de los recursos.

Hoy en día, el sector energético contribuye con el 77 % de las emisiones a nivel nacional. El sector del transporte, por su parte, es responsable del 22 % del total de las emisiones de GEI. Se estima que para el año 2050, el 40 % del parque de vehículos livianos (vehículos cuyo peso es menor a 2.7 toneladas) estará compuesto por vehículos eléctricos, lo que permitirá evitar emisiones equivalentes a 11 millones de toneladas de CO_2 al año [1]. Actualmente, el mercado de vehículos eléctricos ha experimentado un rápido crecimiento. En el año 2022, las ventas de vehículos eléctricos a nivel mundial superaron los 10 millones y se espera un aumento del 35 % para el año 2023. En el ámbito nacional, la flota principal de vehículos eléctricos se encuentra en el transporte público de las principales ciudades; además, el sector privado ha impulsado iniciativas para integrar la electromovilidad en sus operaciones.

En los últimos años, el hidrógeno ha adquirido un papel más destacado como vector energético. En nuestro país, se ha aprobado un fondo de mil millones de dólares, con el propósito de atraer inversiones para el desarrollo del hidrógeno verde, obtenido a través del uso de energías renovables [2]. Esto posiciona al hidrógeno como un vector energético de gran relevancia para el futuro. El hidrógeno puede almacenarse y transportarse para generar energía eléctrica mediante celdas de combustible sin emisiones de GEI. Es una forma de energía limpia y silenciosa, además, posee una densidad energética superior a la de una batería de litio [3], y la recarga de los depósitos puede realizarse en pocos minutos. Debido a estas características, las celdas de hidrógeno se presentan como una alternativa atractiva para su implementación en vehículos eléctricos, especialmente debido a las limitaciones de peso y volumen.

Sin embargo, la pila de combustible (compuesta por celdas) enfrenta importantes desafíos tecnológicos, especialmente debido a su baja densidad de potencia, lo que se traduce en una respuesta lenta en cuanto a la potencia generada (ver Figura 1), y su incapacidad para absorber energía. En una ruta urbana, un vehículo requiere una respuesta rápida para un rendimiento óptimo, y dada la presencia de numerosos frenos en este tipo de rutas, resulta crucial capturar parte de la energía generada por el frenado para su aprovechamiento [4] [5]. Por esta razón, se proponen fuentes de energía auxiliares a la pila de combustible, como baterías y/o supercondensadores, para proporcionar al vehículo una respuesta más rápida y la capacidad de recuperar la energía de los frenos. Estos vehículos híbridos, conocidos como "Fuel Cell Hybrid Electric Vehicle" (FCHEV por sus siglas en inglés), combinan múltiples fuentes de energía para constituir un vehículo eléctrico puro, manteniendo el hidrógeno como fuente de energía principal [6].

1.1. Objetivos

1.1.1. Objetivo principal

Desarrollar y probar mediante simulación una estrategia de control de energía para vehículos eléctricos alimentado con pilas de combustible, baterías o supercondensadores, que tenga como propósito el uso eficiente del hidrógeno.

1.1.2. Objetivos específicos

1. Estudiar el estado del arte en torno a estrategias de control de energía para vehículos híbridos implementados con pilas de combustible.
2. Dimensionar topología del sistema en base criterios de energía y potencia.
3. Diseñar una estrategia de control de energía que asegure el máximo aprovechamiento de hidrógeno.
4. Evaluar el desempeño de la nueva estrategia de control mediante simulación.

1.1.3. Alcance

El presente trabajo se centrará en el diseño de la estrategia de control de energía de sobre las fuentes de almacenamiento presentes en el vehículo eléctrico, donde se contemplarán las variables propias del fenómeno eléctrico (tensiones, corrientes, potencia eléctrica, estados de carga de fuentes de almacenamiento, entre otras) de manera que dicha estrategia actué sobre un modelo eléctrico simplificado de un vehículo eléctrico.

Capítulo 2

Estado del arte

2.1. Modelo de pila de combustible

Las celdas de combustible son dispositivos electroquímicos que convierten la energía química del hidrógeno y el oxígeno en electricidad, agua y calor mediante una reacción tipo redox. El hidrógeno se introduce en el ánodo de la celda, donde se ioniza, liberando protones y electrones. Los protones atraviesan una membrana de intercambio protónico (PEM), mientras que los electrones viajan a través de un circuito externo, generando electricidad. En el cátodo, los protones y electrones se recombinan con el oxígeno para formar agua.

En las celdas de combustible de hidrógeno, el ánodo separa el hidrógeno en protones y electrones utilizando un catalizador, comúnmente de platino. La reacción en el ánodo es:

$$\mathrm{H_2} \rightarrow 2\mathrm{H^+} + 2\mathrm{e^-} \tag{2.1}$$

Los protones atraviesan la membrana de intercambio protónico (PEM) hacia el cátodo, mientras que los electrones viajan a través de un circuito externo, generando así una corriente eléctrica. En el cátodo, los protones y los electrones se recombinan con el oxígeno del aire para formar agua. La reacción en el cátodo es:

$$\frac{1}{2}\mathrm{O_2} + 2\mathrm{H^+} + 2\mathrm{e^-} \rightarrow \mathrm{H_2O} \tag{2.2}$$

Los componentes clave de una celda de combustible incluyen el ánodo, el electrolito (PEM), el cátodo y los catalizadores. El ánodo recibe el hidrógeno y lo descompone en protones y electrones. El electrolito, específicamente una membrana de intercambio protónico (PEM), permite el paso de protones mientras bloquea los electrones. El cátodo facilita la recombinación de protones, electrones y oxígeno del aire para formar agua. Los catalizadores, comúnmente de platino, aceleran estas reacciones electroquímicas.

2.1.1. Celdas de Combustible PEM (PEMFC)

Las celdas de combustible de membrana de intercambio protónico son conocidas por su capacidad de operar a bajas temperaturas, típicamente entre 60°C y 80°C. Esto permite un arranque rápido y reduce el desgaste en los componentes. Tienen una alta densidad de energía, lo que permite diseños compactos y ligeros. Además, las PEMFC pueden ajustar rápidamente la producción de energía en respuesta a la demanda, lo que es crucial para aplicaciones en transporte.

Sin embargo, la eficiencia real de las PEMFC en aplicaciones prácticas suele ser menor que la teórica. Aunque las celdas de combustible pueden tener eficiencias teóricas del 60 % o más, las condiciones operativas reales y las pérdidas internas suelen reducir esta cifra a un rango más realista de entre 40 % y 50 % [7]. Factores como la gestión del agua, el calor generado durante la operación y las pérdidas por resistencias internas contribuyen a esta disminución en la eficiencia.

Los vehículos de pila de combustible ofrecen varias ventajas. Emiten solo vapor de agua, lo que contribuye a la reducción de la contaminación del aire. Ofrecen rangos de conducción comparables a los vehículos de combustión interna, con tiempos de recarga similares a los de recarga de gasolina. Aunque actualmente se centran en el hidrógeno, las PEMFC pueden adaptarse a otros combustibles que generen hidrógeno.

2.1.2. Modelo Eléctrico de la PEMFC

El modelo eléctrico de una celda de combustible PEMFC es fundamental para simular y analizar su comportamiento en sistemas de energía. Existen diferentes enfoques para modelar las celdas de combustible, siendo los más comunes los modelos eléctricos que representan las características de las celdas mediante circuitos equivalentes.
El modelo simplificado de una celda de combustible representa la celda como una fuente de tensión controlada en serie con una resistencia constante. La ecuación del tensión de la celda (V_{fc}) se describe en las Ecuaciones 2.3 y 2.4

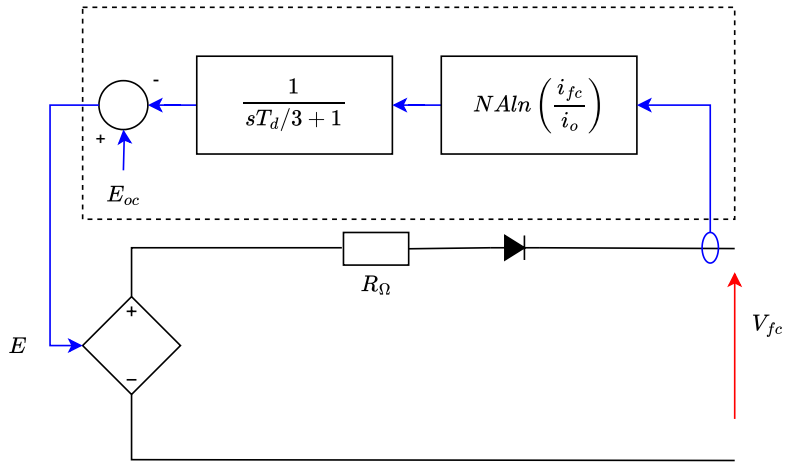


Figura 2.1: Modelo eléctrico simplificado de una celda de combustible PEMFC

$$V_{fc} = E - R_{ohm} \cdot i_{fc} \tag{2.3}$$

$$E = E_{oc} - NAln\left(\frac{i_{fc}}{i_0}\right) \cdot \frac{1}{sT_d/3+1} \tag{2.4}$$

donde:

- E_{oc} es la tensión de circuito abierto
- R_{ohm} es la resistencia interna de la celda
- i_{fc} es la corriente de la celda.
- N representa el número de celas
- A corresponde a la pendiente de Tafel
- i_0 es la corriente de intercambio
- T_d corresponde al tiempo de respuesta de la celda (hasta el 95 % del valor final)
- V_{fc} es la tensión en terminales de la pila

2.2. Modelo de batería

Las baterías, como dispositivos de almacenamiento de energía electroquímica, son fundamentales en numerosas aplicaciones tecnológicas. Existen diversos tipos de baterías, cada uno con características específicas que las hacen adecuadas para distintas aplicaciones. Entre los tipos más comunes se encuentran las baterías de plomo-ácido, níquel-cadmio, níquel-metal hidruro y ion-litio.

Las baterías de ion-litio se han destacado particularmente en el campo de la electromovilidad debido a su alta densidad energética, capacidad de carga rápida y larga vida útil. Estas características las hacen ideales para vehículos eléctricos, donde el peso, el espacio y la eficiencia energética son críticos. Además, su capacidad para manejar cientos de ciclos de carga y descarga con degradación mínima contribuye a su viabilidad económica y sostenibilidad a largo plazo.

2.2.1. Modelo eléctrico de batería

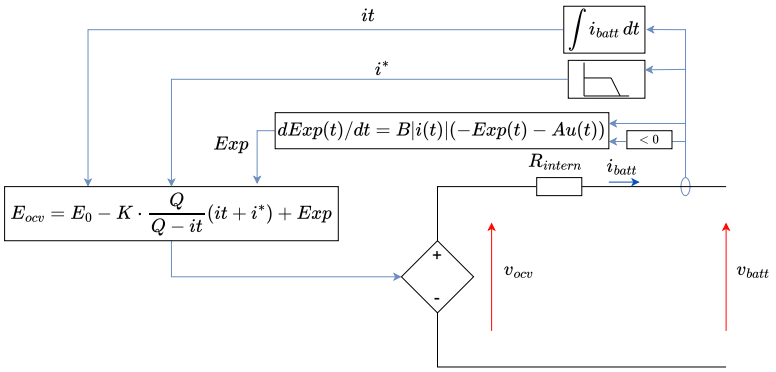


Figura 2.2: Modelo eléctrico simplificado para una batería de ión-litio

El modelo eléctrico para una batería de ion-litio incluye componentes que representan las características electroquímicas y físicas intrínsecas:

- Voltaje de Circuito Abierto (OCV): Función del Estado de Carga (SOC), que refleja la capacidad restante de la batería.
- Resistencia Interna (R): Afecta la eficiencia y la generación de calor durante la operación.
- Capacitancia y Resistencias Dinámicas: Estos elementos simulan la respuesta dinámica de la batería a los cambios de carga y descarga.

Un modelo común utilizado en la simulación de baterías de ion-litio es el modelo de circuito equivalente, descrito por la ecuación:

$$V_{\text{batt}} = E_0 - \frac{K}{Q}(Q - it) \cdot it - R \cdot i + A \exp(-B \cdot it) \tag{2.5}$$

donde:

- E_0 es el voltaje de circuito abierto, que varía con el SOC.

- K representa las pérdidas por polarización.
- Q es la capacidad total de la batería.
- it indica la carga acumulada.
- A y B ajustan la respuesta voltaje-corriente.
- R es la resistencia interna.
- i es la corriente de operación.

2.3. Modelo de súpercondensador

Los supercondensadores (SC por sus siglas), también conocidos como ultracapacitores, son dispositivos de almacenamiento de energía que se destacan por su capacidad de carga y descarga a altas tasas de potencia. A diferencia de los condensadores tradicionales que almacenan energía puramente por medios electrostáticos, los SC combinan métodos electrostáticos con almacenamiento electroquímico, lo que les permite alcanzar capacidades mucho mayores [8].

La estructura de un SC incluye electrodos de carbono poroso de alta superficie, un electrolito y un separador. La energía se almacena mediante la formación de una doble capa eléctrica en la interfaz electrodo-electrolito [9]. Estos dispositivos son particularmente valiosos en sistemas que requieren rápidas ráfagas de energía, tales como en vehículos eléctricos y en dispositivos electrónicos donde se requieren flujos de energía cortos y potentes [10].

2.3.1. Modelo eléctrico de SC

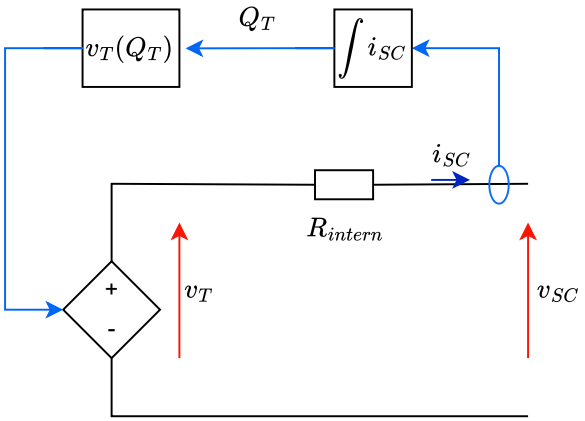


Figura 2.3: Modelo eléctrico para SC

En la Figura 2.3 se expone un modelo simplificado para un SC. Este funciona por medio de una fuente de tensión controlada que toma como entrada la corriente de salida del SC para calcular la tensión de circuito abierto al paso de simulación siguiente. En primera instancia se determina la carga Q_t como la integral temporal de la corriente i_{SC} para luego calcular la tensión de circuito abierto, como se muestra en 2.6

$$v_t = \frac{N_s Q T_d}{N_p N_e \epsilon_0 A_i} + \frac{2 N_e N_s R T}{F} \sinh^{-1}\left(\frac{Q_T}{N_p N_e^2 A_i \sqrt{8 R T \epsilon_0 c}}\right) \tag{2.6}$$

donde las constantes asociadas se detallan en el Anexo A.3.1. Finalmente, para obtener que la tensión en terminales del SC queda como,

$$v_{SC} = v_T - R_{intern} i_{SC} \tag{2.7}$$

2.4. Topologías de circuito de potencias

La hibridación de fuentes de almacenamiento en vehículos eléctricos basados en pilas de combustible permite una mejor gestión de la energía y la potencia, mejora la eficiencia del sistema, extiende la vida útil de las pilas de combustible, optimiza el rendimiento del vehículo, y reduce los costos operativos. Estas ventajas hacen que la hibridación sea una estrategia esencial para el desarrollo de vehículos eléctricos más eficientes y sostenibles.

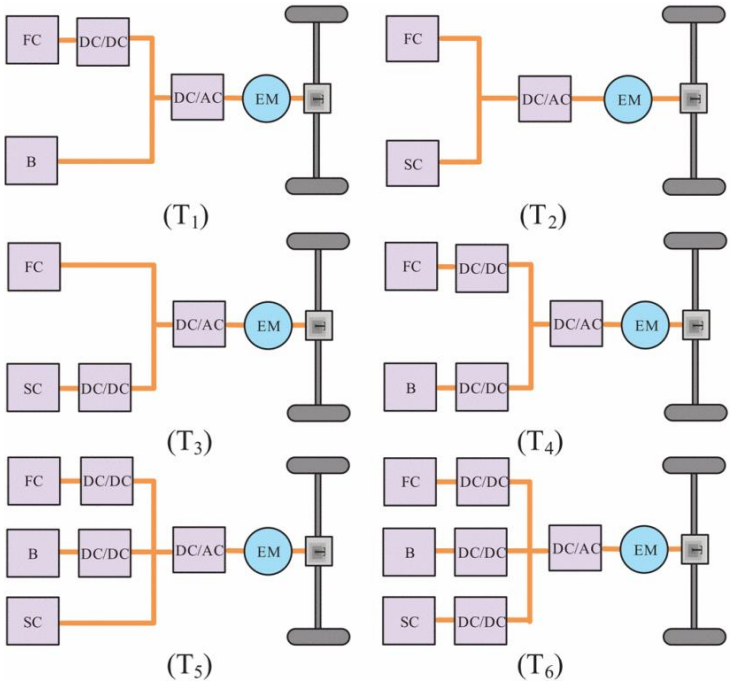


Figura 2.4: Topologías de vehículos eléctricos basados en pilas de combustible. Extraído de [11]

Existen múltiples combinaciones posibles a la hora de realizar esta hibridación (véase Figura 2.4),

En cuanto a la clasificación topológica de los FCHEVs, se pueden identificar varias configuraciones, cada una con sus propias ventajas y desafíos.

2.4.1. Full FCEV

Una de las topologías más básicas es el Full FCEV, que utiliza exclusivamente un stack de celdas de combustible sin unidades adicionales de generación de energía [12]. Este tipo de configuración es adecuado para vehículos de baja velocidad como montacargas, autobuses y vehículos de aerolíneas. Las principales ventajas de esta topología incluyen una alta eficiencia, tiempo de carga rápido, operación silenciosa y baja emisión de contaminantes [13]. Sin embargo, enfrenta desafíos significativos relacionados con los costos elevados y la sensibilidad a la pureza del hidrógeno [14].

2.4.2. Hibridación FC con Batería

Otra configuración común es la hibridación FC con Batería, que combina un stack de celdas de combustible con una batería que proporciona energía adicional durante arranques y condiciones de alta demanda [15]. Esta topología mejora la eficiencia operativa y permite un arranque más rápido del vehículo, siendo ampliamente utilizada en automóviles y vehículos comerciales ligeros. A pesar de sus beneficios, esta configuración introduce una mayor complejidad del sistema y costos adicionales debido a la necesidad de integrar y gestionar dos fuentes de energía [16].

2.4.3. Hibridación FC con Supercondensador (SC)

Una variación de la configuración híbrida es la hibridación FC con Supercondensador (SC), que utiliza un supercondensador para proporcionar energía en situaciones de demanda transitoria [17]. Esta topología es particularmente útil en vehículos que requieren una alta respuesta dinámica. Aunque los supercondensadores ofrecen una respuesta rápida a los cambios en la demanda de energía, su baja densidad de energía y rápida descarga limitan su uso continuo como fuente de energía principal [18].

2.4.4. Hibridación FC, Batería y SC

La hibridación FC, Batería y SC integra celdas de combustible, baterías y supercondensadores para aprovechar las ventajas de cada uno [19]. Esta configuración proporciona energía continua y mejora la respuesta dinámica durante eventos transitorios, siendo ade-

cuada para aplicaciones que requieren operación continua y respuesta rápida. Sin embargo, esta topología es más compleja y costosa de implementar [20].

2.5. Estrategias de control de energía

Los vehículos eléctricos de celda de combustible (FCHEVs) requieren estrategias de gestión de energía efectivas para optimizar el consumo de hidrógeno, prolongar la vida útil de las celdas de combustible y mejorar la eficiencia del sistema. La gestión de energía en FCHEVs es un desafío complejo debido a la necesidad de equilibrar múltiples objetivos, como la eficiencia energética, la durabilidad del sistema y el rendimiento del vehículo. Entre los principales desafíos se encuentran:

- **Variabilidad en la demanda de potencia**
  Los FCHEVs operan en una amplia gama de condiciones, desde el tráfico urbano lento hasta la conducción en autopista. Esta variabilidad requiere una estrategia de control que pueda ajustar rápidamente la distribución de energía entre la celda de combustible, la batería y otros sistemas de almacenamiento, como los supercondensadores.

- **Respuesta rápida ante cambios en las condiciones de operación**
  Durante una aceleración rápida, el sistema de gestión de energía debe ser capaz de proporcionar la potencia necesaria sin comprometer la eficiencia o la vida útil de la celda de combustible. Esto requiere estrategias de control que puedan predecir y responder a las demandas de potencia en tiempo real.

- **Integración de múltiples fuentes de energía y almacenamiento**
  Los FCHEVs a menudo utilizan una combinación de celdas de combustible, baterías y supercondensadores para optimizar el rendimiento. Cada uno de estos componentes tiene diferentes características de potencia y energía, lo que complica la tarea de gestionar la energía de manera eficiente. Además, la gestión de la energía debe considerar factores como la eficiencia de conversión de energía, las pérdidas térmicas y la degradación de los componentes.

- **Durabilidad del sistema**
  Las celdas de combustible pueden degradarse con el tiempo debido a factores como las variaciones en la carga y la exposición a contaminantes. Por lo tanto, las estrategias de gestión de energía deben incluir mecanismos para minimizar la degradación de la celda de combustible, como la limitación de las tasas de cambio de potencia y el uso de modos de operación optimizados.

2.5.1. Control basado en reglas

El control basado en reglas se destaca por su simplicidad y eficacia en la gestión de energía de vehículos de celda de combustible (FCHEVs), fundamentándose en un conjunto de reglas predefinidas que determinan las acciones del sistema según condiciones operativas específicas. Estas reglas, usualmente derivadas de heurísticas basadas en la experiencia o en un conocimiento profundo del sistema, ofrecen ventajas significativas tales como la facilidad de implementación y la capacidad de respuesta rápida a variaciones operativas, proporcionando una solución robusta que maneja eficientemente un rango amplio de situaciones sin necesidad de ajustes complejos.

Sin embargo, este enfoque también presenta desventajas como la suboptimización debido a la naturaleza estática y no adaptativa de las reglas, que puede no ser óptima bajo todas las condiciones operativas. Además, la escalabilidad puede convertirse en un desafío a medida que la complejidad del sistema aumenta, complicando la gestión de un número creciente de reglas. Estas reglas, aunque efectivas en contextos estándar, muestran rigidez y no pueden adaptarse a nuevas circunstancias o cambios en el ambiente operativo sin intervención manual. Ejemplos de Reglas Comunes en FCHEVs incluyen:

- **Regla de Prioridad de Energía**: Utilizar la energía de la batería cuando la demanda de potencia es baja y combinar la celda de combustible con la batería cuando la demanda es alta.
- **Regla de Gestión de Carga de la Batería**: Cargar la batería usando la celda de combustible cuando el SOC es bajo y minimizar la carga desde la celda de combustible cuando el SOC es alto.

La formulación de reglas puede ser enriquecida utilizando enfoques como la lógica difusa, que permite manejar incertidumbres y variabilidades. Este método permite definir reglas en términos lingüísticos, como se muestra en la siguiente formulación:

Si (demanda de potencia es alta) y (SOC de batería es bajo) entonces (aumentar potencia de celda de combustible)

Este enfoque facilita la adaptación a condiciones cambiantes mediante el uso de funciones de pertenencia y un conjunto de inferencias difusas para determinar la acción adecuada.

2.5.2. Control basado en optimización

A diferencia del control basado en reglas, el control basado en optimización utiliza algoritmos matemáticos avanzados para optimizar la gestión de energía en FCHEVs, con el objetivo de minimizar el consumo de combustible y las emisiones mientras se maximiza

la eficiencia del sistema. Este enfoque se basa en técnicas como la programación dinámica, la optimización estocástica, y métodos heurísticos, que no solo ofrecen soluciones de alta eficiencia sino también la adaptabilidad necesaria para responder a variaciones en las condiciones operativas.Algunas técnicas de Optimización Comunes en FCHEVs:

- **Programación Dinámica (DP)**: Descompone problemas complejos en subproblemas más manejables, resolviéndolos recursivamente, como se ilustra en la ecuación de Bellman:

  $$J^*(x_k) = \min_u [g(x_k, u_k) + J^*(x_{k+1})]$$

  donde $J^*(x_k)$ representa el costo mínimo desde el estado x_k, y $g(x_k, u_k)$ es el costo inmediato asociado con la acción u_k.

- **Optimización Estocástica**: Aborda la incertidumbre mediante el uso de procesos estocásticos, ofreciendo una robustez adicional bajo incertidumbre.

2.5.3. Control basado en aprendizaje

El control basado en aprendizaje ha emergido como una poderosa técnica en la automatización y optimización de sistemas complejos. Estas estrategias emplean técnicas de inteligencia artificial para desarrollar sistemas que pueden adaptarse a nuevas situaciones y mejorar su rendimiento con el tiempo.

Las técnicas de inteligencia artificial clásicos se basan en estructuras llamadas redes neuronales donde una neurona corresponde a la unidad básica de calculo de dichas redes. El cálculo que hacen estas unidades responde al modelo de neurona de McCulloch Pitts (1943) y determina el estado o activación de la unidad como se expone en 2.8

$$y = f(\omega x + b) \tag{2.8}$$

donde y corresponde a la salida de la neurona, ω corresponde al peso de la entrada x, b a un bias que determina la activación de la neurona, y finalmente, la función f es una función de activación no lineal. Esta puede ser una función sigmoidea, tangente hiperbólica, softmax, ReLU, etc. cuya elección depende de la aplicación. Estas pueden disponerse en capas, lo cual se puede representar como una composición de funciones, donde las entradas corresponderán a las salidas de la capa anterior, como se muestra en 2.9.

$$y_{k+1} = f(b_{k+1} + \omega_{k+1} \cdot f(\omega_k x_k + b_k)) \tag{2.9}$$

Otra manera de representar redes neuronales como la composición de varias capas es por medio del análisis de grafos, como el expuesto en la Figura 2.5; donde cada nodo representa una unidad de cálculo (o neurona) y cada arista representa un peso $\omega_{i,j}$ entre la neurona

i y una neurona j perteneciente a la capa siguiente.

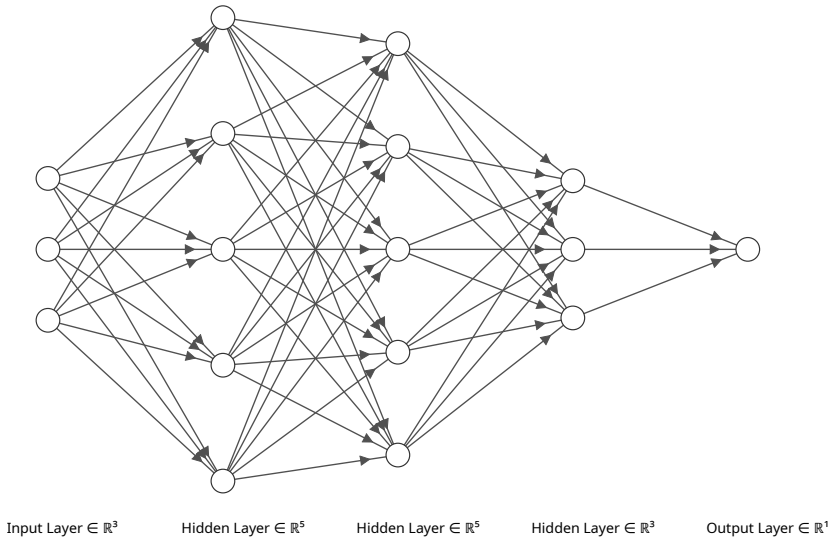


Figura 2.5: Ejemplo de red neuronal representada por medio de grafos

La conexión entre cada capa en las redes neuronales ha sido discutida en la literatura, en donde se destacan dos tipos de conexiones de las cuales se desprenden arquitecturas de red completamente diferentes, estas son las capas convolucionales y totalmente conectadas. Las capas convolucionales, típicas de las redes neuronales convolucionales (CNNs), utilizan filtros que se desplazan sobre la entrada para realizar operaciones de convolución, extrayendo características locales como bordes y texturas [21], [22] lo cual las hace ideales para tareas como el reconocimiento de imágenes dentro del contexto de reconocimiento facial, detección de animales, etc. Por otro lado, las capas totalmente conectadas conectan cada neurona en una capa con todas las neuronas en la capa siguiente, integrando globalmente la información para tareas como la clasificación final [23], las cuales, en la aplicación clásico de control automático, donde no hay una característica espacial inherente entre las variables de control; suelen ser las más indicadas y por tanto las entradas y salidas pueden representarse como arreglos matriciales, tal como se muestra en 2.10.

$$\begin{bmatrix} y_{11} \\ y_{21} \\ \vdots \\ y_{m1} \end{bmatrix} = f\left(\begin{bmatrix} \omega_{11} & \omega_{12} & \cdots & \omega_{1n} \\ \omega_{21} & \omega_{22} & \cdots & \omega_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \omega_{m1} & \omega_{m2} & \cdots & \omega_{mn} \end{bmatrix} \begin{bmatrix} x_{11} \\ x_{21} \\ \vdots \\ x_{m1} \end{bmatrix} + \begin{bmatrix} b_{11} \\ b_{21} \\ \vdots \\ b_{m1} \end{bmatrix} \right) \tag{2.10}$$

donde las variables ω_{ij} y b_{i1} se les conoce como los parámetros aprendibles pues corresponden a los grados de libertad de la red neuronal posee con el fin de aprender una tarea específica.

Los sistemas de control basados en aprendizaje pueden clasificarse en varias categorías, incluyendo el aprendizaje supervisado, no supervisado y por refuerzo. En el contexto de la gestión de energía en vehículos eléctricos de celda de combustible (FCHEVs), el control basado en aprendizaje es crucial debido a la naturaleza dinámica y no lineal de estos sistemas. Las estrategias de control deben ser capaces de adaptarse a cambios en las condiciones operativas, como variaciones en la demanda de energía y la disponibilidad de recursos energéticos. Además, deben optimizar el uso de las diferentes fuentes de energía disponibles, incluyendo la celda de combustible, la batería y los supercondensadores, para maximizar la eficiencia y la vida útil del sistema.

2.5.3.a. Aprendizaje por refuerzo

El aprendizaje por refuerzo es una técnica en la que un agente aprende a tomar decisiones mediante la interacción con el entorno. El agente recibe recompensas o penalizaciones basadas en sus acciones, lo que le permite optimizar su comportamiento para maximizar la recompensa acumulada a largo plazo. Esta técnica es especialmente adecuada para la gestión de energía en FCHEVs, donde el objetivo es optimizar la eficiencia energética y prolongar la vida útil de los componentes del sistema.

En el aprendizaje por refuerzo, la función de valor $Q(s, a)$ estima la recompensa esperada al tomar la acción a en el estado s. La actualización de esta función se realiza mediante la ecuación de Bellman:

$$Q(s, a) = r + \gamma \max_{a'} Q(s', a') \tag{2.11}$$

donde:

- $Q(s, a)$ es la función de valor que estima la recompensa esperada al tomar la acción a en el estado s.
- r es la recompensa inmediata recibida tras realizar la acción a.
- γ es el factor de descuento que determina la importancia de las recompensas futuras.
- $\max_{a'} Q(s', a')$ es el valor máximo esperado de las acciones futuras a' en el estado siguiente s'.

Para implementar el aprendizaje por refuerzo, se entrena una red neuronal para aproximar la función Q. El entrenamiento se realiza minimizando la diferencia entre el valor actual de Q y el valor objetivo calculado usando la ecuación de Bellman. En sistemas como los FCHEVs, el aprendizaje por refuerzo puede optimizar el uso de diferentes fuentes de

energía, ajustando dinámicamente las políticas de gestión de energía en función de las condiciones operativas actuales.

2.5.3.b. Deep deterministic policy gradient (DDPG)

El Deep Deterministic Policy Gradient (DDPG) es una técnica avanzada de aprendizaje por refuerzo que combina métodos de aprendizaje profundo con algoritmos de control determinístico. Este algoritmo fue propuesto por Lillicrap et al. en 2015 y está diseñado para manejar espacios de acción continuos [24]. DDPG es particularmente útil en problemas de control en tiempo real, como el control de brazos robóticos y la gestión de energía en vehículos eléctricos.

El DDPG utiliza dos redes neuronales principales: la red de actor y la red de crítico. La red de actor $\mu(s|\theta^\mu)$ se entrena para seleccionar la mejor acción dada un estado, mientras que la red de crítico $Q(s, a|\theta^Q)$ se entrena para evaluar la acción seleccionada. La función de pérdida para entrenar la red de crítico se define como:

$$L(\theta^Q) = \mathbb{E}[(Q(s, a|\theta^Q) - (r + \gamma Q(s', \mu(s'|\theta^\mu)|\theta^Q)))^2] \tag{2.12}$$

donde:

- $L(\theta^Q)$ es la función de pérdida para la red de crítico.
- $Q(s, a|\theta^Q)$ es la estimación actual de la función de valor Q usando los parámetros θ^Q.
- r es la recompensa inmediata.
- γ es el factor de descuento.
- $\mu(s'|\theta^\mu)$ es la acción seleccionada por la red de actor para el estado siguiente s'.

La red de actor se entrena utilizando el gradiente de la política determinista:

$$\nabla_{\theta^\mu} J \approx \mathbb{E}[\nabla_a Q(s, a|\theta^Q)|_{a=\mu(s|\theta^\mu)} \nabla_{\theta^\mu} \mu(s|\theta^\mu)] \tag{2.13}$$

donde:

- $\nabla_{\theta^\mu} J$ es el gradiente de la política.
- $Q(s, a|\theta^Q)$ es la función de valor crítica.
- $\mu(s|\theta^\mu)$ es la política determinada por la red de actor.
- $\nabla_{\theta^\mu} \mu(s|\theta^\mu)$ es el gradiente de la red de actor respecto a sus parámetros.

Estos gradientes se calculan mediante el método de retropropagación, y las actualizaciones se realizan utilizando optimizadores como Adam [25]. DDPG ha sido aplicado con éxito en diversos escenarios, como el control de formación de vehículos, donde se requiere mantener una distancia y velocidad constantes entre vehículos en un pelotón, mejorando así la eficiencia del tráfico y reduciendo el consumo de energía [26].

2.6. Discusión

En valor de lo expuesto en el presente capitulo respecto a tipos de estrategias de control, topologías y restricciones operativas de las fuentes de energía hoy validadas en la implementación de FCHEVs comerciales, se destaca que la combinación y coordinación inteligente de dos fuentes de almacenamiento auxiliares como baterías y supercondensadores por medio de una topología completamente activa resulta de gran interés, ya que permite sortear los desafíos operativos del powertrain de un FCHEV y a su vez, la oportunidad de desacoplar el control de tensión del link DC de la potencia entregada por la pila de combustible y batería. Aprovechando así la rapidez de actuación de un supercondensador y la capacidad de recuperar la energía del frenado del FCHEV por medio de la batería.

Por otro lado, incorporar objetivos específicos al control de energía de un vehículo requiere de un conocimiento mayor sobre el fenómeno, el cual corresponde a un sistema altamente no lineal que incorpora fenómenos electroquímicos y mecánicos cuyo modelamiento representa un gran desafió. Debido a lo anterior, incorporar una consigna de maximizar la eficiencia de la pila de combustible durante la operación del FCHEV resulta insatisfactorio desde una estrategia de control basado en reglas, donde la efectividad de la reglas a programar se encontrarían sumamente ligadas a un criterio experto, por lo que recurrir a una estrategia basada en optimización se torna atractivo, sin embargo el entorno de operación de un FCHEV dinámico y los tiempos de actuación han de ser lo mas rápidos posibles y, por ende, el poder de procesamiento y calculo necesario se encarece. En consecuencia, una estrategia de control basada en aprendizaje resulta especialmente interesante gracias a su capacidad de aprender relaciones altamente no lineales y por ende tomar decisiones inteligentes en todo rango de operación del FCHEV.

Finalmente, la estrategia de control a diseñar por medio del entrenamiento de una red neuronal considerara la topología del circuito de potencia de la Camioneta a hidrógeno del proyecto CORFO 18PTECC-89477 desarrollado por académicos de la Universidad Técnica Federico Santa María, apoyado por empresas como Codelco, Engie, Fraunhofer, entre otros. El circuito de potencia de este FCHEV corresponde a una topología del tipo T6 (2.4), donde se acciona una pila de combustible HyPM-HD15, un banco de 20 baterías tipo LF105-73103 y un supercondensador del tipo LSUM 129R6C 0062F EA. Las características

de estos dispositivos se encuentran en el Anexo A.2

Capítulo 3

Topología del circuito de potencia y control de convertidores.

3.1. Circuito de potencia

El circuito de potencia del vehículo considerado para el diseño de nuestra estrategia de control corresponde al mostrado en la Figura 3.1, el cual consta de una topología completamente activa, donde cada fuente de almacenamiento de energía está conectada a un convertidor dc-dc tipo boost. El convertidor boost (ilustrado en la Figura **??**) es un convertidor dc-dc no aislado cuya función es elevar la tensión a la salida del mismo mediante el accionamiento de interruptores que coordinan la carga y descarga de un inductor en la entrada sobre un condensador. Esta elección se debe a que el nivel de tensión de cada fuente es menor a los 144 [V] del enlace DC del sistema. Por simplicidad, se considerarán valores típicos para los parámetros de cada convertidor, donde:

$$R = 1m\ [\Omega] \qquad L = 1m\ [H]$$
$$C = 10m\ [F]$$

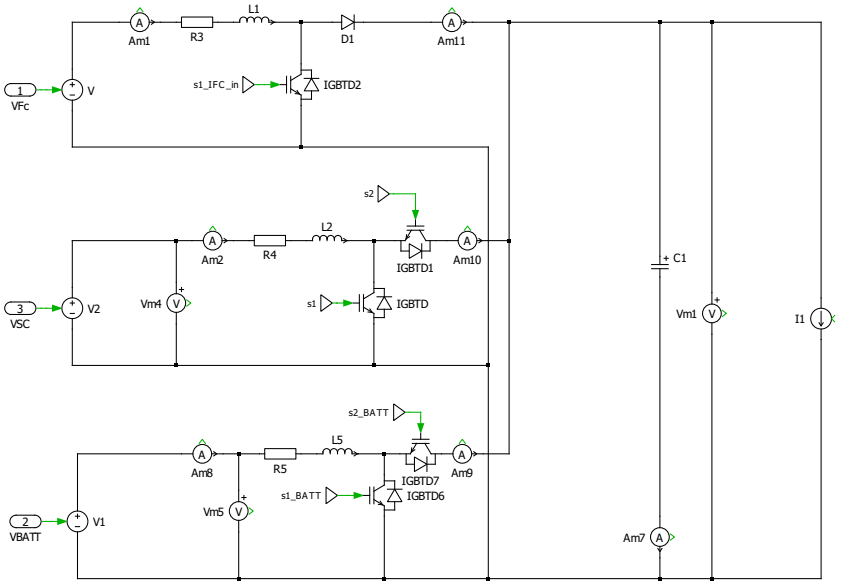


Figura 3.1: Circuito de potencia de topología completamente activa

Las tres fuentes en conjunto suplirán la demanda y las pérdidas del sistema, donde será deber de la estrategia de control de energía asegurar que se cumpla en todo momento el balance de potencia entre la demanda del sistema y el despacho de cada fuente, respetando las limitaciones de cada una.

3.2. Control de convertidores.

El convertidor boost corresponde a una planta de fase no mínima; por lo tanto, para controlar la tensión a la salida del convertidor será necesario implementar un esquema de control anidado compuesto por un lazo interno de corriente y uno externo de tensión. El circuito del convertidor se presenta en la Figura 3.2 y la representación del sistema en variables de estado se muestra en la Ecuación 3.1.

$$\frac{d}{dt}\begin{bmatrix} i_L \\ v_C \end{bmatrix} = \begin{bmatrix} -R/L & -m/L \\ m/C & 0 \end{bmatrix} \cdot \begin{bmatrix} i_L \\ v_C \end{bmatrix} + \begin{bmatrix} V_{in}/L \\ -i_0/C \end{bmatrix} \tag{3.1}$$

donde,

- i_L corresponde a la corriente por el inductor L
- v_C corresponde a la tensión del condensador C
- m corresponde al estado (encendido o apagado) de uno de los interruptores

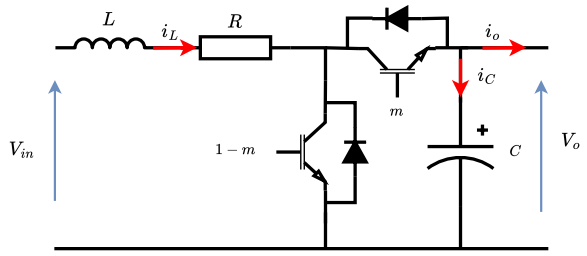


Figura 3.2: Topología de convertidor boost.

Cuando $m = 1$ el circuito del convertidor se comportara como el circuito mostrado en la Figura 3.3 y por el contrario cuando $m = 0$ este se comportara como el circuito expuesto en la Figura 3.4

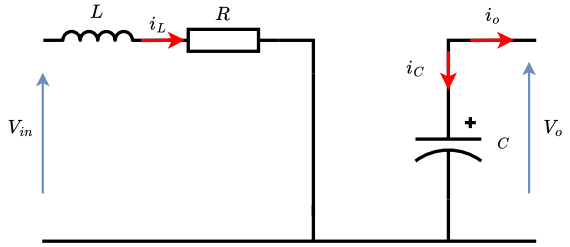


Figura 3.3: Convertidor boost para $m = 1$

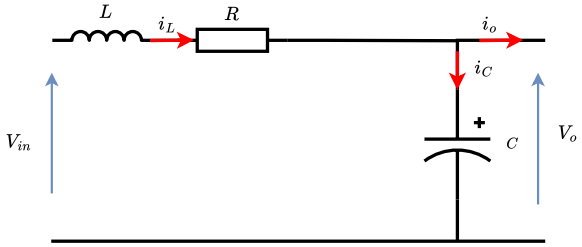


Figura 3.4: Convertidor boost para $m = 0$

3.2.1. Control de convertidor boost

Como se puede observar en la Ecuación 3.1, el sistema presenta una forma no lineal, puesto que la actuación m determina la planta del sistema, lo que dificulta la aplicación de control lineal sobre el convertidor. Por lo tanto, en una primera instancia se debe linealizar la planta para posteriormente aplicar técnicas de control lineal por medio de un esquema de control anidado de tensión y corriente, como se expone en la Figura 3.5. Aquí, la actuación m, a diferencia del apartado anterior, representa el índice de modulación del convertidor boost, actuado mediante una estrategia de ancho de pulso.

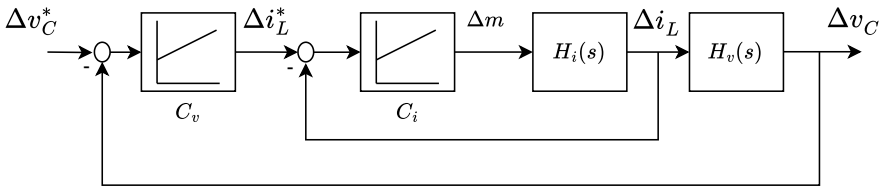


Figura 3.5: Esquema de control anidado para convertidor boost

3.2.1.a. Linealización

Como se mencionó anteriormente, para aplicar técnicas de control lineal primero es necesario linealizar la planta del sistema. Esto se lleva a cabo mediante un análisis de pequeña señal en torno a un punto de operación, como se muestra en la Ecuación 3.2.

$$\frac{d}{dt}\begin{bmatrix} i_{L_0}+\Delta i_L \\ v_{C_0}+\Delta v_C \end{bmatrix} = \begin{bmatrix} -R/L & -\left(m_0+\Delta m\right)/L \\ \left(m_0+\Delta m\right)/C & 0 \end{bmatrix} \cdot \begin{bmatrix} i_{L_0}+\Delta i_L \\ v_{C_0}+\Delta v_C \end{bmatrix} + \begin{bmatrix} v_{C_0/L} \\ -i_0/C \end{bmatrix} \quad (3.2)$$

Donde, despreciando aquellos factores cuadráticamente infinitesimales y aquellos factores constantes interpretables como perturbaciones en el sistema, se obtiene una aproximación lineal de la planta, como se expone en la Ecuación 3.3.

$$\frac{d}{dt}\begin{bmatrix} \Delta i_L \\ \Delta v_C \end{bmatrix} = \begin{bmatrix} -R/L & -m_0/L \\ m_0/C & 0 \end{bmatrix} \cdot \begin{bmatrix} \Delta i_L \\ \Delta v_C \end{bmatrix} + \begin{bmatrix} -v_{C_0/L} \\ i_0/C \end{bmatrix} \cdot \Delta m \quad (3.3)$$

3.2.1.b. Lazo interno de corriente

A partir de la planta linealizada, se procede a determinar el lazo interno de corriente del convertidor, el cual corresponde a la primera fila del sistema descrito en la Ecuación 3.3. Analizado desde el plano de Laplace, se obtiene la función de transferencia $H_i(s)$ (véase la Ecuación 3.4), la cual representa la planta a controlar para el lazo de control interno de corriente.

$$\frac{\Delta i_L}{\Delta m} = H_i(s) = \frac{-v_{C_0/L}}{s + R/L} \quad (3.4)$$

3.2.1.c. Lazo externo de tensión

De forma análoga a lo descrito para el control del lazo interno de corriente, para el lazo externo de tensión se debe considerar la segunda fila del sistema descrito en la Ecuación 3.3. La función de transferencia representativa de la aproximación a la planta, $H_v(s)$, corresponde a la mostrada en la Ecuación 3.5.

$$\frac{\Delta v_C}{\Delta i_L^*} = H_v(s) = \frac{-m_0/C}{s} \quad (3.5)$$

3.2.1.d. sintonización

La sintonización de los controladores de tensión y corriente para el esquema de control anidado propuesto depende del punto de operación en el que se desarrolla la linealización

del sistema. Para ello, se considera una aplicación sobre el supercondensador de la topología completamente activa, cuya tensión nominal es de 129 [V]. Además, se toma en cuenta que, en estado estacionario, la relación entre la tensión de entrada y salida del convertidor boost es como se muestra en la Ecuación 3.6.

$$\frac{V_{out}}{V_{in}} = \frac{1}{1-m} \tag{3.6}$$

Luego, reemplazando los valores y considerando que el convertidor opera correctamente manteniendo una tensión de 144 [V] en la salida,

$$\frac{144}{129} = \frac{1}{1-m_0} \qquad\qquad m_0 = 0{,}1042 \tag{3.7}$$

De esta forma, se obtiene una aproximación de las plantas del sistema, sobre las cuales es posible realizar la sintonización. Esta se lleva a cabo utilizando la herramienta *rltool* de Matlab, ajustando cada lazo para obtener una respuesta al escalón rápida y sin overshoots ni oscilaciones agresivas. Se obtienen los siguientes controladores:

$$C_i(s) = -79{,}9 \cdot 0{,}016 + \frac{-79{,}9}{s} \qquad\qquad C_v(s) = -6{,}7468 + \frac{150}{s} \tag{3.8}$$

3.2.2. Modelo promedio de convertidor boost

Las simulaciones de fuentes conmutadas, como un convertidor boost operado mediante una estrategia de modulación de ancho de pulso, representan una carga computacional considerable, especialmente en simulaciones prolongadas, típicas de un ciclo de conducción de un vehículo. Por ello, para una simulación más eficiente desde el punto de vista computacional, se propone un modelo promedio del convertidor (mostrado en la Figura 3.6). Este modelo consiste en la coordinación de fuentes controladas que emulan el comportamiento real del convertidor.

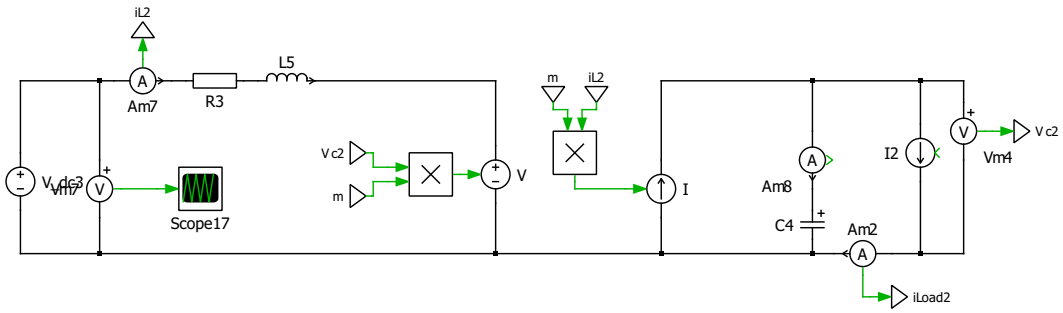


Figura 3.6: Esquema de modelo promedio de convertidor boost

Luego, al comparar la respuesta de ambos sistemas (conmutado y promedio), manteniendo los controladores obtenidos y sometiéndolos a un impacto de carga de 10 [A] en la salida, se obtienen los resultados expuestos en la Figura 3.7. Se observa que la dinámica de ambos modelos del convertidor presenta un comportamiento similar, aunque el modelo real muestra un overshoot ligeramente más agresivo que su versión promedio.

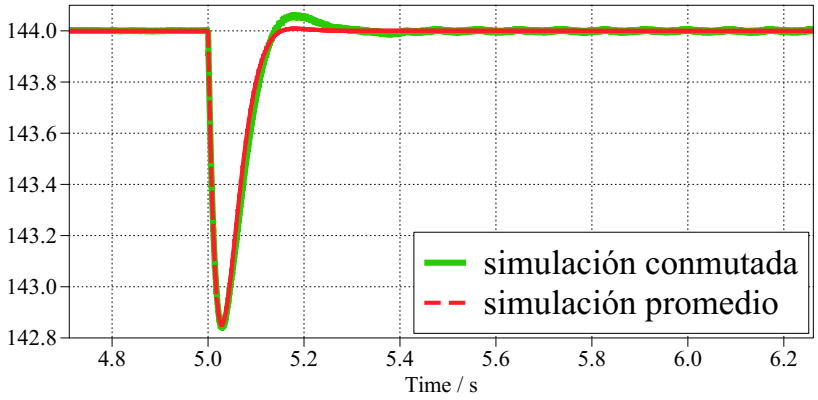


Figura 3.7: Comparación a impacto de carga sobre convertidor promedio y conmutado

Capítulo 4

Estrategia de control de energía

4.1. Generalidades

El sistema a controlar corresponde al circuito de potencia mostrado en la Figura 3.1, donde la fuente de corriente controlada en dicho circuito representa la potencia demandada por el FCHEV a una tensión constante de 144 [V]. Esta corriente será determinada por la demanda, respetando en todo momento la relación mostrada en 4.1.

$$I_{load} = \frac{P_{load}}{V_{dc}} \tag{4.1}$$

A su vez, la demanda de potencia P_{load} sobre un vehículo se puede calcular mediante el análisis de las fuerzas que interactúan sobre él (véase Figura 4.1), considerando tanto la resistencia a la rodadura como la resistencia aerodinámica y asumiendo que no existen virajes ni inclinaciones ($\alpha = 0$).

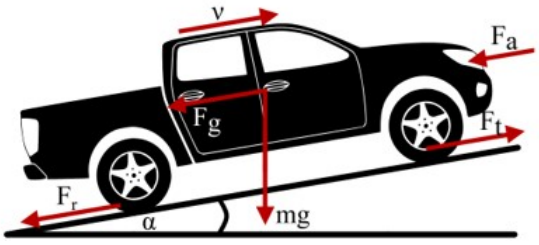


Figura 4.1: Diagrama de cuerpo libre para vehículo

$$P_{\text{load}} = v\left(m \cdot a + m \cdot g \cdot C_r + 0{,}5 \cdot \rho \cdot C_d \cdot A \cdot v^2\right) \tag{4.2}$$

donde:

- v es la velocidad del vehículo en metros por segundo (m/s).
- m es la masa del vehículo en kilogramos (kg), 2.5 toneladas aproximadamente.
- a es la aceleración del vehículo.
- g es la aceleración debida a la gravedad, aproximadamente 9.807 $\mathrm{m/s^2}$.
- C_r es el coeficiente de resistencia a la rodadura, aproximadamente 0.00829.
- ρ es la densidad del aire, aproximadamente 1.293 $\mathrm{kg/m^3}$ a nivel del mar.
- C_d es el coeficiente de resistencia aerodinámica, aproximadamente 0.339.
- A es el área frontal del vehículo en metros cuadrados ($\mathrm{m^2}$), aproximadamente 2.51.

La velocidad y la aceleración corresponden a entradas exógenas al circuito de potencia, que pueden obtenerse mediante ciclos típicos de conducción como los ciclos FTP75, WLTP1, WLTP2, UDSS y HWFET, los cuales representan ciclos con diferentes necesidades respecto a autonomía, potencias máximas y duración del ciclo.

Además, para el cálculo de la potencia de frenado, en el cual interactúan un freno regenerativo y uno mecánico, se considerará que el sistema puede regenerar el 50 % de la energía del freno regenerativo. De esta manera:

$$P_{Load} = \begin{cases} P_{load} & si \quad P_{load} \geq 0 \\ \frac{1}{2} P_{load} & si \quad P_{load} < 0 \end{cases} \tag{4.3}$$

Paralelamente, al desarrollar el balance de potencia entre las salidas de los convertidores y la fuente de corriente que modela la demanda del sistema (véase Figura 3.1), se obtiene lo expuesto en 4.4. En este se observan los grados de libertad del sistema, correspondientes a las potencias despachadas por cada fuente, y además, se muestra la dinámica transitoria de la tensión del enlace DC del sistema, cuyo nivel se debe integrar a los objetivos de control.

$$P_{fc} + P_{batt} + P_{sc} + V_{dc} \cdot C \frac{dV_{dc}}{dt} = P_{load} + P_{loss} \tag{4.4}$$

El despacho de potencia de cada fuente se encuentra delimitado por las limitaciones físicas de cada una, incluyendo tensiones y corrientes máximas, el estado de carga de la batería (SOC_{batt}) y la eficiencia de la pila de combustible. De esta forma, la estrategia de control debe incluir estas restricciones, que se exponen a continuación:

$$10\,\% \leq SOC_{batt} \leq 90\,\% \tag{4.5}$$

$$0[V] \leq V_{sc} \leq 130[V] \tag{4.6}$$

$$0[A] \leq I_{fc} \leq 425[A] \tag{4.7}$$

Por otro lado, el rango permisible para la corriente de la batería está condicionado por su capacidad, la cual depende del sentido de la corriente. De forma que:

$$\begin{aligned} |I_{batt}|_{descarga} &\leq 3C \quad si \quad I_{batt} \geq 0 \\ |I_{batt}|_{carga} &\leq 1C \quad si \quad I_{batt} < 0 \end{aligned} \tag{4.8}$$

donde $1C = 210\ [Ah]$

Vale destacar que para asegurar el cumplimiento de estos límites respecto a la corriente que circula por la batería y/o el supercondensador (SC), los lazos internos de control de corriente de cada fuente de almacenamiento se ajustan para saturarse en los valores máximos soportados por cada una.

La eficiencia de la pila de combustible η_{fc} depende de múltiples factores, incluyendo la presión y temperatura del entorno donde ocurre la reacción redox entre las celdas, así como de la potencia requerida por los servicios auxiliares de la pila. Debido a la complejidad de los modelos electroquímicos que describen este fenómeno, el cálculo de la eficiencia representa un desafío significativo. Por ello, se utiliza la curva de eficiencia proporcionada por el fabricante de la pila de combustible HyPM-HD30, que se basa en dos pilas HyPM-HD15 conectadas en serie. La eficiencia máxima informada por el fabricante, que es del 48 %, se alcanza bajo ciertas condiciones específicas:

1. $21°C$ de temperatura ambiente
2. Altitud de 200 [m]
3. 100 [A] de corriente continua.

Para el modelo de la pila de combustible, se considerarán constantes las variables exógenas al fenómeno eléctrico, como la presión y temperatura, y no se tendrán en cuenta los servicios auxiliares. Por lo tanto, la eficiencia de la pila de combustible se determinará según los datos proporcionados por el fabricante bajo las condiciones de operación mencionadas. Esto se ilustra en la Figura 4.2, donde se observa que la eficiencia máxima se alcanza cuando la pila de combustible opera entregando aproximadamente 5 kW.

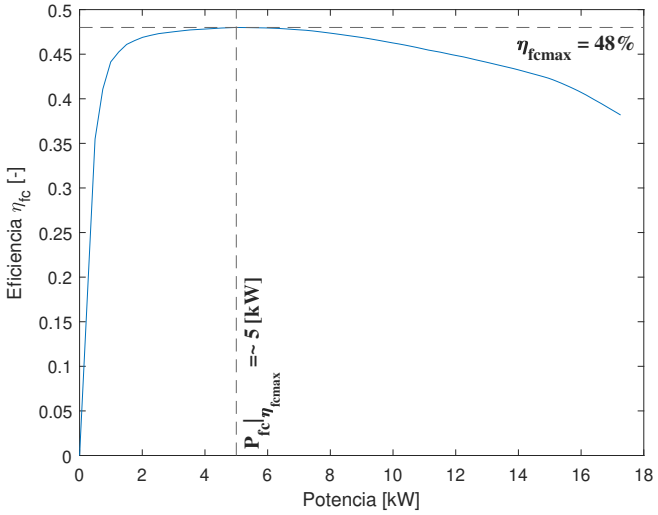


Figura 4.2: Eficiencia de pila de combustible en función de la potencia entregada

Finalmente, la estrategia de control con tres grados de libertad (correspondientes a las potencias despachadas por cada fuente) se reducirá a una de dos grados de libertad, delegando el control de la tensión del enlace DC del sistema al supercondensador mediante un lazo de control anidado con una referencia de tensión constante de 144 [V]. Por otro lado, la potencia entregada por las demás fuentes será determinada mediante una red neuronal cuyas salidas serán las referencias de potencia que deberán despachar cada una, de tal forma que:

$$\frac{P^*_{fc,\,batt}}{V_{fc,batt}} = I^*_{fc,\,batt} \tag{4.9}$$

donde la potencia de referencia, escalada por la tensión de la fuente de almacenamiento en cuestión, corresponderá a la referencia de corriente que se impondrá en los dos lazos de corriente para la pila de combustible y la batería. Mientras tanto, el supercondensador controlará la tensión mediante un lazo anidado de tensión y corriente, como se expone en el Capítulo 3. El diagrama general de esta estrategia se muestra en la Figura 4.3, donde las referencias de potencia mencionadas serán entregadas por medio de una red neuronal, denominada agente, entrenada mediante un algoritmo DDPG.

Tabla 4.1: Variables observadas por el Agente

Observación	Detalle	Observación	Detalle
V_{fc}	Tensión pila de combustible	SOC_{sc}	Estado de carga supercondesador
I_{fc}	Corriente de pila de combustible	ϵV_{dc}	Error de control tensión DC link
I_{sc}	Corriente de supercondensador	SOC_{batt}	Estado de carga de batería
V_{sc}	Tensión de supercondensador	V_{dc}	Tensión link DC
I_{batt}	Corriente batería	η_{fc}	Eficiencia de pila de combustible
V_{batt}	Tensión batería	P^*_{fc}	Referencia de potencia de pila
P_{load}	Potencia demandada		

Se consideraron 13 observaciones, las cuales se muestran en la Tabla 4.1. Las tensiones y corrientes medidas corresponden a variables de los terminales de las fuentes de almacenamiento, además de los estados de carga, la tensión del enlace DC, la potencia demandada, y la referencia de potencia de la pila de combustible, la cual es una salida del Agente.

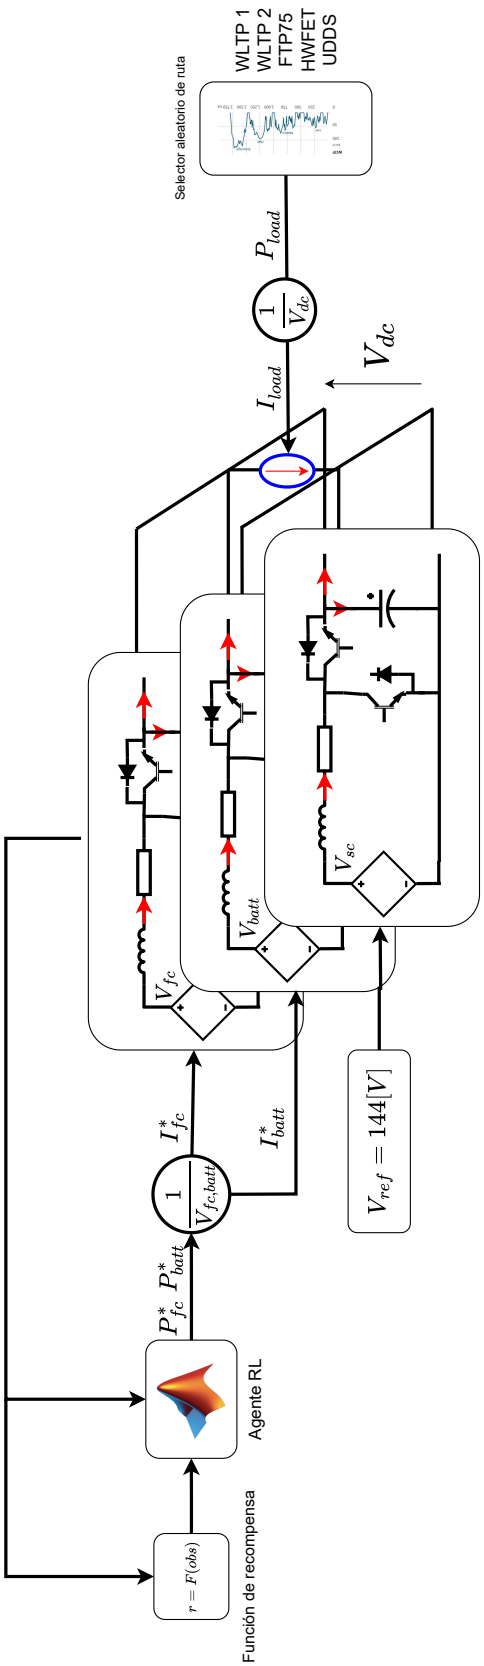


Figura 4.3: Diagrama general de estrategia de control propuesto

4.1.1. Configuración de red neuronal

Como se mencionó previamente, el algoritmo de redes neuronales DDPG plantea el entrenamiento coordinado de dos redes neuronales: una red encargada de depurar una política de control mediante la estimación del valor Q del conjunto estado-observación-recompensa, y la red del actor, que se encarga de ejecutar las acciones e interactuar con el ambiente de simulación.

Por otro lado, debido a que existen variables observadas (véase Tabla 4.1) cuyo rango oscila entre valores positivos y negativos, la función de activación de las neuronas en su dominio debe considerar dicho rango. Por esta razón, se opta por una función tangente hiperbólica, la cual se expone a continuación:

$$f(x) = tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \tag{4.10}$$

Esta función posee un dominio en todos los números reales; sin embargo, como se expone en la Figura 4.4, esta función experimenta una saturación en los valores máximos de su recorrido. De esta forma, las observaciones deben permanecer dentro de un rango acotado del dominio, evitando así la saturación de las neuronas debido a observaciones muy elevadas. Debido a lo anterior, cada observación se escala en función de los valores máximos de operación.

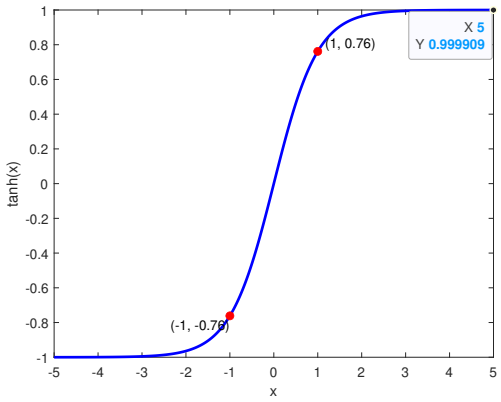


Figura 4.4: Función de activación tangente hiperbólica

Por otro lado, dado que el recorrido de la función está acotado entre 1 y -1, las acciones del agente se escalan a un rango mayor, amplificando la salida del Agente por un factor. En el caso de la salida correspondiente a la referencia de potencia de la pila de combustible, se escala por su potencia máxima, y en el caso de la salida correspondiente a la batería, por la potencia entregada en caso de corriente máxima.

4.1.1.a. Red del crítico

La red del crítico, mostrada en la Figura 4.5, es fundamental para lograr de forma satisfactoria los objetivos de control. Esta tomará como entrada las 13 observaciones descritas (véase Tabla 4.1) y las acciones del agente. Estas dos entradas (vector de observaciones y acciones) se conectarán a capas independientes para luego converger en un camino común, de forma que la red integre la información de las observaciones y acciones en conjunto.

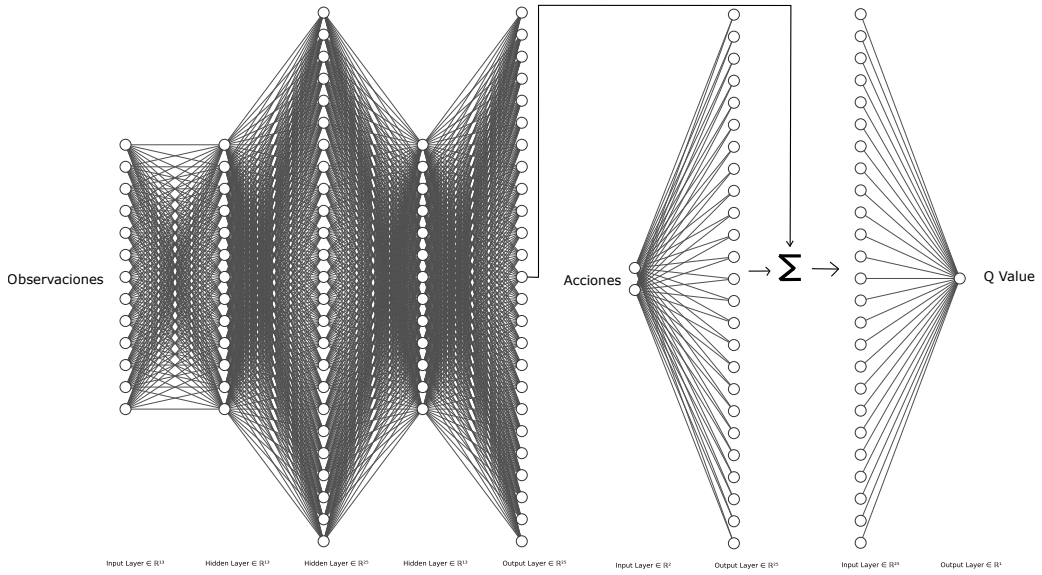


Figura 4.5: Red del crítico

Debido al gran número de observaciones en contraste con la cantidad de acciones, se optó por una red independiente para las observaciones más densa. Esto con el objetivo de que la política aprendida tenga la capacidad de integrar una mayor cantidad de conexiones entre variables observadas y, de esta manera, cumplir con los objetivos de control.

4.1.1.b. Red del actor

La red del actor (mostrada en la Figura 4.6), como se mencionó previamente, representa la red neuronal encargada de interactuar directamente con el sistema, generando las acciones según la política aprendida desde la red del crítico. Esta red tomará como entrada las mismas observaciones consideradas para la red del crítico y las salidas, como se describió anteriormente, corresponderán a las referencias de potencia para la pila de combustible y la batería.

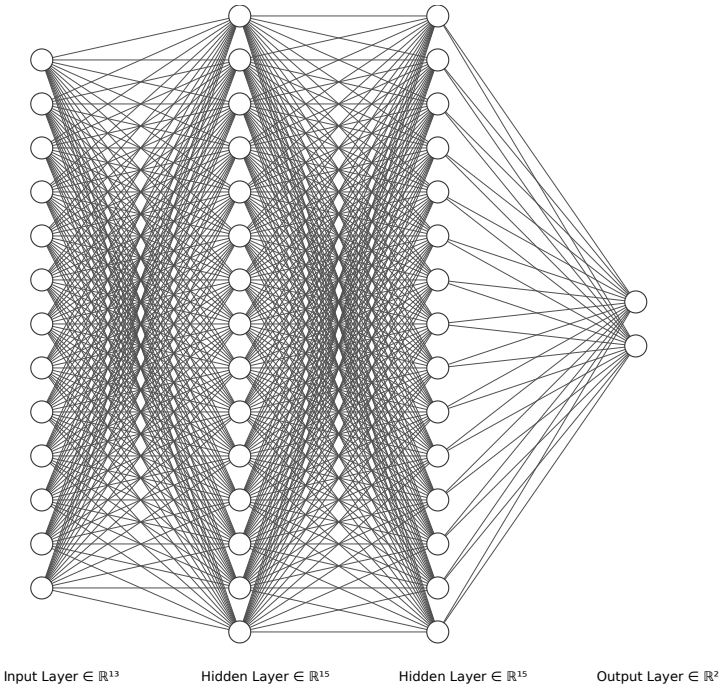


Figura 4.6: Red del actor

4.2. Función de recompensa

La función de recompensa debe considerar directamente los objetivos de control, administrando correctamente la carga de recompensa a cada estado del sistema, idealmente por medio de funciones continuas, de forma que la acumulación de recompensa vista por el Agente posea una dirección de aumento fácil de reconocer. Debido a esto, se opta por campanas de Gauss (expuestas en la Figura 4.7) como funciones de recompensa, donde la desviación estándar σ, la amplitud A y la media μ dependerán del objetivo de control.

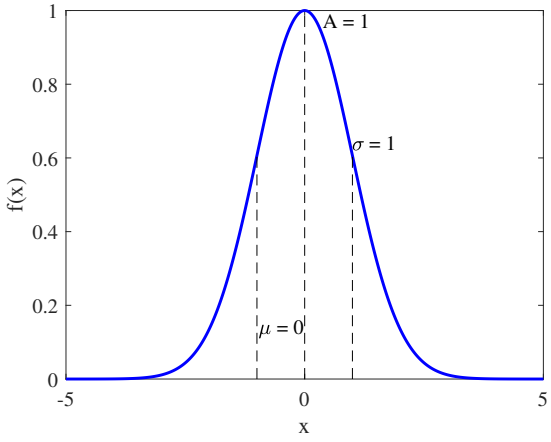


Figura 4.7: Función campana de gauss

$$g = g(x, \mu, \sigma, A) = A \cdot e^{\frac{-(x-\mu)}{2\sigma^2}} \tag{4.11}$$

La Ecuación 4.11 define la función de una campana de Gauss, con media cero y tanto la amplitud como la desviación estándar unitarias. Esta función se ajusta para las siguientes recompensas:

$$r_{SOC_{batt}} = g(SOC_{batt}, 80, 10, 800) \tag{4.12}$$

$$r_{v_{sc}} = \begin{cases} g(v_{sc}, 129, 20, 1000) & \text{si } v_{sc} \in [40, 129] \\ -1000 & \text{si } v_{sc} \notin [40, 129] \end{cases} \tag{4.13}$$

$$r_{\eta_{fc}} = \begin{cases} g(\eta_{fc}, 0{,}48, 0{,}1, 1000) & \text{si } P_{fc} < 17\,[kW] \\ g(\eta_{fc}, 0, 0{,}1, 1000) & \text{si } P_{load} < 0\,[kW] \end{cases} \tag{4.14}$$

$$r_{\epsilon_{v_{dc}}} = g(\epsilon_{v_{dc}}, 0, 5, 7500) \tag{4.15}$$

$$r_{dP} = g(dP, 0, 1000, 5000) \tag{4.16}$$

donde dP corresponde a la diferencia entre la potencia demandada y la entregada por las fuentes de almacenamiento, es decir:

$$dP = P_{load} - P_{sc} - P_{batt} - P_{fc} \tag{4.17}$$

Los valores medios de cada función de recompensa g representan el nivel óptimo de la variable en cuestión. Las amplitudes de cada función fueron determinadas de forma iterativa según la importancia del objetivo de control dentro de esta estrategia. La amplitud mayor corresponde a la asociada al error de control de tensión del enlace DC $r_{\epsilon_{v_{dc}}}$, donde, si bien el Actor no posee una acción directa sobre el control de dicha variable, puede actuar de forma indirecta, y por tanto es importante que las decisiones que tome no comprometan el nivel de tensión del enlace DC del sistema.

Por otro lado, la recompensa asociada a la diferencia entre la potencia demandada y entregada por las fuentes de almacenamiento dP posee una media igual a cero, de forma que la red aprenda a satisfacer la demanda del FCHEV dentro de un margen amplio (reflejado en la desviación estándar de la función r_{dP}). Esto es debido a que no se considera el cálculo de las pérdidas en el circuito de potencia.

La función r_{sc} representa la recompensa asociada al nivel de tensión del SC y se define en dos intervalos. En primer lugar, para una tensión entre 40 y 129[V], existe una campana de Gauss con media en 129 [V], de forma que el Agente identifique la tensión nominal del SC como la óptima. Como complemento de este último intervalo, se define un castigo, con

el objetivo de agraviar la recompensa vista por el Agente en dichas condiciones.

En el mismo sentido, la función $r_{SOC_{batt}}$ corresponde a la recompensa asignada al estado de carga de la batería, cuya media, 80 %, corresponde al estado de carga ideal a mantener en la batería. Finalmente, la función $r_{\eta_{fc}}$ corresponde a la recompensa asignada a la eficiencia de trabajo de la pila de combustible, la cual se define bajo dos condiciones. En primer lugar, se define para potencias $P_{fc} < 17\,\text{kW}$, puesto que el rango de la curva de eficiencia entregada por el fabricante no abarca potencias mayores, y de esta forma también se limita la corriente que entrega la pila de combustible. Además, como uno de los objetivos de esta estrategia de control es maximizar la eficiencia de la pila de combustible, la media de esta función se define en torno a la eficiencia máxima, 0.48.

Por otro lado, se define una segunda parte para la función $r_{\eta_{fc}}$ cuando $P_{load} < 0$, con media cero. Esto con el fin de que el Agente aprenda a disminuir el uso de la pila de combustible cuando el FCHEV frene y el circuito de potencia esté absorbiendo la energía de dicho frenado.

4.3. Entrenamiento

Durante el entrenamiento del Agente se consideran tres etapas. La primera etapa es una simulación de hasta 5 segundos. La segunda etapa se extiende hasta 100 segundos, y la última etapa es de validación, donde la simulación se prolonga hasta finalizar la ruta seleccionada de forma aleatoria. Esto se muestra en la Figura 4.8, donde se indican las secciones correspondientes a cada etapa de entrenamiento.

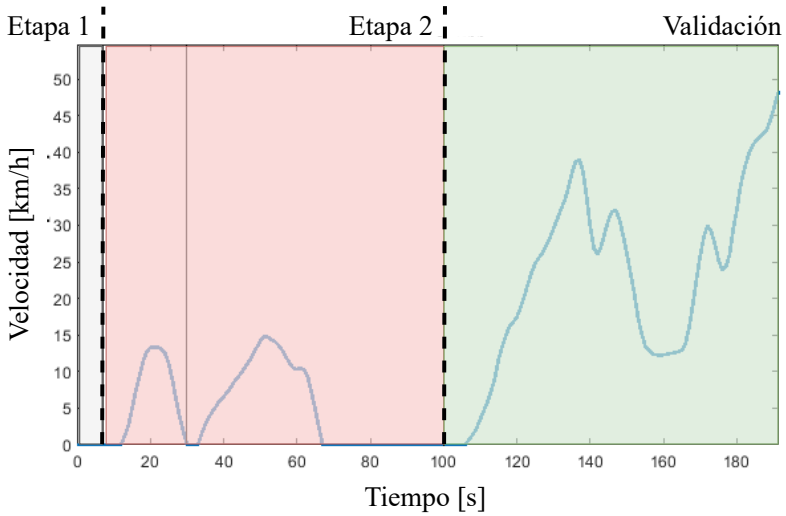


Figura 4.8: Etapas relevantes para proceso de entrenamiento y validación del Agente

Cada etapa posee un objetivo particular. En primera instancia, la Etapa 1 tiene como fin

que el Agente sea capaz de controlar sin demanda de potencia en un período de tiempo acotado. De esta forma, se logra entrenar una mayor cantidad de episodios, reduciendo la carga computacional. Durante esta etapa, el Agente aprende a emitir acciones sin alterar la tensión del link DC. Posteriormente, en la Etapa 2 (hasta los 100 segundos), el Agente deberá aprender a emitir acciones que satisfagan la demanda del FCHEV respetando las restricciones expuestas previamente y maximizando la eficiencia de operación de la pila de combustible. Esta etapa se caracteriza por una alta carga computacional debido a los prolongados tiempos de simulación y por ser la última etapa de entrenamiento. Luego de obtener un comportamiento satisfactorio tras sucesivos episodios de entrenamiento y observar un estancamiento en la recompensa obtenida por el Agente, se procede a la validación, extendiendo el tiempo de simulación a la duración total del ciclo. En esta fase, el Agente se somete a condiciones de demanda máxima y recuperación máxima de energía, manteniendo los niveles de carga de las fuentes de almacenamiento dentro de un margen seguro. La configuración del Agente se realiza mediante el código presente en el Anexo A.1, donde se define la arquitectura de las redes neuronales y los parámetros propios del entrenamiento.

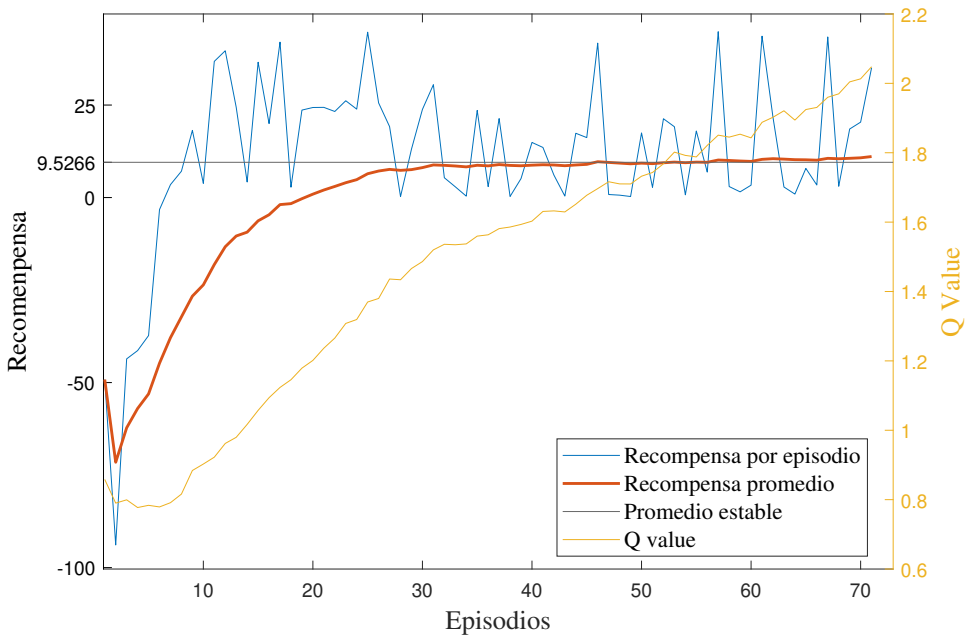


Figura 4.9: Resultados de entrenamiento durante Etapa 2

En la Figura 4.9 se exponen los resultados obtenidos durante el entrenamiento correspondiente a la Etapa 2. Se puede observar cómo en los primeros episodios el Agente acumula recompensas negativas debido a que no es capaz de satisfacer la demanda del FCHEV respetando las restricciones. Sin embargo, el Agente rápidamente aumenta la recompensa acumulada, elevando el valor Q estimado por la red del crítico, lo que implica una me-

jora continua en su desempeño en función de las recompensas programadas. Finalmente, se alcanza un punto de estancamiento en el cual la recompensa no aumenta de manera significativa, lo que indica que esta etapa de entrenamiento ha concluido. Posteriormente, se procede a validar el comportamiento del Agente, lo cual se llevará a cabo en el Capítulo 5.

Capítulo 5

Pruebas y resultados de simulación

5.1. Pruebas sobre ruta FTP-75

En el siguiente capítulo se exponen los resultados obtenidos al someter al Agente a validación. Para esto, se simula el ciclo de conducción FTP-75, debido a que presenta un perfil de aceleración más agresivo, el cual corresponde a un ciclo de conducción urbano con una duración de 2474 segundos. Considerando las condiciones establecidas para el cálculo de la potencia demandada por el vehículo en el Capítulo 4, se obtiene una potencia máxima de 52.6 [kW] y una potencia regenerada durante el frenado de 21 [kW].

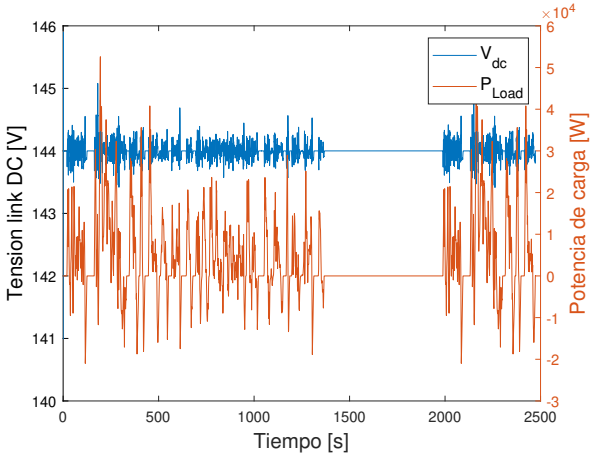


Figura 5.1: Perfil de tensión y potencia demandada

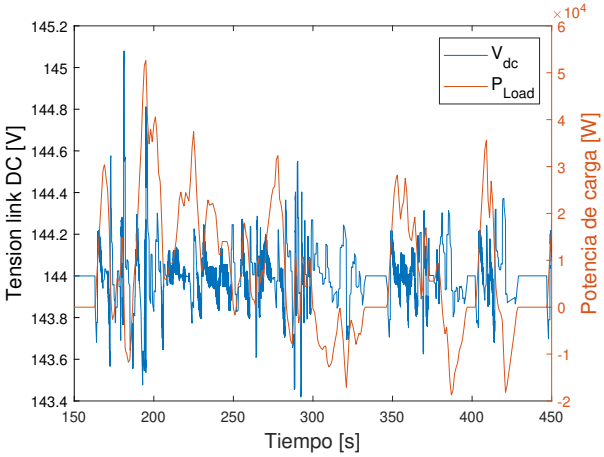


Figura 5.2: Perfil de tensión y potencia demandada ante máxima demanda

La Figura 5.1 muestra la evolución de la tensión del link DC y la potencia demandada por el FECV, donde se puede observar que el Agente es capaz de mantener dicha tensión dentro de márgenes seguros para todo el rango de potencias demandadas. En la Figura 5.2 se expone una sección del período en la cual la demanda de potencia es máxima y mínima; en ambos eventos mencionados, la tensión del link DC no se altera en más de 1

[V] respecto a la tensión de referencia.

Por otro lado, al observar las potencias entregadas por cada fuente de almacenamiento, de forma global a través de la Figura 5.3, y en la sección en torno a la demanda máxima en la Figura 5.4, es posible notar que el Agente entrega aproximadamente 5 [kW] durante todo el ciclo, incluso sin demanda de potencia por parte del FCHEV, lo que indica que el Agente opera la pila de combustible en su punto de máxima eficiencia, como se muestra en la Figura 5.10; donde se expone la evolución de la eficiencia, la cual se mantiene siempre en su valor máximo de 48 %.

El Agente, a partir de las Figuras analizadas, aprende a suministrar la energía del FCHEV principalmente desde la batería, maximizando la eficiencia de la pila de combustible, operando en márgenes seguros los niveles de corriente de cada fuente, como se observa en las Figuras 5.5 y 5.7, donde se muestra la evolución de tensiones y corrientes de la batería y SC.

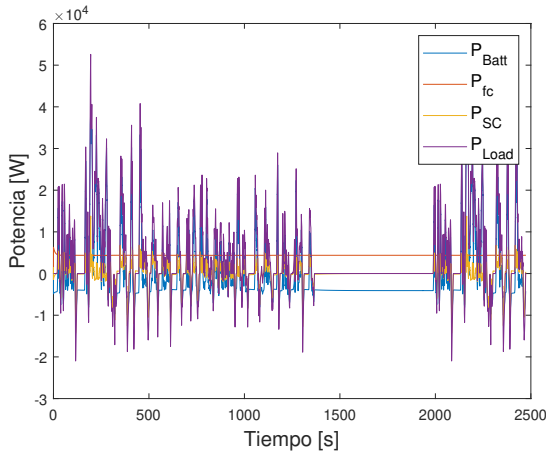


Figura 5.3: Potencia entregada por las fuentes del FCHEV

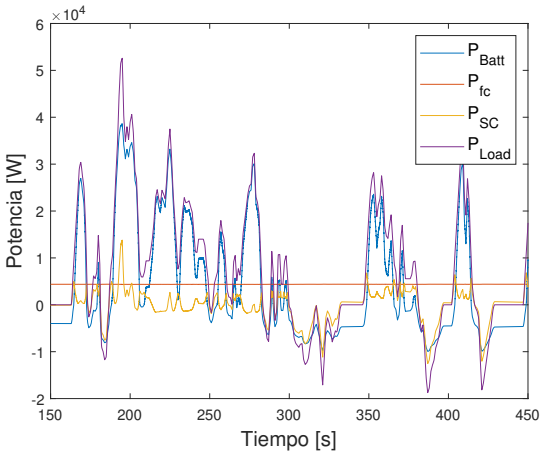


Figura 5.4: Potencia entregada por las fuentes del FCHEV ante máxima demanda

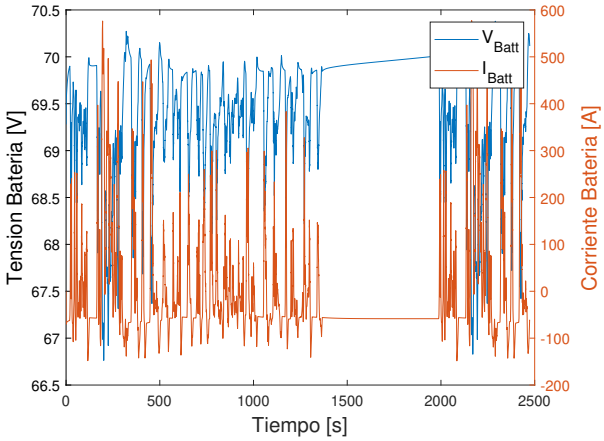


Figura 5.5: Perfil de tensión y corriente de batería

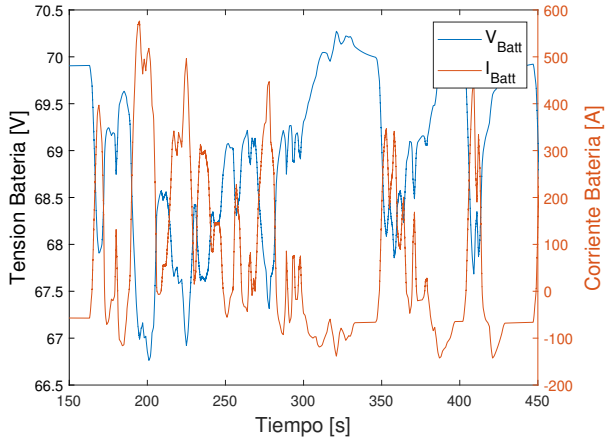


Figura 5.6: Perfil de tensión y corriente de batería ante máxima demanda

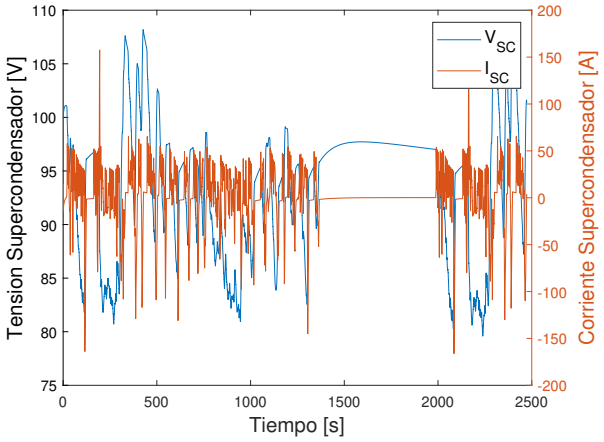


Figura 5.7: Perfil de tensión y corriente de SC

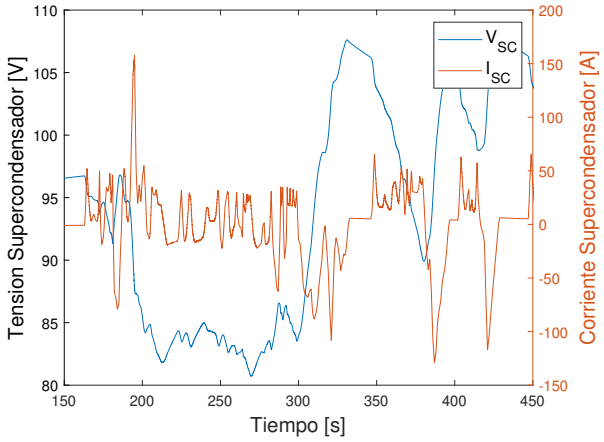


Figura 5.8: Perfil de tensión y corriente de SC ante máxima demanda

Debido a que el Agente opera constantemente la pila de combustible entregando potencia incluso sin demanda, la batería, en consecuencia, debe capturar esa energía, lo que aumenta el SOC de la misma, como se observa en la Figura 5.9. En esta figura se puede ver cómo el SOC de la batería solo disminuye de manera abrupta en el período cercano a la demanda máxima del FCHEV. Luego de este evento, la batería aumenta su SOC de manera constante, lo que implica que, si este ciclo se repite de manera sucesiva, llevaría el estado de carga de la batería al 100 %, lo cual es perjudicial para el equipo.

Paralelamente, es posible observar que la tensión del SC no aumenta a una tasa peligrosa por ciclo; es decir, la tensión final respecto a la tensión al inicio del ciclo no varía de manera significativa, aumentando solo un 1.6 %. Sin embargo, el Agente no es capaz de mantener la tensión del SC en su valor ideal programado como recompensa máxima, que corresponde a los 129 [V] del primer tramo de la función $r_{v_{SC}}$.

En la Tabla 5.1 se muestra información relevante acerca del desempeño del Agente, donde se observa que la corriente máxima de la batería no es superada, la tensión del link DC se controla de manera satisfactoria, y la eficiencia de la pila de combustible se mantiene en su nivel máximo. Sin embargo, debido a lo expuesto previamente respecto a la operación continua de la pila de combustible, el SOC de la batería solo aumenta a lo largo del ciclo, lo que se refleja en la corriente promedio de la batería, la cual es negativa (en promedio regenera energía), elevando el SOC hasta un nivel del 89.22 %, lo cual es negativo para la seguridad y vida útil de la batería. Esto se debe a la alta recompensa asociada a la eficiencia de la pila en detrimento de los demás objetivos de control. Por esta razón, se propone a continuación la aplicación de una banda muerta sobre el Agente. Esta banda muerta permitirá que el Agente solo actúe cuando el valor absoluto de la demanda de potencia sea mayor a 100 [W]; en caso contrario, el Agente no emitirá acciones y, por ende, el sistema se encontrará solo controlando la tensión desde el SC.

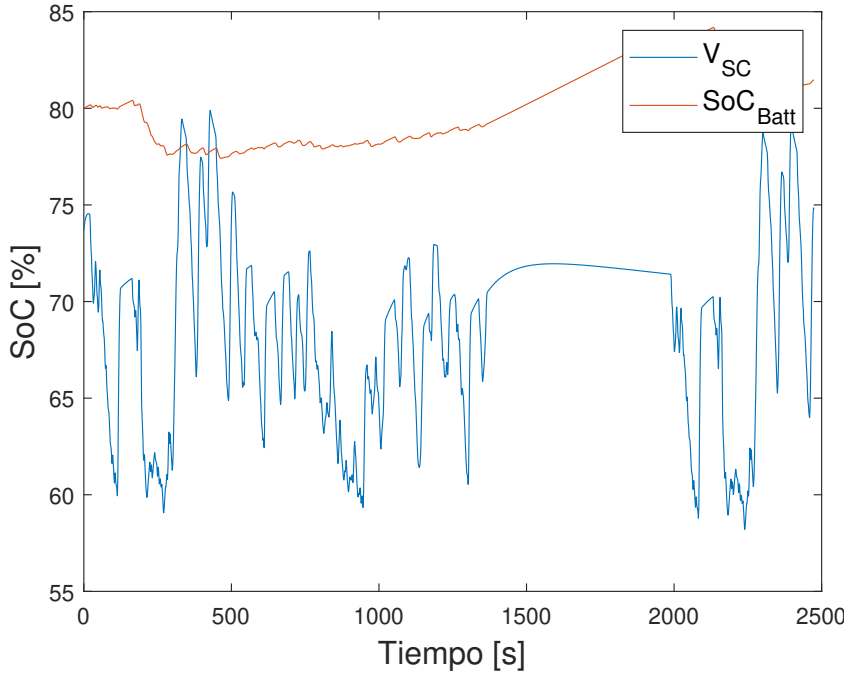


Figura 5.9: Perfil de carga y tensión de batería y SC respectivamente.

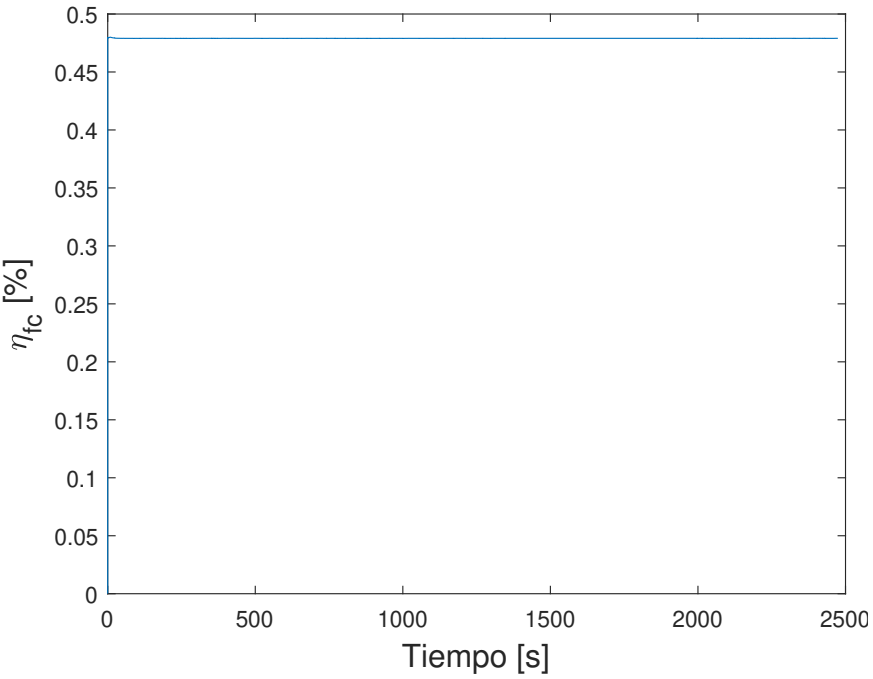


Figura 5.10: Eficiencia de trabajo de la pila de combustible

Tabla 5.1: Resumen estadístico de variables de interés.

Variable	Promedio	Desviación estándar σ	Valor mínimo	Valor máximo
$V_{dc}[V]$	144	0.1081	140.8	145.1
$\eta_{fc}[-]$	0.4797	0.0003323	0	0.48
$I_{batt}[A]$	-22.27	110.9	-152	565
SOC_{batt}	83.17	3.369	78.68	89.22
$V_{sc}[V]$	74.44	6.522	59.29	102

5.2. Aplicación de banda muerta

Debido a que el Agente resultante no logró incorporar en la política de control una estrategia que mantenga el estado de carga de la batería en un 80 %, permitiendo que la carga de la misma supere el 100 % de su capacidad si se repitiesen los ciclos de conducción, se ha decidido aplicar una banda muerta sobre la potencia demandada en torno a los 100 [W]. De esta forma, se omite un proceso de reentrenamiento del Agente.

Al aplicar una banda muerta, las referencias de los lazos de control dentro de la banda serán nulas, de manera que todo impacto de carga sobre el circuito de potencia que sobrepase dicha banda se verá como respuestas a escalón. Esto se puede evidenciar al observar las Figuras 5.11 y 5.12, donde siempre que la demanda supera la banda, hay presencia de overshoots y undershoots en la tensión del link DC.

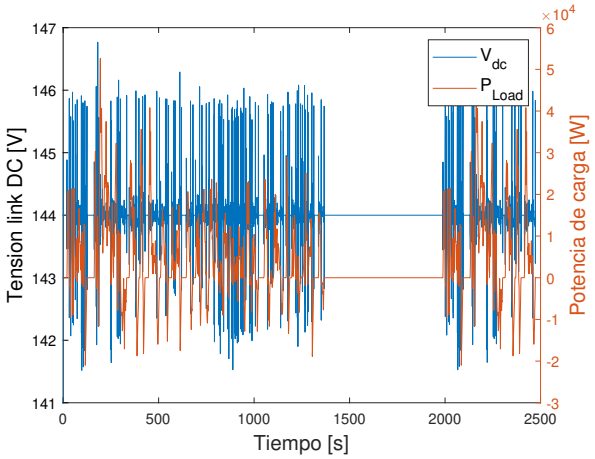


Figura 5.11: Perfil de tensión y potencia demandada

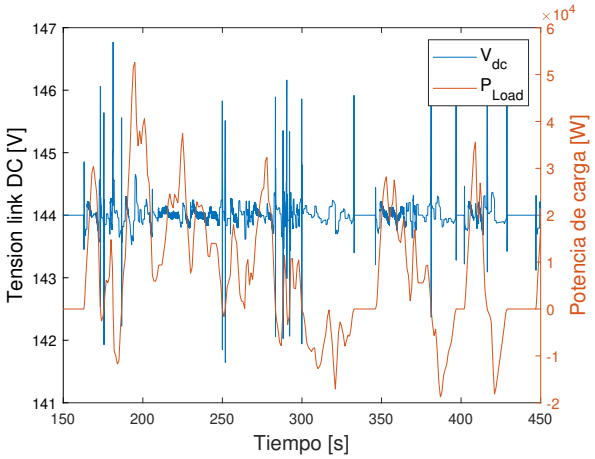


Figura 5.12: Perfil de tensión y potencia demandada ante máxima demanda

En las Figuras 5.13 y 5.14 se muestra el efecto de aplicar la banda muerta sobre las potencias entregadas por cada fuente de almacenamiento del FCHEV, donde se logra corregir el comportamiento del Agente al evitar que inyecte energía desde la pila de combustible sin que exista demanda. Una vez que se supera la banda, la pila de combustible entregará

energía al vehículo operando en su máxima eficiencia, como se observa en la Figura 5.20. En esta figura se muestra la evolución de la eficiencia de la pila de combustible al aplicar la banda muerta, evidenciando que el Agente, cada vez que opera esta fuente, lo hace maximizando su eficiencia.

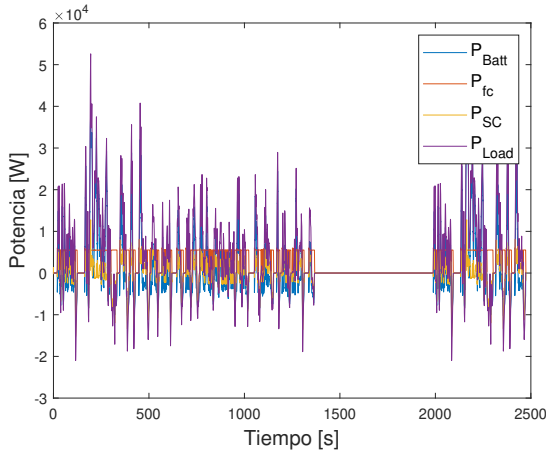


Figura 5.13: Potencia entregada por las fuentes del FCHEV

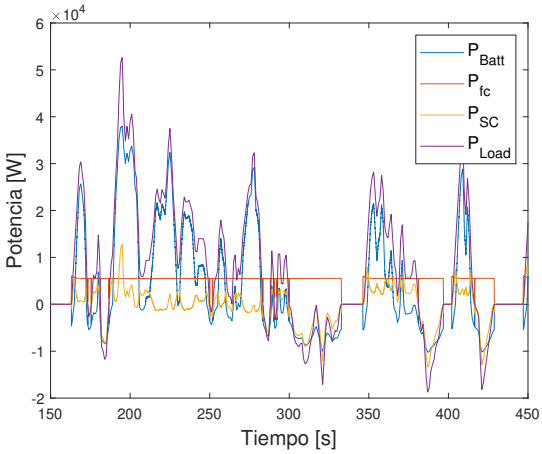


Figura 5.14: Potencia entregada por las fuentes del FCHEV ante máxima demanda

Por otro lado, la aplicación de esta banda muerta no compromete los niveles de tensión y corriente durante la operación del FCHEV, a pesar de que se están aplicando escalones constantemente en los lazos de control. Esto último se puede observar en las Figuras 5.15 y 5.17, las cuales muestran la evolución de dichas variables para la batería y el SC, respectivamente; donde, nuevamente, no se superan los límites para una operación segura. Sin embargo, como se observó en los resultados de simulación sin aplicar la banda muerta, la tensión del SC no alcanza su valor ideal asociado a su recompensa; y, además, al aplicar esta banda, la tasa de crecimiento por ciclo de la tensión aumenta a un 10.18 % sobre la tensión inicial del ciclo.

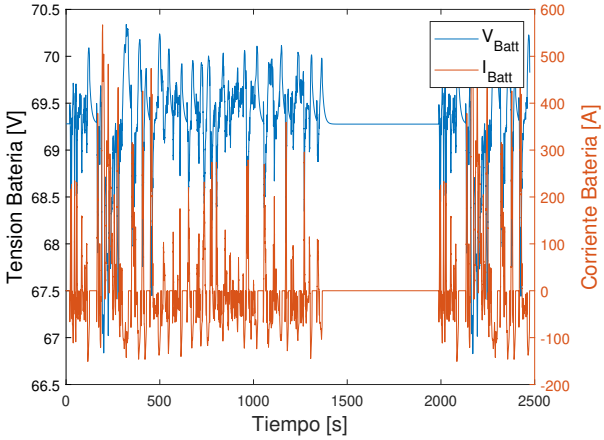


Figura 5.15: Perfil de tensión y corriente de batería

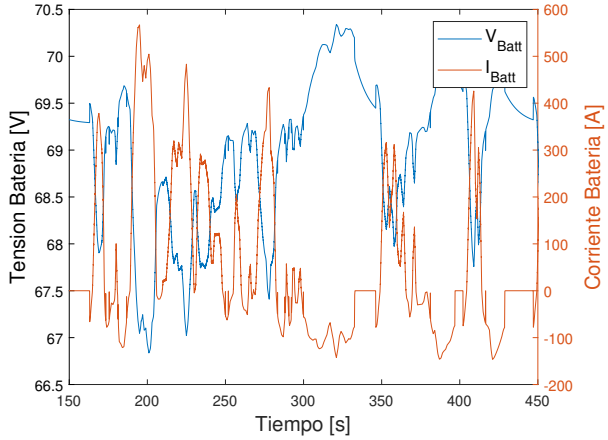


Figura 5.16: Perfil de tensión y corriente de batería ante máxima demanda

Finalmente, se observa un efecto positivo sobre la evolución del SOC de la batería (véase Figura **??**), debido a que este no aumenta progresivamente en aquellos periodos sin demanda producto de la constante inyección de energía desde la pila de combustible. Esta mejora en el desempeño respecto al SOC también se refleja en la nueva corriente promedio, expuesta en la Tabla 5.2; la cual disminuye en magnitud y cambia de sentido, es decir, inyecta en promedio más energía de la que absorbe a una menor tasa. De esta forma, el SOC, respecto a su valor inicial (80 %), disminuye un 3.02 % (estado final presentado en la Tabla, correspondiente al 76.98 %). De manera que el sistema, considerando la cantidad de hidrógeno suficiente, alcanzaría el límite del SOC informado por el fabricante (20 %) tras aproximadamente 20 ciclos.

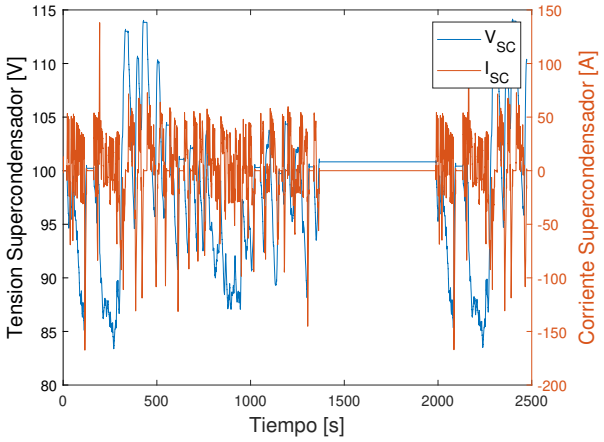


Figura 5.17: Perfil de tensión y corriente de SC.

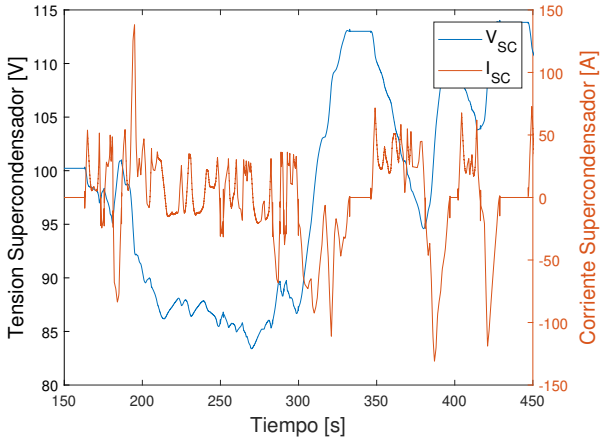


Figura 5.18: Perfil de tensión y corriente de SC ante máxima demanda

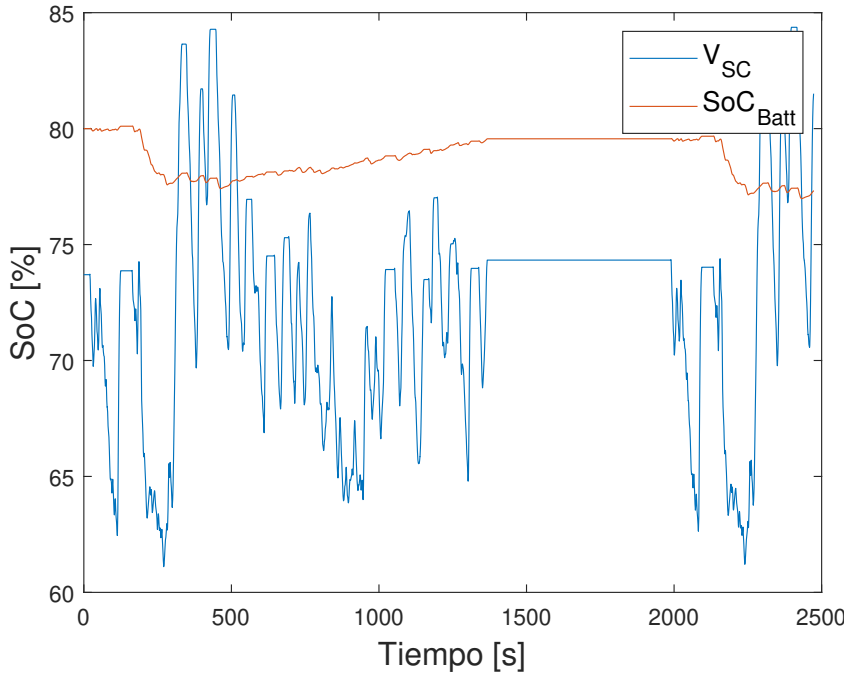


Figura 5.19: Perfil de carga y tensión de batería y SC respectivamente.

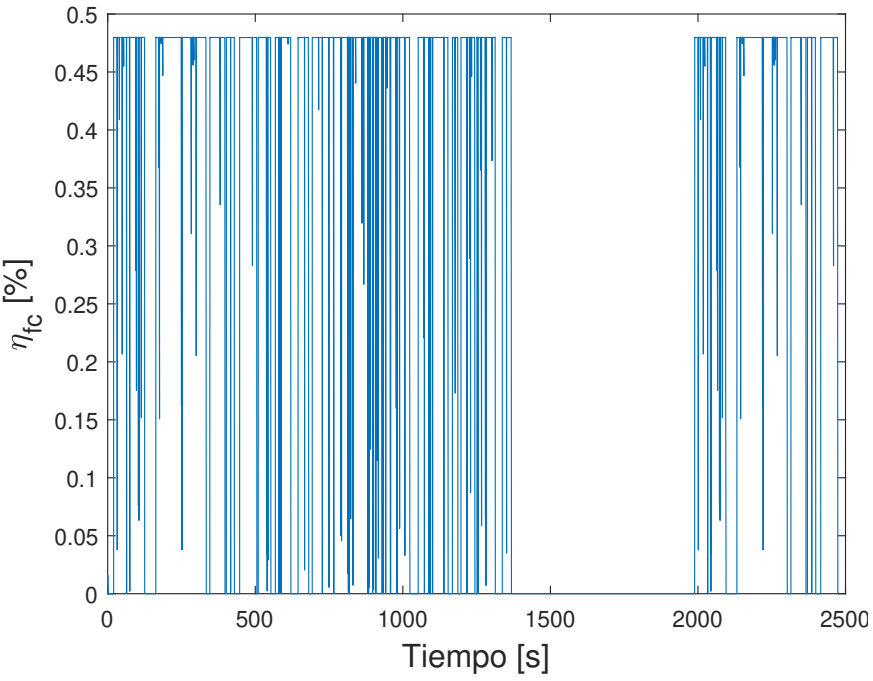


Figura 5.20: Eficiencia de trabajo de la pila de combustible

Tabla 5.2: Resumen estadístico de variables de interés.

Variable	Promedio	Desviación estándar σ	Valor mínimo	Valor máximo
$V_{dc}[V]$	144	0.1486	141	146.8
$\eta_{fc}[-]$	0.4797[1]	0.2334[2]	0	0.48
$I_{batt}[A]$	8.207	104.8	-150.9	567
SOC_{batt}	78.79	0.8618	76.98	80.11
$V_{sc}[V]$	72.45	4.883	61.11	84.37

[1]Esta eficiencia corresponde a la eficiencia promedio de a pila de combustible al operar fuera de la banda muerta.

[2]Esta desviación estándar corresponde a la de todos los datos de eficiencia, dentro y fuera de la banda.

Capítulo 6

Conclusiones.

Respecto a la revisión bibliográfica y el estado del arte en torno a las topologías de circuitos de potencia utilizadas en la implementación de vehículos eléctricos, se observa una gran variedad de combinaciones posibles en cuanto al tipo de fuentes de almacenamiento aplicadas, predominando el uso de baterías de ion-litio por su versatilidad y gran capacidad para entregar y recuperar energía. Sin embargo, se han propuesto soluciones más limpias y sostenibles respecto a la fuente de energía principal, resultando en vehículos eléctricos basados en pilas de combustible de hidrógeno, que no necesitan conectarse y se recargan mediante el reemplazo de los cilindros de hidrógeno. Esta fuente se combina estratégicamente con baterías y/o supercondensadores debido a la lenta actuación de la pila, por lo que las estrategias de control de energía que coordinan estas fuentes son de gran importancia.

El estado del arte en torno a las estrategias de control de energía para vehículos de celda de combustible (FCHEV) muestra una amplia variedad de soluciones, que abarcan desde estrategias rígidas basadas en reglas hasta programas altamente dependientes del criterio de quienes las establecen. Se plantean problemas de optimización que ajustan una o varias variables asociadas al desempeño del vehículo, tales como la eficiencia, el estado de carga de las baterías, los costos operacionales del FCHEV, etc., mostrando resultados satisfactorios al invertir una alta carga computacional sobre la solución del despacho de energía desde las fuentes de almacenamiento del vehículo.

El modelo de control propuesto emplea una red neuronal entrenada mediante un algoritmo de aprendizaje profundo (DDPG), que permite al sistema ajustar de manera adaptativa las contribuciones de la pila de combustible, la batería y el supercondensador en respuesta a las demandas de potencia del vehículo. Este enfoque se muestra eficaz para mantener la pila de combustible operando en su punto de máxima eficiencia, alrededor del 48 %, incluso durante variaciones significativas en la demanda de energía. Se muestra que el agente entrenado fue capaz de operar la pila de combustible en su rango de máxima eficiencia a

lo largo de un ciclo de conducción urbano representado por el ciclo FTP-75. Sin embargo, se observó que el sistema tiende a operar la pila de combustible continuamente, incluso en ausencia de demanda significativa, lo que resultó en una carga progresiva de la batería, lo cual puede comprometer la vida útil de la misma si no se gestiona adecuadamente. Este último aspecto puede deberse a múltiples factores relacionados con el entrenamiento del agente. Dado que los objetivos de control son múltiples y las sesiones de entrenamiento limitadas, para futuros trabajos se propone establecer un esquema multi-agente, es decir, un agente que controle una fuente de almacenamiento y que cada uno sea capaz de integrar objetivos de control diferentes, lo que podría significar importantes mejoras.

Para mitigar este efecto, se propuso y validó la implementación de una banda muerta en la demanda de potencia, que desactiva el agente cuando la demanda es muy baja. Esta modificación permitió reducir el aumento innecesario del estado de carga de la batería, manteniendo al mismo tiempo la eficiencia de la pila de combustible en niveles óptimos durante los momentos en que es necesario su funcionamiento.

Por otro lado, cambiar la acción del agente desde la referencia de un lazo de control clásico hacia directamente entregar los índices de modulación de los convertidores puede significar una gran ventaja, ya que se pueden resolver de manera directa problemas asociados a una sintonización defectuosa de controladores que pueda provocar undershoots o overshoots indeseados, dado que el agente, mediante un entrenamiento más prolongado, puede ser capaz de aprender las dinámicas de cada fuente.

Apéndice A

Anexos

A.1. Código para DDPG

```
clear;clc
plecs
open_system('dclink_v3_RL_v5')
load data_lookup_pot_eta.mat
Pfc = lookuptable_eta(:,1)';
eta_fc = lookuptable_eta(:,2)';
cd = 0.339;
cr = 0.00829;
rho = 1.293;
g = 9.807;
A = 2.51;
m1 = 2500;
m2 = 1910;
SoCbat0=rand*100
train_ep = 1;

fc = 5e3; %[Hz] Carrier frequency
fs = 2 * fc %[Hz] Sampling frecuency = Nyquist Frequency
Ts = 1e-5 %[s] Sampling period
Tf = 1e-5; % [s] Simulation time

obsInfo = rlNumericSpec([13 1]);
obsInfo.Name = "Observations";

% Action space

actInfo = rlNumericSpec([2, 1],...
    LowerLimit=[-1 0]',...
    UpperLimit=[1 (1)]');
actInfo.Name = "Actions";
actInfo.Description = "d";
```

```
% Environment creation
env = rlSimulinkEnv("dclink_v3_RL_v5", "dclink_v3_RL_v5/RL Agent", obsInfo,
    ↪ actInfo);
% Reset function (randomizes the reference values during training).
env.ResetFcn = @(in)localResetFcn(in);
rng(0)

% Observation path
obsPath = [
    featureInputLayer(obsInfo.Dimension(1),Name="obsInLyr")
    fullyConnectedLayer(13)
    tanhLayer()
    fullyConnectedLayer(25,Name="obsPathOutLyr")
    fullyConnectedLayer(13)
    tanhLayer()
    fullyConnectedLayer(25,Name="obsPathOutLyr2")
    ];

% Action path
actPath = [
    featureInputLayer(actInfo.Dimension(1),Name="actInLyr")
    fullyConnectedLayer(25,Name="actPathOutLyr")
    ];

% Common path
commonPath = [
    additionLayer(2,Name="add")
    tanhLayer
    fullyConnectedLayer(1,Name="QValue")
    ];

criticNetwork = layerGraph();
criticNetwork = addLayers(criticNetwork,obsPath);
criticNetwork = addLayers(criticNetwork,actPath);
criticNetwork = addLayers(criticNetwork,commonPath);

criticNetwork = connectLayers(criticNetwork, ...
    "obsPathOutLyr2","add/in1");
criticNetwork = connectLayers(criticNetwork, ...
    "actPathOutLyr","add/in2");

figure
plot(criticNetwork)

criticNetwork = dlnetwork(criticNetwork);
summary(criticNetwork)

critic = rlQValueFunction(criticNetwork, ...
    obsInfo,actInfo, ...
```

```
    ObservationInputNames="obsInLyr", ...
    ActionInputNames="actInLyr");

getValue(critic, ...
    {rand(obsInfo.Dimension)}, ...
    {rand(actInfo.Dimension)})

% Create the Actor

actorNetwork = [
    featureInputLayer(obsInfo.Dimension(1))
    fullyConnectedLayer(15)
    fullyConnectedLayer(15)
    fullyConnectedLayer(actInfo.Dimension(1))
    tanhLayer()
    ];

actorNetwork = dlnetwork(actorNetwork);
summary(actorNetwork)
figure
plot(actorNetwork)
actor = rlContinuousDeterministicActor(actorNetwork,obsInfo,actInfo);
getAction(actor,{rand(obsInfo.Dimension)})

% Create the DDPG Agent

agent = rlDDPGAgent(actor, critic);
Agent options
agent.SampleTime = 0.001;
agent.AgentOptions.TargetSmoothFactor = 1e-3;
agent.AgentOptions.DiscountFactor = 0.995; % gamma
agent.AgentOptions.MiniBatchSize = 128;%64;
agent.AgentOptions.ExperienceBufferLength = 3e7;
agent.AgentOptions.NoiseOptions.Variance = 0.3;
agent.AgentOptions.NoiseOptions.VarianceDecayRate = 1e-3;
agent.AgentOptions.CriticOptimizerOptions.LearnRate = 1e-03;
agent.AgentOptions.CriticOptimizerOptions.GradientThreshold = 1;
agent.AgentOptions.ActorOptimizerOptions.LearnRate = 1e-04;
agent.AgentOptions.ActorOptimizerOptions.GradientThreshold = 1;

getAction(agent,{rand(obsInfo.Dimension)})


% Training options

trainOpts = rlTrainingOptions(...
    MaxEpisodes=10, ...
    MaxStepsPerEpisode=ceil(1e6), ...
    ScoreAveragingWindowLength=2000, ...
```

```
    Verbose=false, ...
    Plots="training-progress",...
    StopTrainingCriteria="AverageReward",...
    StopTrainingValue=800000);


% Training

doTraining = false;
if doTraining
    % Train the agent.
    trainingStats = train(agent,env,trainOpts);
    save("DDPG.mat","agent")
else
    % Load the pretrained agent for the example.
    load("DDPG.mat","agent")

end

% Local Reset Function
function in = localResetFcn(in)
end
```

A.2. Dispositivos

A.2.1. Pila de combustible HyPM-HD15

Parámetro	**Valor**
Rated Electrical Power	15.5 kW
Maximum Electrical Overload	None permitted
Operating Current	0-425 Adc
Operating Voltage	32-64 Vdc
Peak Efficiency	48 %
Time from Off to Idle	$\leq$ 25 s
Time from Idle to Rated Power	$\leq$ 5 s

Tabla A.1: Parámetros de pila de combustible

A.2.2. Batería LF105

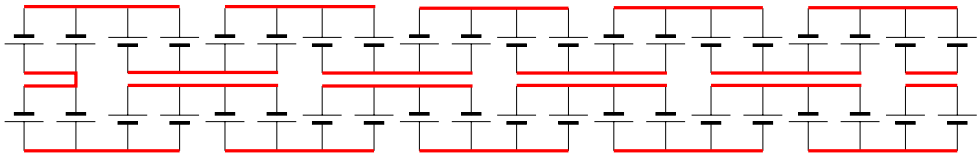


Figura A.1: Configuración de banco de baterías

Tabla A.2: Parametros generales Batería LF105

#	Item	Parámetro	detalle
1	Typical Capacity	106.5 Ah @ 1.0C discharge	Discharge current 1.0C with 2.5V cut off. (25±2)°C
2	Minimum Capacity	105.0 Ah @ 1.0C discharge	
3	Typical Voltage	3.2V	Under 0.5C CA discharge
4	AC Impedance Resistance	$\leq 0{,}5m\Omega$	
5	Charge Current (CC-CV)	Max Charge Current 1C	The maximum charge current of the battery does not exceed 1C under 0°C–45°C.
	Cut-off Voltage	3.65V	
6	Discharge Current	Max Discharge Current 3C	Preference value.
	Cut-off Voltage	2.5V	
7	Charging Standard	2.0h	0.5C charge (time is reference)
	Quick-charge time	1.0h	1C charge (time is reference)
8	Recommend SOC Window	SOC: 10 %–90 %	
9	Charging Temperature	0°C–55°C	See the appendix for details.
10	Discharging Temperature	-20°C–55°C	Battery can work at specified temperature range with capacity loss in tolerance.
11	Storage Temper	One month: -20°C–45°C	
	One year	0°C–35°C	
12	Storage Humidity	¡70 %	
13	Weight	1980g ± 50g	

A.2.2.a. Curva de polarización

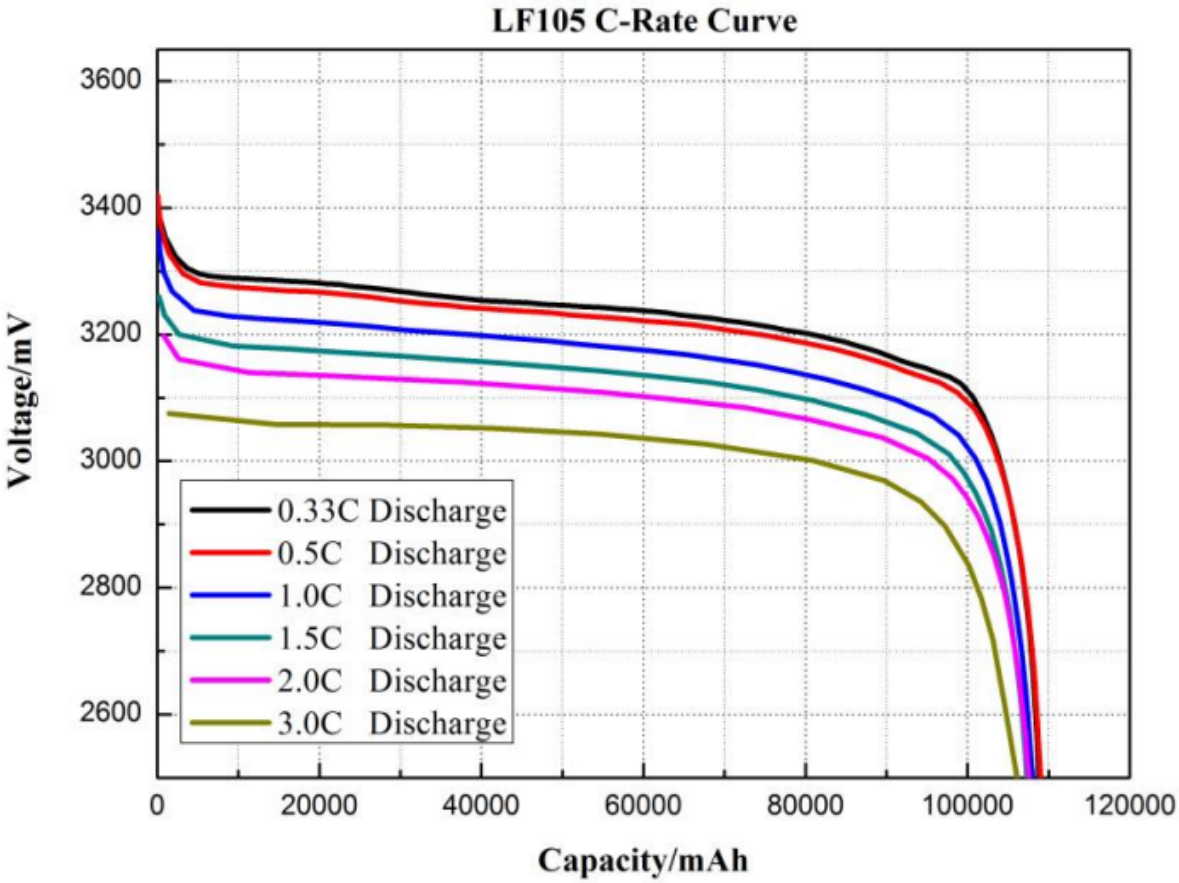


Figura A.2: Curvas de polarización de batería

A.3. Supercondensador LSUM 129R6C 0062F

Tabla A.3: Parámetros supercondensador LSUM 129R6C 0062F

Parametro	**Valor**
Rated Voltage (Nominal)	129.6 V
Serge Voltage	136.8 V
Max. Series Voltage	1,500 V
Capacitance	62 F
Capacitance Tolerance	-0 % / +20 %
Max. ESR DC	11.5 mΩ
Typical ESR DC	10.0 mΩ
Total Energy	144.6 Wh
Max. Current	2,300 A
Leakage Current	¡10 mA
Rated Voltage of Cells	2.7 V
Capacitance of Cells	3000 F
Number of Cells	48 Series

A.3.1. Constantes modelo SC

Tabla A.4: Descripción de las variables en la ecuación del SC

Variable	**Descripción**
A_i	Área interfacial entre electrodos y electrolito (m^2)
c	Concentración molar (mol/m^3) igual a $c = \frac{1}{N_A r^3}$
r	Radio molecular (m)
F	Constante de Faraday
i_{SC}	Corriente del supercondensador (A)
V_{SC}	Tensión del supercondensador (V)
C_T	Capacitancia total (F)
R_{intern}	Resistencia total (Ω)
N_e	Número de capas de electrodos
N_A	Constante de Avogadro
N_p	Número de supercondensadores en paralelo
N_s	Número de supercondensadores en serie
Q_T	Carga eléctrica (C)
R	Constante de gases ideales
d	Radio molecular
T	Temperatura de operación (K)
ϵ	Permisividad del material
ϵ_0	Permisividad del espacio libre

Apéndice B

Otro apéndice

Note que la primera línea del código de este apéndice NO DEBE INCLUIR LA INSTRUCCIÓN:

```
\addcontentsline{toc}{part}{Apéndices}
```

Bibliografía

[1] M. T. Energía M., *Estrategia Nacional de Electromovilidad Un camino para los vehículos eléctricos*, es, 2020. [En línea]. Available: dirección: https://www.energia.gob.cl/sites/default/files/estrategia_electromovilidad-8dic-web.pdf.

[2] M. Hacienda, *Gobierno presenta Fondo por US*1,000*millonesparaeldesarrollodelHidrógenoVerdeenChi* es, 19 junio 2023. [En línea]. Available: dirección: https://www.hacienda.cl/noticias-y-eventos/noticias/gobierno-presenta-fondo-por-us-1-000-millones-para-el-desarrollo-del-hidrogeno..

[3] C. Depcika, T. Cassady, B. Collicott, S. Burugupally, X. Li, S. Alam, J. Arandia y J. Hobeck, "Comparison of lithium ion Batteries, hydrogen fueled combustion Engines, and a hydrogen fuel cell in powering a small Unmanned Aerial Vehicle," en, *Energy Conversion and Management*, 2020.

[4] S. S.Ahmadi y AHHosseinpour, "Improving fuel economy and performance of a fuel-cell hybrid electric vehicle using optimized energy management strategy," en, *Energy Conversion and Management*, vol. 160, 74–84, 2018.

[5] J. al, "Challenges and developments of automotive fuel cell hybrid power system and control," en, *Science China. Information Sciences*, vol. 62, 1–25, 2019.

[6] L. G. Franquelo, J. Rodríguez, J. I. Leon, S. Kouro, R. Portillo y M. A. M. Prats, "The age of multilevel converters arrives," *IEEE Industrial Electronics Magazine*, vol. 2, n.º 2, págs. 28-39, jun. de 2008.

[7] E. Wagner, E. Delp y R. Mishra, "Energy Storage with Highly-Efficient Electrolysis and Fuel Cells: Experimental Evaluation of Bifunctional Catalyst Structures," *Topics in Catalysis*, vol. 66, págs. 546-559, 2023. DOI: 10.1007/s11244-022-01771-7.

[8] B. E. Conway, *Electrochemical Supercapacitors: Scientific Fundamentals and Technological Applications*. New York, NY: Kluwer Academic/Plenum Publishers, 1999.

[9] J. R. Miller y P. Simon, "Materials science: Electrochemical capacitors for energy management," *Science*, vol. 321, n.º 5889, págs. 651-652, 2008. DOI: 10.1126/science.1158736.

[10] C. Zhong, Y. Deng, W. Hu, J. Qiao, L. Zhang y J. Zhang, "A review of electrolyte materials and compositions for electrochemical supercapacitors," *Chemical Society Reviews*, vol. 44, págs. 7484-7539, 2015. DOI: 10.1039/C5CS00303B.

[11] Q. Xun, Y. Liu y E. Holmberg, "A Comparative Study of Fuel Cell Electric Vehicles Hybridization with Battery or Supercapacitor," en *2018 International Symposium on Power Electronics, Electrical Drives, Automation and Motion (SPEEDAM)*, 2018, págs. 389-394. DOI: 10.1109/SPEEDAM.2018.8445386.

[12] J Li, Q Wang, Z Yang y S Ding, "A review of the life cycle assessment of electric vehicles: Considering the influence of batteries," *Science of The Total Environment*, vol. 688, págs. 1184-1191, 2019.

[13] M Uzunoglu, O. Onar y M. Alam, "Modeling, control and simulation of a PV/FC/UC based hybrid power generation system for stand-alone applications," *Renewable Energy*, vol. 34, n.º 3, págs. 509-520, 2009.

[14] J. Correa, F. Farret, L. Canha y M. Simoes, "An electrochemical-based fuel-cell model suitable for electrical engineering automation approach," *IEEE Transactions on Industrial Electronics*, vol. 51, n.º 5, págs. 1103-1112, 2004.

[15] B. McLarty y T Zhao, "Current status of hybrid, battery and fuel cell electric vehicles: From electrochemistry to market prospects," *Journal of Power Sources*, vol. 415, págs. 196-213, 2019.

[16] J. Deane, B. O'Gallachoir y E. McKeogh, "Techno-economic review of existing and new pumped hydro energy storage plant," *Renewable and Sustainable Energy Reviews*, vol. 14, n.º 4, págs. 1293-1302, 2010.

[17] A Emadi, L Young-Joo y K Rajashekara, "Power electronics and motor drives in electric, hybrid electric, and plug-in hybrid electric vehicles," *IEEE Transactions on Industrial Electronics*, vol. 55, n.º 6, págs. 2237-2245, 2008.

[18] C. Chan, "The state of the art of electric and hybrid vehicles," *Proceedings of the IEEE*, vol. 90, n.º 2, págs. 247-275, 2002.

[19] P Thounthong, S Rael y B Davat, "Control strategy of fuel cell/supercapacitors hybrid power sources for electric vehicle," *Journal of Power Sources*, vol. 158, n.º 1, págs. 806-814, 2006.

[20] L Barelli, G Bidini, A Ottaviano y E Rossi, "Control strategy for a hybrid electric vehicle with a PEM fuel cell," *Energy Conversion and Management*, vol. 48, n.º 11, págs. 3001-3008, 2007.

[21] Y. LeCun, L. Bottou, Y. Bengio y P. Haffner, "Gradient-based learning applied to document recognition," *Proceedings of the IEEE*, vol. 86, n.º 11, págs. 2278-2324, 1998.

[22] A. Krizhevsky, I. Sutskever y G. E. Hinton, "Imagenet classification with deep convolutional neural networks," en *Advances in neural information processing systems*, 2012, págs. 1097-1105.

[23] I. Goodfellow, Y. Bengio y A. Courville, *Deep Learning*. MIT Press, 2016.

[24] T. e. a. Lillicrap, "Continuous control with deep reinforcement learning," *arXiv preprint arXiv:1509.02971*, 2015.

[25] D. P. Kingma y J. Ba, "Adam: A method for stochastic optimization," *arXiv preprint arXiv:1412.6980*, 2014.

[26] M. e. a. Berahman, "Multi-Task Vehicle Platoon Control: A Deep Deterministic Policy Gradient Approach," *Future Transportation*, vol. 2, n.º 4, págs. 1028-1046, 2022.