

# Diseño óptimo de tren de propulsión para vehículos eléctricos híbridos con mínima capacidad en pila de combustible de hidrógeno más Batería

---

Pablo Ignacio Loyola Alfaro

---


2024

Requisito parcial para obtener el título de:  
Ingeniero Civil Electricista

Profesor Guía:  
Antonio Sánchez (UTFSM)

Profesor Correferente:  
Ricardo Flores (UTFSM)  
Felipe Morales (UTFSM)

Santiago, 2024.



# Diseño óptimo de tren de propulsión para vehículos eléctricos híbridos con mínima capacidad en pila de combustible de hidrógeno más Batería

---

Pablo Ignacio Loyola Alfaro

---

2024

*“Hell, it’s about time.”*  
— *J.R.*

# Agradecimientos

En primer lugar, deseo expresar mi más profundo agradecimiento a mi madre, quien ha sido el pilar fundamental a lo largo de mi trayectoria académica. Su apoyo incondicional ha sido esencial para superar cada desafío de este proceso. A mi querida Lelita, cuya constante preocupación y cuidado hacia mí y nuestra familia han sido una fuente invaluable de fortaleza y amor. Asimismo, extendo mi gratitud a mi hermano, por su presencia y respaldo en cada etapa de este camino.

En memoria de mi abuelita Leticia, cuyo cariño y enseñanzas siguen presentes en mi corazón. Su ejemplo de fortaleza y bondad ha sido una inspiración que me ha acompañado en cada etapa de este camino.

Quiero expresar mi más sincero agradecimiento a mis amigos y excompañeros de colegio y liceo: Sofía, Daniela, Cristóbal y Felipe, quienes siempre han estado a mi lado brindándome su apoyo. También extendo mi gratitud a mis amigos de la universidad, que desempeñaron un papel fundamental a lo largo de mi experiencia académica. En especial, agradezco a Franco, Romano, Ernesto, Juanito, Leandro, Giorgio y Pancho por su compañía y amistad en este importante periodo.

Finalmente, quiero agradecer profundamente a los profesores Antonio Sánchez, Felipe Morales y Ricardo Flores, cuyo respaldo y orientación fueron esenciales para el desarrollo de este trabajo de memoria.

# Índice de Contenidos

|                                                                      |           |
|----------------------------------------------------------------------|-----------|
| Índice de Contenidos                                                 | I         |
| Índice de Figuras                                                    | III       |
| Índice de Tablas                                                     | V         |
| Resumen                                                              | 1         |
| <b>1. Introducción</b>                                               | <b>2</b>  |
| 1.1. Motivación . . . . .                                            | 2         |
| 1.2. Objetivos . . . . .                                             | 3         |
| 1.3. Metodología . . . . .                                           | 3         |
| <b>2. Discusión bibliográfica</b>                                    | <b>5</b>  |
| <b>3. Topología y ciclos de conducción.</b>                          | <b>7</b>  |
| 3.1. Pila de combustible o <i>Fuel Cell</i> ( <i>FC</i> ) . . . . .  | 7         |
| 3.2. Baterías . . . . .                                              | 8         |
| 3.3. Topología de tren de propulsión . . . . .                       | 9         |
| 3.4. Vehículos en la industria con topología <i>FC+BAT</i> . . . . . | 10        |
| 3.5. Especificaciones del vehículo. . . . .                          | 11        |
| 3.5.1. Batería . . . . .                                             | 11        |
| 3.5.2. Pila de combustible . . . . .                                 | 11        |
| 3.5.3. Motor . . . . .                                               | 11        |
| 3.5.4. Dimensiones exteriores . . . . .                              | 11        |
| 3.6. Ciclos de conducción . . . . .                                  | 12        |
| 3.7. Cálculo de la potencia y energía . . . . .                      | 13        |
| 3.7.1. Consideraciones para el cálculo . . . . .                     | 14        |
| <b>4. Modelamiento del tren de propulsión</b>                        | <b>16</b> |
| 4.1. Modelamiento de la batería . . . . .                            | 16        |
| 4.1.1. Conexión del sistema . . . . .                                | 16        |
| 4.1.2. Dimensionamiento de componentes . . . . .                     | 17        |
| 4.1.3. Controladores . . . . .                                       | 17        |
| 4.2. Modelamiento de la pila de combustible . . . . .                | 18        |
| 4.2.1. Conexión del sistema . . . . .                                | 19        |
| 4.2.2. Dimensionamiento de componentes . . . . .                     | 19        |
| 4.2.3. Controladores . . . . .                                       | 19        |

|           |                                                                              |           |
|-----------|------------------------------------------------------------------------------|-----------|
| <b>5.</b> | <b>Selección previa de componentes para el tren de propulsión</b>            | <b>21</b> |
| 5.1.      | Baterías . . . . .                                                           | 21        |
| 5.2.      | Pila de combustible . . . . .                                                | 22        |
| <b>6.</b> | <b>Metodologías para la optimización</b>                                     | <b>24</b> |
| 6.1.      | Problemática de optimización . . . . .                                       | 24        |
| 6.2.      | Algoritmo secuencial . . . . .                                               | 25        |
| 6.3.      | <i>Reinforcement Learning</i> . . . . .                                      | 26        |
| 6.3.1.    | Agente DQN . . . . .                                                         | 27        |
| 6.3.2.    | Asignación de parámetros . . . . .                                           | 27        |
| 6.3.3.    | Entorno . . . . .                                                            | 29        |
| 6.3.4.    | Recompensas . . . . .                                                        | 29        |
| <b>7.</b> | <b>Resultados y análisis</b>                                                 | <b>30</b> |
| 7.1.      | Resultados para la solución de 5[kW] . . . . .                               | 30        |
| 7.1.1.    | Desempeño en el Caso 1 . . . . .                                             | 30        |
| 7.1.2.    | Desempeño en el Caso 2 . . . . .                                             | 31        |
| 7.1.3.    | Homologación . . . . .                                                       | 32        |
| 7.1.4.    | Resumen de la solución . . . . .                                             | 33        |
| 7.2.      | Resultados para la solución de 20[kW] . . . . .                              | 34        |
| 7.2.1.    | Desempeño en el Caso 3 . . . . .                                             | 35        |
| 7.2.2.    | Homologación y pruebas adicionales . . . . .                                 | 37        |
| 7.2.2.a.  | Sometimiento a un ciclo de velocidad constante . . . . .                     | 37        |
| 7.2.2.b.  | Prueba de ciclo de velocidad constante con pendiente. . . . .                | 38        |
| 7.2.3.    | Solución ideal . . . . .                                                     | 39        |
| 7.2.4.    | Resumen de la solución . . . . .                                             | 40        |
| 7.3.      | Discusión sobre aspectos del uso del <i>Reinforcement Learning</i> . . . . . | 41        |
| <b>8.</b> | <b>Conclusiones.</b>                                                         | <b>44</b> |
|           | <b>Anexo</b>                                                                 | <b>51</b> |
|           | <b>Anexo</b>                                                                 | <b>51</b> |

# Índice de Figuras

|      |                                                                                                                                                                                                    |    |
|------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| 3.1. | Esquema de la reacción química de una <i>PEMFC</i> [10]. . . . .                                                                                                                                   | 7  |
| 3.2. | Esquema resumido de la pila de combustible[11]. . . . .                                                                                                                                            | 8  |
| 3.3. | Diagrama de Ragone[15]. . . . .                                                                                                                                                                    | 9  |
| 3.4. | <i>FC</i> + <i>BAT</i> [18]. . . . .                                                                                                                                                               | 10 |
| 3.5. | WLTP clase 3. Elaboración propia. . . . .                                                                                                                                                          | 12 |
| 3.6. | Diagrama de fuerzas para el cálculo de la potencia. Elaboración propia. .                                                                                                                          | 13 |
| 3.7. | Método de obtención del área frontal del Toyota Mirai mediante Auto-CAD. Elaboración propia. . . . .                                                                                               | 15 |
| 4.1. | Convertidor <i>Buck</i> y su modelo promediado a la derecha. Elaboración propia.                                                                                                                   | 17 |
| 4.2. | Rechazo de perturbaciones en respuesta a escalón para el control de corriente. Debido a la acción del control proporcional, existe un error en estado estacionario estable. . . . .                | 18 |
| 4.3. | Rechazo de perturbaciones en respuesta a escalón para el control de tensión.                                                                                                                       | 18 |
| 4.4. | Convertidor <i>Boost</i> y su modelo promediado a la derecha. Elaboración propia.                                                                                                                  | 19 |
| 4.5. | Rechazo de perturbaciones en respuesta a escalón para el control de corriente Boost. . . . .                                                                                                       | 20 |
| 5.1. | Tipo de batería a utilizar para el pack del tren de propulsión [34]. . . . .                                                                                                                       | 21 |
| 5.2. | Relación potencia-masa de las pilas de combustible. . . . .                                                                                                                                        | 23 |
| 5.3. | Relación potencia-volumen de las pilas de combustible. . . . .                                                                                                                                     | 23 |
| 6.1. | Esquema del algoritmo secuencial en cascada con la optimización entero-mixto. . . . .                                                                                                              | 25 |
| 6.2. | Esquema del agente RL interactuando con el entorno. Elaboración propia.                                                                                                                            | 26 |
| 6.3. | Esquema del agente RL DQN [39]. Se aprecia la incorporación de la red neuronal o <i>Deep Neural Network</i> (DNN) dentro de la estructura del agente.                                              | 27 |
| 6.4. | Arquitectura de la red neuronal del agente RL. . . . .                                                                                                                                             | 28 |
| 7.1. | El gráfico muestra la evolución de las potencias durante la sección de ida en el caso 1, la cual se repite para el tramo de regreso. . . . .                                                       | 31 |
| 7.2. | Evolución de las potencias a lo largo del ciclo diario en el caso 2. . . . .                                                                                                                       | 31 |
| 7.3. | Ciclo de conducción NYCC el cual es repetido 3 veces a lo largo del día. .                                                                                                                         | 32 |
| 7.4. | Energía acumulada homologada para el caso 1. . . . .                                                                                                                                               | 33 |
| 7.5. | Vista superior aproximada del Toyota Mirai con la <i>FC</i> optimizada más dos tanques adicionales a la izquierda y con la <i>FC</i> original del Mirai a la derecha. Elaboración propia . . . . . | 34 |
| 7.6. | Evolución de las potencias para el Caso 3. . . . .                                                                                                                                                 | 35 |
| 7.7. | <i>Federal Test Procedure</i> (FTP)-72. . . . .                                                                                                                                                    | 35 |

|       |                                                                                                                                                                            |    |
|-------|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| 7.8.  | <i>Federal Test Procedure</i> (FTP)-75. . . . .                                                                                                                            | 36 |
| 7.9.  | <i>Highway Fuel Economy Test</i> (HWFET). . . . .                                                                                                                          | 36 |
| 7.10. | <i>New European Driving Cycle</i> (NEDC)[49]. . . . .                                                                                                                      | 36 |
| 7.11. | Evolución del SOC para el caso 3. . . . .                                                                                                                                  | 37 |
| 7.12. | Ciclo de conducción a velocidad constante. . . . .                                                                                                                         | 38 |
| 7.13. | Evolución de las potencias para el caso 3 en velocidad constante. . . . .                                                                                                  | 38 |
| 7.14. | Ciclo de conducción a velocidad constante con una pendiente. . . . .                                                                                                       | 39 |
| 7.15. | Evolución de las potencias en una pendiente a 50[km/h]. . . . .                                                                                                            | 39 |
| 7.16. | Entrenamiento del agente RL para los casos de manera individual. Tiempo<br>total de entrenamiento $\approx$ 10 minutos. . . . .                                            | 41 |
| 7.17. | Evolución de entrenamiento para múltiples ciclos de conducción que se<br>gestan de forma aleatoria. Tiempo total de entrenamiento = aproximada-<br>mente 9 horas . . . . . | 42 |

# Índice de Tablas

|      |                                                                     |    |
|------|---------------------------------------------------------------------|----|
| 3.1. | Batería del Toyota Mirai [3]. . . . .                               | 11 |
| 3.2. | Pila de combustible del Toyota Mirai [3][25][26]. . . . .           | 11 |
| 3.3. | Datos del motor del Toyota Mirai [3] . . . . .                      | 11 |
| 3.4. | Datos generales del Toyota Mirai [3]. . . . .                       | 11 |
| 3.5. | Ciclos de conducción aleatorizados para el agente RL. . . . .       | 12 |
| 5.1. | Batería de referencia para el tren de propulsión [34]. . . . .      | 22 |
| 7.1. | Resultados generales para la solución de 5[kW] . . . . .            | 33 |
| 7.2. | Resultados generales caso 3 . . . . .                               | 40 |
| 1.   | Catálogo de pilas de combustible disponibles en el mercado. . . . . | 51 |

# Nomenclatura.

|                |   |                                                     |
|----------------|---|-----------------------------------------------------|
| FC             | : | Pila de combustible.                                |
| BAT            | : | Batería(s).                                         |
| RL             | : | <i>Reinforcement Learning</i> .                     |
| DQN            | : | <i>Deep Q-Learning</i> .                            |
| C              | : | <i>C-rate</i> .                                     |
| P              | : | Potencia.                                           |
| T              | : | Torque.                                             |
| Fg             | : | Componente de la fuerza de gravedad.                |
| Fa             | : | Fuerza que ejerce el aire sobre un cuerpo.          |
| Fd             | : | Fuerza de desplazamiento.                           |
| Fr             | : | Fuerza de roce.                                     |
| v              | : | Velocidad.                                          |
| m; M           | : | Masa.                                               |
| t              | : | Tiempo.                                             |
| $\alpha$       | : | Ángulo de inclinación.                              |
| $\mu$          | : | Coeficiente de roce.                                |
| g              | : | Gravedad.                                           |
| C <sub>d</sub> | : | Coeficiente de arrastre o <i>Drag Coefficient</i> . |
| $\rho$         | : | Densidad volumétrica.                               |
| A              | : | Área superficial.                                   |
| V              | : | Volumen.                                            |
| $\eta$         | : | Eficiencia.                                         |
| SOC            | : | Estado de carga o <i>State of Charge</i> .          |
| N              | : | Número.                                             |
| E              | : | Energía.                                            |

# Resumen

El presente trabajo aborda el diseño y optimización de un tren de propulsión híbrido compuesto por una pila de combustible ( $FC$ ) y baterías ( $BAT$ ), con el objetivo de minimizar la potencia de la  $FC$  y, consecuentemente, reducir costos, peso y tamaño de la pila de combustible. Para lograr esto, se propusieron dos metodologías principales: un algoritmo secuencial y un agente de aprendizaje por refuerzo (*Reinforcement Learning*, RL) basado en el método *Deep Q-Network* (DQN). El objetivo del algoritmo es comparar los resultados con aquellos obtenidos mediante el agente RL para verificar la validez de la solución y analizar las ventajas y desventajas de cada enfoque.

El algoritmo secuencial dimensiona iterativamente la  $FC$ , partiendo de un valor inicial mínimo de potencia y ajustando el número de baterías necesarias para satisfacer las demandas de los ciclos de conducción. Posteriormente, se realiza una optimización entera-mixta basada en el costo de las  $FC$  disponibles en el catálogo. Por otro lado, el agente RL entrenado mediante el enfoque DQN selecciona directamente las  $FC$  del catálogo, maximizando recompensas proporcionales que integran restricciones de potencia, masa, volumen y estado de carga de las baterías (SOC).

Los resultados se analizaron en tres casos representativos: uno con el ciclo WLTP combinado, otro adicionando el New York City Cycle (NYCC), y un tercero con ciclos más exigentes posicionados de forma aleatoria dentro de un ciclo completo (FTP-72, FTP-75 y HWFET). En el caso más exigente, el sistema optimizado utilizó una  $FC$  de 20 kW y 388 baterías adicionales, logrando una autonomía de 286,3 km con un consumo de 1,96 [kg] de hidrógeno por cada 100 [km], manteniendo el SOC mínimo por encima del 61 % y reduciendo el costo un  $\Delta\text{USD} = -80.536\text{\$USD}$ .

# Capítulo 1

## Introducción

### 1.1. Motivación

Los costos, la autonomía y el tiempo de recarga representan dos de los desafíos principales para la adopción de vehículos eléctricos (VE). Los vehículos eléctricos a batería (BEVs) y los híbridos enchufables (PHEVs) ofrecen una autonomía limitada debido a la capacidad de sus baterías, y su rango sigue siendo inferior al de los vehículos de combustión interna. Según el U.S. Department of Transportation, la autonomía promedio obtenida por cada hora de carga desde una toma de corriente convencional es de aproximadamente 32 kilómetros [1]. Aunque los cargadores rápidos de corriente continua (DCFC) aumentan esta autonomía en menor tiempo, su uso intensivo puede afectar la vida útil de las baterías debido a la generación de calor [2].

En cuanto al tiempo de recarga, a pesar de los avances en tecnologías de carga rápida, este proceso sigue siendo considerablemente más lento que el reabastecimiento de un vehículo de combustión. En el caso de los BEVs, el tiempo de carga completa sin el uso de DCFC puede extenderse hasta cuatro horas, mientras que los PHEVs necesitan entre una y dos horas [1]. En contraste, los vehículos eléctricos híbridos de hidrógeno, como el Toyota Mirai, ofrecen una alternativa rápida de recarga mediante hidrógeno, ya que no requieren conexión a la red eléctrica. Estos vehículos combinan una batería de menor capacidad (1.24 kWh en el caso del Mirai [3]) con una pila de combustible que provee la energía primaria al motor y recarga la batería según se necesite. Sin embargo, las pilas de combustible tienen ciertas limitaciones, incluyendo una menor densidad de potencia y tiempos de respuesta más lentos que las baterías [4].

Dado este contexto, una observación crítica es que muchos vehículos híbridos de hidrógeno en el mercado están equipados con pilas de combustible de gran tamaño, lo que puede representar un sobredimensionamiento innecesario. Este diseño incrementa los costos y ocupa un espacio considerable. Por ello, este trabajo de memoria utiliza el Toyota Mirai como vehículo base representativo, con el objetivo de optimizar su tren de propulsión al reemplazar la pila de combustible original por una de menor capacidad y añadir baterías adicionales. Esta configuración busca reducir la masa neta, los costos y el tamaño de la pila, mientras se satisface la potencia demandada por los ciclos de conducción seleccionados.

## 1.2. Objetivos

Objetivo General:

- Diseñar el tren de propulsión de un vehículo eléctrico híbrido genérico el cual se compone de batería más  $FC$  optimizada para capacidad y que opera en forma continua.

Objetivos Específicos:

- Revisar el estado del arte de los ciclos de conducción para vehículos de ciudad, trenes de propulsión  $FC +$  batería y vehículos híbridos.
- Optimizar el tamaño de la  $FC$  para que permita la carga continua de la batería para cualquier modo de operación.
- Simular el tren de propulsión optimizado.
- Proponer un procedimiento para diseñar vehículos híbridos alimentados con  $FC$  y baterías

## 1.3. Metodología

El objetivo principal de este trabajo es optimizar la potencia de la pila de combustible de un tren de propulsión híbrido ( $FC + BAT$ ) con el fin de reducir los costos, la masa y el tamaño de la  $FC$ . Para lograrlo, se lleva a cabo una serie de etapas interrelacionadas, detalladas a continuación.

Primero, en el Capítulo 2 se realiza una revisión bibliográfica que abarca metodologías de optimización utilizadas en trabajos previos sobre trenes de propulsión híbridos. Esto incluye una síntesis de los enfoques aplicados y sus resultados para sentar las bases del presente estudio.

En el Capítulo 3 se introduce la topología  $FC + BAT$  y se detalla la selección del Toyota Mirai de segunda generación como vehículo base. En este contexto, se retira la pila de combustible original y se optimiza su tamaño. Se analizan además los ciclos de conducción utilizados para evaluar el desempeño del sistema, con especial énfasis en el WLTP combinado, y se especifican las condiciones bajo las cuales se realizan las simulaciones.

El modelamiento del tren de propulsión se detalla en el Capítulo 4, donde se describen los elementos utilizados para la simulación, así como los controladores asociados a los convertidores.

El Capítulo 5 describe la selección de la batería complementaria y las ecuaciones necesarias para estimar la potencia mínima requerida de la pila de combustible. También se define el procedimiento para seleccionar una pila válida del mercado.

En el Capítulo 6 se detallan las dos metodologías de optimización propuestas: Un algoritmo secuencial en cascada con un procedimiento entero-mixto que selecciona una solución óptima desde un catálogo de  $FC$  y un modelo de aprendizaje por refuerzo basado en *Deep Q-Learning*, utilizado en paralelo para corroborar los resultados y explorar situaciones no lineales con variables discretas.

---

Finalmente, el Capítulo 7 presenta los resultados obtenidos mediante las metodologías descritas, junto con la discusión técnica correspondiente, para concluir el trabajo en el Capítulo 8.

## Capítulo 2

# Discusión bibliográfica

En el estudio realizado por Lei Zhang et al. [5], se empleó el método de optimización *Non-dominated Sorting Genetic Algorithm* (NSGA-II) para minimizar el costo y el peso del sistema de almacenamiento de energía híbrido (HESS), compuesto por baterías y supercapacitores, con el objetivo adicional de prolongar la vida útil de las baterías en un tren de propulsión. El ciclo de conducción utilizado fue el *Urban Dynamometer Driving Schedule* (UDDS), y la gestión de la potencia entre baterías y supercapacitores se llevó a cabo mediante un algoritmo de transformación *wavelet*. Aunque los resultados demostraron que el HESS optimizado alcanzó una solución efectiva, los costos estimados del sistema ascendieron a 120.000 \$USD.

El enfoque adoptado por Zhang et al. se centra en una configuración *battery-supercapacitor*, que puede ser adecuada para ciertos escenarios. Sin embargo, al utilizar únicamente el ciclo UDDS, el estudio no explora la variabilidad que otros ciclos de conducción, como el WLTP o el NYCC, podrían introducir en el diseño y la optimización. Estos ciclos, al representar diferentes condiciones operativas, podrían contribuir a identificar configuraciones más robustas y económicamente viables. Adicionalmente, la implementación de una configuración alternativa, como un sistema basado en pila de combustible de hidrógeno más baterías, podría ofrecer ventajas significativas en términos de costos y eficiencia, especialmente considerando la mayor densidad energética y la creciente disponibilidad de infraestructura de hidrógeno.

En M. Khamesipour et al. [6], se utilizó una red neuronal artificial (ANN) para predecir las demandas de potencia en un vehículo híbrido en serie, empleando datos de 14 ciclos de conducción experimentales y ciclos estándar como el WLTP clase 3 y el FTP75, lo que refuerza la representatividad del modelo. El estudio destaca por integrar condiciones reales de conducción y una estrategia de gestión de potencia basada en *power-follower*, optimizando el tamaño de la batería a 1.44 kWh y del motor eléctrico a 80 kW. Sin embargo, la exclusión de factores como la eficiencia térmica limitan la generalización de los resultados a otras arquitecturas híbridas.

En Snoussi et al. [7], se presenta una metodología innovadora que combina una estrategia de gestión energética basada en la separación de frecuencias y la optimización multiobjetivo mediante el algoritmo MOGWO. Este enfoque permite minimizar el peso del sistema de almacenamiento híbrido y evaluar su impacto en el desempeño del vehículo, destacando la importancia de considerar la masa adicional en la demanda energética. El

estudio integra explícitamente la influencia del peso del tren de propulsión (pila de combustible, baterías y supercapacitores) en ciclos de conducción representativos como el UDDS y el NEDC.

En el trabajo de Zhenpo Wang et al. [8], se destaca el uso del algoritmo de optimización multiobjetivo de enjambre de partículas (MOPSO) para el dimensionamiento de los componentes de un tren de propulsión en un vehículo eléctrico. La estrategia se centra en minimizar los costos de inversión, operativos y el peso de elementos clave, como la pila de combustible, el pack de baterías y un banco de supercapacitores, empleando ciclos de conducción representativos como el SFTP-SC03, NEDC, Artemis y WLTP. Este enfoque permitió optimizar el consumo energético, logrando un menor uso de hidrógeno comparado con otras metodologías, y se distinguió por su validación experimental, lo que refuerza la aplicabilidad práctica de los resultados. Sin embargo, el trabajo podría haberse beneficiado de una exploración más detallada de la interacción entre la distribución de masas y la eficiencia del sistema, dado su impacto directo en el desempeño dinámico y energético del vehículo.

# Capítulo 3

## Topología y ciclos de conducción.

En la literatura y en la industria, los trenes de propulsión de vehículos eléctricos híbridos a hidrógeno suelen estar configurados principalmente con pilas de combustible y baterías [9]. Esta combinación permite aprovechar las ventajas de ambos sistemas para ofrecer una mayor eficiencia y autonomía. En este trabajo, se utiliza el Toyota Mirai como base, dado que representa un caso importante de esta configuración *FC + BAT*, ampliamente adoptada en vehículos híbridos a hidrógeno. A continuación, se describen las características principales de las pilas de combustible y las baterías, destacando su papel en el tren de propulsión.

### 3.1. Pila de combustible o *Fuel Cell* (FC)

Es un dispositivo que convierte oxígeno e hidrógeno molecular en energía eléctrica, agua y calor mediante una reacción química de óxido-reducción, sin generar emisiones contaminantes. En esencia, las moléculas de hidrógeno ingresan al ánodo de la celda, donde se descomponen en protones y electrones. Los protones atraviesan una membrana de intercambio de protones (PEM), mientras que los electrones fluyen a través de un circuito externo, generando corriente eléctrica. Finalmente, en el cátodo, los protones y electrones se combinan con el oxígeno del aire para formar agua como subproducto.




Figura 3.1. Esquema de la reacción química de una PEMFC[10].




**Figura 3.2.** Esquema resumido de la pila de combustible[11].

En general, las pilas de combustible destacan por su alta energía específica (kWh/kg), lo que las convierte en una opción ideal para el almacenamiento y manejo de energía a través de hidrógeno comprimido, generalmente almacenado a 700 bar [12]. Sin embargo, presentan una potencia específica relativamente baja.

En la industria automotriz, las *Proton Exchange Membrane Fuel Cells (PEMFC)* son las más utilizadas debido a su alta eficiencia. Estas ofrecen una mayor potencia específica, buena resistencia a vibraciones y un diseño compacto, características que las hacen especialmente adecuadas para cumplir con las exigencias de los vehículos modernos [11].

## 3.2. Baterías

Las baterías desempeñan un papel crucial en los trenes de propulsión al respaldar a la pila de combustible, gracias a su mayor potencia específica, lo que les permite satisfacer demandas rápidas de energía. Además, tienen la capacidad de regenerar energía lo que contribuye no solo a mejorar la eficiencia del sistema, sino también a reducir el desgaste en componentes mecánicos y optimizar la seguridad energética. Sin embargo, las baterías tienen una energía específica menor en comparación con la pila de combustible, lo que limita su capacidad para almacenar grandes cantidades de energía de manera eficiente.

Es importante también considerar aspectos relacionados con la seguridad y la degradación. La temperatura juega un rol crítico en el rendimiento de las baterías de ión-litio. Altas temperaturas pueden inducir reacciones químicas no deseadas, acelerando la pérdida de capacidad y aumentando la resistencia interna, lo que afecta negativamente tanto la potencia como la capacidad. En condiciones extremas, podría ocurrir un fallo térmico (thermal runaway), resultando en riesgos graves como incendios o explosiones [2]. Por ello, una adecuada gestión térmica es esencial para prevenir estos efectos adversos, especialmente en aplicaciones automotrices que involucran altas tasas de carga y descarga.

Adicionalmente, la degradación de las baterías afecta significativamente su desempeño en vehículos eléctricos. Este fenómeno incluye la degradación cíclica, que ocurre con los ciclos de carga y descarga, y la degradación calendarizada, causada por la exposición prolongada a ciertas condiciones. Factores como temperaturas elevadas, estados de carga (SOC) altos y altas tasas de descarga aceleran estos procesos, resultando en pérdida de capacidad y aumento de la impedancia, lo que impacta negativamente la autonomía y la potencia del sistema [13].

En la industria, las baterías más utilizadas son las de ión-litio. Entre estas, las de

níquel-manganeso-cobalto (LiNMC) destacan por su alta energía específica, mientras que las de hierro-fosfato (LiFePO<sub>4</sub>) son valoradas por su mayor estabilidad térmica y vida útil más prolongada, lo que las hace especialmente adecuadas para aplicaciones que requieren un balance entre seguridad y rendimiento [14].

A continuación se muestra el diagrama de Ragone en el que se mapean los rangos de especificidad de energía y potencia asociados a cada componente:




**Figura 3.3.** Diagrama de Ragone[15].

Como se observa en la figura 3.3, las pilas de combustible destacan por su alta energía específica, lo que las convierte en una solución ideal para aplicaciones de larga duración y autonomía extendida. Por otro lado, los capacitores y supercapacitores lideran en términos de potencia específica, siendo particularmente útiles para suplir demandas de alta potencia en cortos períodos, como durante aceleraciones rápidas o frenado regenerativo. Estos dispositivos también se caracterizan por su larga vida útil y alta eficiencia en ciclos de carga y descarga. Sin embargo, presentan limitaciones importantes, como su elevado costo y su capacidad de almacenamiento significativamente inferior en comparación con las baterías lo cual impide que sean del todo atractivas para vehículos eléctricos híbridos a hidrógeno [16].

### 3.3. Topología de tren de propulsión

La topología de tren de propulsión a optimizar en este trabajo es la configuración *FC + BAT*, compuesta por una pila de combustible y una batería. Esta elección se fundamenta en la arquitectura utilizada por el Toyota Mirai, que se adopta como base para la optimización, aunque en la literatura se encuentran, también, otras topologías comunes, como *FC + SC* (pila de combustible más supercapacitor) y *FC + SC + BAT* [17].

En esta topología, la pila de combustible y la batería se conectan a sus respectivos convertidores DC/DC, que regulan la potencia y energía entregadas al sistema. Ambos convertidores se enlazan a un bus de corriente continua (DC link), desde donde se controla la distribución de energía. Posteriormente, el bus DC alimenta un inversor, necesario para accionar un motor síncrono de imanes permanentes (PMSM), que realiza la conversión electromecánica. Este diseño permite un control eficiente tanto de la energía como de la

potencia entregada al motor. El esquema de la topología  $FC + BAT$  se presenta en la Figura 3.4.




**Figura 3.4.**  $FC + BAT$ [18].

El convertidor asociado a la  $FC$  debe estar diseñado para bloquear el flujo de corriente inversa, ya que las celdas de la pila de combustible no están diseñadas para operar en modo regenerativo y podrían sufrir daños si se permite el flujo de energía en sentido contrario. Por otro lado, el convertidor asociado a la batería debe ser bidireccional para garantizar tanto la entrega de energía al sistema como la recuperación de energía durante el frenado regenerativo del motor, optimizando así la eficiencia energética del tren de propulsión.

### 3.4. Vehículos en la industria con topología $FC + BAT$

En el mercado automotriz actual, vehículos como el Toyota Mirai, el Hyundai Nexo, el Honda Clarity Fuel Cell y el Mercedes-Benz GLC F-Cell emplean la topología de tren de propulsión  $FC + BAT$ . Sin embargo, en todos estos modelos, la mayor parte de la potencia es proporcionada por la pila de combustible, mientras que las baterías cumplen un rol secundario al gestionar picos de potencia o recuperar energía. Por ejemplo, las potencias máximas de las  $FC$  son de 128 kW, 95 kW y 103 kW para el Toyota Mirai, el Hyundai Nexo y el Honda Clarity, respectivamente. En contraste, las potencias de las baterías en estos vehículos son menores: 25,5 [kW], 40[kW] y 25,5[kW] (estimada) respectivamente, pero considerando una alta tasa de descarga al verificar las energías de cada una: 1,24[kWh], 1,56[kWh] y 1,7[kWh] [3] [19] [20] [21] [22].

Debido a esto es que se plantea la idea de utilizar uno de estos vehículos como base y minimizar su pila de combustible con el objetivo de disminuir la masa, el tamaño de su  $FC$  y el costo que involucra invertir en una pila de combustible para solventar la demanda. En este contexto, se elige el Toyota Mirai como el vehículo base para la optimización debido a su relevancia en la industria automotriz. Este modelo fue uno de los primeros en incorporar un tren de propulsión basado exclusivamente en la topología  $FC + BAT$ , convirtiéndose en un referente tanto a nivel tecnológico como comercial. Además, Toyota ha liderado el desarrollo de infraestructura de hidrógeno en Chile, destacando con la inauguración de su primera planta de hidrógeno en el país [23]. También, el Ministerio de Transportes y Telecomunicaciones de Chile ha homologado al Toyota Mirai, lo que lo refuerza como un vehículo representativo para estudios relacionados con esta tecnología [24].

### 3.5. Especificaciones del vehículo.

En las Tablas 3.1, 3.2, 3.3 y 3.4, se presentan las especificaciones técnicas relevantes del Toyota Mirai:

#### 3.5.1. Batería

Tabla 3.1  
BATERÍA DEL TOYOTA MIRAI [3].

| Batería         |           |
|-----------------|-----------|
| Tipo            | Ión-litio |
| Tensión[V]      | 310,8     |
| Capacidad [kWh] | 1,24      |
| Masa [kg]       | 44,6      |

#### 3.5.2. Pila de combustible

Tabla 3.2  
PILA DE COMBUSTIBLE DEL TOYOTA MIRAI [3][25][26].

| Pila de combustible |                        |
|---------------------|------------------------|
| Tipo                | Electrolito polimérico |
| Potencia [kW]       | 128                    |
| Masa aprox [kg]     | 400                    |
| Volumen aprox [L]   | 550                    |

#### 3.5.3. Motor

Tabla 3.3  
DATOS DEL MOTOR DEL TOYOTA MIRAI [3]

| Motor          |                               |
|----------------|-------------------------------|
| Tipo           | Sincrónico de imán permanente |
| $P_{max}$ [kW] | 134                           |
| $T_{max}$ [Nm] | 300                           |

#### 3.5.4. Dimensiones exteriores

Tabla 3.4  
DATOS GENERALES DEL TOYOTA MIRAI [3].

| Dimensiones externas                      |      |
|-------------------------------------------|------|
| Ancho [mm]                                | 1885 |
| Largo [mm]                                | 4975 |
| Alto [mm]                                 | 1470 |
| Coefficiente de arrastre [-]              | 0,29 |
| Peso bruto ( <i>Gross Weight</i> ) [kg]   | 2415 |
| Peso en vacío ( <i>Kerb Weight</i> ) [kg] | 1900 |

### 3.6. Ciclos de conducción

Los ciclos de conducción son patrones o perfiles de velocidad que puede presentar un vehículo durante su uso en un contexto determinado. Estos permiten evaluar el desempeño de un vehículo en condiciones controladas o simuladas. Para este trabajo se utilizarán uno de los perfiles más recurrentes en la literatura: el *Worldwide Harmonized Light Vehicles Test Procedure* (WLTP) class 3.

El WLTP clase 3, también conocido como WLTP combinado, es un ciclo de 1800 segundos de duración que busca representar condiciones de conducción más realistas, incluyendo trayectos urbanos, suburbanos y de carretera, puesto que posee 4 fases: una de bajas velocidades, otra de media, alta y extra alta (llegando sobre los 120[km/h]) [27]. Esto último equivale a 15 minutos de viaje normal por la ciudad, mientras que la otra mitad se va avanzando a la autopista y/o carretera. En la Figura 3.5, se presenta el perfil de velocidad del WLTP clase 3:




**Figura 3.5.** WLTP clase 3. *Elaboración propia.*

Este ciclo de conducción representa un trayecto de ida y vuelta en un ciclo diario de 24 horas, comenzando a las 7:30 a.m. y repitiéndose a las 5:30 p.m., simulando un día laboral para el procedimiento de optimización. Además, se incorporan aleatoriamente de uno a cuatro ciclos adicionales, seleccionados entre los ciclos estandarizados, para representar la variabilidad e incertidumbre que podrían afectar la autonomía del vehículo.

Tabla 3.5  
CICLOS DE CONDUCCIÓN ALEATORIZADOS PARA EL AGENTE RL.

| Ciclo        | Duración [s] |
|--------------|--------------|
| WLTP class 3 | 1800         |
| FTP72        | 1372         |
| FTP75        | 2474         |
| HWFET        | 765          |
| NEDC         | 1180         |
| JC08         | 1204         |
| US06         | 600          |
| NYCC         | 598          |

### 3.7. Cálculo de la potencia y energía

Para llevar a cabo la optimización de un tren de propulsión, es fundamental conocer la potencia requerida por el vehículo durante su operación. Este cálculo se basa en el análisis de las fuerzas que actúan sobre el vehículo, representadas en el siguiente diagrama:




**Figura 3.6.** Diagrama de fuerzas para el cálculo de la potencia. Elaboración propia.

A partir de este esquema, se determina que la potencia necesaria para el desplazamiento del vehículo se calcula mediante la siguiente sumatoria:

$$P_{desp} = m \cdot v \cdot \frac{dv}{dt} + m \cdot g \cdot \sin(\alpha) \cdot v + \mu \cdot g \cdot \cos(\alpha) \cdot v + \frac{1}{2} \cdot C_d \cdot \rho_a \cdot A_f \cdot (v + v_w)^2 \cdot v + P_{aux}$$

Dónde:

- $m$ : masa del vehículo [kg].
- $v$ : velocidad instantánea [m/s].
- $g$ : aceleración de gravedad como 9.98 [m/s<sup>2</sup>].
- $t$ : tiempo [s].
- $\alpha$ : ángulo de inclinación [°].
- $\mu$ : resistencia al rodamiento[-].
- $C_d$ : coeficiente de arrastre o *drag*[-].
- $\rho_a$ : densidad del aire [kg/m<sup>3</sup>].
- $A_f$ : área frontal del vehículo[m<sup>2</sup>].
- $v_w$ : velocidad del viento en ese instante[m/s].

- $P_{aux}$  potencia de los servicios auxiliares del vehículo [kW].

Además, hay que considerar que el sistema está sujeto a pérdidas entre la potencia que entregan las fuentes del tren de propulsión y la potencia a la salida del motor, por tanto, se tiene lo siguiente:

$$P_{tren} = \frac{P_{desp}}{\eta_{Motor} \cdot \eta_{DC/DC} \cdot \eta_{DC/AC}} \quad (3.1)$$

Dónde:

- $P_{tren}$ : potencia total que deben entregar las fuentes del tren de propulsión.
- $\eta_{Motor}$ : eficiencia del motor.
- $\eta_{DC/DC}$ : eficiencia de los convertidores DC/DC.
- $\eta_{DC/AC}$ : eficiencia del convertidor DC/AC.

### 3.7.1. Consideraciones para el cálculo

- La resistencia al rodamiento = 0,01 [28].
- La velocidad del viento se asume como constante y con un valor de 3,139[m/s] [29].
- La densidad del aire  $\rho_a$  se establece como 1,225[kg/m<sup>3</sup>]
- La potencia de los servicios auxiliares se asume como 4,23[kW] [30]
- Las eficiencias del motor y los convertidores  $\eta = 0,95$  [31].
- El área frontal se calcula mediante el uso del cálculo de área de AutoCAD lo cual da como resultado 2,33[m<sup>2</sup>] (ver Figura 3.7).
- La pila de combustible entregará potencia máxima en cada recorrido con una eficiencia del 40 % respecto al consumo de hidrógeno[32][33].




**Figura 3.7.** *Método de obtención del área frontal del Toyota Mirai mediante AutoCAD. Elaboración propia.*

Estableciendo todo esto, se calcula la energía como:

$$E_{tren} = \int_0^T P(t) dt$$

# Capítulo 4

## Modelamiento del tren de propulsión

El modelo del tren de propulsión híbrido utilizado para las simulaciones está compuesto por dos fuentes de tensión continua (batería y pila de combustible), dos convertidores DC/DC conectados a un capacitor (DC-Link) y una carga modelada como una fuente de corriente variable. Este capítulo describe el diseño y dimensionamiento de los componentes, el control de los convertidores y la integración del sistema completo.

Este modelo tiene como objetivo representar de manera simplificada el tren de propulsión híbrido para analizar su desempeño bajo diferentes condiciones operativas y ciclos de conducción en términos de potencia y energía. Las decisiones de diseño, como la selección de convertidores y controladores, se realizaron priorizando la estabilidad del sistema y la eficiencia del flujo de potencia, dejando de lado los transitorios y fenómenos dinámicos, ya que el enfoque del estudio está en el análisis estacionario.

### 4.1. Modelamiento de la batería

La batería fue modelada como una fuente de tensión continua, diseñada para priorizar la representación de su estado de carga (*SOC*). La corriente que fluye a través de la batería se mide y se integra para calcular el SOC, que a su vez se utiliza como señal de control para la operación de la pila de combustible.

#### 4.1.1. Conexión del sistema

La batería se conecta al sistema mediante un convertidor *buck* de dos cuadrantes, cuya función es regular la tensión del DC-Link a un valor fijo de 144 [V]. La elección de un convertidor *buck* sobre un *boost* se debe a su simplicidad y linealidad en el control, lo que facilita su implementación. Además, dado que el enfoque del estudio está en el análisis estacionario del flujo de potencia y no en los transitorios ni en fenómenos dinámicos complejos, el uso de un *buck* simplifica significativamente el modelado sin comprometer los resultados relevantes.

El convertidor *buck* utiliza un esquema de control en cascada, compuesto por un lazo interno de corriente que regula el flujo hacia el DC-Link y un lazo externo de tensión

encargado de mantener la estabilidad de la tensión en el bus.

El diagrama del convertidor *buck* y su modelo promediado se presentan en la Figura 4.1.




**Figura 4.1.** Convertidor Buck y su modelo promediado a la derecha. Elaboración propia.

#### 4.1.2. Dimensionamiento de componentes

El dimensionamiento de los componentes del convertidor considera una eficiencia del 95 % y una potencia máxima de salida de  $P=100[\text{kW}]$ . La resistencia del sistema se calcula como:

$$R_L = 0,05 \cdot \frac{V_{out}^2}{P} \approx 10[\text{m}\Omega]$$

Se seleccionaron una inductancia de  $L=1\text{mH}$  y un capacitor de  $C=100[\mu\text{F}]$  para una frecuencia de conmutación de  $f_s=20[\text{kHz}]$ . Esta frecuencia fue elegida considerando un equilibrio práctico entre la eficiencia energética, las pérdidas de conmutación y la estabilidad dinámica del sistema. Frecuencias más bajas podrían incrementar el tamaño de los componentes pasivos, mientras que frecuencias más altas podrían aumentar las pérdidas de conmutación en los dispositivos semiconductores. Los valores seleccionados se verificaron utilizando las ecuaciones de rizado de corriente y tensión, garantizando que el comportamiento del convertidor sea adecuado para las condiciones de operación previstas.

$$\Delta I_L = \frac{(V_g - V_{out}) \cdot D}{f_s \cdot L} \approx 0,6 \%$$

$$\Delta V_{out} = \frac{\Delta I_L}{8 \cdot f_s \cdot C} \approx 0,1 \%$$

#### 4.1.3. Controladores

El control del convertidor *buck* se realiza mediante controladores PI, ajustados para garantizar un comportamiento estable en ambos lazos. Los parámetros del controlador, determinados utilizando la herramienta `rltool` en MATLAB, son:

$$K_{pc} = 34,31 \quad K_{ic} = 0$$

$$K_{pv} = 12,91 \quad K_{iv} = 12914$$




**Figura 4.2.** Rechazo de perturbaciones en respuesta a escalón para el control de corriente. Debido a la acción del control proporcional, existe un error en estado estacionario estable.




**Figura 4.3.** Rechazo de perturbaciones en respuesta a escalón para el control de tensión.

## 4.2. Modelamiento de la pila de combustible

La pila de combustible fue modelada como una fuente de tensión continua con operación discreta: inyecta potencia máxima al sistema cuando el SOC de las baterías es inferior a 0,8, y se apaga cuando el SOC alcanza o supera este valor.

### 4.2.1. Conexión del sistema

La conexión de la pila de combustible se implementa a través de un convertidor *boost* de un cuadrante, diseñado específicamente para asegurar un flujo controlado de potencia hacia el DC-Link. Este convertidor emplea un único lazo de control de corriente para garantizar que la pila de combustible entregue su potencia máxima al sistema de manera estable.

El diagrama del convertidor *boost* y su modelo promediado se muestran en la Figura 4.4.




**Figura 4.4.** Convertidor Boost y su modelo promediado a la derecha. *Elaboración propia.*

### 4.2.2. Dimensionamiento de componentes

Los componentes del convertidor se dimensionaron para garantizar una eficiencia del 95 %  $P=100[\text{kW}]$  y una tensión de entrada de  $V_g=100[\text{V}]$ . Los valores seleccionados incluyen:

$$R_L = 0,05 \cdot \frac{V_{in}^2}{P} \approx 0,5[\text{m}\Omega]$$

$$D = 1 - \frac{V_g}{V_o} = 0,3$$

$$\Delta I_L = \frac{V_g \cdot D}{f_s \cdot L} \approx 0,15 \%$$

### 4.2.3. Controladores

El controlador PI utilizado para el lazo de corriente tiene los siguientes parámetros:

$$K_{pc} = 9,37 \quad K_{ic} = 93,73$$




**Figura 4.5.** Rechazo de perturbaciones en respuesta a escalón para el control de corriente Boost.

# Capítulo 5

## Selección previa de componentes para el tren de propulsión

### 5.1. Baterías

Dado que el objetivo de la optimización es reducir la potencia de la pila de combustible, se decide complementar la batería existente con otro modelo capaz de proporcionar principalmente potencia. En el mercado, existe una amplia gama de baterías, y se opta por seleccionar las de tecnología LiFePO4 debido a su alta densidad energética. Se elige el siguiente modelo como representativo:



**Figura 5.1.** Tipo de batería a utilizar para el pack del tren de propulsión [34].

Tabla 5.1  
BATERÍA DE REFERENCIA PARA EL TREN DE PROPULSIÓN [34].

| Batería de referencia |                    |
|-----------------------|--------------------|
| Marca                 | Power Long Battery |
| Modelo                | IFR26650-30B       |
| Tipo                  | LiFePO4            |
| Tensión nominal [V]   | 3,2                |
| Capacidad [mAh]       | 3000               |
| Masa [kg]             | 0,085              |
| Volumen [L]           | 0,0355             |
| C-rate continuo       | 10                 |
| C-rate 1 minuto       | 15                 |
| C-rate 10 segundos    | 20                 |

Por otra parte, son más compactas, por ende, es posible armar un pack de baterías que no utilice tanto espacio además de su reducción en peso. Sin embargo, esto podría generar un problema de sobrecalentamiento, pero el Toyota Mirai utiliza un sistema de refrigeración por aire lo cual puede mitigar el calor generado por las baterías adicionales [35], en consideración de que sólo se extraerá la pila de combustible. Además, se utilizará principalmente el uso hasta 10C de estas baterías lo que implica un aumento de 55[°C] según la curva  $T[°C]$  v/s Capacidad [mAh] presentada por el fabricante [34].

## 5.2. Pila de combustible

En el caso de las pilas de combustible, se hace una revisión de aquellas disponibles en el mercado presente. Luego, se realiza una relación entre la potencia, la masa y el volumen para modelarlas en un espectro continuo y de esa manera estimar una potencia mínima ideal para tener como base. A continuación se presentan las relaciones entre potencia-masa, potencia-volumen y potencia-precio.

A partir de estos gráficos de las Figuras 5.2 y 5.3 se puede obtener la siguiente relación entre potencia-masa y potencia- volumen utilizando las curvas  $Potencial(Msup)$  y  $Potencial(Vsup)$  las cuales representan la mayor masa y el mayor volumen por potencia:

$$Masa_{FC} = e^{0,835 \cdot \ln(P_{FC}) + 1,795} \quad (5.1)$$

$$Volumen_{FC} = e^{0,887 \cdot \ln(P_{FC}) + 2,07} \quad (5.2)$$

Cabe destacar que todas las pilas de combustible revisadas para estos gráficos son de tipo PEMFC las cuales poseen una alta eficiencia en la conversión de hidrógeno en energía y están altamente presentes en el mercado de transportes [36].




**Figura 5.2.** *Relación potencia-masa de las pilas de combustible.*




**Figura 5.3.** *Relación potencia-volumen de las pilas de combustible.*

# Capítulo 6

## Metodologías para la optimización

En este trabajo de memoria se proponen dos metodologías para la optimización. La primera corresponde a la creación de un algoritmo secuencial para determinar la mínima potencia del tren de propulsión, mientras que, en paralelo, se entrena una inteligencia artificial o *Machine Learning* para que optimice bajo opciones más limitadas en base al propio catálogo de pilas de combustible.

### 6.1. Problemática de optimización

Se busca minimizar la potencia de la pila de combustible, ya que con ello es posible reducir costos, el peso y mejorar el espacio dentro del vehículo, puesto que estas poseen una mayor densidad energética que de potencia, por tanto, el vehículo tiene la posibilidad de aprovechar esa disminución de masa para ampliar el uso de más baterías como las propuestas anteriormente y/o dar más espacio a los tanques de hidrógeno. Para ello, se retira la pila de combustible original del vehículo.

$$M_{vehiculo} = M_{bruto} - M_{FC_{original}} = 2015[kg]$$

Esto también se aplica al volumen para generar una restricción de espacio al añadir baterías adicionales que compensen la potencia requerida por el ciclo de conducción:

$$V_{disponible} = V_{FC} = 550[L]$$

En ambos casos, se considera una holgura del 10 % al comparar los datos originales con los resultados de las optimizaciones.

Además, debido a la potencia que exige el ciclo, el conjunto debe tener una potencia igual o superior y, además, la pila de combustible debe ser lo suficientemente grande en potencia como para evitar que el estado de carga de la batería (SOC) caiga bajo el 10 %, debido a que puede provocar una degradación acelerada e incluso la pérdida de la batería. También, para asegurar de que la batería se mantiene en un rango seguro de operación, se exige que el SOC final en cada escenario sea igual al SOC con el que empieza el vehículo. Se considera un límite superior del 80 % de SOC para evitar los efectos de degradación

acelerada en niveles de carga elevados [37]. De esta manera el problema de optimización se puede resumir de la siguiente forma:

$$\text{Min } P_{FC}$$

s.a.

1.  $P_{max} \leq P_{BAT} + P_{FC}$
2.  $M_{bruto} \geq M_{BAT} + M_{FC} + M_{vehiculo}$
3.  $V_{disponible} \geq V_{BAT} + V_{FC}$
4.  $SOC_{final} = 0,8$
5.  $SOC_{mn} \geq 0,1$

## 6.2. Algoritmo secuencial

Una de las propuestas para resolver este problema de optimización es implementar un algoritmo secuencial que dimensiona una pila de combustible iniciando con una potencia de 0.1 kW, incrementándola en pasos de 0.1 kW mientras el algoritmo evalúa y descarta cada opción de  $FC$ . En cada iteración, se calcula la cantidad adicional de baterías necesarias para satisfacer la demanda de potencia del ciclo de conducción, ajustando la masa total y recalculando la potencia necesaria en el ciclo. Esto permite obtener una estimación preliminar de la masa y el volumen, que luego se simulan para verificar su validez como solución viable para alcanzar una potencia mínima de  $FC$ . Posteriormente, este valor preliminar se somete a una optimización entera-mixta que selecciona la  $FC$  más adecuada del catálogo según una nueva restricción de costo en USD. Finalmente, el resultado obtenido se somete nuevamente al algoritmo secuencial para validar la factibilidad de la solución.




**Figura 6.1.** Esquema del algoritmo secuencial en cascada con la optimización entera-mixta.

### 6.3. Reinforcement Learning

El aprendizaje por refuerzo o *Reinforcement Learning* (RL) es un método de aprendizaje automático en el que un agente (entidad que aprende por medio de ejercer acciones) interactúa con un entorno definido y toma decisiones de acuerdo a la problemática que se plantee. Las decisiones que toma el agente buscan asemejarse a un proceso de ensayo y error a través del método RL y va ajustando su comportamiento a medida que va recibiendo penalizaciones o recompensas de acuerdo a las acciones que toma con el fin de maximizar la recompensa acumulada por episodio. A medida que el agente va ganando experiencia, va adquiriendo una política la cual se va optimizando para que mejoren sus decisiones y acciones futuras.

Para ello, el aprendizaje por refuerzo se compone de 4 elementos: el agente, el entorno y las acciones y las recompensas. El agente es quien realiza las acciones y recibe recompensas, el *environment* o entorno representa el contexto en donde se realizan las acciones y todo aquello que no controla el agente, por ejemplo, el entorno podría ser un juego de ajedrez, por tanto, las acciones del agente están asociadas al movimiento de las piezas, no obstante, la reacción del jugador contrario también es parte del entorno en este caso, es decir, la reacción del entorno a la acción del agente RL. En este caso el entorno corresponde a la simulación del tren de propulsión y el ciclo de conducción por el que pasa. Finalmente, están las recompensas las cuales son el indicador que tiene el agente para saber y optimizar su comportamiento para lograr el objetivo, mientras que las acciones son todas las decisiones que toma el agente para llegar al objetivo. El agente, a su vez, se puede componer generalmente de un actor quien ejecuta las acciones y un crítico quien evalúa la calidad de dichas acciones. Ambos pueden ser redes neuronales para mejorar aún más el aprendizaje del agente, dependiendo de la complejidad de los problemas que se le presenten. A continuación se presenta el esquema del aprendizaje por refuerzo:




**Figura 6.2.** Esquema del agente RL interactuando con el entorno. *Elaboración propia.*

En la literatura se pueden identificar dos tipos recurrentes de aprendizaje por refuerzo: el *Deep Q-Network* (DQN), ideal para problemáticas con acciones discretas, y el *Deep Deterministic Policy Gradient* (DDPG), cuya principal característica es que puede trabajar con un espectro de acción continua. Para efectos de este trabajo de título, se enfocará en

el RL DQN.

### 6.3.1. Agente DQN

El agente RL DQN se caracteriza por ser una versión mejorada del método *Q-Learning* para inteligencias artificiales. Este último se basa en utilizar una tabla denominada *Q-table* la cual va evaluando las acciones del agente en base a las decisiones que toma y les da un valor de acuerdo a la calidad de la acción. Esta tabla es actualizada constantemente a medida que el agente es entrenado de modo que sus valores van cambiando en torno a la maximización de la recompensa. Una de las problemáticas que tiene el *Q-Learning* es que los entornos no pueden ser tan complejos, ya que la *Q-table* puede crecer de manera exponencial lo cual puede desestabilizar al agente. Debido a lo anterior, surge el aprendizaje por refuerzo DQN, dónde el método *Q-Learning* pasa a ser manejado por una red neuronal que toma rol de actor-crítico del agente RL y busca aproximarse a una función *Q* en lugar de generar una tabla, por tanto, el agente puede manejar un entorno de mayor complejidad en la evaluación y ejecución de la toma de decisiones. En el trabajo de Woong Lee et al. [38] se crea una optimización para el *Energy Management System* de un vehículo eléctrico mediante DQN.




**Figura 6.3.** Esquema del agente RL DQN [39]. Se aprecia la incorporación de la red neuronal o Deep Neural Network(DNN) dentro de la estructura del agente.

### 6.3.2. Asignación de parámetros

Para la problemática de este trabajo, al agente se lo define con las siguientes características:

- Acciones: el agente escogerá una pila de combustible directamente desde el catálogo de Fuel Cells.
- Observaciones: se definen 6 observaciones que el agente extraerá del entorno:
  1. Ratio de energía: es la energía total del ciclo diario en kWh dividido en el tiempo total.
  2. SOC final
  3. SOC mínimo alcanzado

4. Ratio de masa: cociente entre la masa total y la máxima.
5. Ratio de volumen: cociente entre el volumen total y el disponible.
6. Ratio de potencia: cociente entre la potencia que puede alcanzar el tren de propulsión y la potencia máxima del ciclo de conducción.

Respecto a la red neuronal del crítico, se configura cada nodo como completamente conectado lo cual implica que el agente puede asociar múltiples características y hacer relaciones no-lineales de forma más eficiente. A continuación se muestra la arquitectura de la red neuronal utilizada:



**Figura 6.4.** *Arquitectura de la red neuronal del agente RL.*

A la hora de entrenar al agente RL, es necesario hacer uso de los hiperparámetros para hacer que el aprendizaje sea más rápido, eficiente y estable. Estos dependen mucho del contexto al que se somete el agente RL. A continuación se presentan los hiperparámetros y sus respectivos valores seleccionados:

- *Learn Rate*: es la tasa con la que el agente va aprendiendo con cada episodio de entrenamiento y puede tomar valores entre 0 y 1. Se escoge 0,001, es decir, una tasa lenta de aprendizaje, ya que de esta manera el agente puede converger a una solución explorando todo el espectro. Si fuese un valor muy alto, el agente podría encontrar una solución sub-óptima y no la global entendiendo que el rango de acciones es limitado [40].
- *Discount Factor*: Este factor indica si el agente deberá valorar más las recompensas inmediatas si es cercano a 0 o las futuras si es cercano a 1. En este caso, se escoge 0,97 para que el agente pueda ir mejorando sus decisiones con el paso de cada episodio de simulación lo que le permite alcanzar, por lo menos un máximo local dentro del universo de recompensas disponible [41].
- *Experience Buffer Length*: Corresponde al tamaño de la memoria en donde se almacena la experiencia del agente (estados, acciones, recompensas y estados siguientes). Se escoge  $1e6$ , ya que es un valor razonable al número de experiencias a las que se someterá el agente. Este valor va de la mano con el *Mini Batch Size* y a medida que se va llenando, se van eliminando las experiencias más antiguas [42].
- *Mini Batch Size*: Es el tamaño de los bloques de experiencia que adquiere el agente. En este caso se escoge 128 lo que quiere decir que cada 128 experiencias tomadas del *buffer*, el agente se actualiza. Se selecciona este valor para que el agente saque provecho de las experiencias, actualizándose sin consumir en exceso memoria del equipo utilizado para simular [40]. En general, se utilizan potencias de 2 para la elección del

*Mini Batch Size*, puesto que está relacionado directamente con la memoria requerida por el agente, por tanto, otras elecciones típicas pueden ser 32 o 64, por ejemplo.

- *Epsilon*: Es un valor que va de 0 a 1 que indica la aleatoriedad de las acciones que tomará el agente. Se escoge el valor 0,5 lo cual significa que el agente explorará con el 50 % de las acciones, cuyo comportamiento será aleatorio, mientras que el otro 50 % será dictado por la política interna del agente[43].
- *Epsilon Decay*: Es el ratio con que va decayendo el valor de Epsilon. Es importante que este valor decaiga porque podría ocasionar inestabilidad en el aprendizaje del agente RL. Sin embargo, el decaimiento tampoco debe ser rápido, ya que podría afectar negativamente a la exploración, por ello, se selecciona el valor  $2e-3$ [40] [43] lo cual implica que el valor *Epsilon* decaerá a un ritmo de  $2e-3$  por cada episodio de entrenamiento.

### 6.3.3. Entorno

El entorno en el que opera el agente RL incluye tanto el cálculo de la cantidad de baterías necesarias como la potencia demandada en el ciclo de conducción, además de la simulación completa del sistema.

### 6.3.4. Recompensas

Las recompensas se definen como proporcionales, ya que de esta manera se puede suavizar el espectro de soluciones y el agente tiene una mayor flexibilidad a la hora de escoger un valor de pila de combustible. En este caso se definen como:

$$Recompensa = \epsilon_1 \cdot \frac{P_{total} - P_{mx}}{P_{mx}} + \epsilon_2 \cdot \frac{M_{max} - M_{total}}{M_{max}} + \epsilon_3 \cdot \frac{V_{disponible} - V_{total}}{V_{disponible}} - \epsilon_4 P_{FC}$$

Donde  $\epsilon_1 = \epsilon_2 = \epsilon_3 = 1$  para que las recompensas respecto a las restricciones sean homogéneas y  $\epsilon_4 = 0,25$  para dar prioridad a la minimización de la pila de combustible. Además, se le asigna una recompensa de -2,5 si el SOC mínimo es menor a 0,1 y -1,5 si el SOC final es distinto a 0,8 para penalizar las elecciones que no cumplan con la simulación.

# Capítulo 7

## Resultados y análisis

Los resultados se someten a tres casos distintos, según el ciclo de conducción utilizado durante la optimización. El primer caso se basa exclusivamente en el ciclo WLTP combinado. El segundo caso incorpora varios tramos del ciclo New York City Cycle (NYCC), ubicados de manera aleatoria a lo largo del día, ya que este ciclo simula trayectos urbanos de baja velocidad [44]. Finalmente, el tercer caso utiliza 4 ciclos seleccionados aleatoriamente, resultando en un ciclo diario compuesto por 6 tramos en total.

Los tres casos fueron evaluados utilizando dos enfoques: un algoritmo secuencial y un agente de aprendizaje por refuerzo (RL). El algoritmo secuencial seleccionó una pila de combustible de 5[kW] para los Casos 1 y 2, mientras que aumentó la potencia a 20[kW] en el Caso 3 para satisfacer las mayores demandas de energía. En contraste, el agente RL optó consistentemente por la pila de combustible de 20[kW] para los tres casos, priorizando configuraciones que maximizaban la recompensa acumulada, reflejando una preferencia por soluciones más robustas.

### 7.1. Resultados para la solución de 5[kW]

La pila de combustible seleccionada para esta solución corresponde a la empresa Horizon Fuel Cell Technologies, con un costo de 20.100 \$USD. Esta configuración incorpora 582 baterías adicionales, lo que resulta en una reducción de masa  $\Delta M =$  de -305,53[kg], un cambio de volumen  $= \Delta V$  de -442,16[L] y un ahorro económico de  $\Delta \$USD = -70.376,15$  USD.

Aunque esta opción no fue preferida por el agente de aprendizaje por refuerzo (RL), demostró ser capaz de satisfacer las demandas de los casos 1 y 2 sin inconvenientes. Sin embargo, en el caso 3, las exigencias del ciclo de conducción llevaron al SOC a disminuir por debajo del 10 %.

#### 7.1.1. Desempeño en el Caso 1

En el Caso 1, el ciclo de conducción WLTP combinado presentó una demanda energética significativa, como se observa en la Figura 7.1. La pila de combustible operó de forma continua a lo largo del trayecto, con un consumo de  $\approx 1$ [kg] de hidrógeno para completar el recorrido. Sin embargo, el vehículo debe detenerse luego del recorrido para evitar que el

SOC caiga del 10 % y recargarse por medio de la pila. El tiempo estimado para la recarga fue de aproximadamente 46 minutos.




**Figura 7.1.** El gráfico muestra la evolución de las potencias durante la sección de ida en el caso 1, la cual se repite para el tramo de regreso.

### 7.1.2. Desempeño en el Caso 2




**Figura 7.2.** Evolución de las potencias a lo largo del ciclo diario en el caso 2.

Como se mencionó anteriormente, el Caso 2 consistió en tres repeticiones del New York City Cycle (NYCC), lo que afectó la autonomía del sistema. El vehículo recorrió 52,23[km] en total, con un consumo de hidrógeno de 1,18[kg]. A partir del gráfico de potencias en la Figura 7.2, se obtiene que el sistema rinde 2,25[kg] de hidrógeno por cada 100[km], lo que equivale a una autonomía de 248[km].

El ciclo NYCC es menos exigente en términos de potencia, lo que permite una recarga más rápida de la batería. Sin embargo, el consumo de hidrógeno sigue siendo significativo, considerando que la velocidad máxima del ciclo no supera los 45[km/h] (Figura 7.3).




**Figura 7.3.** Ciclo de conducción NYCC el cual es repetido 3 veces a lo largo del día.

### 7.1.3. Homologación

Para evaluar el desempeño del sistema optimizado en relación con un vehículo comercial, se realizó una homologación del ciclo de conducción considerando únicamente un conductor y la masa en vacío (*Kerb Weight*). El Toyota Mirai presenta un consumo de hidrógeno entre 0,79[kg]/100[km] y 0,89[kg]/100[km] [22].

A partir del gráfico de energía (Figura 7.4), el sistema optimizado consumió 0,43[kg] de hidrógeno en 23,25[km], equivalente a 1,85[kg]/100[km]. Este valor es considerablemente superior al del Toyota Mirai, lo que se explica por la eficiencia del 40 % utilizada en el sistema optimizado. Esto se valida mediante los siguientes cálculos energéticos:

$$E_{WLTP_{original_1}} = \frac{0,89[kg]}{100[km]} \cdot 23,25[km] \cdot 33 \frac{[kWh]}{[kg]} = 6,9[kWh]$$

$$E_{WLTP_{original_2}} = \frac{0,79[kg]}{100[km]} \cdot 23,25[km] \cdot 33 \frac{[kWh]}{[kg]} = 6,5[kWh]$$

$$E_{WLTP_{obtenido}} = \frac{1,85[kg]}{100[km]} \cdot 23,25[km] \cdot 33 \frac{[kWh]}{[kg]} \cdot 0,4 = 5,8[kWh]$$




**Figura 7.4.** *Energía acumulada homologada para el caso 1.*

Estos resultados indican una autonomía homologada de 297[km] para el tren de propulsión optimizado, en comparación con los 629[km] del Toyota Mirai. Sin embargo, el sistema optimizado puede operar durante 5 días y medio sin necesidad de recargar con hidrógeno.

#### 7.1.4. Resumen de la solución

En la Tabla 7.1, se resumen los resultados clave de la solución de 5[kW].

Tabla 7.1

RESULTADOS GENERALES PARA LA SOLUCIÓN DE 5[kW]

| Parámetro                           | Valor                  |
|-------------------------------------|------------------------|
| Potencia de la FC seleccionada [kW] | 5                      |
| N° total de baterías                | 582                    |
| N° de baterías en serie             | 97                     |
| N° de paralelos                     | 6                      |
| Energía total de las baterías [kWh] | 5,6                    |
| $\Delta M$ [kg]                     | -305,53                |
| $\Delta V$ [L]                      | -442,16                |
| Autonomía en H2 [kg]                | 0,43                   |
| Autonomía [km]                      | 296                    |
| $\Delta \$USD$                      | -70.376,15 USD         |
| Marca                               | Horizon Fuel Cell Shop |

## 7.2. Resultados para la solución de 20[kW]

Debido a las exigencias del Caso 3, la última solución fue una pila de combustible de 20[kW] perteneciente a la empresa Zhusuan (Wuxi) Technology Company con un costo de 11.880 \$USD. Adicionalmente, se añaden 388 baterías adicionales, por tanto, se obtuvo un  $\Delta M = -287[\text{kg}]$ ,  $\Delta V = -436 [\text{L}]$  y un ahorro de  $\Delta \$\text{USD} = -80.536,15\$$ USD.

Estos resultados de masa y volumen pueden dar a entender de que podría ser válida la instalación de más cilindros para un mayor almacenamiento. Sin embargo, si consideramos, por ejemplo, modelos similares a los que posee el Toyota Mirai como los que ofrece Anhui Clean Energy Co. Ltd [45] los cuales poseen un volumen de 118[L], una masa de 39[kg] y mantienen el hidrógeno a 700 [bar], podrían ocupar el espacio como se muestra en la Figura 7.5 a continuación:




**Figura 7.5.** Vista superior aproximada del Toyota Mirai con la FC optimizada más dos tanques adicionales a la izquierda y con la FC original del Mirai a la derecha. *Elaboración propia*

No obstante, se desconoce la geometría interna del vehículo y la Figura 7.5 no considera la posición de las baterías. Además, es posible que se añada un riesgo al colocar los tanques tan cerca de la transmisión delantera más la FC debido a las vibraciones y la generación de calor.

Cabe destacar que, debido al amplio salto en potencia de la solución, se verificó la solución ideal dentro del algoritmo secuencial la cual fue de 7,2[kg] y que es evaluada posteriormente en esta sección.

### 7.2.1. Desempeño en el Caso 3




**Figura 7.6.** *Evolución de las potencias para el Caso 3.*

La Figura 7.6 muestra la evolución de las potencias durante el Caso 3, en el cual el sistema optimizado enfrentó ciclos de conducción de alta exigencia, como el FTP 72 y FTP 75. Estos ciclos, que alcanzan velocidades máximas de hasta 91,25[km/h], representan trayectorias urbanas con alta variabilidad en la aceleración y frenado [46] [47]. Además, el sistema fue evaluado con el ciclo HWFET, diseñado para medir el desempeño en condiciones de carretera [48].

A pesar de su obsolescencia como estándar, el ciclo NEDC se incluyó en este caso para introducir mayor diversidad en el perfil de conducción. La combinación de estos ciclos permite evaluar la capacidad del sistema para operar en escenarios mixtos y exigentes. Los detalles de cada ciclo se presentan en las Figuras 7.7, 7.8, 7.10 y 7.10.




**Figura 7.7.** *Federal Test Procedure(FTP)-72.*




**Figura 7.8.** *Federal Test Procedure(FTP)-75.*




**Figura 7.9.** *Highway Fuel Economy Test (HWFET).*




**Figura 7.10.** *New European Driving Cycle (NEDC)[49].*

La pila no actúa de manera continua como en los casos anteriores, ya que respeta (mediante el control) que el SOC no supere el 80 % como muestra la Figura 7.11, entonces, deja de inyectar potencia en ese transcurso de tiempo. Esto puede afectar a la degradación de la pila de combustible al largo plazo debido a los ciclos térmicos al encendido y apagado [50].

A pesar de que el ciclo diario es más exigente el SOC no bajó del 62 % lo cual permite que el vehículo siga operativo para algún recorrido posterior como el NYCC o los FTP que, como muestra la Figura 7.11, no tienen tanto impacto como si lo es el WLTP combinado. En esta configuración, el HWFET no reduce el SOC por debajo del 77 %.




**Figura 7.11.** *Evolución del SOC para el caso 3.*

### 7.2.2. Homologación y pruebas adicionales

La homologación de la autonomía para este caso, en comparación con el Toyota Mirai, resultó en un alcance de 286,3 [km], con un consumo de 0,45 [kg] de hidrógeno por recorrido del ciclo WLTP combinado.

Dado el desempeño observado en el Caso 3, caracterizado por la potencia de la pila de combustible y la rapidez con la que el vehículo puede estar nuevamente disponible, se realizaron dos pruebas adicionales para evaluar las capacidades de esta configuración de tren de propulsión: una prueba a velocidad constante y otra en condiciones de pendiente. Estas pruebas permiten analizar el comportamiento del sistema en escenarios específicos que representan desafíos comunes en la operación diaria.

#### 7.2.2.a. Sometimiento a un ciclo de velocidad constante

La solución se somete a un ciclo de velocidad constante de 100[km/h] durante el máximo tiempo posible antes de que el SOC caiga bajo el 10 %. Se obtuvo que este tiempo corresponde a 105 minutos. A continuación se presentan los gráficos del ciclo y de potencia:




**Figura 7.12.** *Ciclo de conducción a velocidad constante.*




**Figura 7.13.** *Evolución de las potencias para el caso 3 en velocidad constante.*

A partir del gráfico de potencias de la Figura 7.13, se calcula que el vehículo alcanza una autonomía de 338,5 [km] utilizando todo el hidrógeno disponible más 0,1 kg para terminar de recargar la batería para un recorrido de 345,22 [km]. El vehículo requiere una recarga de aproximadamente 10 minutos para restablecer el SOC y la potencia máxima requerida por el ciclo es de 36,4[kW].

#### 7.2.2.b. Prueba de ciclo de velocidad constante con pendiente.

Ahora el ciclo es reducido de manera que el vehículo sólo recorra 6[km] a 50[km/h]. De este modo se busca la pendiente máxima que el vehículo puede soportar sin que el SOC caiga bajo el umbral del 10 %.




**Figura 7.14.** *Ciclo de conducción a velocidad constante con una pendiente.*




**Figura 7.15.** *Evolución de las potencias en una pendiente a 50[km/h].*

A partir del SOC y la potencia mostrados en la Figura 7.15, se determinó que la pendiente máxima alcanzada fue de  $17^\circ$ , con una potencia máxima de 87[kW]. En esta condición, las baterías experimentaron una tasa de descarga de 13,7 veces su corriente nominal. Aunque este nivel de descarga es soportable gracias a sus características de diseño, podría tener un impacto adverso en la vida útil de las baterías a largo plazo.

### 7.2.3. Solución ideal

El caso ideal del Caso 3 corresponde a una pila de 7,2[kW] con 582 baterías adicionales, cuya autonomía homologada es de 294[km] y un SOC mínimo del 43 %.

En la prueba de velocidad constante, se determinó que el vehículo puede operar durante 19 minutos y estar un periodo de 36 minutos para su recarga completa. Por otro lado, en la prueba con pendiente, el sistema alcanzó un ángulo máximo de  $18^\circ$ , requiriendo una potencia de 92,2[kW]. Esto fue posible gracias al mayor número de baterías, aunque se observó una tasa de descarga equivalente a 12,34 veces la corriente nominal, lo que refleja

el esfuerzo adicional del sistema en dichas condiciones.

En general, la principal desventaja con su contraparte de 20[kW] es que necesita recargarse por períodos más largos, sin embargo, puede alcanzar hasta 7[kW] más de potencia en forma continua.

#### 7.2.4. Resumen de la solución

En la Tabla 7.2, se resumen los resultados clave de la solución de 20[kW].

Tabla 7.2  
RESULTADOS GENERALES CASO 3

| Caso                                | 3                            |
|-------------------------------------|------------------------------|
| Mín Potencia de la FC [kW]          | 7,2                          |
| Potencia de la FC seleccionada [kW] | 20                           |
| N° total de baterías                | 388                          |
| N° de baterías en serie             | 97                           |
| N° de paralelos                     | 4                            |
| Energía total de las baterías [kWh] | 3,7                          |
| $\Delta M$ [kg]                     | -287,02                      |
| $\Delta V$ [L]                      | -435,87                      |
| Autonomía en H2 [kg]                | 0,45                         |
| Autonomía [km]                      | 286,3                        |
| $\Delta$ \$USD                      | -80.536,15 USD               |
| Marca                               | Zhusuan (wuxi) Technology Co |

### 7.3. Discusión sobre aspectos del uso del *Reinforcement Learning*

En cuanto al agente de aprendizaje por refuerzo (RL), en los tres casos seleccionados, optó por la pila de combustible de 20[kW] con 388 baterías. Esta elección se debe a que, en promedio, representó la mejor acción según las recompensas acumuladas a lo largo de cada episodio de entrenamiento, como se observa en las curvas de la Figura 7.16. Aunque el agente de RL contribuyó a la comparación de los resultados, ya que la pila de combustible de 20[kW] presenta un precio más bajo que la de 5[kW], no logró superar al algoritmo secuencial respecto al tiempo, puesto que este último sólo tardó 5,1 minutos de compilación.




**Figura 7.16.** Entrenamiento del agente RL para los casos de manera individual. Tiempo total de entrenamiento  $\approx 10$  minutos.

Un aspecto clave del agente RL es que debe ser entrenado con cada ciclo de conducción de manera independiente para obtener resultados más rápidos y precisos. Sin embargo, al introducir aleatoriedad en los ciclos de conducción, como se observa en la Figura 7.17, el proceso de aprendizaje se ralentiza. Esto ocurre porque el agente necesita un mayor número de iteraciones para identificar patrones consistentes que lo guíen hacia las acciones de mayor recompensa en un entorno más variable.

La curva  $Q_0$  representada en color amarillo, muestra cómo evoluciona el valor estimado de la recompensa acumulada al inicio de cada episodio de entrenamiento. Este valor refleja la capacidad del agente para predecir correctamente las recompensas futuras en función del estado inicial del sistema. En los entrenamientos realizados con ciclos independientes,  $Q_0$  tiende a estabilizarse rápidamente, indicando que el agente converge hacia una política óptima específica para ese ciclo. Sin embargo, en escenarios con ciclos aleatorios, como los de la Figura 7.17,  $Q_0$  no se estabiliza adecuadamente en el tiempo de entrenamiento evaluado, lo que sugiere que el agente tiene dificultades para generalizar entre diferentes patrones de conducción. Esto resalta la necesidad de prolongar el entrenamiento o ajustar la

función de recompensas para mejorar la capacidad de aprendizaje del agente y la precisión de las estimaciones realizadas por la red neuronal del crítico.




**Figura 7.17.** *Evolución de entrenamiento para múltiples ciclos de conducción que se gestan de forma aleatoria. Tiempo total de entrenamiento = aproximadamente 9 horas*

Es fundamental que el equipo empleado para las simulaciones cumpla con los requisitos técnicos necesarios para soportar entrenamientos prolongados, especialmente en términos de capacidad de memoria RAM y procesamiento. Herramientas como la interfaz de MATLAB *Reinforcement Learning Designer* ofrecen ventajas significativas al facilitar la gestión de hiperparámetros, la configuración de ciclos de entrenamiento y las condiciones de parada del proceso. No obstante, su uso puede ser contraproducente en sistemas con recursos limitados, ya que tienden a incrementar considerablemente el consumo computacional.

Si bien el agente RL presenta desventajas en términos de consumo computacional y tiempo de entrenamiento en comparación con el algoritmo secuencial, ofrece la ventaja de ser relativamente sencillo de implementar. Su flexibilidad para adaptarse a diferentes escenarios sin intervención manual lo convierte en una herramienta prometedora para problemas de optimización complejos. Sin embargo, la principal dificultad al trabajar con un agente RL radica en la definición precisa de las recompensas. Estas deben diseñarse de manera que reflejen adecuadamente los objetivos del sistema, evitando que ciclos de conducción específicos interfieran entre sí en diferentes etapas del entrenamiento. En este estudio, se demostró que la correcta estructuración de las recompensas permite al agente identificar configuraciones de *FC* y batería que mantienen un equilibrio entre autonomía y estabilidad del SOC, incluso en escenarios de alta variabilidad.

Adicionalmente, se observó que introducir aleatoriedad en los ciclos de conducción aumenta la dificultad del entrenamiento, ya que el agente requiere más tiempo para aprender patrones óptimos y generalizar adecuadamente. Esto subraya la importancia de establecer un entorno de simulación que sea consistente pero lo suficientemente variado para reflejar

condiciones realistas. Finalmente, aunque el algoritmo secuencial mostró ser más eficiente en términos de tiempo, el uso de RL abre la puerta a optimizaciones más avanzadas en problemas no lineales y con múltiples variables discretas, como los presentados en configuraciones híbridas de trenes de propulsión.

# Capítulo 8

## Conclusiones.

En este trabajo se diseñó y optimizó un tren de propulsión híbrido  $FC + BAT$ , enfocado en minimizar la potencia de la pila de combustible ( $FC$ ) y complementar su desempeño con baterías que gestionen las demandas dinámicas de potencia. A través de simulaciones con diferentes ciclos de conducción y el uso de algoritmos de optimización, se lograron configuraciones eficientes y adaptables para diversas condiciones operativas, cumpliendo con los objetivos planteados.

Entre los resultados obtenidos, la configuración con una  $FC$  de 20[kW] y 388 baterías destacó por su efectividad en ciclos exigentes como los definidos por los estándares FTP y WLTP. Esta solución logró un equilibrio adecuado entre autonomía y nivel del SOC, manteniéndose por encima del 62% incluso bajo condiciones de alta demanda, con una autonomía estimada de 286,3[km] en el escenario más desafiante. Además, se obtuvo una reducción considerable de los costos con un  $\Delta = -80.536,15$  \$USD y una disminución significativa en la masa y el volumen del sistema, abriendo posibilidades para añadir más baterías o cilindros de hidrógeno según las necesidades del diseño.

La incorporación de ciclos de conducción aleatorios y la combinación de ciclos estandarizados permitió evaluar la robustez del sistema en escenarios realistas. Este enfoque resaltó la importancia de diseñar trenes de propulsión capaces de mantener su desempeño bajo variaciones en el estilo de conducción y las condiciones operativas, aspectos particularmente relevantes en aplicaciones urbanas.

Desde un punto de vista económico, reducir la potencia de la  $FC$  permitió disminuir costos iniciales, haciendo esta tecnología más accesible. Sin embargo, se identificó la necesidad de considerar costos a largo plazo relacionados con la degradación de las baterías y el mantenimiento de la  $FC$ , lo que podría influir en la sostenibilidad del sistema.

Las metodologías utilizadas, que incluyen algoritmos secuenciales y aprendizaje por refuerzo (*Reinforcement Learning*), demostraron ser herramientas valiosas para optimizar configuraciones complejas. Aunque el algoritmo secuencial mostró mayor rapidez, el *RL* destacó por su flexibilidad y capacidad para adaptarse a escenarios más complejos, posicionándose como una metodología prometedora para aplicaciones futuras en optimización.

Con base en todo lo anterior, se propone que, para el diseño de un vehículo híbrido con una potencia mínima de pila de combustible, se seleccione una  $FC$  que permita al pack de baterías estar disponible rápidamente después de un recorrido, asegurando la capacidad del sistema para responder a las demandas dinámicas de energía. En este contexto, el ciclo

WLTP es ampliamente utilizado como estándar para evaluar el desempeño de vehículos en condiciones controladas. Sin embargo, puede resultar insuficiente si no se considera la incertidumbre inherente al uso práctico del vehículo, como variaciones en el estilo de conducción, por ejemplo. Esto resalta la importancia de una visión integral de la autonomía del vehículo, en la que no solo influye el ciclo de conducción empleado, sino también la eficiencia de los componentes del tren de propulsión, que desempeñan un papel crucial en la determinación de la autonomía real.

# Bibliografía

- [1] U.S. Department of Transportation. *EV Toolkit: Charging Speeds*. 2024. URL: <https://www.transportation.gov/rural/ev/toolkit/ev-basics/charging-speeds>.
- [2] Shuai Ma et al. "Temperature effect and thermal impact in lithium-ion batteries: A review". En: *Progress in Natural Science: Materials International* 28.6 (2018), págs. 653-666. ISSN: 1002-0071. DOI: <https://doi.org/10.1016/j.pnsc.2018.11.002>. URL: <https://www.sciencedirect.com/science/article/pii/S1002007118307536>.
- [3] Toyota Motor Corporation. "2024 Toyota Mirai - MPG, Other Features, Price". En: *Toyota* (2024). URL: [https://www.toyota.com/mirai/2024/features/mpg\\_other\\_price/3002/3003](https://www.toyota.com/mirai/2024/features/mpg_other_price/3002/3003).
- [4] Jamila Snoussi et al. "Optimal Sizing of Energy Storage Systems Using Frequency-Separation-Based Energy Management for Fuel Cell Hybrid Electric Vehicles". En: *IEEE Transactions on Vehicular Technology* 67.10 (2018), págs. 9337-9346. DOI: 10.1109/TVT.2018.2863185.
- [5] Lei Zhang et al. "Multiobjective Optimal Sizing of Hybrid Energy Storage System for Electric Vehicles". En: *IEEE Transactions on Vehicular Technology* 67.2 (2018), págs. 1027-1035. DOI: 10.1109/TVT.2017.2762368.
- [6] M. Khamesipour et al. "Component sizing of a series hybrid electric vehicle through artificial neural network". En: *Energy Conversion and Management* 254 (2022), pág. 115300. ISSN: 0196-8904. DOI: <https://doi.org/10.1016/j.enconman.2022.115300>. URL: <https://www.sciencedirect.com/science/article/pii/S0196890422000966>.
- [7] Jamila Snoussi et al. "Optimal Sizing of Energy Storage Systems Using Frequency-Separation-Based Energy Management for Fuel Cell Hybrid Electric Vehicles". En: *IEEE Transactions on Vehicular Technology* 67.10 (2018), págs. 9337-9346. DOI: 10.1109/TVT.2018.2863185.
- [8] Zhenpo Wang et al. "Optimal Component Sizing of a Four-Wheel Independently-Actuated Electric Vehicle With a Real-Time Torque Distribution Strategy". En: *IEEE Access* 6 (2018), págs. 49523-49536. DOI: 10.1109/ACCESS.2018.2801564.
- [9] Mehrdad Ehsani et al. "State of the Art and Trends in Electric and Hybrid Electric Vehicles". En: *Proceedings of the IEEE* 109.6 (2021), págs. 967-984. DOI: 10.1109/JPROC.2021.3072788.
- [10] Emilio Morón. *Pilas de combustible de hidrógeno: limitaciones y una posible solución*. 2022. URL: <https://hive.blog/hive-196387/@emiliomoron/pilas-de-combustible-de-hidrogeno-limitaciones-y-una-posible-solucion>.

- [11] Olivier Bethoux. “Hydrogen Fuel Cell Road Vehicles: State of the Art and Perspectives”. En: *Energies* 13.21 (2020), pág. 5843.
- [12] IEA Fuel Cell Group. *Storage and Refueling of Hydrogen in Fuel Cell Vehicles*. 2024. URL: <https://www.ieafuelcell.com/index.php?id=33#:~:text=It%20typically%20requires%20high%2Dpressure,%2D700%20bar%20tank%20pressure>.
- [13] Samuel Pelletier et al. “Battery degradation and behaviour for electric vehicles: Review and numerical analyses of several models”. En: *Transportation Research Part B: Methodological* 103 (2017). Green Urban Transportation, págs. 158-187. ISSN: 0191-2615. DOI: <https://doi.org/10.1016/j.trb.2017.01.020>. URL: <https://www.sciencedirect.com/science/article/pii/S0191261516303794>.
- [14] Wang Q. et al. “Thermal runaway mechanism of lithium ion battery for electric vehicles: a review”. En: *Progress in Energy and Combustion Science* 73 (2019), págs. 95-131.
- [15] Md Rashedul Islam et al. “Smart Electronic Textile-Based Wearable Supercapacitors”. En: *Advanced Science* 9.31 (2022), pág. 2203856. DOI: <https://doi.org/10.1002/advs.202203856>. eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1002/advs.202203856>. URL: <https://onlinelibrary.wiley.com/doi/abs/10.1002/advs.202203856>.
- [16] Poonam et al. “Review of supercapacitors: Materials and devices”. En: *Journal of Energy Storage* 21 (2019), págs. 801-825. ISSN: 2352-152X. DOI: <https://doi.org/10.1016/j.est.2019.01.010>. URL: <https://www.sciencedirect.com/science/article/pii/S2352152X18306339>.
- [17] Dai-Duong Tran et al. “Thorough state-of-the-art analysis of electric and hybrid vehicle powertrains: Topologies and integrated energy management strategies”. En: *Renewable and Sustainable Energy Reviews* 119 (2020), pág. 109596. ISSN: 1364-0321. DOI: <https://doi.org/10.1016/j.rser.2019.109596>. URL: <https://www.sciencedirect.com/science/article/pii/S1364032119308044>.
- [18] Ceyda Kök y Suha O. Mert. “Energetic and Exergetic Performance Investigation of Different Topologies for Hybrid Fuel Cell Vehicles”. En: *International Journal of Energy Research* 2023.1 (2023), pág. 7165382. DOI: <https://doi.org/10.1155/2023/7165382>. eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1155/2023/7165382>. URL: <https://onlinelibrary.wiley.com/doi/abs/10.1155/2023/7165382>.
- [19] Hyundai Motor America. “Hyundai Nexo - Compare Specs”. En: *Hyundai USA* (2024). URL: <https://www.hyundaiusa.com/us/en/vehicles/nexo/compare-specs>.
- [20] ISeeCars. “Honda Clarity Fuel Cell - Specs”. En: *ISeeCars* (2024). URL: <https://www.iseecars.com/car/honda-clarity-fuel-cell-specs>.
- [21] Honda Motor Co. “2021 Clarity Fuel Cell - Specifications and Features”. En: *Honda News* (2021). URL: <https://hondanews.com/en-US/honda-automobiles/releases/release-4f88c507e72a4e7630685979cb04f2cb-2021-clarity-fuel-cell-specifications-features>.
- [22] km77.com. *Toyota Mirai (2021) - Información técnica*. <https://www.km77.com/coches/toyota/mirai/2021/estandar/informacion/toyota-mirai-2021-informacion-tecnica>. 2021.

- [23] Rutas Motor. “Toyota estrena en Chile la primera planta a hidrógeno”. En: *Rutas Motor* (2023). URL: <https://www.rutamotor.com/toyota-estrena-en-chile-la-primera-planta-a-hidrogeno/>.
- [24] Autocosmos Noticias. “Ministerio de Transportes homologa el primer auto a hidrógeno de Chile”. En: *Rutas Motor* (2022). URL: <https://noticias.autocosmos.cl/2022/12/27/ministerio-de-transportes-homologa-el-primer-auto-a-hidrogeno-de-chile>.
- [25] Toyota Motor Corporation. *Toyota Mirai FCV Posters*. 2020. URL: [https://www.smartcircular.com/wp-content/uploads/2020/06/Toyota-Mirai-FCV-Posters\\_LR.pdf](https://www.smartcircular.com/wp-content/uploads/2020/06/Toyota-Mirai-FCV-Posters_LR.pdf).
- [26] Toyota Motor Corporation. *Toyota to Unveil All-New "Mirai" Fuel Cell Electric Vehicle*. 2024. URL: <https://global.toyota/en/newsroom/corporate/34799439.html>.
- [27] Monica Tutuianu et al. “Development of the World-wide harmonized Light duty Test Cycle (WLTC) and a possible pathway for its introduction in the European legislation”. En: *Transportation Research Part D: Transport and Environment* 40 (2015), págs. 61-75. ISSN: 1361-9209. DOI: <https://doi.org/10.1016/j.trd.2015.07.011>. URL: <https://www.sciencedirect.com/science/article/pii/S1361920915001030>.
- [28] Thomas D. Gillespie. *Fundamentals of Vehicle Dynamics*. Society of Automotive Engineers, 1999, pág. 117. ISBN: 1-56091-199-9.
- [29] Meteored. *Tiempo en Santiago de Chile*. 2024. URL: [https://www.meteored.cl/tiempo-en\\_Santiago+de+Chile-America+Sur-Chile-Region+Metropolitana+de+Santiago-SCEL-sactual-18578.html](https://www.meteored.cl/tiempo-en_Santiago+de+Chile-America+Sur-Chile-Region+Metropolitana+de+Santiago-SCEL-sactual-18578.html).
- [30] U.S. Department of Energy. *Plug-In Hybrid Electric Vehicles*. 2024. URL: <https://afdc.energy.gov/vehicles>.
- [31] Robert W. Erickson y Dragan Maksimovic. *Fundamentals of Power Electronics*. 2nd. Eficiencia típica de convertidores DC/DC en aplicaciones de alta potencia de entre 90 % y 95 %. Kluwer Academic Publishers, 2001. ISBN: 978-0-7923-7270-7.
- [32] Ziyad Salameh. “Chapter 4 - Energy Storage”. En: *Renewable Energy System Design*. Ed. por Ziyad Salameh. Boston: Academic Press, 2014, págs. 201-298. ISBN: 978-0-12-374991-8. DOI: <https://doi.org/10.1016/B978-0-12-374991-8.00004-0>. URL: <https://www.sciencedirect.com/science/article/pii/B9780123749918000040>.
- [33] Plug Power. *Fuel Cell Efficiency 101: The Key Metrics*. 2024. URL: <https://www.plugpower.com/fuel-cell-efficiency-101-the-key-metrics/#:~:text=PEM%20fuel%20cells%2C%20Plug's%20technology,35%25%20efficiency%20in%20powering%20cars>.
- [34] Power Long Battery. *26650 Battery 3000mAh*. URL: <https://www.powerlongbattery.com/26650-battery-3000mah>.
- [35] Toyota España. *Componentes del coche de hidrógeno de Toyota*. <https://www.toyota.es/world-of-toyota/articles-news-events/componentes-coche-hidrogeno-toyota>.

- [36] Lixin Fan, Zhengkai Tu y Siew Hwa Chan. “Recent development in design a state-of-art proton exchange membrane fuel cell from stack to system: Theory, integration and prospective”. En: *International Journal of Hydrogen Energy* 48.21 (2023), págs. 7828-7865. ISSN: 0360-3199. DOI: <https://doi.org/10.1016/j.ijhydene.2022.11.212>. URL: <https://www.sciencedirect.com/science/article/pii/S0360319922055306>.
- [37] Nildari Roy Chowdhury et al. “Influence of state of charge window on the degradation of Tesla lithium-ion battery cells”. En: *Journal of Energy Storage* 76 (2024), pág. 110001. DOI: 10.1016/j.est.2023.110001.
- [38] Woong Lee et al. “A Real-Time Intelligent Energy Management Strategy for Hybrid Electric Vehicles Using Reinforcement Learning”. En: *IEEE Access* 9 (2021), págs. 72759-72768. DOI: 10.1109/ACCESS.2021.3079903.
- [39] Dilith Jay. *Deep Q-Networks (DQN)*. 2021. URL: <https://dilithjay.com/blog/dqn>.
- [40] Yoshua Bengio. *Practical recommendations for gradient-based training of deep architectures*. 2012. arXiv: 1206.5533 [cs.LG]. URL: <https://arxiv.org/abs/1206.5533>.
- [41] Richard S Sutton y Andrew G Barto. *Reinforcement Learning: An Introduction*. 2nd. MIT press, 2018.
- [42] Volodymyr Mnih et al. “Human-level control through deep reinforcement learning”. En: *Nature* 518.7540 (2015), págs. 529-533.
- [43] Kai Arulkumaran et al. “Deep Reinforcement Learning: A Brief Survey”. En: *IEEE Signal Processing Magazine* 34.6 (2017), págs. 26-38. ISSN: 1053-5888. DOI: 10.1109/msp.2017.2743240. URL: <http://dx.doi.org/10.1109/MSP.2017.2743240>.
- [44] TransportPolicy.net. *EPA NYCC Cycle - US Light-Duty Standards*. 2024. URL: <https://www.transportpolicy.net/standard/us-light-duty-nycc-test/#:~:text=EPA%20NYCC%20Cycle&text=Duration%3A%20598%20seconds,%2Fh%20%3D%2044.6%20km%2Fh>.
- [45] Anhui Clean Energy Co. Ltd. *Car Compressed Hydrogen Plastic Inner Carbon Fiber Fully Wound Gas Cylinder (35Mpa)*. URL: <https://www.gascylindersupplier.com/car-compressed-hydrogen-plastic-inner-carbon-fiber-fully-wound-gas-cylinder35mpa>.
- [46] M. Mazer et al. “Comparison between the WLTC and the FTP-75 driving cycles applied to a 1.4 L light-duty vehicle running on ethanol”. En: *SAE Technical Paper* 2019-36-0144 (2020). DOI: 10.4271/2019-36-0144. URL: <https://doi.org/10.4271/2019-36-0144>.
- [47] DieselNet. *FTP75 Cycle*. 2024. URL: <https://dieselnet.com/standards/cycles/ftp75.php>.
- [48] DieselNet. *HWFET Cycle*. 2024. URL: <https://dieselnet.com/standards/cycles/hwfet.php>.
- [49] DieselNet. *ECE and EUDC Cycles*. 2024. URL: [https://dieselnet.com/standards/cycles/ece\\_eudc.php](https://dieselnet.com/standards/cycles/ece_eudc.php).

- 
- [50] Veeresh Patil et al. "Degradation mechanisms in PEM fuel cells: A brief review". En: *Materials Today: Proceedings* (2023). ISSN: 2214-7853. DOI: <https://doi.org/10.1016/j.matpr.2023.03.603>. URL: <https://www.sciencedirect.com/science/article/pii/S221478532301670X>.

# Anexo

Tabla 1: Catálogo de pilas de combustible disponibles en el mercado.

| Potencia [kW] | Masa [kg] | Volumen [L] | Precio [USD] | Modelo         | Fabricante             |
|---------------|-----------|-------------|--------------|----------------|------------------------|
| 45            | 145       | 503,0       | -            | FCmove-MD      | Ballard                |
| 70            | 247       | 904,5       | -            | FCmove-HD      | Ballard                |
| 85            | 256       | 993,8       | -            | FCveloCity-HD  | Ballard                |
| 60            | 244       | 993,8       | -            | FCveloCity-HD  | Ballard                |
| 100           | 285       | 1055,3      | -            | FCveloCity-HD  | Ballard                |
| 120           | 238       | 751,2       | -            | Fcmove-XD      | Ballard                |
| 100           | 256       | 973,9       | -            | FCmove-HD+     | Ballard                |
| 100           | 280       | 946,1       | -            | FCmove-HD+     | Ballard                |
| 0,15          | 25        | 78,12       | 2,183        | HM4H           | Brogen                 |
| 0,01          | 0,28      | 0,49        | 506          | H-12 FCS-B12   | Horizon Fuel Cell Shop |
| 0,10          | 1.29      | 2,31        | 1,643        | H-100 FCS-C100 | Horizon Fuel Cell Shop |
| 2.5           | 40,3      | 168,39      | -            | T-2500         | Horizon Fuel Cell Shop |
| 1             | 18        | 41,62       | -            | T-1000         | Horizon Fuel Cell Shop |
| 3             | 40,3      | 84,19       | -            | T-3000         | Horizon Fuel Cell Shop |
| 0,02          | 0,28      | 0,25        | 604          | H-20 FCS-B20   | Horizon Fuel Cell Shop |
| 0,03          | 0,28      | 0,28        | 981          | H-30 FCS-B30   | Horizon Fuel Cell Shop |

*Continúa en la siguiente página*

| Potencia [kW] | Masa [kg] | Volumen [L] | Precio [USD] | Modelo           | Fabricante                                  |
|---------------|-----------|-------------|--------------|------------------|---------------------------------------------|
| 0,06          | 0,90      | 0,67        | 1528         | H-60 FCS-B60     | Horizon Fuel Cell Shop                      |
| 0,20          | 2,23      | 2,03        | 2231         | H-200 FCS-C200   | Horizon Fuel Cell Shop                      |
| 0,30          | 2,79      | 2,91        | 2755         | H-300 FCS-C300   | Horizon Fuel Cell Shop                      |
| 0,50          | 2,52      | 4,29        | 3179         | H-500 FCS-C500   | Horizon Fuel Cell Shop                      |
| 0,50          | 3,90      | 4,32        | 6023         | H-500XP          | Horizon Fuel Cell Shop                      |
| 1,00          | 4,00      | 7,22        | 4646         | H-1000 FCS-C1000 | Horizon Fuel Cell Shop                      |
| 1,00          | 5,00      | 5,57        | 8030         | H-1000XP         | Horizon Fuel Cell Shop                      |
| 2,00          | 10,00     | 19,41       | 9228         | H-2000 FCS-C2000 | Horizon Fuel Cell Shop                      |
| 3,00          | 15,00     | 26,77       | 12434        | H-3000 FCS-C3000 | Horizon Fuel Cell Shop                      |
| 5,00          | 30,00     | 48,23       | 20100        | H-5000 FCS-C5000 | Horizon Fuel Cell Shop                      |
| 0,05          | 0,25      | 0,33        | 1210         | BCH-50W          | Jiangsu Ice-City Hydrogen Energy Technology |
| 0,1           | 0,5       | 0,67        | 1700         | BCH-100W         | Jiangsu Ice-City Hydrogen Energy Technology |
| 0,20          | 0,6       | 1,10        | 2240         | BCH-200W         | Jiangsu Ice-City Hydrogen Energy Technology |
| 2             | 100       | 10,00       | 3892         | -                | Jiangsu Ice-City Hydrogen Energy Technology |
| 0,5           | 0,63      | 0,96        | 6360         | BCH-500w         | Jiangsu Ice-City Hydrogen Energy Technology |
| 1             | 1,15      | 2,30        | 9180         | BCH-1000W        | Jiangsu Ice-City Hydrogen Energy Technology |
| 1,5           | 1,5       | 2,44        | 14130        | BCH-1500         | Jiangsu Ice-City Hydrogen Energy Technology |
| 2             | 2,3       | 9,43        | 19610        | BCH-2000         | Jiangsu Ice-City Hydrogen Energy Technology |

*Continúa en la siguiente página*

| Potencia [kW] | Masa [kg] | Volumen [L] | Precio [USD] | Modelo                                 | Fabricante       |
|---------------|-----------|-------------|--------------|----------------------------------------|------------------|
| 15,5          | 55        | 52,00       |              | HyPM HD 15                             | Laboratorio      |
| 0,30          | 1,5       | 1,47        | 335          | 300W                                   | Youon            |
| 3             | 12        | 15,00       | 2376         | 3kW                                    | Zhusuan          |
| 0,5           | 2         | 2,50        | 378          | 500W                                   | Zhusuan          |
| 1,2           | 4,8       | 6,00        | 853,2        | 1,2kW                                  | Zhusuan          |
| 2             | 8         | 10,00       | 756          | 2kW                                    | Zhusuan          |
| 20            | 80        | 100,00      | 11880        | 20kW                                   | Zhusuan          |
| 62            | 248       | 310,00      | 28638,36     | 62kW                                   | Zhusuan          |
| 80            | 320       | 400,00      | 37800        | 80kW                                   | Zhusuan          |
| 88            | 352       | 440,00      | 51840        | 88kW                                   | Zhusuan          |
| 160           | 640       | 800,00      | 74520        | 160kW                                  | Zhusuan          |
| 135           | 540       | 675,00      | 63720        | 135kW                                  | Zhusuan          |
| 80            | 160       | 380,25      | 63720        | ZS-QN80KW                              | Zhusuan          |
| 135           | 217       | 430,45      | 93798        | zs-135                                 | Zhusuan          |
| 1             | 17        | 34,04       | 2800         | H2E-1kW-AJ                             | H2E Technologies |
| 1             | 4,30      | 6,85        | 5692         | G-HFCS-1kW36V                          | Hidrogenia       |
| 2             | 7,80      | 10,455      | 10713        | G-HFCS-2kW48V                          | Hidrogenia       |
| 3             | 12        | 21,199      | 14564        | G-HFCS-3kW48V                          | Hidrogenia       |
| 5             | 15        | 23,9088     | 22632        | G-HFCS-5kW66V                          | Hidrogenia       |
| 0,1           | 0,65      | 1,09        | 1351         | G-HFCS-100W12V                         | Hidrogenia       |
| 0,2           | 1,08      | 1,79        | 1991         | G-HFCS-200W15V                         | Hidrogenia       |
| 0,6           | 3,14      | 5,26        | 3863         | G-HFCS-600W24V                         | Hidrogenia       |
| 0,3           | 1,70      | 1,41        | 6871         | 300W Liquid Cooled PEM Fuel Cell Stack | Hidrogenia       |
| 0,2           | 1,6       | 0,942       | 6486         | 200W Liquid Cooled PEM Fuel Cell Stack | Hidrogenia       |
| 0,1           | 1,5       | 0,47        | 5808         | 100W Liquid Cooled PEM Fuel Cell Stack | Hidrogenia       |