

Diseño y evaluación de un sistema de gestión y control energético para un vehículo híbrido

PROBLEMA

Los Fuel Cell Plug-in Hybrid Electric Vehicles cuentan con un rango corto de manejo, lo que exige un elevado consumo de energía en recorridos cotidianos reduciendo la vida útil de la batería y elevando el consumo del combustible de hidrogeno.

OBJETIVO GENERAL

Gestionar la potencia de un vehículo híbrido liviano para mejorar los ciclos de vida de la batería, la eficiencia de las celdas de combustible, reducir los gastos por reabastecimiento y optimizar el desempeño del motor a distintas velocidades.

PROPUESTA

Diseñar un sistema de gestión energética en base a una Inteligencia Artificial con metodología de Aprendizaje por Reforzamiento, usando como herramienta Matlab – Simulink para modelar el tren de potencia de un vehículo tipo “Go-Kart” con baterías de litio como fuente principal, celdas de hidrógeno como secundaria y un motor/regenerador como mecanismo de recuperación.




Figura 1 – Fuel Cell Plug-in Hybrid Electric Vehicle

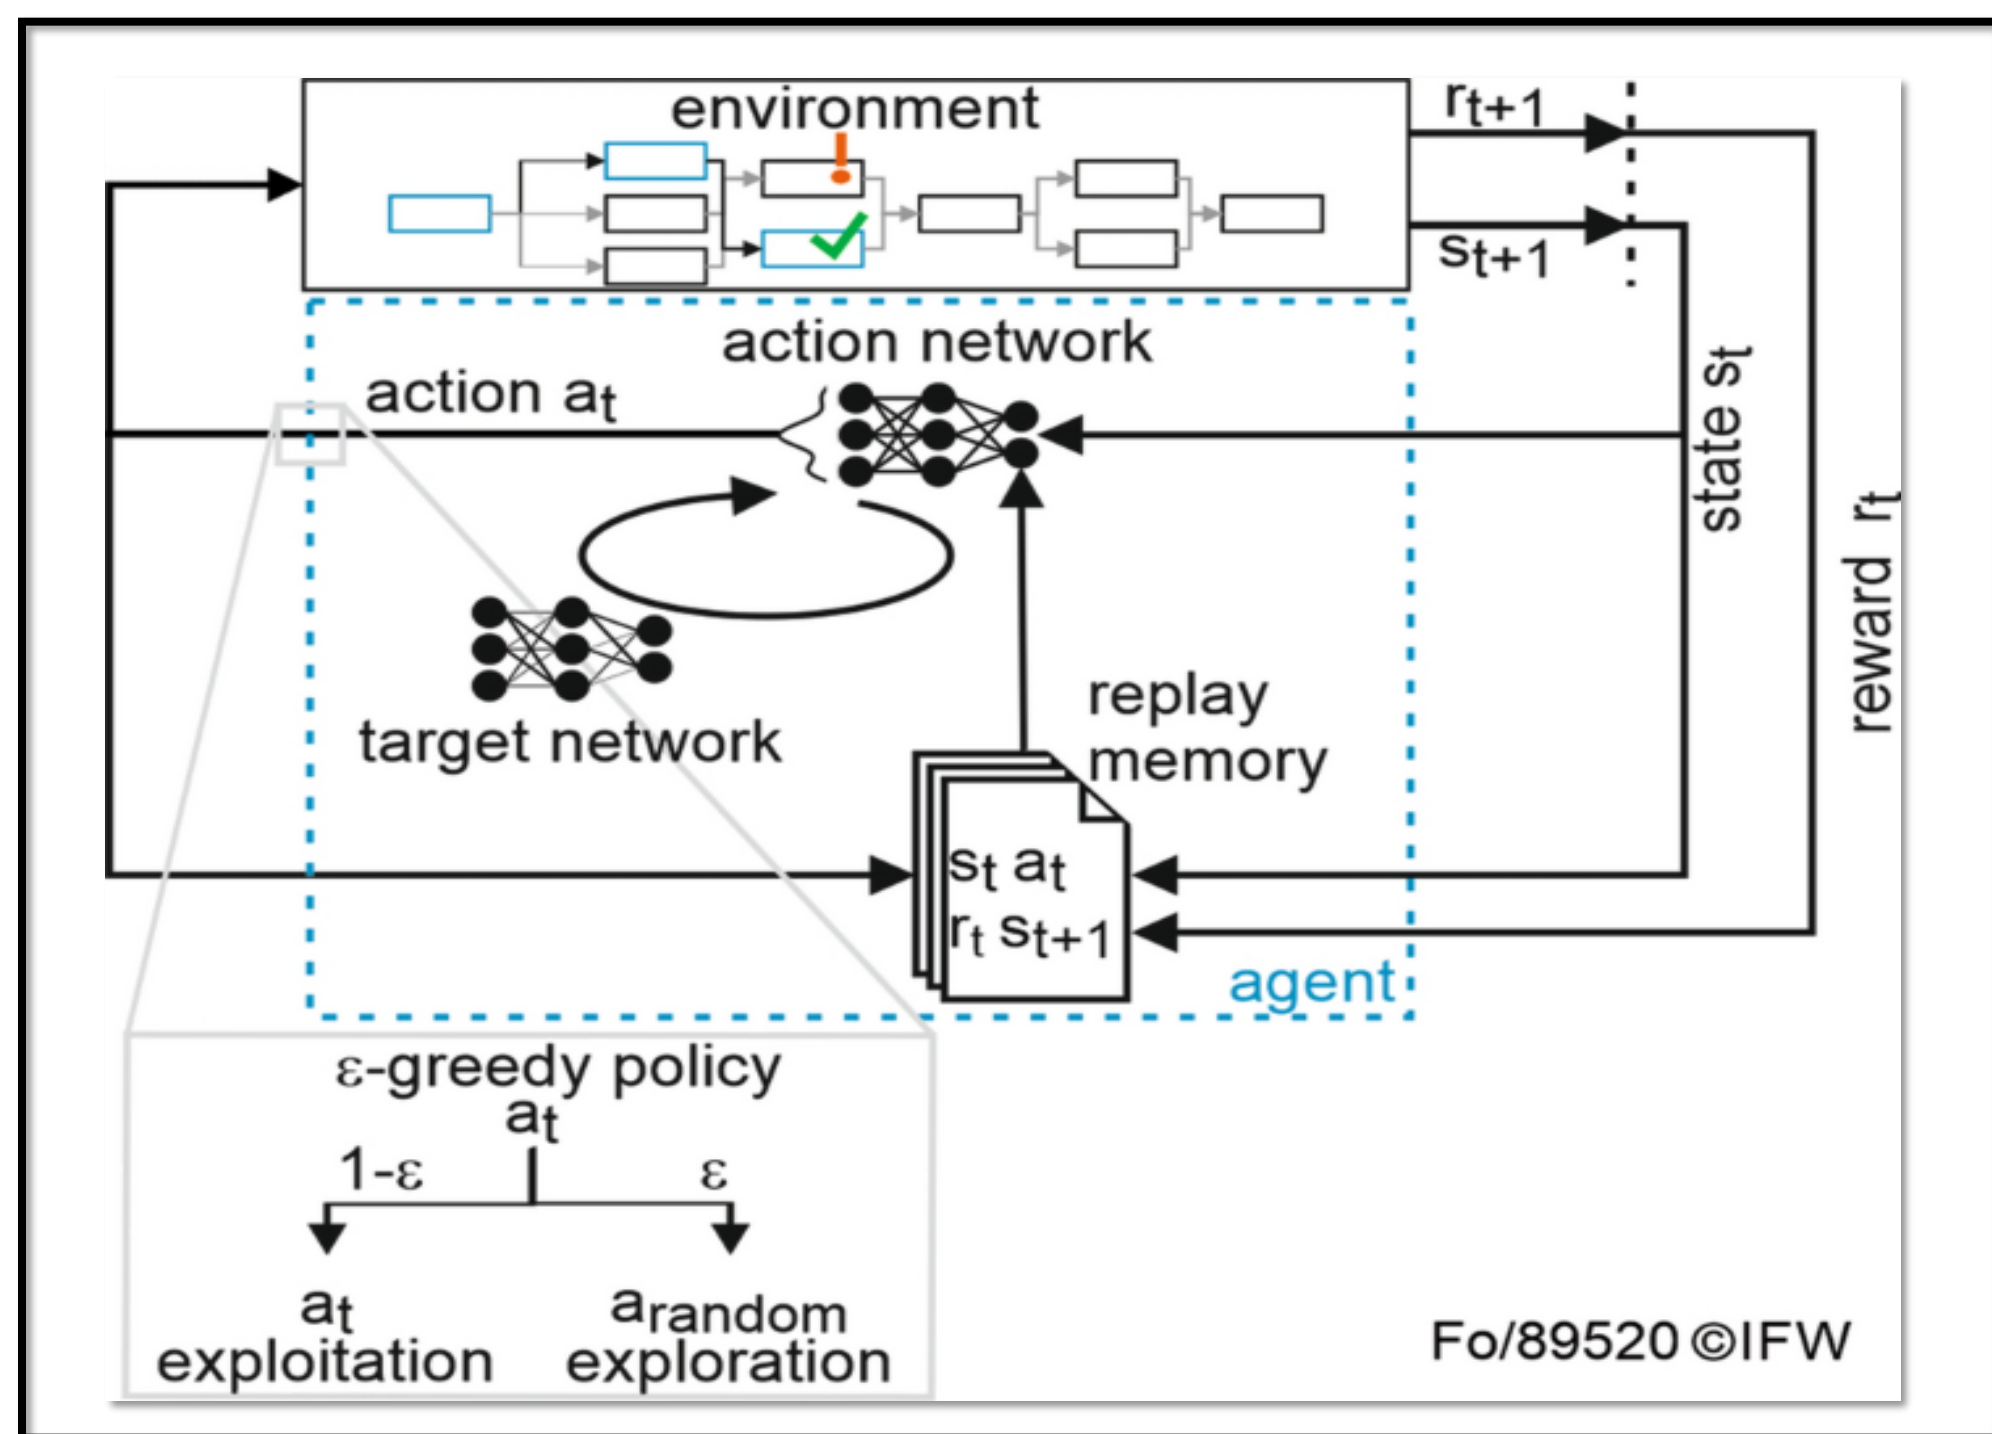


Figura 2 - Arquitectura de Aprendizaje Reforzado con Q-Learning

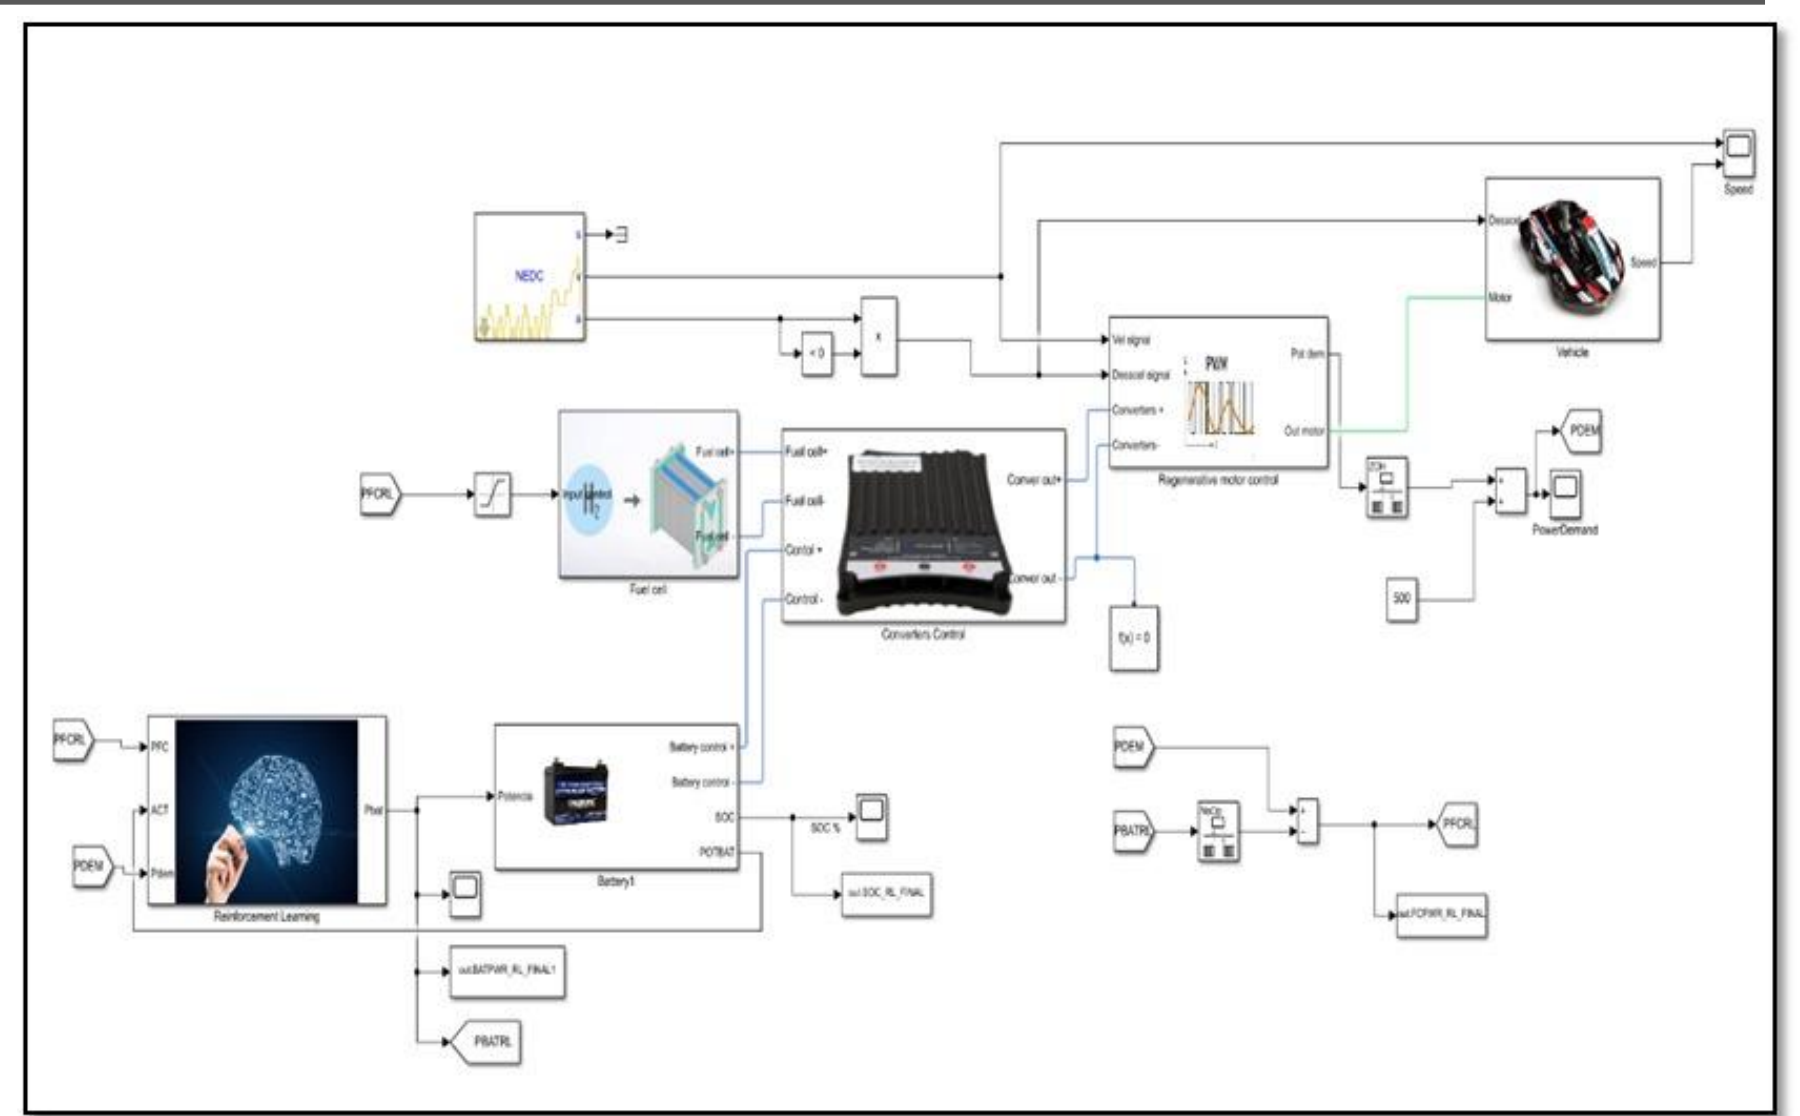


Figura 3 – Tren de potencia en paralelo del FCPHEV

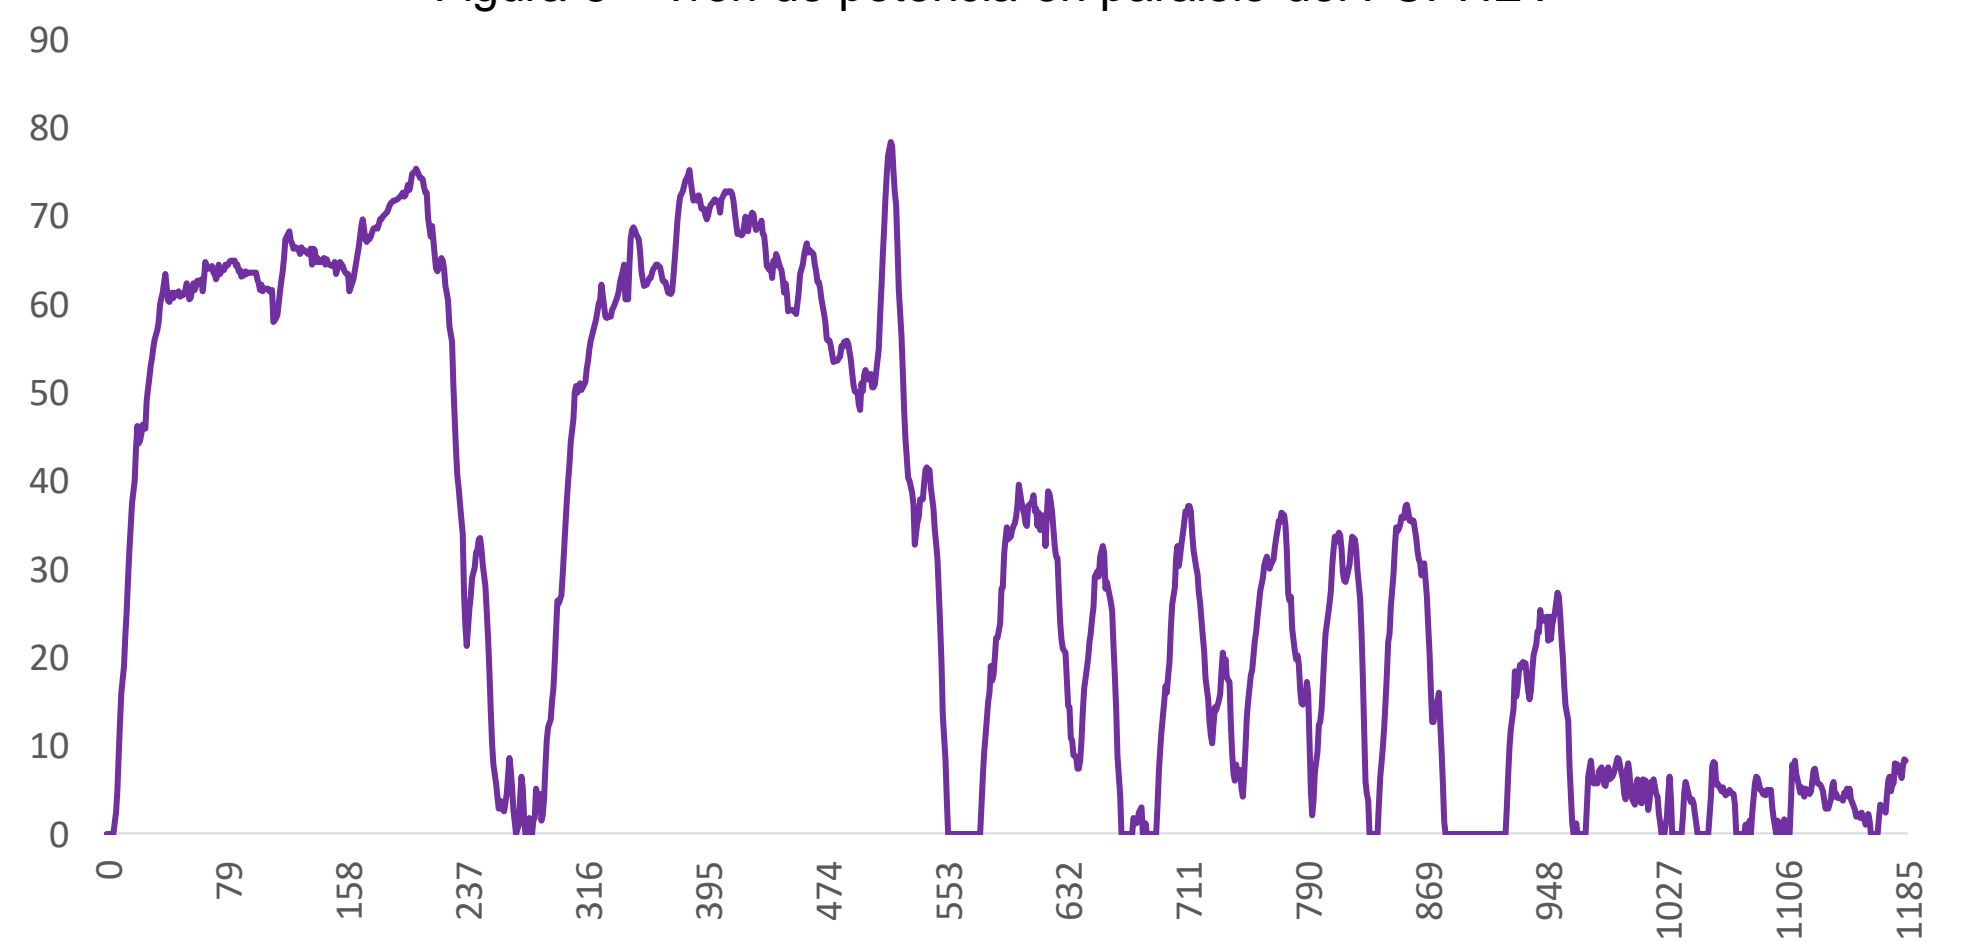


Figura 4 – Ciclo de Manejo en el Distrito Metropolitano de Quito

RESULTADOS

- Se aumentan más de 10000 km de vida útil a la batería a comparación del algoritmo Dynamic Programming.
- El estado de carga mejora en 1.6% con respecto a Dynamic Programming y 5.8% en referencia a ADVISOR.
- Se reducen los desechos de la batería en un 47% en relación a Dynamic Programming.
- Transfer Learning, al usar otro ciclo de manejo se obtuvieron beneficios muy similares.




Figura 5 – Aprendizaje con Q-Learning




Figura 6 – Estado de carga por cada Sistema




Figura 7 – Consumo de hidrógeno por cada Sistema

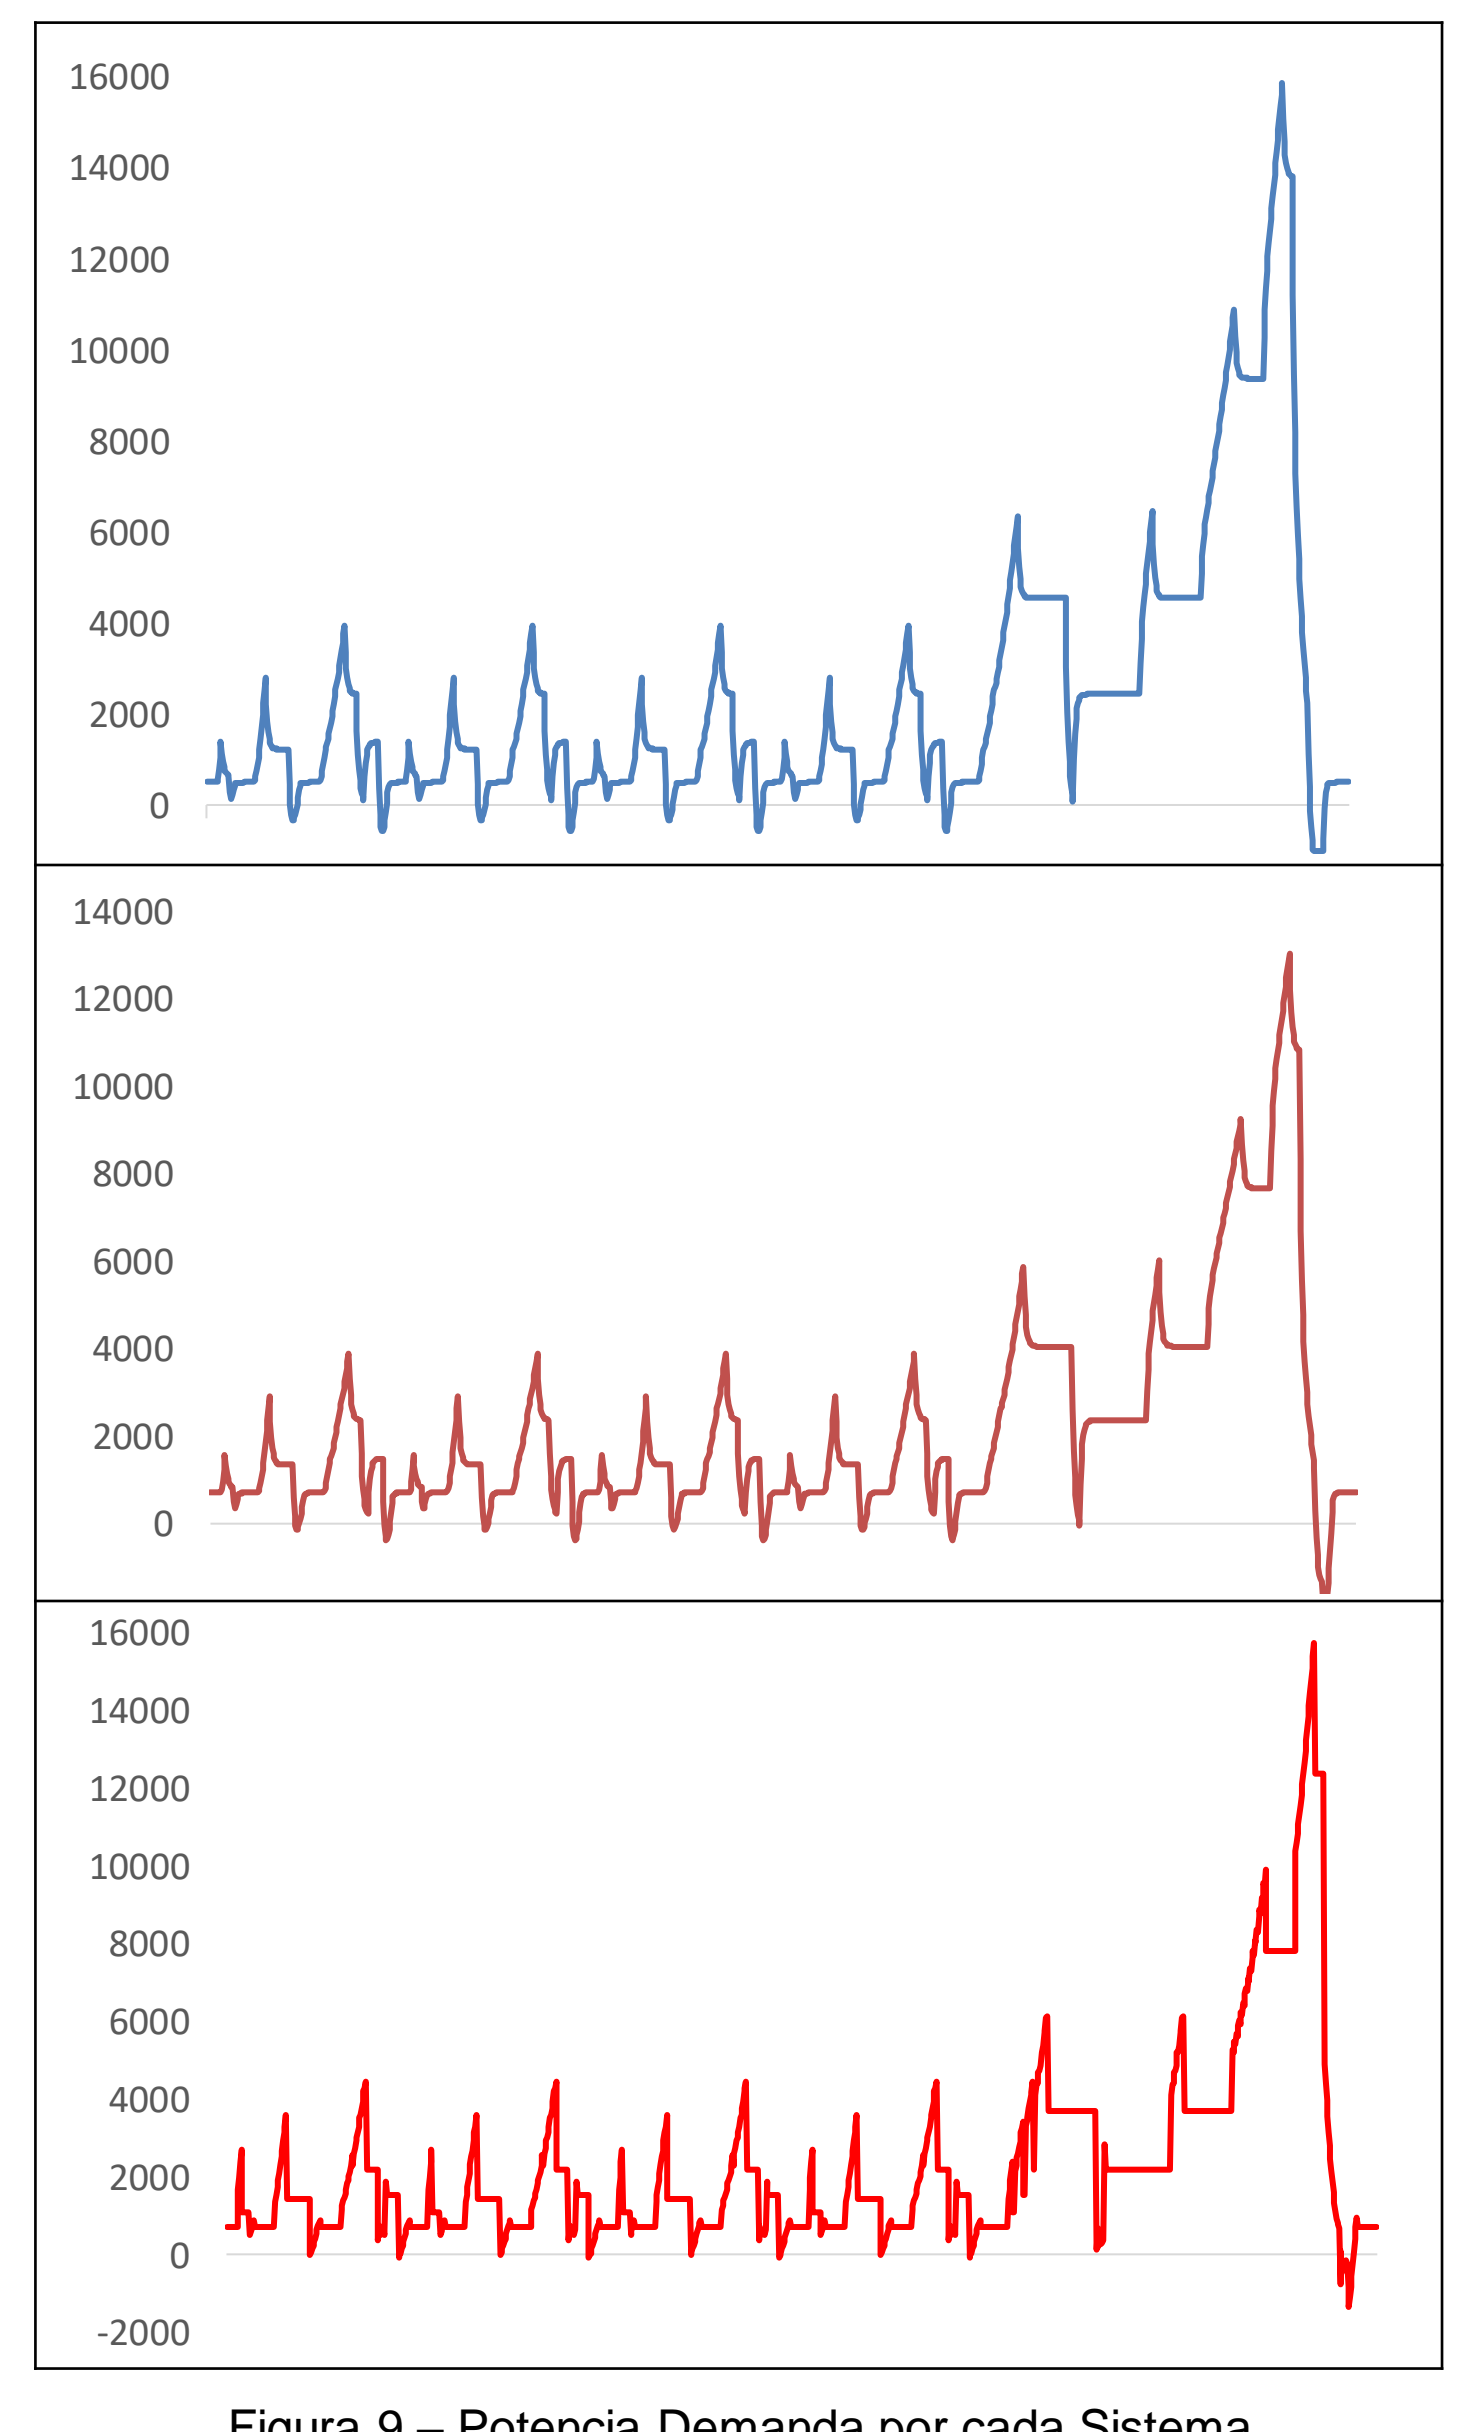


Figura 9 – Potencia Demanda por cada Sistema

CONCLUSIONES

- Con el Aprendizaje Reforzado se mantiene con mayor constancia el estado de carga de la batería, lo que aumenta su ciclo de vida y autonomía con respecto al Dynamic Programming.
- Aunque el sistema que emplea Aprendizaje Reforzado resulte en un mayor consumo de hidrógeno al compararlo con el obtenido con Dynamic Programming, el ahorro por mantener el estado de carga es mayor y de alta rentabilidad, pues puede recorrer más kilómetros con menos de 0.05 kg.
- Al entrenar con la arquitectura de Q-Learning se tiene un aprendizaje inicial lento que necesita de altos requerimientos computacionales, pero al usar Transfer Learning directamente sobre otro ciclo de manejo se consigue un alto rendimiento.