

Implementation in an FPGA of an optimization algorithm to maximize the productivity of a MEC

José de Jesús Colín Robles* Ixbalank Torres Zúñiga*
Mario Alberto Ibarra Manzano* Víctor Alcaraz González**

* C.A. de telemática, Departamento de Ingeniería Electrónica,
Universidad de Guanajuato, Carr. Salamanca-Valle de Santiago km
3.5 + 1.8km, Com. de Palo Blanco, 36885 Salamanca, Mexico (e-mail:
jáj.colinrobles@ugto.mx, ixbalank@ugto.mx, ibarram@ugto.mx).

** Centro Universitario de Ciencias Exactas e Ingeniería, Universidad
de Guadalajara, M. García Barragán 1451, 44430, Guadalajara,
Mexico +(52) 33 1378 5900 (e-mail: victor.alcaraz@cucei.udg.mx)

Abstract: In this work, the implementation of an optimization algorithm in an FPGA is presented with the objective of maximizing the hydrogen flow rate produced by the degradation of organic matter in a microbial electrolysis cell. Through numerical simulation tests, the correct performance of the digital architecture was verified. The feasibility of implementing this optimization algorithm in an FPGA to replace a computer is verified through an analysis of hardware resources, execution time and power consumed.

Keywords: Hydrogen production, FPGA-based implementation, hardware description, optimization, microbial electrolysis cell.

1. INTRODUCCIÓN

Este documento presenta la implementación en un FPGA (Field Gate Programmable Gate Array, por sus siglas en inglés) de un algoritmo de optimización diseñado para mejorar la productividad de una Celda de Electrólisis Microbiana (MEC, por sus siglas en inglés). En la actualidad se considera al hidrógeno como una alternativa prometedora para remplazar a los combustibles fósiles y ser la principal fuente para satisfacer las necesidades de consumo energético en el mundo (Sørensen and Spazzafumo, 2018) debido a que su combustión genera agua y es 2.75 veces más eficiente que cualquier combustible fósil, por lo tanto, el hidrógeno es una fuente limpia, renovable y con mayor rendimiento. Desafortunadamente el 90% de la producción mundial de hidrógeno se obtiene a partir de técnicas que dependen del consumo de combustibles fósiles como la electrólisis del agua, dando lugar a la generación de una gran cantidad de CO_2 (10 toneladas CO_2 /tonelada H_2) (Maddy et al., 2003). Por otro lado, el hidrógeno se puede obtener mediante el uso de sistemas biotecnológicos como las MECs con la ventaja de que estos sistemas requieren de menor cantidad

de energía en comparación con la electrólisis del agua (Liu et al., 2005; Sangeetha and Muthukumar, 2011).

Aunque existen otras alternativas como el uso de fermentadores oscuros para degradar la materia orgánica y producir hidrógeno, el problema está, en que su rendimiento de producción es relativamente bajo en comparación con las MECs (40% o menos) (Nath and Das, 2004). Con el objetivo de producir hidrógeno limpio a una escala industrial, el estudio de algoritmos de optimización, control y monitoreo de sistemas biotecnológicos como las MECs ha sido de gran interés para la comunidad científica.

En ese sentido, mejorar el hidrógeno producido en una MEC puede conseguirse de varias maneras, como por ejemplo en Cui et al. (2019) se consiguió dicho objetivo mediante la inhibición del crecimiento de las bacterias metanogénicas en una MEC de una sola cámara. Bajo condiciones alcalinas (pH=11.25), se consiguió una productividad de hidrógeno del 85% a 90% mientras que la producción de metano se mantuvo debajo de 15%. Otro ejemplo se presenta en Cho et al. (2019) donde se encontró que aplicar una fuente de energía intermitente para superar el potencial en el cátodo, aumentó en un 40% la productividad de hidrógeno, mientras que la eficiencia energética aumento en un 20%. Tomando otro enfoque en la mejora la productividad, encontramos el trabajo Azwar et al. (2020) donde se demuestra un buen desempeño en la implementación del controlador PID Ziegler-Nichols

* Sponsor and financial support acknowledgment goes here. Paper titles should be written in uppercase and lowercase letters, not all uppercase.

(PID ZN) y del controlador basado en un modelo interno de red neuronal (IMC NN, por sus siglas en inglés). En Tartakovsky et al. (2011) se demostró un aumento en la productividad de hidrógeno y una disminución en la energía consumida por una MEC mediante un ajuste en el voltaje de alimentación de tal manera que se minimiza la resistencia aparente entre los electrodos. La estrategia hace uso de observadores para estimar las perturbaciones presentes en el sistema. El algoritmo fue probado en una MEC a escala de laboratorio la cual fue alimentada con acetato.

Los trabajos citados anteriormente donde se usan algoritmo de control para mejorar la productividad de hidrógeno, tienen en común el uso de una computadora personal para ejecutarlos y obtener resultados. Esto trae como consecuencia un consumo de potencia innecesario a pesar de la existencia de mejores alternativas donde la potencia consumida es mucho menor. El desarrollo de sistemas digitales basados en microcontroladores, FPGAs o Procesadores Digitales de Señales (DSP, por sus siglas en inglés) con gran capacidad de procesamiento, bajo consumo de potencia y optimización en los recurso de hardware, representan una excelente opción para poder implementar algoritmos de control. Sin embargo, se ha mostrado que el uso de un FPGA como plataforma de implementación es la mejor opción debido a su bajo consumo de potencia, procesamiento paralelo y gran adaptabilidad a los cambios en el uso de protocolos de comunicación que van cambiando con el tiempo. Por ejemplo en (Lucia et al., 2017) se muestran las ventajas de usar un FPGA sobre los microcontroladores en la implementación de un controlador predictor basado en el modelo (MPC, por sus siglas en inglés). Por su parte en (Krim et al., 2019) se muestra la gran velocidad de procesamiento del FPGA con respecto a un DSP al implementar un controlador difuso de torque directo (FDTC, por sus siglas en inglés) en un motor de inducción. Tomando en cuenta las ventajas de un FPGA, en este trabajo se presenta la implementación de un algoritmo de optimización para mejorar la productividad de hidrógeno en una MEC de tal manera que se tenga un balance positivo entre la energía consumida y la producida.

2. MODELO MATEMÁTICO

Generalmente una MEC consiste principalmente de dos cámaras que están separadas por una membrana catódica. En la cámara anódica, el ánodo está cubierto por una biopelícula donde se da la existencia de las bacterias anodofilicas y las bacterias metanogénicas. La MEC es alimentada con acetato y su degradación tiene lugar en la cámara anódica, como producto se obtienen protones de hidrógeno y un flujo de electrones. Los protones pasan por la membrana a la cámara catódica y es ahí donde se combinan con el flujo de electrones para producir el hidrógeno. Un pequeño voltaje es aplicado entre los electrodos para generar una diferencia de potencial que permita a los electrones pasar del ánodo al cátodo. Respecto a la

degradación del acetato, se contempla una competición entre las bacterias anodofilicas y metanogénicas para decidir quien será la responsable de dicha degradación.

Este comportamiento se puede modelar mediante el siguiente sistema de ecuaciones diferenciales (Flores-Estrella et al., 2020):

$$\dot{s} = (s_{in} - s)D_{in} - k_a\mu_a x_a - k_m\mu_m x_m \quad (1)$$

$$\dot{x}_a = \mu_a x_a - k_{d,a} x_a - \alpha_a D_{in} x_a \quad (2)$$

$$\dot{x}_m = \mu_m x_m - k_{d,m} x_m - \alpha_m D_{in} x_m, \quad (3)$$

donde s es concentración de acetato (mgL^{-1}), mientras que x_a y x_m son las concentraciones de bacterias anodofilicas y metanogénicas respectivamente (mgL^{-1}); D_{in} es la tasa de dilución, $D_{in} = F_{in}/V_{reac}$ (d^{-1}), donde F_{in} es el flujo de entrada (Ld^{-1}) y V_{reac} es el volumen del reactor (L); α_a y α_m son constantes adimensionales de retención de la biopelícula. μ_a y μ_m son tasa de crecimiento (d^{-1}) para las bacterias anodofilicas y metanogénicas respectivamente y están definidas de la siguiente manera:

$$\mu_a = \mu_{max,a} \frac{s}{k_{s,a} + s} \frac{1}{1 + e^{-\frac{F}{RT}\eta}} \quad (4)$$

$$\mu_m = \mu_{max,m} \frac{s}{k_{s,m} + s}, \quad (5)$$

donde $\mu_{max,a}$ y $\mu_{max,m}$ son tasas de máximo crecimiento ($\text{mg}(s)L^{-1}$), $k_{s,a}$ y $k_{s,m}$ son constantes de tasa media de crecimiento ($\text{mg}(s)L^{-1}$), F es la constante de Faraday ($\text{C mol}^{-1} \text{e}^{-1}$), R es la constante de los gases ideales ($\text{J mol}^{-1}\text{K}^{-1}$), T es la temperatura (K), $\eta = E_{anode} - E_{Ka}$ es el potencial local, donde E_{anode} es el potencial del ánodo (V) y E_{Ka} es el potencial de aceptor de electrones anódicos (EA) de velocidad media máxima (V), i.e., el potencial que ocurre cuando $S = k_{S,a}$ y la tasa de crecimiento es la mitad de la máxima tasa de crecimiento (Kato Marcus et al., 2007).

2.1 Productividad de la MEC

El flujo de hidrógeno producido por la MEC es modelado mediante la ecuación (6). Donde se puede ver la relación que tiene con la corriente generada por el flujo de electrones entre los electrodos.

$$Q_{H_2} = Y_{H_2} A_a \frac{I_{MEC}}{mF} \frac{RT}{P}, \quad (6)$$

donde la constante Y_{H_2} es la eficiencia adimensional del cátodo, A_a es el área del ánodo (m^2), m es el número de electrones en moles por especie ($\text{mol e}^{-} \text{mol}^{-1} \text{M}^{-1}$) y P es la presión dentro de la cámara catódica (atm). En la ecuación (6), el consumo por parte de las bacterias metanogénicas es ignorado y únicamente se considera a las bacterias anodofilicas como las responsables de la degradación del acetato. La corriente entre los electrodos es modelada de la siguiente manera:

$$I_{MEC} = (\gamma_s k_a \mu_a x_a L_f (1 - f_s^0) + \gamma_x b x_a L_f) A_{sur}, \quad (7)$$

donde γ_s y γ_x ($\text{mFM}^{-1}\text{W}_s^{-1}$) son coeficientes relacionados con el numero de coulombs que es posible obtener de

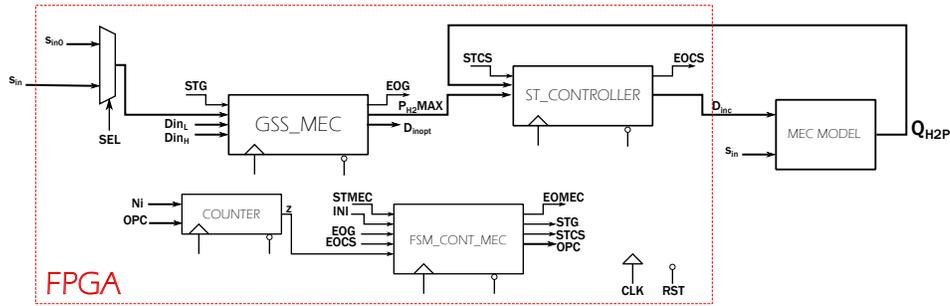


Fig. 1. Esquema de optimización de la productividad de hidrógeno de la MEC.

W_s (g mol^{-1}) y W_x (g mol^{-1}), i.e. del acetato y la biomasa respectivamente; f_s^0 es la fracción adimensional de electrones usados para síntesis celular, b es coeficiente de decaimiento endógeno (d^{-1}) y L_f es el grosor de la biopelícula (m).

Por otro lado, la productividad de hidrógeno $Q_{H_2,p}$ se define como el flujo de hidrógeno producido por volumen del reactor ($L[H_2]L^{-1}d^{-1}$):

$$Q_{H_2,p} = \frac{Q_{H_2,p}}{V_{\text{reac}}} \quad (8)$$

3. PLANTEAMIENTO DEL PROBLEMA

La productividad de hidrógeno se puede expresar en términos de D_{in} y s_{in} . D_{in} es la variable de optimización, mientras que s_{in} se considera como la perturbación de la MEC. En la Figura (2) se puede observar el comportamiento de la productividad de hidrógeno en un rango de s_{in} . Se puede observar un punto de máxima productividad asociado a un valor óptimo de la tasa de dilución ($Q_{H_2,p}^{max}$, $D_{in,opt}$). Por lo tanto el problema de optimización consiste en encontrar ese valor $D_{in,opt}$ que asegura una máxima productividad de la MEC $Q_{H_2,p}^{max}$.

El problema de optimización se puede resolver, si y solo si, se puede calcular a $D_{in,opt}$ en la vecindad Γ de la región de operación de $Q_{H_2,p}$ para cada valor de s_{in} . Asegurar la existencia de $D_{in,opt}$ implica cumplir las siguientes suposiciones:

Suposición: La función $Q_{H_2,p}$ es doble y continuamente diferenciable con respecto a D_{in} en Γ tal que:

$$\begin{aligned} \frac{\partial Q_{H_2,p}(D_{in,opt}, s_{in})}{\partial D_{in}} &= 0 \\ \frac{\partial^2 Q_{H_2,p}(D_{in}, s_{in})}{\partial D_{in}^2} &< 0 \end{aligned} \quad (9)$$

Suposición: La función $Q_{H_2,p}$ es convexa, unimodal y $D_{in,opt}$ es considerado un maximizador global de la productividad de hidrógeno para cada s_{in} .

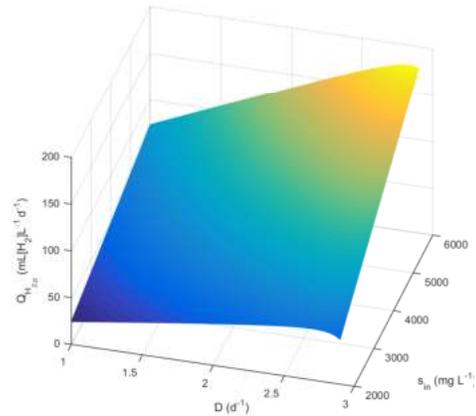


Fig. 2. Productividad de hidrógeno de la MEC en estado estable.

Por lo tanto el problema de optimización se plantea de la siguiente manera:

$$\begin{aligned} \max_{D_{in}} Q_{H_2,p}(D_{in}, s_{in}) \\ \text{tal que:} \\ \dot{x}(t) &= f(x, D_{in}, s_{in}) \\ y(t) &= Q_{H_2,p}(x), \end{aligned} \quad (10)$$

donde $x = [s, x_a, x_m]^T$, $f(x, D_{in}, s_{in})$ se define mediante el modelo (1)-(5) y La salida medida $Q_{H_2,p}(x)$ se define mediante la ecuación (8).

La figura (1) muestra el esquema del algoritmo de optimización en el FPGA para resolver el problema (10). Dicho algoritmo de optimización está integrado por el algoritmo de búsqueda dorada (GSS, por sus siglas en inglés) y el controlador super-twisting. El algoritmo GSS calcula el punto ($Q_{H_2,p}^{max}$, $D_{in,opt}$) en base al valor de s_{in} . Como se puede observar, $Q_{H_2,p}^{max}$ es utilizado como referencia por parte del controlador super-twisting para llevar $Q_{H_2,p}$ a su máximo valor.

4. IMPLEMENTACIÓN EN EL FPGA

La arquitectura digital del algoritmo de optimización usa un formato de representación de punto fijo (16,24).

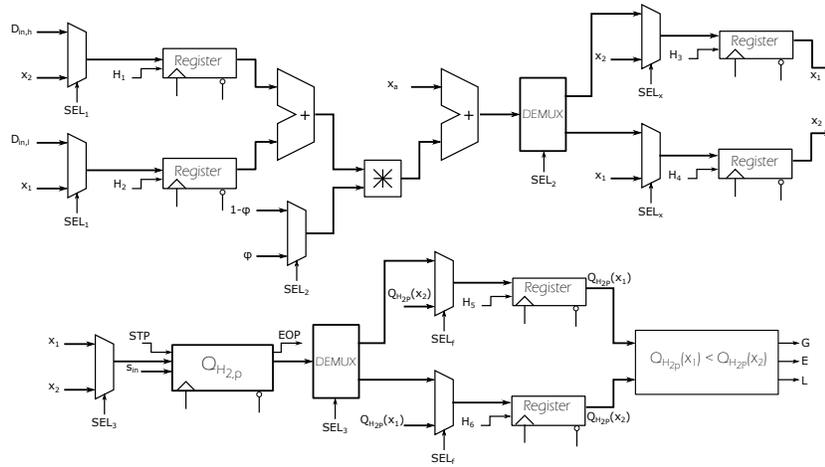


Fig. 3. Arquitectura digital del algoritmo GSS.

La descripción de hardware se realizó en VHDL (Very high Description Language) y la tarjeta utilizada fue la ALTERA DE2 con el chip EP2C35F672C6 a una frecuencia $f_{clock} = 50MHz$.

4.1 Implementación del algoritmo GSS

El algoritmo GSS inicia su operación definiendo la región de búsqueda $D_{in,A} = 1 d^{-1}$, $D_{in,C} = 3 d^{-1}$ donde la función de productividad de la MEC en estado estable (11) incluye un valor óptimo $D_{in,opt}$.

$$Q_{H2,p}(D_{in}, s_{in}) = \frac{L_f A_{sur} Y_{H2} A_a RT D_{in} (s_{in} - s^*)}{mFPV_{reac} \left[\gamma_s (1 - f_s^0) + \frac{\gamma_x b \psi (k_{sa} + s^*)}{k_a \mu_{max,a} s^*} \right]} \quad (11)$$

donde

$$s^* = \frac{k_{s,a} k_{d,a} + k_{s,a} \alpha_a D_{in}}{\frac{\mu_{max,a}}{\psi} - k_{d,a} - D_{in} \alpha_a} \quad (12)$$

El algoritmo GSS calcula dos puntos de evaluación dentro de la región de búsqueda de la siguiente manera:

$$D_{in,1} = D_{in,A} + d \quad (13)$$

$$D_{in,2} = D_{in,C} - d, \quad (14)$$

donde

$$d = (\varphi - 1)(D_{in,A} - D_{in,C}). \quad (15)$$

Mediante el Algoritmo 1 se obtiene la máxima productividad $Q_{H2,p,max}$ después de unas cuantas iteraciones dependiendo del valor de tolerancia establecido por el usuario. La arquitectura digital de la Figura (3) se diseñó para ejecutar dicho algoritmo. Como se puede observar, la ecuación (11) se implementó dentro de la arquitectura digital del algoritmo GSS mediante el módulo $Q_{H2,p}$.

Algorithm 1: GSS

Input: ($D_A, D_B, tolerance$)
Result: ($Q_{H2,max}[k], D_{opt}[k]$)

```

 $f_1 = Q_{H2,p}(D_1);$ 
 $f_2 = Q_{H2,p}(D_2);$ 
while  $err > tolerance$  do
  if  $f_1 > f_2$  then
     $D_A = D_2;$ 
     $D_2 = D_1;$ 
     $D_1 = D_A + \eta;$ 
     $f_2 = f_1;$ 
     $f_1 = Q_{H2,p}(D_1);$ 
     $D_{opt}[k] = D_1;$ 
     $Q_{H2,max} = f_1$ 
  else
     $D_C = D_1;$ 
     $D_1 = D_2;$ 
     $D_2 = D_C - \eta;$ 
     $f_1 = f_2;$ 
     $f_2 = Q_{H2,p}(D_2);$ 
     $D_{opt}[k] = D_2;$ 
     $Q_{H2,max} = f_2;$ 
  end
   $err = (\varphi - 1) \left| \frac{D_C - D_A}{D_{opt}} \right|;$ 
end

```

4.2 Implementación del controlador super-twisting

El controlador super-twisting es una excelente alternativa para controlar procesos que están operando bajo condiciones de incertidumbres paramétricas y perturbaciones externas (Salgado et al., 2016). Para propósitos de implementación en el FPGA, se consideró al controlador super-twisting en tiempo discreto (DTSTC, por sus siglas en inglés). Las ecuaciones del DTSTC son las siguientes:

$$D_c[k] = -\rho_1 \sqrt{|\epsilon_c|} sign(\epsilon_c) + D_{nom}[k] \quad (16)$$

$$D_{nom}[k+1] = D_{nom}[k] + \tau \rho_2 sign(\epsilon_c) \quad (17)$$

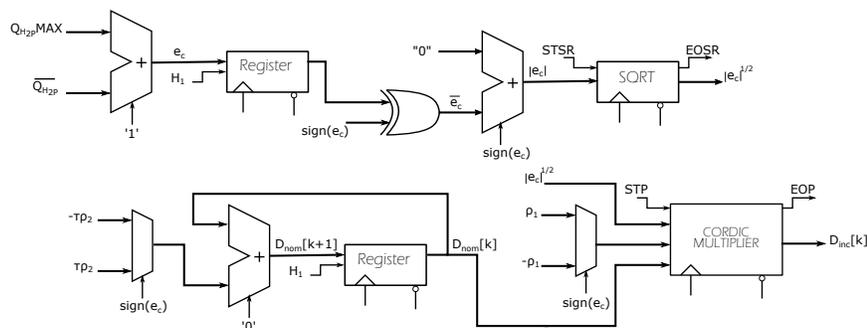


Fig. 4. Arquitectura digital del DTSTC.

donde la función de error se define como:

$$\epsilon_c[k] = Q_{H_{2,p}}[k] - Q_{H_{2,p}}[k] \quad (18)$$

τ es el tiempo de muestro mientras que ρ_1 y ρ_2 son las ganancias del controlador y su valor se especifica en la tabla (1).

Table 1. Ganancias del DTSTC.

Ganancia	valor
ρ_1	0.09
ρ_2	0.19

5. RESULTADOS

Se realizaron pruebas de simulación numérica utilizando un formato de representación de punto fijo (16,24) y tiempo de muestreo $\tau = 0.004d$ para verificar el correcto funcionamiento del algoritmo de optimización implementado en el FPGA que se mencionó anteriormente, la prueba consistió en simular el comportamiento de la MEC mediante las ecuaciones (1)-(6) utilizando el solver ODE15s de Matlab. Mediante los parámetros de la tabla (2), se agregaron incertidumbres al modelo con el objetivo de tener una mejor aproximación de las simulaciones con la realidad. Al establecer un puerto de comunicación entre el FPGA y la computadora, se puede transferir información. Durante cada instante τ se envía el valor de la productividad de hidrógeno obtenida del modelo, a la arquitectura digital del algoritmo de optimización, después de $150\mu s$ el FPGA genera la acción de control $D_{in,c}$ y se queda en espera de un nuevo valor de productividad de hidrógeno.

Durante un periodo de operación de 200 días se alimentó a la MEC con una concentración de acetato a la entrada como la que se muestra en la figura (5). Los resultados de productividad $Q_{H_{2,p}}$ y de la tasa de dilución $D_{in,opt}$ obtenidos del FPGA se muestran en la figura (6).

5.1 Reporte de síntesis

La arquitectura digital del algoritmo de optimización consume un 21% de los elementos lógicos y un 45% de los multiplicadores embebidos en el FPGA. La Tabla (3)

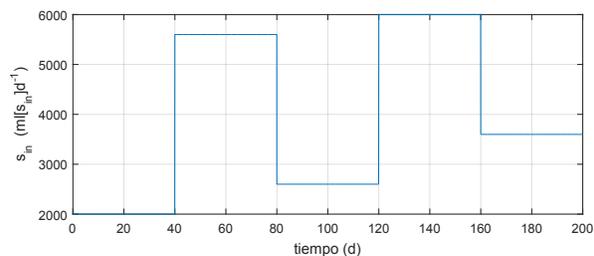


Fig. 5. Concentración de acetato a la entra de la MEC s_{in} .

Table 2. Parámetros del modelo de la MEC con incertidumbres.

Descripción	Símbolo	Valor	variación (%)
Constante de los Gases ideales ($J mol^{-1}K^{-1}$)	R	8.31	0.00
Constante de Faraday ($C mol^{-1}e^{-1}$)	F	96485	0.00
Temperatura (K)	K	298.15	-20.00
Coefficiente de rendimiento ($mg(s) mg^{-1}(x_a)$)	k_a	0.667	+15.00
Coefficiente de rendimiento ($mg(s) mg^{-1}(x_m)$)	k_m	4.7067	-20.00
Decaimiento microbiano (d^{-1})	$k_{d,a}$	$0.05\mu_{max,a}$	+5.00
Decaimiento microbiano (d^{-1})	$k_{d,m}$	$0.05\mu_{max,m}$	+2.00
Constante de retención	α_a	0.5	+12.00
Constante de retención	α_m	0.5	+5.00
Tasa máxima de crecimiento ($mg(s) L^{-1}$)	$\mu_{max,a}$	1.97	20.00
Tasa máxima de crecimiento ($mg(s) L^{-1}$)	$\mu_{max,m}$	0.30	+14.00
Constante de crecimiento medio ($mg(s) L^{-1}$)	$k_{s,a}$	20	+15.00
Constante de crecimiento medio ($mg(s) L^{-1}$)	$k_{s,m}$	80	-15.00
Potencial local (V)	η	0.3	+10.00

Table 3. Recursos de hardware del algoritmo de optimización.

Elementos digitales	Recursos	Usados	%
Elementos lógicos		7089	21.34%
Solo registros	33,216	291	0.87%
Registros/LUT		1472	4.43%
D.L.R.		1724	5.19%
M4K	483,340	0	0.00%
8b-Mult.	70	45	64.00%
I-O delay (Nó. ciclos)	50 MHz	7500	$150\mu s$

muestra con detalle el reporte de síntesis obtenido del programa Quartus web Free. Únicamente se requirió un 21% del total de los elementos lógicos, 5.19% de los registros lógicos dedicados (D.L.R.) y un 64% del total de multiplicadores de 8 bits (8b-mult) en el chip Cyclone II. El retardo necesario para calcular la acción de control después de haber leído los valores de s_{in} y $Q_{H_{2,p}}$, es de $150\mu s$. La estimación de potencia consumida del chip EP2C35F672C6 utilizando los recursos de hardware

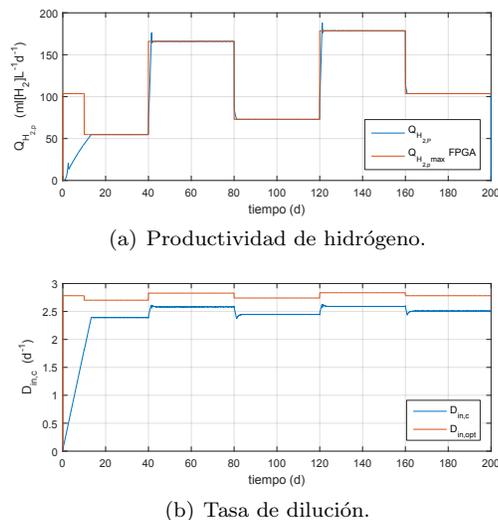


Fig. 6. Resultados del optimizador de la MEC en el FPGA.

antes mencionados, fue de $146mW$. Esta estimación fue calculada utilizando la PowerPlay Early Power Estimator spreadsheet for Cyclone II family v8.0 SP1.

6. CONCLUSIONES

Como se puede observar en los resultados obtenidos, el optimizador implementado en el FPGA trabaja muy bien utilizando el formato de representación (16,24). Mediante el reporte de síntesis se puede concluir que la arquitectura digital del algoritmo de optimización ocupa pocos recursos de hardware y por lo tanto se puede implementar en cualquier FPGA de bajo costo. Respecto a la potencia consumida, también se pudo demostrar que estos dispositivos son una excelente alternativa para remplazar a una computadora.

ACKNOWLEDGEMENTS

Este estudio fue apoyado por la Universidad de Guanajuato y la Universidad de Guadalajara. Fue parcialmente apoyado por el Consejo Nacional de Ciencia y Tecnología (CONACyT) bajo el número 614412/327289.

REFERENCES

Azwar, A., Muslim, A., Mukhlshien, M., Jakfar, J., and Zani, M. (2020). Automation of bio-hydrogen gas production in a fed-batch microbial electrolysis cell reactor by using internal model control of neural network. *Journal of Advanced Research in Fluid Mechanics and Thermal Sciences*, 67(2), 89–96.

Cho, S.K., Lee, M.E., Lee, W., and Ahn, Y. (2019). Improved hydrogen recovery in microbial electrolysis cells using intermittent energy input. *International Journal of Hydrogen Energy*, 44(4), 2253–2257.

Cui, W., Liu, G., Zeng, C., Lu, Y., Luo, H., and Zhang, R. (2019). Improved hydrogen production in the single-chamber microbial electrolysis cell with inhibition of methanogenesis under alkaline conditions. *RSC advances*, 9(52), 30207–30215.

Flores-Estrella, R., Rodríguez-Valenzuela, G., Ramírez-Landeros, J., Alcaraz-González, V., and González-Álvarez, V. (2020). A simple microbial electrochemical cell model and dynamic analysis towards control design. *Chemical Engineering Communications*, 207(4), 493–505.

Kato Marcus, A., Torres, C.I., and Rittmann, B.E. (2007). Conduction-based modeling of the biofilm anode of a microbial fuel cell. *Biotechnology and bioengineering*, 98(6), 1171–1182.

Krim, S., Gdaim, S., Mtibaa, A., and Mimouni, M.F. (2019). Control with high performances based dtc strategy: Fpga implementation and experimental validation. *EPE Journal*, 29(2), 82–98.

Liu, H., Grot, S., and Logan, B.E. (2005). Electrochemically assisted microbial production of hydrogen from acetate. *Environmental science & technology*, 39(11), 4317–4320.

Lucia, S., Navarro, D., Lucia, O., Zometa, P., and Find-eisen, R. (2017). Optimized fpga implementation of model predictive control for embedded systems using high-level synthesis tool. *IEEE transactions on industrial informatics*, 14(1), 137–145.

Maddy, J., Cherryman, S., Hawkes, F., Hawkes, D., Dinsdale, R., Guwy, A., Premier, G., and Cole, S. (2003). *Hydrogen 2003: Report Number 1: ERDF Part-funded Project Entitled: 'A Sustainable Energy Supply for Wales: Towards the Hydrogen Economy'*. University of Glamorgan.

Nath, K. and Das, D. (2004). Improvement of fermentative hydrogen production: various approaches. *Applied microbiology and biotechnology*, 65(5), 520–529.

Salgado, I., Kamal, S., Bandyopadhyay, B., Chairez, I., and Fridman, L. (2016). Control of discrete time systems based on recurrent super-twisting-like algorithm. *ISA transactions*, 64, 47–55.

Sangeetha, T. and Muthukumar, M. (2011). Catholyte performance as an influencing factor on electricity production in a dual-chambered microbial fuel cell employing food processing wastewater. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, 33(16), 1514–1522.

Sørensen, B. and Spazzafumo, G. (2018). *Hydrogen and fuel cells: emerging technologies and applications*. Academic Press.

Tartakovsky, B., Mehta, P., Santoyo, G., and Guiot, S. (2011). Maximizing hydrogen production in a microbial electrolysis cell by real-time optimization of applied voltage. *International journal of hydrogen energy*, 36(17), 10557–10564.