



Computational Intelligence in Electrical Engineering
Vol. 16, No. 4, 2026
pp. 1-16
[Research Paper](#)

Maximum Power Tracking in Proton Exchange Membrane-Based Fuel Cell Using Neural Network Trained with Metaheuristic Optimization Algorithm

Mohamad Abedini

¹ Associate Professor, Department of Electrical Engineering, Ayatollah Boroujerdi University, Boroujerd, Iran

Abstract:

Considering the limited ability of fuel cells to produce energy, it is necessary to provide solutions in which the efficient power generated by fuel cells can be achieved. Therefore, there is a need for maximum-power-tracking methods that adjust the duty cycle of the boost converter in fuel cells. Thus, in this paper, a new power tracking method has been used that is based on the combination of neural networks and a meta-heuristic algorithm called frog jump optimization to overcome the problems of conventional methods caused by rapid changes in the operating point and power fluctuations. The proposed method has been proposed in order to perform quickly and increase the efficiency achievable from proton exchange membrane-based fuel cells. The modeling results have been presented in the MATLAB environment and compared with several different power tracking methods. The results show that the proposed method shows less than one percent error in the three evaluated temperatures for tracking the maximum power compared to the actual power of the fuel cell, and is also robust to input changes in the fuel cell.

Keywords: Neural Network, Fuel Cell, Meta-Heuristic Optimization, Maximum Power Point Tracking, Converter.



This is an open access article under the CC BY-NC-ND/4.0/ License (<https://creativecommons.org/licenses/by-nc-nd/4.0/>).



<https://doi.org/10.22108/isee.2025.145950.1750>

یک رویکرد نوین برای ردیابی ماکسیمم توان بر پایه شبکه عصبی با الهام از بهینه‌سازی فرا-ابتکاری در پیل‌های سوختی غشایی

محمد عابدینی*

۱- دانشیار، گروه برق، دانشکده فنی و مهندسی، دانشگاه آیت الله بروجردی، بروجرد، ایران

m.abedini@abru.ac.ir

چکیده: با در نظر گرفتن توانایی محدود پیل‌های سوختی برای تولید انرژی، ارائه راه‌حلی که در آنها توان کارآمد تولید شده توسط پیل‌های سوختی قابل دستیابی باشد، الزامی است؛ از این رو، به روش‌های ردیابی حداکثر توان از طریق تنظیم سیکل کاری مبدل بوست در پیل‌های سوختی نیاز است. در این مقاله، از یک روش جدید ردیابی توان استفاده شده است که بر پایه ترکیب شبکه‌های عصبی و یک الگوریتم فرا-ابتکاری به نام بهینه‌سازی جهش قورباغه است تا بتواند بر مشکلات روش‌های مرسوم ناشی از تغییرات سریع در نقطه کار و نیز نوسانات توان فائق آید. روش پیشنهادی به منظور عملکرد سریع و نیز افزایش بازده قابل حصول از پیل‌های سوختی بر پایه غشایی تبادل پروتون پیشنهاد شده است. نتایج مدل‌سازی در محیط متلب ارائه شده و با چندین روش مختلف ردیابی توان مقایسه شده است. نتایج نشان می‌دهد روش پیشنهادی در سه دمای مورد ارزیابی برای ردیابی حداکثر توان نسبت به توان واقعی پیل سوختی، کمتر از یک درصد خطا را نشان می‌دهد و نیز نسبت به تغییرات ورودی در پیل سوختی مقاوم است.

واژه‌های کلیدی: شبکه عصبی، پیل سوختی، افزایش بازده، ردیابی نقطه حداکثر توان، مبدل بوست.

۱- مقدمه

در عصری که تقاضا برای انرژی روزبه‌روز در حال افزایش است و نگرانی برای پایداری زیست‌محیطی در درجه اول اهمیت قرار دارد، اکتشاف منابع انرژی پاک و کارآمد به یک اولویت جهانی تبدیل شده است. در این میان، پیل‌های سوختی به عنوان یک راه‌حل امیدوارکننده ظاهر شده‌اند. سلول‌های سوختی دستگاه‌های الکتروشیمیایی هستند که انرژی شیمیایی را از منبع سوخت مستقیماً به انرژی الکتریکی تبدیل می‌کنند. پیل‌های سوختی ترکیبی منحصربه‌فرد از مزایا را ارائه می‌دهند که آنها را به گزینه‌ای جذاب برای طیفی وسیع از کاربردها تبدیل می‌کند [۱].

عملکرد مداوم پیل‌های سوختی تا زمانی که سوخت و اکسیژن تأمین می‌شود، آنها را از باتری‌های معمولی متمایز

می‌کند که به شارژ مجدد دوره‌ای نیاز دارند. این ویژگی، همراه با اندازه‌های متنوع آنها، سلول‌های سوختی را برای کاربردهای مختلف، از تأمین انرژی خودروهای الکتریکی گرفته تا تأمین نیروی پشتیبان برای زیرساخت‌های حیاتی، مناسب می‌کند. پیل‌های سوختی در واقع عمده‌تاً بر اساس نوع الکترولیتی طبقه‌بندی می‌شوند که استفاده می‌کنند. این طبقه‌بندی نوع واکنش‌های الکتروشیمیایی را که در سلول انجام می‌شود، نوع کاتالیزورهای مورد نیاز، محدوده دماهایی که سلول در آن کار می‌کند، سوخت مورد نیاز و عوامل دیگر را تعیین می‌کند. در اینجا، برخی از انواع سلول‌های سوختی بر اساس الکترولیت استفاده شده آورده شده‌اند که عبارت‌اند از: سلول سوختی غشایی تبادل پروتون (PEMFC)^۱، پیل سوختی مستقیم متانول (DMFC)^۲، پیل سوختی قلیایی (AFC)^۳، پیل سوختی

نشانی نویسنده مسئول: ایران، بروجرد، دانشگاه آیت الله بروجردی، دانشکده مهندسی

^۱ تاریخ ارسال مقاله: ۱۴۰۴/۰۴/۲۲

تاریخ پذیرش مقاله: ۱۴۰۴/۰۹/۳۰

نام نویسنده مسئول: محمد عابدینی

اسید فسفریک^۴ (PAFC)، پیل سوختی کربنات مذاب^۵ (MCFC)، پیل سوختی اکسید جامد (SOFC)^۶، پیل سوختی هوا روی (ZAFC)^۷ و پیل سوختی سرامیکی فوتونیک (PCFC)^۸ که با توجه به دمای کارشان متمایز می‌شوند [۲].

PEMFC و DMFC از غشای پلیمری استفاده می‌کنند، در حالی که PAFC، SOFC و DMFC به ترتیب از اسید فسفریک خالص، مواد سرامیکی و مخلوط مذاب کربنات‌های سدیم، لیتیم و پتاسیم استفاده می‌کنند. امیدوارکننده‌ترین فناوری پیل سوختی به دلیل راندمان تبدیل انرژی زیاد و توانایی کارکرد در دماهای نسبتاً کم، PEMFC است.

از آنجا که PEMFC ولتاژ خروجی کمی تولید می‌کند، از یک مبدل قدرت برای تقویت و تنظیم ولتاژ پیل سوختی استفاده می‌شود تا PEMFCها در نقطه توان بهینه کار کنند و همچنین، یک منبع توان جریان مستقیم قابل اجرا را فراهم کند. از سوی دیگر، مشخصات خروجی PEMFC تحت تأثیر تغییرات در چندین پارامتر، مانند دمای سلول، فشار جزئی اکسیژن و هیدروژن و تقاضای بار قرار می‌گیرد [۳]؛ بنابراین، برای عملکرد بهینه و مناسب باید از یک الگوریتم ردیابی حداکثر توان (MPPT)^۹ استفاده شود.

در بررسی مقاله‌های موجود، تعداد زیادی روش MPPT کلاسیک گزارش شده‌اند [۴-۲۹]. با این حال، متداول‌ترین روش‌های استفاده شده عبارت‌اند از: روش مدار اتصال کوتاه یا باز کسری [۴]، اغتشاش و مشاهده (P&O)^{۱۰} [۵، ۶]، روش‌های مبتنی بر ولتاژ و جریان [۷]، روش رسانایی افزایشی [۸، ۹]، کنترل جست‌وجوی اکستریم [۱۰، ۱۱]، روش کنترل مد لغزشی [۱۲، ۱۳]، جابه‌جایی جریان [۱۴] و کنترل منطق فازی [۱۵، ۱۶].

تکنیک‌های محاسباتی هوشمند و پیشرفته مانند بهینه‌سازی شبکه عصبی مصنوعی (Ann)^{۱۱} [۱۷]، روش مبتنی بر دنباله فیبوناچی [۱۸] و روش‌های فرا-ابتکاری همچون الگوریتم ژنتیک [۱۹]، الگوریتم حرکت پرندگان [۲۰]، الگوریتم جست‌وجوی فاخته [۲۱] از جمله روش‌های جدیدی هستند که امروزه در فرایند ردیابی ماکسیمم توان در سیستم‌های پیل سوختی استفاده شده‌اند.

این مقاله یک روش ردیابی حداکثر توان پیش‌بینی‌کننده را برای یک سیستم PEMFC بر پایه ساختار شبکه عصبی

بهبود داده‌شده بررسی می‌کند.

برخلاف روش‌های مرسوم، برای آموزش شبکه عصبی از الگوریتم بهینه‌سازی جدید جهش قورباغه به علت سرعت زیاد آن در رسیدن به مقدار بهینه برای آموزش وزن‌های شبکه عصبی استفاده شده است تا دقت و سرعت آموزش افزایش داده شود. سه عاقل دما، تغییرات فشار اکسیژن و فشار هیدروژن به عنوان ورودی و سیکل کاری مبدل بوسست به عنوان خروجی شبکه عصبی مدل‌سازی می‌شوند.

در نهایت، نتایج با روش عصبی آموزش داده‌شده به روش‌های دیگر همچون روش ولتاژ مدار باز و روش تداخل و مشاهده مقایسه می‌شود. انتظار می‌رود این روش ردیابی پیشنهادشده همگرایی سریع به نقطه ماکسیمم توان، دقت فوق‌العاده و استحکام زیادی را با توجه به تغییرات محیطی نشان دهد. کل شبیه‌سازی در محیط متلب اجرا شده است، زیرا این محیط در تنظیم شرایط عملیاتی بسیار انعطاف‌پذیر است.

ساختار مقاله در ادامه عبارت است از: یک مدل ریاضی کاملاً کاربردی از یک PEMFC برای نشان دادن یک مدل سیستم پیل سوختی معرفی می‌شود و سپس یک مبدل تقویت‌کننده DC-DC برای کنترل ولتاژ تولیدشده از سیستم PEMFC مدل‌سازی خواهد شد. هدف از کنترل ولتاژ پیل سوختی حفظ توان پیل سوختی در نقطه ماکسیمم توان است. در قسمت دوم، مدل‌سازی پیل سوختی آورده شده است. معرفی شبکه عصبی و کاربرد آن در طراحی کنترل‌کننده ردیابی حداکثر توان در بخش سوم بیان می‌شود. اجرای روش فرا-ابتکاری برای بهینه‌کردن وزن‌های شبکه عصبی در بخش چهارم آورده شده است و در بخش پنجم، درباره نتایج شبیه‌سازی بحث خواهد شد.

۲- مدل‌سازی یک پیل سوختی

در این قسمت، مدل ریاضی از یک پیل سوختی و نیز تأثیرات دما و فشار بر روی منحنی‌های ولتاژ-جریان بیان می‌شود.

شکل (۱) بلوک پیل سوختی و دیاگرام مداری پیل سوختی را نشان می‌دهد. این سیستم از مدل پیل سوختی، مبدل dc-dc، کنترل‌کننده MPPT و بار تشکیل شده است. واکنش‌های

$$+4.308 \times 10^{-5} T \times \left(\ln P_{H_2} + \frac{1}{2} \ln P_{O_2} \right)$$

در رابطه بالا، P_{H_2} و P_{O_2} فشار جزئی هیدروژن و اکسیژن هستند و T دمای عملیاتی پیل سوختی می است.

۲-۲- ولتاژ خروجی تک سلول

در یک سلول سوختی غشایی تبادل پروتون، تلفات الکتریکی را می توان به سه تلفات اصلی طبقه بندی کرد که عبارتند از: تلفات برانگیختگی (V_{act}) که به دلیل کندی واکنش در سطح الکترودها رخ می دهد. این کندی سبب می شود هنگام انتقال الکترون ها از یک الکترود به الکترود دیگر مقداری افت ولتاژ داشته باشیم. دومین تلفات ناشی از تلفات اهمی است (V_{ohm}). این تلفات ناشی از مقاومت الکترودها در برابر عبور الکترون ها و همچنین مقاومت الکترولیت در برابر عبور یون ها است. افت ولتاژ ناشی از این نوع تلفات رابطه مستقیم با چگالی جریان دارد؛ به همین دلیل، به آن تلفات اهمی می گویند. آخرین تلفات ناشی از غلظت است (V_{conc}) که ناشی از تغییر غلظت واکنشگرها در سطح الکترودهاست؛ یعنی تغییر غلظت سوخت هیدروژن و اکسیژن باعث تغییر ولتاژ می شود. در پیل سوختی هیدروژنی، اکسیژن معمولاً از هوا تأمین می شود؛ بنابراین، فشار آن را ثابت می گیریم اما فشار هیدروژن به مرور زمان کاهش می یابد. بنابراین، ولتاژ یک سلول (V_{fc}) را می توان به صورت معادله (۵) محاسبه کرد:

$$V_{fc} = E_{Nernst} - V_{act} - V_{ohm} - V_{conc} \quad (5)$$

که در آن، هر یک از تلفات به صورت زیر معرفی می شود:

$$V_{act} = \lambda_1 + \lambda_2 \times T + \lambda_3 \times T \times \ln(CO_2) + \lambda_4 \times T \times \ln(I) \quad (6)$$




$$V_{ohm} = R_M \times I \quad (7)$$

$$V_{conc} = \eta \times \ln\left(\frac{J_{max}}{J_{max}}\right) \quad (8)$$


که در معادله بالا، λ ها مقادیر ثابت هستند، CO_2 غلظت

اکسیژن، I جریان عملیاتی پیل سوختی، R_M مقاومت معادل الکترون و پروتون، η مقداری ثابت، J و J_{max} به ترتیب

الکتروشیمیایی روی الکترودها را می توان در معادلات (۱) تا (۳) توضیح داد. معادلات اول و دوم به ترتیب واکنش های جانبی آند و کاتد را نشان می دهند و معادله سوم واکنش الکتروشیمیایی کلی را نشان می دهد [۲۲]:



(الف): مدل شماتیک پیل سوختی



(ب): مدار معادل الکتریکی پیل سوختی

شکل (۱): مدل پیل سوختی

در ادامه، معادلات مربوط به افت ولتاژ در پیل سوختی را مدل سازی می کنیم [۲۳].

۲-۱- ولتاژ نرنست

پتانسیل الکتریکی سلول همچنین به عنوان Nernst شناخته می شود و مطابق رابطه زیر، برحسب انرژی آزاد شده در معادله (۴) بیان می شود:

$$E_{Nernst} = 1.229 - 8.5 \times 10^{-4} T \quad (4)$$

یک رویکرد نوین برای ردیابی ماکسیمم توان بر پایه شبکه عصبی با الهام از بهینه‌سازی فرا-ابتکاری در پیل‌های سوختی غشایی


$$P_{Loss} = \kappa_h (T - T_a) \quad (14)$$

$$(P_h^G - P_{Loss}) = \alpha_p \frac{dT}{dt} \quad (15)$$


در معادلات (۱۳) تا (۱۵)، P_h^G گرمای تولیدشده، P_{Loss} گرمای ازدست‌رفته، κ_h ضریب انتقال حرارت، T دمای سلول و T_a دمای محیط، α_p ضریب حرارتی پیل سوختی و N_{cel} است.

۲-۴- منحنی مشخصات یک پیل سوختی

فقط یک نقطه ماکسیمم وجود دارد که در آن، PEMFC بهینه عمل می‌کند. از آنجا که PEMFC برحسب فیدبک جریان کار می‌کند، توان خروجی نسبت به تغییرات جریان در مقایسه با تغییرات ولتاژ حساس‌تر است. بنابراین، برای بررسی PEMFC برای انجام MPPT، انتخاب ویژگی‌های $P - I$ به جای $P - V$ گزینه‌ای بهتر است؛ با کاهش دما ولتاژ و توان افت می‌کند و با کاهش فشار هیدروژن نیز ولتاژ افت می‌کند. منحنی‌های ولتاژ-جریان و توان-جریان در شکل (۲) به‌ازای دماهای مختلف رسم شده‌اند. وقتی دما افزایش می‌یابد، ولتاژ و توان نیز افزایش یافته‌اند.



(الف): منحنی توان-جریان پیل سوختی



(ب): منحنی ولتاژ-جریان پیل سوختی

چگالی جریان و چگالی جریان ماکسیمم هستند.

۲-۳- ضرایب و دینامیک انتقال پیل سوختی

در این قسمت، معادلات مربوط به مقاومت غشا در یک پیل سوختی آورده شده‌اند [۲۳، ۳۱، ۳۰].

$$R_M = \frac{r_m t_m}{A} \quad (9)$$

در رابطه (۹)، t_m برابر طول الکترولیت (سانتی‌متر) است، A برابر مساحت (سانتی‌متر مربع) از الکترولیت است که پروتون می‌تواند به آن جریان یابد و r_m مقاومت ویژه (سانتی‌متر) الکترولیت است که می‌توان آن را به صورت زیر بیان کرد:

$$r_m = 181.6 \frac{1 + 0.03(\frac{I}{A}) + 0.0062(\frac{T}{303})^2(\frac{I}{A})^{2.5}}{\lambda_m - 0.634 - 3(\frac{I}{A}) \exp^{4.18(\frac{T-303}{T})}} \quad (10)$$

که در آن، λ_m محتوای آب غشایی است که بین ۰ تا ۱۴ متغیر است. این مقدار نشان‌دهنده رطوبت نسبی بین ۰ تا ۱۰۰ درصد است [۳۰]. حداکثر مقدار ممکن m می‌تواند در شرایط بالا اشباع به ۲۳ درصد برسد [۳۱].

فشارهای جزئی هیدروژن و اکسیژن، P_{H_2} و P_{O_2} را می‌توان در حوزه زمان به صورت زیر نوشت [۲۳]:

$$P_{H_2}(t) = \frac{1}{k_{H_2}} (2k_r I \exp(\frac{-t}{\tau_{H_2}}) + q_{H_2}^{in} - 2k_r I) \quad (11)$$

$$P_{O_2}(t) = \frac{1}{k_{O_2}} (k_r I \exp(\frac{-t}{\tau_{O_2}}) + q_{O_2}^{in} - k_r I) \quad (12)$$

که در آن، t زمان، k_{H_2} و k_{O_2} به ترتیب ثابت‌های مولی دریاچه هیدروژن و اکسیژن هستند، k_r ثابت مدل‌سازی است، τ_{H_2} و τ_{O_2} به ترتیب ثابت‌های زمانی هیدروژن و اکسیژن هستند و q_{H_2} و q_{O_2} به ترتیب جریان مولی هیدروژن و اکسیژن هستند.

در ادامه، معادلات مربوط به دینامیک حرارتی پیل سوختی که بر روی بازده مؤثر هستند به صورت خلاصه آورده شده‌اند [۳۴]:

$$P_h^G = N_{cel} (E_{Nerst} - V_{fc}) \quad (13)$$

با تغییر سیکل کاری، می‌توان به نقطه‌ای ماکسیمم توان دست یافت. در این مبدل، رابطه ولتاژ خروجی عبارت است از:

$$V_o = \frac{V_i}{1-d} \quad (۱۶)$$


۳- شبکه عصبی

شبکه‌های عصبی مصنوعی نوعی مدل یادگیری ماشینی هستند که از ساختار و عملکرد مغز انسان الهام گرفته شده است.

شبکه‌های عصبی مصنوعی از مجموعه‌ای از گره‌های به هم پیوسته به نام نورون‌های مصنوعی تشکیل شده‌اند که در لایه‌هایی سازمان‌دهی شده‌اند. هر نورون ورودی از نورون‌های دیگر اطلاعات دریافت می‌کند، ورودی را پردازش می‌کند و سیگنال خروجی تولید می‌کند که می‌تواند به نورون‌های دیگر ارسال شود. اتصالات بین نورون‌ها از طریق وزن‌ها برقرار می‌شود و وزن‌ها در طول فرایند آموزش برای بهینه‌سازی شبکه تنظیم می‌شوند [۲۵، ۲۷] (شکل ۵).


در شبکه‌های عصبی، اگر یک سلول آسیب ببیند، بقیه سلول‌ها می‌توانند نبود آن را جبران کنند و نیز در بازسازی آن سهیم باشند. این شبکه‌ها قادر به یادگیری هستند.

یکی از این نتایج این رویه یادگیری قابلیت شبکه عصبی برای تعمیر و وابسته کردن داده است. بعد از آموزش موفقیت‌آمیز، یک شبکه عصبی می‌تواند راهکارهایی منطقی و معقول را برای مسائل مشابه از کلاس مشابه پیدا کند که صریحاً آموزش دیده نشده بودند. این عمل در واقع به نتایجی در درجه‌ای بالا از تحمل‌پذیری خطا در مقابل داده نویزدار منجر می‌شود.




شکل (۵): ساختار یک نرون طبیعی [۳۳]

شکل (۲): الف منحنی‌های پیل سوختی با دمای کاری متفاوت



(الف): منحنی توان-جریان پیل سوختی




(ب): منحنی ولتاژ-جریان پیل سوختی

شکل (۳): منحنی‌های پیل سوختی با فشار متفاوت


منحنی ولتاژ-جریان و توان-جریان در شکل (۳) به‌ازای فشارهای هیدروژن مختلف رسم شده است. وقتی فشار افزایش یافته است، ولتاژ نیز افزایش یافته است. با توجه به منحنی‌ها، مشاهده می‌شود تأثیر دما بیشتر از تأثیر فشار است.

۲-۵- مدل مبدل بوست

مبدل بوست برای هر سیستم ردیابی ماکسیمم توان لازم است. این مبدل بین بار و هدل پیل سوختی به کار گرفته می‌شود که در شکل (۴) نمایش داده شده است [۲۸، ۲۹].



شکل (۴): مدار معادل مبدل بوست




شکل (۷): ساختار شبکه عصبی استفاده شده

۳-۱- ساختار شبکه عصبی

در مدل شبکه عصبی مصنوعی، به هر ورودی یک وزن $(w_1, \dots, w_m)$ اختصاص می‌دهیم که در شکل (۶) نمایش داده شده است. این وزن‌ها در واقع اهمیت ورودی‌ها برای ما هستند؛ یعنی هرچه وزن بیشتر باشد، ورودی برای آموزش شبکه مهم‌تر است. سپس تمامی ورودی‌ها با هم جمع و به صورت یک‌لایه به آکسون وارد می‌شوند. در مرحله بعد، تابع فعال‌ساز را بر روی داده‌ها اعمال می‌کنیم.

تابع فعال‌ساز در واقع نسبت به نیاز مسئله و نوع شبکه عصبی ما تعریف می‌شود. این تابع شامل یک فرمول ریاضی برای به‌روزرسانی وزن‌ها در شبکه است.

پس از انجام محاسبات در این مرحله، اطلاعات ما از طریق سیناپس‌های خروجی وارد نرون دیگر می‌شود و این مرحله تا جایی ادامه پیدا می‌کند که شبکه اصطلاحاً $train$ شده باشد.



شکل (۶): ساختار کلی یک شبکه عصبی

۴-۱- الگوریتم بهینه‌سازی جهش قورباغه

الگوریتم ترکیبی جهش قورباغه^{۱۲} یک روش بهینه‌سازی فراکاوشی است که از تکامل میمیک^{۱۳} یک گروه از قورباغه‌ها، زمانی که دنبال مکانی با حداکثر میزان غذای در دسترس می‌گردند، تقلید می‌کند. در الگوریتم‌های فراکاوشی، تابع هدف دارای روند آگاهانه است و فضای تصمیم به صورت هوشمندانه بررسی می‌شود [۲۶].

۴-۱- ساختار الگوریتم ترکیبی جهش قورباغه

الگوریتم SFL هر دو عنصر راهبرد قطعیت و تصادفی را در یافتن جواب بهینه داراست. راهبرد قطعیت به الگوریتم اجازه می‌دهد تا از اطلاعات سطحی جواب به صورت مؤثر در راستای هدایت جست‌وجوی اکتشافی مانند الگوریتم حرکت پرندگان استفاده کند. عناصر تصادفی انعطاف و قدرت الگوی جست‌وجو را در روش پیشنهادی تضمین می‌کنند. در این مقاله، از روش SFL برای تعیین ضریب‌های وزنی شبکه عصبی استفاده شده است و تابع هدف مسئله مینیمم‌سازی مربعات خطاست. مراحل الگوریتم SFL به صورت زیر آورده شده‌اند:

مرحله اول: جمعیت اولیه‌ای شامل N جواب مسئله همچون $P = \{X_1, X_2, \dots, X_n\}$ تولید می‌شود. یک راه‌حل مسئله برای بهره‌های اولیه در کنترلر شکل‌های (۵) و (۶) به صورت زیر در نظر گرفته شده است:

$$X_i = [w_{ij}, b_{ij}]$$

مرحله دوم: با استفاده از تابع برازندگی تعریف‌شده در (۱۷)، هر یک از جواب‌های مسئله ارزیابی می‌شوند و با توجه به مقادیر شایستگی‌شان، به صورت نزولی مرتب

در این مقاله، از ساختار شبکه عصبی بهبود داده‌شده برای بهبود سیستم ردیاب فیوسل به علت مشکلات روش‌های مرسوم ناشی از گنبد بودن در پاسخ‌گویی به تغییرات دما و فشار هیدروژن و اکسیژن استفاده شده است. در روش‌های مرسوم، از دما و فشار هیدروژن و نیز اکسیژن به عنوان ورودی و از سیکل کاری مبدل بوست به عنوان خروجی شبکه عصبی استفاده می‌شود. در این مقاله نیز به منظور اجرای کنترل‌کننده پیشنهادی برای افزایش ردیابی توان بهینه در فیوسل، از یک شبکه عصبی با سه ورودی و یک خروجی با ۷ لایه پنهان مشابه شکل (۷) استفاده شده است.

می‌شوند:

$$RMSE = \sqrt{\frac{(\sum (y_i - \hat{y}_i))^2}{n}} \quad (17)$$

تابع هدف معرفی شده برای بهبود ریشه میانگین مربع خطا است که در آن، y_i مقدار واقعی است، $\hat{y}_i$ مقدار پیش‌بینی شده است و n تعداد نمونه مورد مطالعه است.

مرحله سوم: کل جمعیت به m بخش مساوی تقسیم می‌شود که به هر کدام از این زیربخش‌ها ممپلکس گفته می‌شود. در هر ممپلکس، n راه‌حل مسئله قرار می‌گیرد:

$$n = \frac{N}{m}$$

اول قرار می‌گیرد، دومین راه‌حل در ممپلکس دوم، m^{th} راه‌حل در ممپلکس m^{th} و $(m+1)^{th}$ راه‌حل مجدداً در ممپلکس اول قرار می‌گیرد و این روند تا توزیع تمامی راه‌حل‌ها ادامه می‌یابد.

مرحله چهارم: از آنجا که تمایل قورباغه‌ها حول قورباغه‌ای خاص متمرکز می‌شود که ممکن است بهینه محلی باشد، همیشه مطلوب نیست که از بهترین قورباغه استفاده شود؛ بنابراین، زیرمجموعه‌ای از ممپلکس‌ها در نظر گرفته می‌شود که ساب ممپلکس نامیده می‌شود. در هر کدام از ممپلکس‌ها، راه‌حل‌های با بدترین و بهترین میزان شایستگی مشخص و به ترتیب با X_w و X_b نشان داده می‌شوند. همچنین، راه‌حل با بهترین مقدار شایستگی در میان کل جمعیت نیز با X_g مشخص می‌شود. در طی فرایند تکامل ممپلکس‌ها، بدترین راه‌حل به سمت بهترین راه‌حل حرکت می‌کند. در شکل (۸)، نحوه تکامل ممپلکس‌ها نشان داده شده است.

مرحله پنجم: موقعیت جدید بدتر با استفاده از قانون پرش قورباغه‌ها در الگوریتم SFL به صورت زیر محاسبه می‌شود:

$$D = rc(x_b - x_w) + w \quad (18)$$

$$x_w^{new} = \begin{cases} x_w + D & \|D\| \leq D_{max} \\ x_w + \frac{D}{\sqrt{D^T D}} D_{max} & \|D\| > D_{max} \end{cases} \quad (19)$$

که در آن، r عددی تصادفی بین ۰ و ۱، C عددی ثابت بین ۱ و ۲، r اعداد تصادفی بین ۱- تا ۱، D حداکثر مسافت مجاز پرش و w حداکثر حرکت و نفوذ مجاز است.


مرحله ششم: به‌روزرسانی بدترین جواب به‌صورت زیر:

$$\text{if } f(x_w^{new}) < f(x_w) \text{ then } x_w = x_w^{new} \quad (20)$$

در غیر این صورت، X_g جایگزین X_b می‌شود و مجدداً از معادله (۱۹) محاسبه می‌شود. در صورتی که باز هم بهبودی در جواب حاصل نشود، X_w حذف و یک راه‌حل جدید به صورت تصادفی جایگزین آن می‌شود. گفتنی است، این فرایند به عنوان جهش‌های محلی به اندازه Ns بار در الگوریتم باید انجام شود.

مرحله هفتم: این مرحله پروسه ترکیب نامیده می‌شود که در آن، تمامی جمعیت ممپلکس‌ها با یکدیگر ترکیب می‌شوند و مجدداً به مرحله دوم بازمی‌گردیم.

مرحله هشتم: چنانچه تعداد تکرارهای مشخص شده برآورده شد، فرایند بهینه‌سازی به اتمام می‌رسد.



شکل (۸): فرایند پرش در الگوریتم SFL [۲۶]

در شکل (۹)، فرایند روش پیشنهادی نمایش داده شده است، همان‌طور که در شکل دیده می‌شود، ولتاژ خروجی مبدل بوست که از طریق تغییرات سیکل کاری (d) به وسیله شبکه عصبی تولید می‌شود، با ولتاژ مرجع مقایسه و سپس میانگین مربع خطای آن برای داده‌های آموزش محاسبه می‌شود و سپس بر اساس آن، وزن‌های شبکه عصبی به‌روزرسانی

یک رویکرد نوین برای ردیابی ماکسیمم توان بر پایه شبکه عصبی با الهام از بهینه‌سازی فرا-ابتکاری در پیل‌های سوختی غشایی

می‌شوند تا در نهایت این خطا به صفر برسد.

ردیابی حداکثر توان، از مشخصات پیل سوختی بر پایه سلول سوختی غشایی تبادل پروتون استفاده شده که در جدول (۱) آورده شده است. در جدول (۲) نیز پارامترهای SFL آورده شده است.

دو سناریو مدنظر قرار گرفته شده‌اند. در سناریوی اول، دما ۳۰۰ کلوین و فشار اکسیژن و هیدروژن ثابت است و در سناریوی دوم، فشار و دما به صورت تغییرات سه‌پله‌ای ارائه می‌شود و نتایج سیستم کنترلر پیشنهادی نمایش داده خواهد شد.


۱-۵- سناریوی اول

در این حالت، به کمک داده‌های ورودی برای شبکه عصبی آن را آموزش داده‌ایم. برای آموزش شبکه عصبی، ۲۰۰۰ داده در نظر گرفته شده‌اند.


جدول (۱): اطلاعات پیل سوختی مورد مطالعه

پارامتر	مقادیر	نماد	واحد
دما	۳۰۰	T	[k]
فشار هیدروژن	۲/۴۷	PH_2	[atm]
فشار اکسیژن	۷۵	PO_2	[atm]
ثابت	۹۵۱۴/۰	λ_1	[V]
ثابت	-۰/۰۰۳۱۲	λ_2	[V.K ⁻¹]
ثابت	-۷/۴ × ۱۰-۵	λ_3	[V.K ⁻¹]
ثابت	۱/۸۷ × ۱۰-۴	λ_4	[V.K ⁻¹]
ماکسیمم چگالی جریان	۰/۰۶۲	J_{max}	A cm ⁻¹
ماکسیمم ولتاژ	۵۶/۸	V_{max}	[V]
ماکسیمم جریان	۱۳/۰۱	I_{max}	[A]
ثابت	۰/۱	η	--
تعداد سلول	۱۲	N	--
مقاومت انتقال پروتون	۰.۰۰۰۳	R_C	Ω
مبدل بوست			
خازن	50×10^{-6}	C	F
سلف	100×10^{-3}	L	H
مقاومت	۵۰	R	Ω

محدوده دما از (۲۵ تا ۵۰ درجه)، فشار عملیاتی هیدروژن



(الف): شماتیک روش شبکه عصبی آموزش داده شده با SFL




(ب): نحوه عملکرد سیستم MPPT پیشنهادی


شکل (۹): نمودارهای روش پیشنهادی پیشینه توان در پیل سوختی

۵- شبیه‌سازی و نتایج


در این قسمت، به منظور نمایش دادن عملکرد روش



شکل (۱۱): توان خروجی پیل سوختی



شکل (۱۲): ولتاژ خروجی مبدل بوست برای سه روش مختلف




شکل (۱۳): توان خروجی مبدل بوست

از P_{H_2} از ۰/۰۱ تا ۰/۶ بار و فشار عملیاتی اکسیژن P_{O_2} از ۰/۰۰۲۲ تا ۰/۰۰۲۲ بار متغیر بوده است. گفتنی است، با استفاده از رابطه ولتاژ-توان در بخش دوم، نقطه ماکسیمم توان در شرایط مختلف فشار، دما و بار در محیط متلب استخراج شده است.

جدول (۲): پارامترهای کنترلی الگوریتم بهینه‌سازی SFL

مقدار	نام متغیر
۶۰	جمعیت (N)
۶	تعداد گروه (m)
۱۰	تعداد قورباغه‌ها در هر گروه (n)
۱۰	تعداد جهش محلی (Ns)
۰/۶	حداکثر مسافت مجاز پرش (D)
۸۰	تکرار

وقتی P_{H_2} و P_{O_2} به ترتیب برابر ۰/۰۱ و ۰/۰۰۲۲ بار هستند، توان تولیدشده توسط PEMFC در کمترین مقدار نسبت به فشار سایر گازهاست. تابع فعال‌سازی لایه ورودی و لایه خروجی به ترتیب تانسینگ و پورلین است.



شکل (۱۰): ولتاژ خروجی پیل سوختی برای سه روش مختلف

یک رویکرد نوین برای ردیابی ماکسیمم توان بر پایه شبکه عصبی با الهام از بهینه‌سازی فرا-ابتکاری در پیل‌های سوختی غشایی

سریع ورودی پیل سوختی در مقایسه با سایر روش‌های بیان شده است. با استفاده از طرح کنترل MPPT پیشنهادی، بهبود ۵ درصدی در توان پیل سوختی به دست می‌آید.


در شکل‌های (۱۲) و (۱۳) نیز خروجی از ولتاژ و توان مبدل نمایش داده شده است که در روش شبکه عصبی بهینه‌شده نوسان کمتر و زمان نشست کمتری دارد. همچنین، سطح ولتاژ و توان مبدل نیز در مقایسه با دو روش سنتی و هوشمند بیشتر است که نشان از عملکرد مناسب روش دارد.

شکل (۱۴) نیز خروجی تابع هدف SFL برای رسیدن به حداقل مقدار تابع هدف را نمایش می‌دهد. در شکل (۱۵)، میانگین مربعات خطا نمایش داده شده است. در شکل دیده می‌شود در دوره‌های ۰ تا ۲۰ هر سه منحنی به سرعت کاهش داشته‌اند که نشان از عملکرد خوب روش پیشنهادی است.

در جدول (۳) نیز مقایسه‌ای میان روش پیشنهادی و روش‌های دیگر ردیابی حداکثر توان در شرایط دمایی متفاوت صورت گرفته است که نشان از دقت زیاد روش پیشنهادی دارد.


در شکل (۱۶) نیز مقایسه‌ای برحسب درصد خطا از مقدار توان خروجی واقعی در پیل سوختی برای روش‌های مختلف نمایش داده شده است که نشان از عملکرد مناسب روش شبکه عصبی بهینه‌شده توسط روش بهینه‌سازی SFL دارد. برای میانگین سه دمای مطالعه‌شده، روش‌های کلاسیک همچون P&O و InC که دو روش رایج هستند، به ترتیب حدود ۲/۹ و ۳/۴ درصد کارایی کمتری نسبت به روش پیشنهادی از خود نمایش می‌دهند. همچنین، در مقایسه با روش Fuzzy-PSO که عملکردی نسبتاً خوب دارد، روش پیشنهادی همچنان ۱/۶ درصد عملکردی بهتر را نشان می‌دهد. به علاوه، روش پیشنهادی از روش شبکه عصبی بهینه‌نشده ۱/۵ درصد عملکردی بهتر را نمایش می‌دهد.

به منظور انجام آنالیز حساسیت، دو پارامتر تعداد جهش محلی (N_s) و تعداد گروه (m) بررسی شده‌اند؛ زیرا N_s برای مدل‌سازی جست‌وجوی محلی است و m برای جست‌وجوی سراسری استفاده می‌شود.



شکل (۱۴): نمودار همگرایی روش SFL برای آموزش شبکه

عصبی



شکل (۱۵): نمودار عملکرد برای SFL

در شکل‌های (۱۰) و (۱۱)، ولتاژ و توان خروجی پیل سوختی به ترتیب نمایش داده شده‌اند و مقایسه‌ای با دو روش دیگر روش اغتشاش و مشاهده (P&O) و روش ردیابی حداکثر ولتاژ (VMPP) صورت گرفته است.

همان‌گونه که در شکل (۱۰) دیده می‌شود، سطح ولتاژ پیل برای شبکه عصبی بهینه‌شده افزایش یافته است. به علاوه، زمان نشست آن نیز در مقایسه با دو روش دیگر کمتر است.

در شکل (۱۱)، توان‌های هر سه روش با یکدیگر مقایسه شده‌اند و نتایج نشان می‌دهد روش MPPT پیشنهادی دارای دقت زیاد، پاسخ سریع و عملکرد بهتر به ویژه در تغییرات

جدول (۳): مقایسه‌ای میان روش‌های MPPT


توان واقعی پیل (وات)	P&O [4]	InC [9]	Fuzzy- P&O [32]	Ann [17]	VMPP [7]	Proposed Ann	دما (کلوین)
۶۳۳	۶۰۹	۶۰۸	۶۲۱	۶۱۸	۶۰۱	۶۲۹	۳۰۰
۶۶۱	۶۳۵	۶۳۲	۶۴۹	۶۴۶	۶۲۶	۶۵۴	۳۱۰
۷۴۲	۷۱۶	۷۱۱	۷۲۸	۷۲۴	۷۰۱	۷۳۵	۳۲۰

از شکل (۱۶) دیده می‌شود که روش پیشنهادی دارای خطای کمتر از یک درصد برای دمای عملیاتی ۳۰۰ کلوین است و برای دمای عملیاتی ۳۱۰ کلوین، خطای آن نزدیک به ۱/۰۳۴ درصد است.


برای انجام آن، ۲۰ بار الگوریتم بهینه‌سازی اجرا شده است و مقدار متوسط تابع هدف RMSE برای هر دو حالت در شکل‌های (۱۷) و (۱۸) نمایش داده شده است. کمترین مقدار در شکل‌های (۱۷) و (۱۸) در واقع نشان‌دهنده بهترین انتخاب پارامتر برای داشتن کمترین مقدار تابع هدف خواهد بود. برای آنالیز حساسیت m ، تعداد جهش محلی ثابت فرض می‌شود و مقدار تابع هدف برای مقادیر مختلف m محاسبه می‌شود. برای آنالیز حساسیت Ns ، تعداد گروه‌ها ثابت فرض می‌شود و مقدار تابع هدف برای مقادیر مختلف Ns محاسبه می‌شود. با توجه به شکل‌های (۱۷) و (۱۸)، بهترین تنظیم برای آموزش شبکه عصبی بر اساس الگوریتم SFL، تعداد گروه ۶ و تعداد جهش محلی ۱۰ است.

۵-۲- سناریوی دوم


در این سناریو، یک فشار هیدروژن سه‌سطحی و یک دمای متغیر سه‌سطحی مطابق شکل‌های (۱۹) و (۲۰) در نظر گرفته شده است. توان و ولتاژ برای این تغییر دما و فشار نمایش داده شده‌اند که در شکل‌های (۲۱) و (۲۲) آورده شده‌اند. شبکه عصبی به‌خوبی توانسته است تغییرات فشار و دما را دنبال کند و توان ماکسیمم در خروجی مبدل پوست به بار تحویل دهد. نتایج شبیه‌سازی کارایی روش پیشنهادی را نشان داد. در واقع، برای موقعیت‌ها و شرایط مختلف، الگوریتم پیشنهادی توانسته است سیکل کاری مبدل را به‌خوبی تنظیم کند تا حداکثر توان را همان‌طور که در نتایج ارائه شده است، به دست آورد.



شکل (۱۶): درصد خطا از مقدار توان خروجی واقعی در پیل سوختی برای روش‌های مختلف



شکل (۱۷): آنالیز حساسیت برای تعداد گروه‌های مختلف




شکل (۱۸): آنالیز حساسیت برای تعداد جهش محلی مختلف

۶- نتیجه‌گیری


در این مقاله، یک روش ردیابی توان به همراه مبدل بوست و پیل سوختی بر پایه شبکه عصبی و بهینه‌سازی جهش قورباغه در محیط متلب ارائه شد. برای نمایش کارایی روش پیشنهادی، دو سناریو مدل‌سازی شدند که در سناریوی اول، تابش و دمای ثابت برای پیل سوختی فراهم شد و نتایج آن با روش‌های کلاسیک همچون P&O با گام ثابت مقایسه شد که نشان از دقت زیاد روش در تحویل توان ماکسیمم به بار داشت. به علاوه، در سه دمای عملیاتی، نتایج با روش‌هایی جدید همچون P&O با ساختار فازی و شبکه عصبی با روش آموزش سستی مقایسه شد. روش‌های کلاسیک همچون P&O و InC که دو روش رایج هستند، به ترتیب حدود $2/9$ و $3/4$ درصد کارایی کمتری نسبت به روش پیشنهادی از خود نمایش دادند. همچنین، در مقایسه با روش ترکیبی فازی بهینه‌شده که عملکردی نسبتاً خوب داشت، روش پیشنهادی $1/6$ درصد عملکردی بهتر را نشان داد. در سناریوی دوم نیز، یک تغییر در دما و تابش ورودی اعمال شد و بدون نیاز به آموزش شبکه عصبی، توان ماکسیمم با حداقل نوسانات و زمان نشست کم به بار تحویل داده شد که نشان از توانایی زیاد روش پیشنهادی دارد. در حالت کلی، مزایای شبکه عصبی بهینه‌شده را می‌توان افزایش سرعت ردیابی، دقت زیاد، عملکرد مناسب در شرایط متغیر دما و تابش، عدم نوسان در نقطه حداکثر توان و در نتیجه، کاهش تلفات انرژی دانست. اما روش پیشنهادی معایبی نیز دارد که از جمله می‌توان به وابستگی به داده‌های آموزشی، هزینه زیاد اجرای سخت‌افزاری و نیز در صورت تغییر در پارامترهای سیستم، نیاز به آموزش مجدد را نام برد.

مراجع


- [1] Y. Awin, N. Dukhan, "Experimental performance assessment of metal-foam flow fields for proton exchange membrane fuel cells", *Applied Energy*, Vol. 252, 2019. <https://doi.org/10.1016/j.apenergy.2019.113458>
- [2] A. Kirubakaran, S. Jain, R. K. Nema, "A review on fuel cell technologies and power electronic interface", *Renew. Sustain. Energy Rev.* Vol. 13, pp. 2430–2440, 2009. <https://doi.org/10.1016/j.rser.2009.04.004>
- [3] R. Putala, V. Ferencey, "Hydrogen Fuel Cell System Modeling Approaches", 2025




شکل (۱۹): فشار هیدروژن متغیر برای آزمودن شبکه عصبی



شکل (۲۰): دمای متغیر برای آزمودن شبکه عصبی



شکل (۲۱): توان خروجی مبدل بوست



شکل (۲۲): ولتاژ خروجی مبدل بوست

- fluctuating atmospheric conditions”, *Journal of Intelligent & Fuzzy Systems*, Vol. 42, No. 2, pp. 807–816, 2022. <https://doi.org/10.3233/JIFS-189750>
- [12] R. B. Bollipo, S. Mikkili, P. K. Bonthagorla, “Hybrid, optimization, intelligent and classical PV MPPT techniques: A Review”, *CSEE J. Power Energy Syst.*, Vol. 7, pp. 9–33. *Energies*, 2023. <https://doi.org/10.17775/cseejpes.2019.02720>
- [13] Y. Fang, Y. Zhu, J. Fei, “Adaptive Intelligent Sliding Mode Control of a Photovoltaic Grid-Connected Inverter”, *Appl. Sci.* Vol. 8, pp. 1749–1756, 2018. <http://dx.doi.org/10.3390/app8101756>
- [14] K. Tsang, W. Chan, “Maximum power point tracking for PV systems under partial shading conditions using current sweeping. *Energy Convers.*”, *Manag.*, Vol. 93, pp. 249–258, 2015. <https://doi.org/10.1016/j.enconman.2015.01.029>
- [15] S. J. Ankar, M. Sivanesan, K. P. Pinkymol, “Load-Following Control and Fuzzy Logic-Based Energy Management in Fuel Cell Hybrid Electric Vehicles”, 2025 IEEE Energy Conversion Congress & Exposition Asia (ECCE-Asia), Bengaluru, India, pp. 1-6, 2025. <https://doi.org/10.1109/ECCE-Asia63110.2025.11111887>
- [16] C. Larbes, S. A. Cheikh, T. Obeidi, A. Zerguerras, “Genetic algorithms optimized fuzzy logic control for the maximum power point tracking in photovoltaic system”, *Renewable Energy*, Vol. 34, No. 10, pp. 2093–2100, 2009. <https://doi.org/10.1016/j.renene.2009.01.006>
- [17] S. V. Krishna, C. H. Basha, B. Sahoo, S. Rafikiran, “A Novel Development of ANN-fed Fuel Cell for Hybrid Electric Vehicles, *International Conference on Computing Technologies & Data Communication*, HASSAN, India, pp. 1-6, 2025. <https://doi.org/10.1109/ICCTDC64446.2025.11158776>
- [18] J. H. Zhang, X. Y. Wei, L. J. G. HuMa, “A MPPT Method based on improved Fibonacci search photovoltaic array”, *Teh. Vjesn.*, Vol. 26, pp. 163–170, 2019. <https://doi.org/10.17559/TV-20180721153103>
- [19] S. Hadji, J. P. Gaubert, F. Krim, “Real-Time Genetic Algorithms-Based MPPT: Study and Comparison (Theoretical and Experimental) with Conventional Methods”, *Energies*, Vol. 11, pp. 450–459, 2018. <https://doi.org/10.3390/en11020459>
- [20] Y. Wang, G. Wu, C. Ye, P. Li, Y. Wang, “Neural Network Control for Fuel Cell Boost Converter Based on Particle Swarm Cybernetics & Informatics (K&I), Mikulov na Morave, Czech Republic, pp. 1-7, 2025. <https://doi.org/10.1109/KI64036.2025.10916424>
- [4] H. A. Sher, A. F. Murtaza, A. Noman, K. E. Addoweesh, K. Al-Haddad, M. Chiaberge, “A new sensorless hybrid MPPT algorithm based on fractional short-circuit current measurement and P&O MPPT”, *IEEE Trans. Sustain. Energy*, Vol. 6, pp. 1426–1434, 2015. <https://doi.org/10.1109/TSTE.2015.2438781>
- [5] F. Mokhliss, E. A. Chater, N. Laaroussi, “Comparative Study of IC and P&O MPPT Techniques for Fuel Cell System Control”, 2025 5th International Conference on Innovative Research in Applied Science, Engineering and Technology, Fez, Morocco, pp. 1-6, 2025. <https://ieeexplore.ieee.org/document/11008282>
- [6] G. Anusha, A. Sudhakar, S. Rafikiran, R. R. Deshmukh, C. H. Basha, “Modeling of a Fuel Cell with Boost Converter Using Artificial Neural Network”, 2025 International Conference on Visual Analytics and Data Visualization), Tirunelveli, India, pp. 683–690, 2025. <https://ieeexplore.ieee.org/document/10961057>
- [7] G. Sreedhar, C. H. Basha, S. Rafikiran, A. Sudhakar, F. Alsaif, S. Senthilkumar, “Development of VSS-FOCV and IC MPPT Controllers for PEMFC Systems”, 2025 International Conference on Visual Analytics and Data Visualization, Tirunelveli, India, pp. 676–682, 2025. <https://ieeexplore.ieee.org/document/10960861>
- [8] A. Harrag, S. Messalti, “Variable Step Size IC MPPT Controller for PEMFC Power System Improving Static and Dynamic Performances”, *Fuel Cells*, Vol. 17, pp. 816–824, 2017. <https://doi.org/10.1002/fuce.201700047>
- [9] M. U. Burhani, J. S. Panggabean, T. Adiono, I. Syafalni, N. Sutisna, “Variable Clock Frequency for Incremental Conductance MPPT Performance”, 2023 IEEE 66th International Midwest Symposium on Circuits and Systems (MWSCAS), Tempe, AZ, USA, pp. 250–254, 2023. <https://doi.org/10.1109/MWSCAS57524.2023.10406007>
- [10] N. Bizon, P. Thounthong, M. Raducu, L. M. Constantinescu, “Designing and modelling of the asymptotic perturbed extremum seeking control scheme for tracking the global extreme”, *Int. J. Hydrog. Energy*, Vol. 42, pp. 17632–17644, 2017. <https://doi.org/10.1016/j.ijhydene.2017.01.086>
- [11] I. Pervez, A. Sarwar, A. Alam, M. Tariq, R. K. Chakraborty, M. J. Ryan, “An MPPT method using hybrid radial movement optimization with teaching-learning based optimization under

- <https://doi.org/10.3390/en13020371>
- [29] M. Abedini, "A variable maximum power tracking method based on fuzzy logic for solar systems", *Fuzzy Systems and its Applications*, pp. 151-174, 2023. <https://doi.org/10.22034/jfsa.2023.385336.1161> [In persian]
- [30] J. Y. Fam, S. Y. Wong, H. B. M. Basri, M. O. Abdullah, K. B. Lias, and S. Mekhilef, "Predictive Maximum Power Point Tracking for Proton Exchange Membrane Fuel Cell System," in *IEEE Access*, vol. 9, pp. 157384-157397, 2021. [https://doi: 10.1109/ACCESS.2021.3129849](https://doi.org/10.1109/ACCESS.2021.3129849).
- [31] I. Soltani, "An intelligent, fast, and robust maximum power point tracking for proton exchange membrane fuel cell", *World Appl. Program*, Vol. 3, pp. 264281, Jul. 2013. <https://www.academia.edu/4729395/>
- [32] M. Zerouali, S. Zouirech, A. E. Ougli, B. Tidhaf, H. Zrouri, "Improvement of Conventional MPPT Techniques P&O and INC by Integration of Fuzzy Logic", 2019 7th International Renewable and Sustainable Energy Conference (IRSEC), Agadir, Morocco, pp. 1-6, 2019. <https://doi.org/10.1109/IRSEC48032.2019.9078330>
- [33] A. Salmanpour, M. Berahman, "Memristor Bridge Synapse Application for Integrate and Fire and Hodgkin-Huxley Neuron Cell", *Journal of Iranian Association of Electrical and Electronics Engineers*, Vol. 20, pp. 9-14, 2023. <https://dor.isc.ac/dor/20.1001.1.26765810.1402.20.1.2.5>
- [34] M. H. Nehrir, C. Wang, "Dynamic Modeling and Simulation of PEM Fuel Cells", in *Modeling and Control of Fuel Cells: Distributed Generation Applications*, IEEE, pp.57-84, 2009. <https://doi.org/10.1109/9780470443569.ch3>
- Optimization", 2024 China Automation Congress (CAC), Qingdao, China, pp. 1611-1615, 2024. <https://doi.org/10.1109/CAC63892.2024.10865696>
- [21] S. Purushothaman, H. Senthamarai, S. R. Pillai, M. J. Prasanna, M. Dhanush, "Soft Switching Technique in a Modified SEPIC Converter with MPPT using Cuckoo Search Algorithm", *Recent Advances in Electrical & Electronic Engineering (Formerly Recent Patents on Electrical & Electronic Engineering)*, Vol. 17, No. 9, pp. 896-907. 2024. <https://doi.org/10.2174/0123520965263412231031060225>
- [22] B. Rismanchi, M. Akbari, "Performance prediction of proton exchange membrane fuel cells using a three-dimensional model", *Int. J. Hydrog. Energy*, Vol. 33, pp. 439– 448, 2008. <https://doi.org/10.1016/j.ijhydene.2007.07.046>
- [23] S. Ahmadi, S. Abdi, M. Kakavand, "Maximum power point tracking of a proton exchange membrane fuel cell system using PSO-PID controller", *Int. J. Hydrogen Energy*, Vol. 42, No. 32, pp. 20430–20443, Aug. 2017. <https://doi.org/10.1016/j.ijhydene.2017.06.208>
- [24] M. Derbeli, O. Barambones, L. Sbita, "A Robust Maximum Power Point Tracking Control Method for a PEM Fuel Cell Power System", *Appl. Sci.*, Vol. 8, pp. 2440-2449, 2018. <https://doi.org/10.3390/app8122449>
- [25] A. Mohamed, H. Ibrahim, K. -B. Kim, "PEM Fuel Cell Design Simulation for Electric Vehicles Using Artificial Neural Networks", 2022 IEEE International Conference on Consumer Electronics (ICCE), Las Vegas, NV, USA, pp. 1-4, 2022. <https://doi.org/10.1109/ICCE53296.2022.9730347>
- [26] H. MoayediBui, D. T. Bui, P. T. Thi Ngo, "Shuffled Frog Leaping Algorithm and Wind-Driven Optimization Technique Modified with Multilayer Perceptron", *Applied Sciences*, Vol. 10, No. 2, pp. 684-689, 2020. <https://doi.org/10.3390/app10020689>
- [27] A. G. Al-Gizi, A. Craciunescu, S. J. Al-Chlahawi, "The use of ANN to supervise the PV MPPT based on FLC", in 2017 10th International Symposium on Advanced Topics in Electrical Engineering (ATEE), pp. 703–708, Bucharest, Romania, 2017. <https://doi.org/10.1109/ATEE.2017.7905128>
- [28] C. Basha, C. Rani, "Different conventional and soft computing MPPT techniques for solar PV systems with high step-up boost converters: a comprehensive analysis", *Energies*, Vol. 13, No. 2, pp. 371, 2020.

-
- ¹ Proton-exchange membrane fuel cells (PEMFC)
 - ² Direct Methanol Fuel Cell (DMFC)
 - ³ Alkaline fuel cell (AFC)
 - ⁴ Phosphoric acid fuel cells (PAFC)
 - ⁵ Molten-carbonate fuel cells (MCFC)
 - ⁶ Solid Oxide Fuel Cells (SOFC)
 - ⁷ Zinc air fuel cell (ZAFC)
 - ⁸ Protonic ceramic fuel cell (PCFC)
 - ⁹ Maximum Power Point Tracking (MPPT)
 - ¹⁰ Perturbation & Observation (P&O)
 - ¹¹ Artificial neural networks (Ann)
 - ¹² Frog Algorithm
 - ¹³ Memetic

یک رویکرد نوین برای ردیابی ماکسیمم توان بر پایه شبکه عصبی با الهام از بهینه‌سازی فرا-ابتکاری در پیل‌های سوختی غشایی