

مدل سازی نیروی رانش القایی و توان الکتریکی مصرفی محرک پلاسمای DBD با استفاده از شبکه عصبی و الگوریتم ژنتیک

محمدرضا حسینی

دانشجوی دکتری، مجتمع دانشگاهی هوافضا، دانشگاه صنعتی مالک اشتر، تهران، ایران،
mr.hosseini.1368@gmail.com

یوسف عباسی*

استادیار، مجتمع دانشگاهی هوافضا، دانشگاه صنعتی مالک اشتر، تهران، ایران، yosefabbasi@mut.ac.ir

رضا اسماعیل زاده اول

دانشیار، مجتمع دانشگاهی هوافضا، دانشگاه صنعتی مالک اشتر، تهران، ایران، rsmael@gmail.com

غلامحسین پور یوسفی

استادیار، دانشکده مهندسی هوافضا، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران،
pouryoussefi@kntu.ac.ir

چکیده

در پژوهش حاضر با هدف بهره‌مندی از مزایای مدل‌سازی سیستم‌ها برای محرک‌های پلاسمایی تخلیه مانع دی‌الکتریک یا DBD، ابتدا به کمک شبکه عصبی مصنوعی برای نیروی رانش القایی و توان الکتریکی مصرفی متناظر با آن، مدلی مبتنی بر داده‌های آزمایشگاهی موجود تولید شده است. سپس به منظور بهبود فرآیند آموزش شبکه عصبی و افزایش دقت مدل، الگوریتم ژنتیک مورد استفاده قرار گرفته است. بررسی معیارهای همبستگی و کمینه کردن خطا، اشاره به عملکرد و دقت مناسب مدل داشته و ترکیب الگوریتم ژنتیک با شبکه عصبی را به عنوان روش مناسبی برای افزایش دقت مدل گزارش می‌کند. در خاتمه نیز با هدف بررسی تعمیم‌دهی مدل برای داده‌های جدیدی که در فرآیند مدل‌سازی از آن‌ها استفاده نشده است، یک آزمون تجربی اجرا گردیده، تا نتایج آزمایشگاهی جدید با نتایج خروجی مدل مورد ارزیابی قرار گیرند.

واژه‌های کلیدی: محرک پلاسمایی DBD، رانش القایی، توان مصرفی، مدل‌سازی، شبکه عصبی مصنوعی، الگوریتم ژنتیک.

Modeling of Induced Momentum Force and Electrical Power Consumption of DBD Plasma Actuator Using Neural Network and Genetic Algorithm

M. R. Hosseini

Department of Aerospace, Malek Ashtar University of Technology, Tehran, Iran

Y. Abbasi

Department of Aerospace, Malek Ashtar University of Technology, Tehran, Iran

R. Esmaelzadeh Aval

Department of Aerospace, Malek Ashtar University of Technology, Tehran, Iran

Gh. Pouryoussefi

Department of Aerospace Engineering, K.N. Toosi University of Technology, Tehran, Iran

Abstract

In this research, to leverage the advantages of system modeling for dielectric barrier discharge (DBD) plasma actuators, an artificial neural network model was initially developed based on available experimental data to predict the induced momentum force and its corresponding electrical power consumption. Subsequently, a genetic algorithm was employed to optimize the training process of the neural network and enhance the model accuracy. By examining correlation coefficients and minimizing errors, the study indicates that the model performs well and that the combination of genetic algorithm and neural network is an effective approach to improve model accuracy. Finally, to evaluate the model's generalization capability to novel data not encountered during the training phase, an experimental test was conducted. The results of this test were compared with the model's predictions.

Keywords: DBD Plasma Actuator, Induced Momentum, Power Consumption, Modeling, Artificial Neural Network (ANN), Genetic Algorithm (GA).

۱- مقدمه

نداشتن قسمت‌های متحرک، زمان پاسخ بسیار کوتاه، وزن بسیار پایین، توان مصرفی پایین، عدم نیاز به برداشتن محرک در مواقعی که به آن نیاز نیست و کارایی نسبتاً خوب در تبدیل انرژی الکتریکی به انرژی مکانیکی است.


امروزه محرک‌های پلاسمایی به دلیل امکان ایجاد یک نیروی خالص حجمی که از آن به عنوان مومنتوم القایی پلازما یاد می‌شود، بسیار مورد توجه قرار گرفته‌اند و از روش‌های نوین مطرح در علم کنترل فعال جریان و حوزه میکرو رانشگرها هستند. یکی از انواع محرک‌های پلاسمایی سرد که در حوزه پژوهش‌های رانشگرهای

محرک‌های پلاسمایی^۱ در مقایسه با روش‌های متداول گذشته، ابزارهای نوینی هستند که به منظور کنترل جریان هوا و بهبود عملکرد آپروپدینامیکی در سیستم‌های مختلف به کار می‌روند. این محرک‌ها با استفاده از تخلیه پلازما، می‌توانند جریان هوا را به صورت فعال کنترل کنند که با توجه به پتانسیل آن‌ها، در پژوهش‌های حوزه هوایی و فضایی اهمیت بسیار زیادی پیدا کرده‌اند. مزیت عمده این محرک‌ها، عدم وجود قطعات متحرک، کاربرد ساده، قابلیت اطمینان بالا به دلیل

^۱ Plasma Actuators

هوافضایی نیز کاربرد دارد، محرک‌های پلاسمایی نوع تخلیه مانع دی‌الکتریک^۱ یا همان محرک‌های DBD هستند [۱].


مفهوم تخلیه مانع دی‌الکتریک (DBD) اولین بار برای تولید ازن توسط ورنر فون زیمنس^۲ در سال ۱۸۵۷ پیشنهاد شد. همان‌طور که در شکل ۱ نشان داده شده است، این محرک‌ها از دو الکترود مستطیلی شکل تشکیل شده‌اند که میان آن‌ها یک مانع دی‌الکتریک قرار گرفته است. به الکترودی که زیر عایق قرار می‌گیرد، الکترود پوشیده و به الکترود دیگر، در معرض هوا می‌گویند.



شکل ۱- نمای سه بعدی طرح‌واره‌ی محرک پلاسمایی DBD [۲]

در صورتیکه ولتاژ متناوب بزرگی به الکترودهای محرک اعمال شود، میدان الکتریکی قوی شکل خواهد گرفت که موجب یونیزه شدن هوای بالای الکترودها و تشکیل پلازما می‌شود. در نتیجه این اتفاق جریان القایی باد یونی از الکترود در معرض هوا به سمت الکترود پوشیده به وجود می‌آید. تشکیل پلازما و حرکت ذرات باردار شتابدار در نهایت باعث اعمال یک نیروی حجمی مؤثر بر ذرات خنثی هوا در اطراف محرک می‌شود. این نیرو مکانیزم مورد استفاده در کنترل فعال جریان است [۳ و ۴].

در شکل ۲، طرح‌واره‌ی یک رانشگر پلاسمایی الکتریکی سرد نشان داده شده است. همانگونه که مشاهده می‌شود اساس این نوع رانشگر، از یک محرک پلاسمایی DBD تشکیل شده است که از طریق ایجاد یک جریان القایی باد یونی (تولید مومنتوم القایی ناشی از تخلیه پلازما)، نهایتاً باعث تولید نیروی مومنتوم (رانش القایی) می‌شود.



شکل ۲- طرح‌واره رانشگر DBD با هدف ایجاد نیروی رانش [۵]

نخستین بار براون در سال ۱۹۲۸ پیشنهاد استفاده از باد یونی را برای تولید نیرو مطرح کرده است [۶]. از آن زمان تاکنون مطالعاتی بر روی کارایی رانشگرهای الکترودینامیکی^۳ انجام شده است. ماسویاما

و برت پتانسیل جلوبرنده‌های الکترودینامیکی را در مقیاس آزمایشگاهی مورد بررسی قرار داده‌اند که از نتایج آن می‌توان به قابل مقایسه بودن نسبت رانش به توان این نوع از رانشگرها با جلوبرنده‌های جت مرسوم اشاره کرد [۷]. در سال ۱۹۶۷ نیز اولین مقاله در رابطه با رانشگرهای الکترودینامیکی منتشر شده است [۸].

بهبود عملکرد محرک‌های پلاسمایی از طریق بیشینه کردن نیروی رانش تولیدی و کمینه کردن توان الکتریکی مصرفی، وابسته به شناخت و مطالعه متغیرهای مؤثر بر عملکرد این نوع از محرک‌ها است. این متغیرها عبارتند از [۹]:

۱. متغیرهای الکتریکی: مانند ولتاژ، فرکانس حامل و شکل موج ولتاژ در تحریک پایه، فرکانس تحریک و سیکل کاری در تحریک ناپایا.
۲. متغیرهای هندسی: مانند پهنای الکترودها، ضخامت دی‌الکتریک و فاصله‌ی بین الکترودها.

۳. متغیرهای ساختاری: مانند جنس دی‌الکتریک و الکترودها.

۴. متغیرهای محیطی: مانند فشار، دما و رطوبت نسبی محیط.

از این رو پژوهشگران با رویکردهای مختلف به مطالعه پارامتری این نوع محرک‌های پلاسمایی پرداخته‌اند. به عنوان مثال می‌توان به بررسی اثر شکل موج ولتاژ، پهنای الکترود پوشیده، و ضخامت دی‌الکتریک [۱۰] و اثر فرکانس و جنس دی‌الکتریک بر نیروی رانش [۱۱]. مطالعه انتخاب مواد با ثابت دی‌الکتریک متفاوت [۱۲]. چگونگی اثر فشار و دمای هوای اطراف محرک بر نیروی رانش [۱۳]. اثر طول الکترود بر نیروی رانش و توان مصرفی محرک [۱۴]. تغییر در هندسه، چیدمان و زاویه نصب المان‌های محرک [۱۵ و ۱۶]. و بهبود عملکرد و نیروی رانش به کمک نسل جدید رانشگرهای DBD سه الکتروده [۱۷] و یا تحت میدان مغناطیسی خارجی [۱۸] اشاره نمود.

با بررسی پیشینه پژوهش‌های انجام شده در این حوزه، این مطلب مشخص می‌شود که بخش زیادی از پژوهش‌ها به شناسایی متغیرهای مؤثر بر نیروی رانش تولیدی توسط محرک و بهبود آن پرداخته‌اند. هدف این پژوهش‌ها، افزایش چگالی پلازما و شتابدار کردن یون‌ها با بالاترین سرعت ممکن برای انتقال بیشترین مومنتوم ممکن به هوای خنثی اطراف محرک، از طریق تغییر آرایش خطوط میدان الکتریکی و گرادیان آن است. در نتیجه، این اتفاق باعث افزایش نیروی رانش تولیدی می‌شود.

از طرفی اجرای آزمون‌های آزمایشگاهی به منظور مطالعه یک پدیده و یا بررسی پارامترهای مؤثر بر آن معمولاً سخت و زمان‌بر بوده و نیازمند شرایط و تجهیزات آزمایشگاهی خاص است. مدل‌سازی پدیده‌ها یکی از ابزارهای قدرتمند در علوم و مهندسی است که به درک، تحلیل، و پیش‌بینی رفتار سیستم‌ها کمک می‌کند. این امر در رابطه با مطالعه تجربی پلازما و محرک‌های پلاسمایی اهمیتی دو چندان پیدا می‌کند. چرا که از طرفی تجهیزات آزمایشگاهی مورد نیاز پیچیده و گران قیمت بوده و تأمین آن‌ها دشوار است، و از طرف دیگر اجرای آزمون‌های تجربی نیازمند به شرایط ایمنی و محیطی مخصوص می‌باشد.

مدل‌سازی با استفاده از شبکه عصبی مصنوعی^۴ یکی از روش‌های پیشرفته و مؤثر در تحلیل داده‌ها و پدیده‌های پیچیده است. این روش

⁴ Artificial Neural Network (ANN)


¹ Dielectric Barrier Discharge

² Werner von Siemens

³ EAD Thrusters

مؤثرترین روش‌ها در زمینه یادگیری ماشین و هوش مصنوعی است. این تکنیک به ویژه در تحلیل داده‌های پیچیده و غیرخطی کاربرد دارد و به محققان و مهندسان این امکان را می‌دهد که رفتار سیستم‌های مختلف را شبیه‌سازی کنند [۲۵]. شبکه‌های عصبی مصنوعی از ساختار مغز انسان الهام گرفته و به عنوان یک ابزار محاسباتی برای شناسایی الگوها و یادگیری از داده‌ها توسعه یافته‌اند. از زمان معرفی اولین مدل‌های شبکه عصبی در دهه ۱۹۵۰، این تکنیک به طور مداوم تکامل یافته و به یکی از ارکان اصلی تحقیقات و کاربردهای هوش مصنوعی تبدیل شده است [۲۶].

شبکه عصبی مصنوعی معادل مصنوعی مغز بیولوژیکی است و می‌توان آن را به عنوان شبکه‌ای موازی و به هم پیوسته از عناصر محاسباتی که به عنوان نورون‌های مصنوعی شناخته می‌شوند، توصیف کرد. در شکل ۳ طرحواره یک نورون مصنوعی نمایش داده شده است. در این مدل که مدل نرون مک‌کلوج-پیتز^۲ نامیده می‌شود، هر کدام از سیگنال‌های ورودی در یک وزن موسوم به وزن‌های سیناپسی ضرب و سپس با مقدار بایاس جمع می‌شوند و از یک تابع غیرخطی موسوم به تابع فعال‌سازی عبور و خروجی را تولید می‌کنند.



شکل ۳- طرحواره مدل مک‌کلوج پیتز برای یک نورون [۲۵]

از نظر ریاضی، نورون k نشان داده شده در شکل ۳ را می‌توان با معادله زیر توصیف کرد:

$$y_k = \varphi\left(\sum_{j=1}^m w_{kj} x_j + b_k\right) \quad (1)$$

در رابطه بالا y_k خروجی نورون، φ تابع فعال‌سازی، w_{kj} وزن‌های سیناپسی مربوطه نورون k ، x_j ورودی‌ها و b_k معرف بایاس است. شبکه‌ی عصبی پرسپترون^۳ نوع خاصی از شبکه‌های عصبی است که در آن هر نورون به تمامی نورون‌های لایه‌ی پیشین خود متصل و تمامی اتصال‌ها از نوع پیشرو و فقط بین لایه‌های مجاور است [۲۷]. شبکه‌های عصبی پرسپترون چندلایه^۴ از توسعه شبکه پرسپترون ساده به وجود می‌آیند که در آن‌ها نورون‌ها در چندین لایه سازماندهی می‌شوند. این شبکه‌ها قادرند با انتخاب مناسب تعداد لایه‌ها و نورون‌ها، که اغلب هم زیاد نیستند، یک نگاشت غیرخطی را با دقت دلخواه انجام دهند [۲۵]. در شکل ۴ یک تصویر شماتیک از یک MLP سه لایه، متشکل از دو لایه پنهان و یک لایه خروجی نشان داده شده است.

به دلیل قابلیت‌های خاص خود، نظیر توانایی یادگیری غیرخطی [۱۹]، قابلیت تعمیم‌دهی [۲۰]، مقاومت در برابر نویز [۲۱]، پتانسیل برای پردازش داده‌های حجیم [۲۲]، انعطاف‌پذیری در مدل‌سازی انواع داده‌ها [۲۳]، خودآموزی و بهبود مستمر [۲۴]، به یکی از ابزارهای اصلی در تحلیل داده‌های پیچیده و مدل‌سازی پدیده‌های غیرخطی تبدیل شده است. همچنین الگوریتم ژنتیک^۱ نیز یکی از روش‌های بهینه‌سازی است که از اصول تکامل طبیعی و نظریه انتخاب طبیعی الهام گرفته شده است. این الگوریتم به دلیل مزایای فراوان در بسیاری از مسائل بهینه‌سازی پیچیده کاربرد دارد. ترکیب شبکه عصبی با الگوریتم ژنتیک یک رویکرد قدرتمند و کارآمد در حل مسائل پیچیده بهینه‌سازی و یادگیری ماشین است. این ترکیب، مزایای منحصر به فردی دارد که باعث بهبود فرآیند آموزش شبکه عصبی می‌شود.

در نتیجه با توجه به موارد ذکر شده، استفاده از شبکه عصبی می‌تواند ابزار مفیدی برای مدل‌سازی عملکرد محرک‌های پلاسمایی باشد.

آنچه در این پژوهش به آن پرداخته شده و وجه تمایز سایر مطالعات صورت گرفته در حوزه رانش القایی محرک‌های DBD می‌باشد، استفاده از روش شبکه عصبی مصنوعی برای مدل‌سازی عملکرد نیروی رانش همراه با بررسی توان الکتریکی وابسته به آن است. همچنین به منظور افزایش دقت مدل، الگوریتم ژنتیک برای بهبود فرآیند آموزش شبکه عصبی مورد استفاده قرار گرفته است. در خاتمه نیز برای ارزیابی بهتر، خروجی مدل‌ها با نتایج حاصل از اجرای آزمون آزمایشگاهی بررسی شده است.

در ادامه ابتدا مفهوم و نظریه‌های لازم برای مدل‌سازی به کمک شبکه عصبی مصنوعی ارائه شده و سپس الگوریتم ژنتیک به عنوان یک روش بهینه‌سازی قوی برای ترکیب با شبکه عصبی معرفی می‌شود. پس از آن، مجموعه داده‌های تجربی مورد استفاده در بخش اول مدل‌سازی و روش و تجهیزات آزمون لازم برای داده‌های تجربی جدید معرفی می‌گردد. تنظیمات و خروجی‌های مدل و سپس تنظیمات و خروجی‌های شبکه تعلیم داده شده با الگوریتم ژنتیک ارائه و در خاتمه، مدل‌ها با نتایج آزمون تجربی جدید مورد ارزیابی قرار گرفته است.

۲- روش مدل‌سازی

در اکثر مسائل طراحی مهندسی رابطه بین تابع هدف و متغیرهای طراحی به صورت تحلیلی موجود نیست، و برای شناسایی و تعیین این رابطه، آزمایش‌ها و یا شبیه‌سازی‌های فراوانی باید انجام شود. انجام هر کدام از این آزمایش‌ها و شبیه‌سازی‌ها، در بیشتر موارد گران و زمان‌بر است [۹]. یکی از راه‌های برطرف کردن این مشکل، استفاده از مدل‌های تقریبی موسوم به مدل‌های جانشین است. در سال‌های اخیر، شبکه‌های عصبی مصنوعی به عنوان مدل‌های جانشین کارایی فوق‌العاده‌ای را از خود نشان داده‌اند [۹].

۲-۱- شبکه عصبی مصنوعی

مدل‌سازی با استفاده از شبکه‌های عصبی، یکی از مهم‌ترین و

^۲ McCulloch-Pitts


^۳ Perceptron neural network

^۴ Multilayer Perceptron (MLP)

^۱ Genetic Algorithm (GA)

۲-۲- الگوریتم ژنتیک

الگوریتم ژنتیک یک روش جستجو و بهینه‌سازی بسیار محبوب برای حل مسائل بسیار پیچیده است که موفقیت روش‌های آن در زمینه‌های مربوط به رویکردهای یادگیری ماشین^۲ به اثبات رسیده است [۲۸]. این الگوریتم ابتدا توسط جان هالند در دهه ۱۹۷۰ معرفی شد و از آن زمان به عنوان یکی از پرکاربردترین روش‌ها در حل مسائل بهینه‌سازی شناخته می‌شود [۲۹]. الگوریتم ژنتیک با استفاده از مکانیزم‌هایی نظیر انتخاب، ترکیب^۳ و جهش^۴، به دنبال بهینه‌سازی تابع هدف در فضای جستجو می‌گردد. در این روش، ابتدا جمعیتی از جواب‌های ممکن به صورت تصادفی تولید می‌شود. سپس با ارزیابی هر یک از این جواب‌ها بر اساس یک تابع برازش^۵، بهترین افراد برای تولید نسل‌های بعدی انتخاب می‌شوند. این فرآیند تا زمانی ادامه می‌یابد که شرط توقفی مانند تعداد تکرارها یا رسیدن به حداقل بهبود در جواب‌ها برآورده شود. در شکل ۶ روندنمای الگوریتم ژنتیک استاندارد نمایش داده شده است [۲۸].



شکل ۶- روندنمای الگوریتم ژنتیک استاندارد (GA) [۲۸]

اولین گام شامل ایجاد یک جمعیت اولیه از کروموزوم‌ها (راه‌حل‌های ممکن) است. راه‌حل‌های ممکن به شکل رشته‌هایی با نام کروموزوم^۶ نمایش داده می‌شوند. هر کروموزوم معمولاً به صورت یک بردار باینری یا عددی کدگذاری می‌شود. به عنوان مثال:


$$\text{Chromosome} = [x_1, x_2, \dots, x_n] \quad (3)$$

که x_i ها ژن‌های کروموزوم هستند. برای ارزیابی کیفیت هر کروموزوم، تابع برازندگی همانند رابطه زیر به کار می‌رود:

$$f(x) = f(x_1, x_2, \dots, x_n) \quad (4)$$

در رابطه فوق، $f(x)$ مقدار برازندگی یک کروموزوم را نشان می‌دهد که هدف، بیشینه یا کمینه کردن این تابع است [۳۰].

عوامل تأثیرگذار بر عملکرد یک شبکه عصبی شامل تعداد لایه‌ها، تعداد نورون‌های هر لایه، نوع توابع فعال‌سازی استفاده شده در هر نورون، وزن‌ها و بایاس‌های هر نورون است. در واقع هدف از طراحی یک شبکه عصبی تعیین این پارامترها به گونه‌ای است که آن شبکه عملکرد مطلوب مورد نظر را داشته باشد [۲۷].




شکل ۴- طرحواره یک شبکه عصبی پرسپترون با دو لایه‌ی پنهان [۲۵]

به فرآیند تعیین وزن‌ها و بایاس‌های یک شبکه عصبی با ساختار مشخص، آموزش^۱ آن شبکه عصبی گفته می‌شود، زیرا شبکه حاصل به گونه‌ای طراحی می‌شود که رفتار مناسب و مطلوب را از خود نشان بدهد. برای مدل‌سازی یک فرآیند، باید شبکه عصبی به شکل تابعی از ورودی‌ها به شرط یک سری پارامتر، که همان وزن‌ها و بایاس‌ها هستند، آموزش داده شود [۲۷].

$$\hat{y} = f(\vec{x} | \theta) \quad (2)$$

که در این معادله $\hat{y}$ خروجی شبکه عصبی، $\vec{x}$ بردار متغیرهای ورودی و θ پارامترهای شبکه عصبی است. شکل ۵ چگونگی ایجاد خطای ناشی از مدل‌سازی با شبکه عصبی را نشان می‌دهد. اعمال مجموعه ورودی‌های $\vec{x}_i$ به یک فرآیند مشخص باعث ایجاد خروجی y_i و اعمال همین ورودی‌ها به شبکه عصبی مدل شده، باعث ایجاد خروجی $\hat{y}_i$ می‌شود.



شکل ۵- خطای مدل‌سازی با شبکه عصبی

با توجه به مفهوم خطای ارائه شده، مدلی مطلوب خواهد بود که خطای پیش‌بینی آن در کمترین مقدار ممکن باشد. هرچند دستیابی به خطای صفر به طور کامل غیرممکن است، اما می‌توان با استفاده از روش‌های بهینه‌سازی، این خطا را به حداقل رساند. در واقع، فرآیند آموزش شبکه عصبی را می‌توان به عنوان یک مسئله بهینه‌سازی در نظر گرفت که در آن، هدف پیدا کردن بهترین ترکیب وزن‌ها و بایاس‌ها برای شبکه است تا خطای کلی مدل کمینه شود.

² Machine Learning

³ Crossover

⁴ Mutation

⁵ Fitness Function


⁶ Chromosome

¹ Training


مصرفی به عنوان تابعی از ولتاژ و فرکانس برای محرکی با عرض الکتروود پوشیده ۱/۵ سانتی متر ترسیم شده است.

ترسیم این دسته از نمودارها نشان می‌دهد که در هر فرکانس با افزایش ولتاژ، نیروی رانش، به دلیل افزایش قدرت میدان الکتریکی به صورت پیوسته افزایش می‌یابد. همچنین در هر ولتاژ با افزایش فرکانس نیز، نیروی رانش به صورت پیوسته افزایش خواهد یافت. برای توان مصرفی نیز می‌توان بیان کرد که در هر فرکانس، با افزایش ولتاژ، توان مصرفی به دلیل افزایش قدرت میدان الکتریکی پیوسته افزایش یافته و در هر ولتاژ نیز، با افزایش فرکانس، توان مصرفی پیوسته افزایش خواهد یافت.

(الف)



(ب)



شکل ۷- (الف) تغییرات نیروی رانش تولیدی بر حسب ولتاژ و فرکانس (ب) تغییرات توان الکتریکی مصرفی بر حسب ولتاژ و فرکانس، برای محرک با پهنای الکتروود پوشیده ۱/۵ سانتی متر

۳-۱- مشخصات آزمون تجربی برای اعتبارسنجی

برای تولید داده‌های تجربی آزمایشگاهی جدید با هدف استفاده در اعتبارسنجی، یک محرک پلاسمایی ساخته شده و در یک بستر آزمون مناسب و مشابه شرایط تولید داده‌های اولیه [۳۱]، تحت آزمایش قرار گرفته است. در محرک پلاسمایی از ورق کامپوزیت به ضخامت ۲ میلی متر به عنوان دی الکتریک و از نوار مسی به ضخامت ۵۰ μm برای الکتروود در معرض هوا با عرض ۱ سانتی متر، و برای الکتروود پوشیده با عرض ۲/۵ سانتی متر استفاده شده است. محرک ساخته شده در شکل ۸ نمایش داده شده است.

سپس کروموزوم‌هایی که برازندگی بالاتری دارند، برای تولید نسل بعدی انتخاب می‌شوند. یکی از روش‌های معمول انتخاب، روش انتخاب تناسبی چرخ رولت^۱ است. در این حالت، احتمال انتخاب کروموزوم λ_m به صورت زیر محاسبه می‌شود [۳۰]:

$$P_i = \frac{f(x_i)}{\sum_{j=1}^N f(x_j)} \quad (5)$$

N تعداد کل کروموزوم‌ها در جمعیت است. اکنون نوبت مرحله ترکیب است. یعنی دو کروموزوم (والد) برای تبادل بخش‌هایی از ژن‌های خود با یکدیگر انتخاب می‌شوند تا دو کروموزوم جدید (فرزند) ایجاد شود. در ادامه به منظور حفظ تنوع در جمعیت، جهش انجام می‌شود. در این مرحله، با احتمال P_m ، ژن‌های یک کروموزوم تغییر می‌کنند. برای مثال، اگر ژن x_i یک بیت باینری باشد، جهش به صورت زیر انجام می‌شود [۳۰]:

$$x'_i = 1 - x_i \quad (6)$$

پس از انجام مراحل ترکیب و جهش، نسل جدید جایگزین نسل قبلی می‌شود. این فرآیند تا زمانی ادامه می‌یابد که شرط توقف برقرار شود. الگوریتم ژنتیک تا زمانی که یکی از شرایط توقف شامل تکامل تعداد مشخصی از نسل‌ها، رسیدن به برازندگی مطلوب یا عدم مشاهده بهبود قابل توجه در نسل‌های اخیر، برآورده شود ادامه می‌یابد.

۳- مجموعه داده‌های مورد استفاده

برای مدل‌سازی شبکه‌های عصبی، به مجموعه داده‌های آزمون تجربی آزمایشگاهی نیاز است. داده‌های تجربی مورد استفاده در بخش اول مدل‌سازی این پژوهش مطابق با مرجع [۳۱] می‌باشد. اما به منظور اعتبارسنجی مدل‌های به دست آمده، یک محرک پلاسمایی ساخته شده و در بستر آزمون مناسب مورد سنجش قرار گرفته است. به کمک این آزمون، داده‌های تجربی جدید تولید می‌گردد تا در فرآیند ارزیابی مدل به کار گرفته شوند.

در بخش‌های قبل متغیرهای موثر بر محرک پلاسمای DBD معرفی شده‌اند. هدف از آزمون‌های تجربی مرجع [۳۱] بررسی اثر ولتاژ اعمالی، فرکانس تحریک و پهنای الکتروود پوشیده بر عملکرد رانش تولیدی و توان الکتریکی مصرفی محرک پلاسمایی است. روش طراحی آزمایش برای استخراج داده‌ها، بر مبنای رویکرد طراحی عاملی کامل^۲ است. در این رویکرد به جای تغییر یک متغیر در هر زمان، متغیرها به طور همزمان تغییر داده می‌شوند و همه حالات بررسی می‌گردد [۲۷]. با استفاده از این روش می‌توان اثرات یک عامل را به ازای سطوح مختلف عامل‌های دیگر بررسی کرد و این باعث می‌شود تا نتایج حاصل به ازای محدوده وسیعی از متغیرها معتبر باشد [۳۲]. در نتیجه باید برای هر متغیر، سطوح مشخصی در نظر گرفته شود. سطوح متغیرهای مورد بررسی برای پهنای الکتروود پوشیده برابر با ۱، ۱/۵، ۲ و ۲/۵ سانتی متر، برای فرکانس حامل برابر با ۱۲، ۱۴، ۱۶، ۱۸ و ۲۰ کیلوهرتز، و برای ولتاژ (قله تا قله) برابر با ۱ تا ۱۰ کیلوولت است.

به منظور نمایش بخشی از داده‌های استفاده شده و برای پرهیز از تکرار، در شکل ۷ تغییرات نیروی رانش تولیدی و توان الکتریکی

^۱ Roulette Wheel


^۲ Full Factorial Designs



شکل ۸- تصویر محرک پلاسمایی ساخته شده


همچنین بلوک دیاگرام چیدمان آزمایش در شکل ۹ نمایش داده شده است. این ستاپ شامل تجهیزات زیر می‌باشد:

۱. تولیدکننده سیگنال
۲. ترانسفورماتور
۳. تقویت‌کننده
۴. مولتی متر
۵. اسیلوسکوپ
۶. وات‌متر دیجیتال
۷. ترازو
۸. استند یا پایه نگهدارنده
۹. رانشگر پلاسمایی.



شکل ۹- بلوک دیاگرام چیدمان آزمایش

منبع تغذیه پلاسمای مورد استفاده یک منبع تغذیه AC با ماکزیمم ولتاژ اعمالی 70 kV قله تا قله، ماکزیمم فرکانس تحریک 1000 Hz و بیشینه توان الکتریکی خروجی 1000 W است. همچنین اسیلوسکوپ دیجیتال مدل GPS-1072 و مولتی‌متر دیجیتال مدل ویکتور VC97 مورد استفاده قرار گرفته‌اند. توان الکتریکی نیز به کمک میکرو پاورمتر دیجیتال BENETECH GM86 با دقت ۰/۰۱ وات سنجیده شده است. به منظور قرار دادن محرک به صورت صحیح (شکل ۱۰) و در فاصله ایمن بر روی ترازو (جهت جلوگیری از ایجاد نویز)، یک استند از چوب بالسا ساخته شده است. همچنین سنجش مقدار رانش به کمک یک ترازوی دیجیتال مدل DLS100-5 انجام شده که می‌تواند حداکثر جرم ۳۰۰ گرم را با دقت ۰/۰۰۱ گرم اندازه‌گیری نماید. با هدف افزایش حفاظت مدارهای ترازو در برابر میدان الکتریکی قوی محرک پلاسمایی، تمام سطح آن به کمک یک ورق آلومینیومی پوشانده شده است.



شکل ۱۰- شماتیک محرک پلاسمایی و جهت نیروی تولید شده

۴- مدل‌سازی

برای اجرای مدل‌سازی شبکه عصبی از کد نویسی در محیط نرم‌افزار MATLAB استفاده شده است. ورودی کد مورد نظر، ماتریسی از داده‌ها شامل مقادیر متغیرهای ورودی (ولتاژ، فرکانس) و مقادیر پارامترهای سنجشی متناظر با آن‌ها (مومنوم القایی و توان الکتریکی)


است. با تغییر تنظیمات کد و چندین مرتبه اجرای آن، مجموعه‌ای از شبکه‌های عصبی تولید شده است که عملکرد متفاوتی با یکدیگر دارند. از بین مدل‌های به دست آمده با توجه به معیارهای اعتبارسنجی آماری و تجربی، مدلی با بهترین عملکرد انتخاب گردیده که مشخصات آن در جدول ۱ ارائه شده است.

جدول ۱- تنظیمات و مشخصات شبکه عصبی طراحی شده


۲	تعداد لایه شبکه
۵	تعداد نورون لایه پنهان
۱	تعداد نورون لایه خروجی
tansig	تابع فعال‌سازی لایه پنهان
purelin	تابع فعال‌سازی لایه خروجی
۷۰	درصد داده‌های آموزش
۱۵	درصد داده‌های اعتبارسنجی
۱۵	درصد داده‌های آزمون
MSE	شاخص عملکرد
Levenberg-Marquardt	روش و تابع آموزش
۱۰۰۰	تعداد تکرار مجاز آموزش
۱۰	تعداد شکست پیاپی عملیات اعتبارسنجی
۰	کمترین مقدار خطای قابل قبول

۴-۱- اعتبارسنجی آماری مدل

ابتدا نمودارهای همبستگی و انطباق خروجی مدل با داده‌های هدف، برای مدل برگزیده شبکه عصبی نیروی رانش القایی و توان الکتریکی مصرفی در اشکال ۱۱ و ۱۲ نمایش داده شده است.



(الف)



(ب)

شکل ۱۱- نتایج حاصل از مدل بر حسب نتایج تجربی برای مومنوم القایی (الف) نمودارهای همبستگی (ب) انطباق خروجی مدل با داده‌های هدف

معیار ضریب معین یا R^2 نشان‌دهنده میزان احتمال همبستگی نتایج حاصل از آزمون آزمایشگاهی با نتایج خروجی از مدل است. معمولاً در صورتیکه مقدار این معیار بیش از ۹۰ درصد باشد، مدل دارای دقت مناسبی خواهد بود. میانگین مربعات خطا (MSE) و جذر میانگین مربعات خطا (RMSE) دو معیار مهم برای ارزیابی دقت مدل‌های رگرسیونی هستند، اما میانگین مربعات خطا به دلیل داشتن ابعاد یکسان با مقادیر هدف، برای آنالیز مناسب‌تر است. هرچه مقدار این دو معیار سنجش خطا کمتر باشد، مدل پیش‌بینی دقیق‌تری ارائه می‌دهد. پس با توجه به مطالب بیان شده، شکل‌های ۱۱ و ۱۲ و مقادیر جدول‌های ۲ و ۳، مدل‌های پیشنهاد شده برای مونتوم القایی و توان مصرفی مدل‌های قابل قبول و دقیقی هستند.

۴-۲- اعتبارسنجی تجربی مدل

براساس تنظیمات جدول ۱ از ۷۰ درصد داده‌ها برای آموزش و ۱۵ درصد برای اعتبارسنجی استفاده شده است. ۱۵ درصد اطلاعات نیز برای آزمایش باقی مانده که اکنون می‌توان دقت مدل‌ها را با آن بررسی نمود. نتایج حاصل از آنالیز خوش سازگاری برای داده‌های آزمایش مدل نیروی رانش القایی و توان الکتریکی مصرفی به ترتیب در جدول ۴ و ۵ ارائه شده است.

جدول ۴- خوش سازگاری برای داده‌های آزمایش مدل مونتوم القایی


۰/۹۸۰	R
۹۶/۰۴ %	R^2
۰/۰۴۲	MSE
۰/۲۰	RMSE

جدول ۵- خوش سازگاری برای داده‌های آزمایش مدل توان مصرفی


۰/۹۸۴	R
۹۶/۸ %	R^2
۰/۱۰۲	MSE
۰/۳۲	RMSE

نتایج حاصل از ارزیابی خوش سازگاری داده‌های آزمایش برای هر دو مدل رانش و توان مصرفی نیز مقادیر قابل قبولی را نشان می‌دهد که مجدداً اثبات دقت مناسب مدل‌ها است. به منظور مقایسه خروجی‌های حاصل از مدل شبکه عصبی با نتایج تجربی استفاده شده در آموزش آن (شکل ۱۳)، یک نمونه از نمودارهای شکل ۷ برای آنالیز انتخاب شده است. مشخصات حالت انتخاب شده، فرکانس ۱۶ کیلوهرتز و عرض الکتروود پوشیده ۱/۵ سانتی‌متر است. بررسی نمودارهای شکل ۱۳ نیز به دقت مناسب مدل برای پیش‌بینی عملکرد محرک پلاسمایی اشاره دارد.

(الف)



(ب)



شکل ۱۲- نتایج حاصل از مدل بر حسب نتایج تجربی برای توان الکتریکی مصرفی (الف) نمودارهای همبستگی (ب) انطباق خروجی مدل با داده‌های هدف

برای بررسی اینکه مدل ارائه شده تا چه اندازه با مجموعه مشاهدات تجربی متناسب است، از آنالیز خوش سازگاری^۱ استفاده می‌شود. لذا مقادیر ضریب همبستگی، ضریب معین، جذر میانگین مربعات خطا^۲ و میانگین مربعات خطا برای مدل نیروی رانش القایی و توان الکتریکی مصرفی، در جدول‌های ۲ و ۳ ارائه شده است.

جدول ۲- خوش سازگاری برای مدل مونتوم القایی

۰/۹۸۸	R
۹۷/۶ %	R^2
۰/۰۴۶	MSE
۰/۲۱	RMSE


جدول ۳- خوش سازگاری برای مدل توان الکتریکی مصرفی

۰/۹۸۷	R
۹۷/۴ %	R^2
۰/۰۹	MSE
۰/۳	RMSE


^۱ Goodness of fit

^۲ Root Mean Square Error (RMSE)

(الف)



(ب)



شکل ۱۳- خروجی‌های حاصل از مدل و نتایج تجربی استفاده شده در آموزش برای حالت فرکانس ۱۶ کیلوهرتز و عرض الکترود پوشیده ۱/۵ سانتی‌متر (الف) نیروی رانش القایی (ب) توان الکتریکی مصرفی

۴-۳- آموزش با الگوریتم ژنتیک


همان‌طور که پیش‌تر اشاره شد، در فرآیند مدل‌سازی شبکه عصبی بخشی با هدف آموزش شبکه وجود دارد. در این قسمت از پژوهش، هدف استفاده از الگوریتم ژنتیک به عنوان یک روش بهینه‌سازی در آموزش شبکه عصبی، به جای استفاده از الگوریتم لوبز-مارکارد خواهد بود. وظیفه کد نوشته شده الگوریتم ژنتیک، پیدا و گزارش کردن بهترین جمعیت و تبدیل آن به خروجی در قالب یک شبکه عصبی است. مشخصات و تنظیمات کد الگوریتم ژنتیک در جدول ۶ ارائه شده است.

جدول ۶- مشخصات و تنظیمات کد الگوریتم ژنتیک


تعداد جمعیت هر نسل	۳۰
احتمال عمل ترکیب	۰/۷
احتمال رخداد جهش	۰/۰۰۵
تعداد مراحل تولید نسل جدید	۱۰۰

در شکل ۱۴ نمودار تغییرات تابع هزینه به ازای هر مرتبه تولید جمعیت، برای هر دو مدل ترسیم شده است.

(الف)



(ب)



شکل ۱۴- تغییرات تابع هزینه به ازای هر مرتبه تولید جمعیت (الف) مدل نیروی رانش القایی (ب) مدل توان الکتریکی مصرفی

همچنین نتایج حاصل از آنالیز خوش سازگاری برای مدل نیروی رانش القایی و توان الکتریکی مصرفی به ترتیب در جدول ۷ و ۸ ارائه شده است.

جدول ۷- خوش سازگاری برای مدل مومنتوم القایی با آموزش

الگوریتم ژنتیک

R	۰/۹۹
R ²	۹۸٪
MSE	۰/۰۱۴
RMSE	۰/۱۲

جدول ۸- خوش سازگاری برای مدل توان الکتریکی با آموزش

الگوریتم ژنتیک

R	۰/۹۸۹
R ²	۹۷/۹٪
MSE	۰/۰۳۳
RMSE	۰/۱۸

مشخصاً بررسی جداول آنالیز خوش سازگاری و مقایسه مقادیر آن با آنالیزهای پیشین، بهبود و افزایش دقت شبکه عصبی را اثبات می‌کند. به عنوان مثال، بهترین مقدار جذر میانگین مربعات خطا برای مدل مومنتوم القایی مقدار ۰/۲۱ را نشان می‌دهد، در حالیکه این مقدار برای شبکه عصبی تعلیم داده شده با روش الگوریتم ژنتیک عددی برابر

۶- نتیجه گیری

به طور خلاصه مدل سازی نیروی رانش القایی محرک پلاسمای DBD با در نظر گرفتن توان الکتریکی مصرفی متناظر با آن، هدف کلی پژوهش انجام شده است. با توجه به عملکرد مناسب و پتانسل روش شبکه عصبی مصنوعی در مدل سازی سیستم ها و پدیده های پیچیده، در مرحله اول به کمک آن مجموعه ای از مدل ها تولید شده است. سپس مدل های به دست آمده از نقطه نظر میزان همبستگی، و میزان خطای به وجود آمده مورد ارزیابی قرار گرفته و بهترین آن انتخاب شده است. برای هر دو مدل نیروی رانش و توان مصرفی ضریب همبستگی حدوداً دارای مقدار ۰/۹۸ است. از طرفی ضریب معین یا R^2 نیز برای هر دو مدل حدود ۹۷٪ می باشد. میانگین مربعات خطا و جذر آن نیز دو معیار بسیار مهم هستند که مقدار هر کدام از آن ها به ترتیب برابر با ۰/۰۴۶ و ۰/۲۱ برای مدل مومنتوم و ۰/۰۳ و ۰/۳ برای مدل توان مصرفی است. بررسی مقادیر معیارهای همبستگی و خطا به مناسب بودن هر دو مدل به دست آمده اشاره دارد. اما برای بررسی دقت و صحت عملکرد آن ها باید اعتبارسنجی تجربی انجام شود که نتایج آنالیز خوش سازگاری برای داده های آزمایش مدل مومنتوم و مدل توان مصرفی نیز تأیید کننده صحت و دقت مدل ها است.

در گام بعدی با هدف تلاش برای افزایش دقت مدل ها به مسأله آموزش شبکه عصبی و تعیین وزن ها و بایاس های آن به شکل یک مسأله ی بهینه سازی نگاه شده است. یعنی باید خطاها تا حد ممکن کمینه یا صفر شوند. این بار با توجه به پیشینه و عملکرد الگوریتم ژنتیک در حل مسائل بهینه سازی، بخش تعلیم شبکه عصبی به این روش سپرده شده است. بررسی مدل های حاصل از روش ترکیبی شبکه عصبی و الگوریتم ژنتیک نشان می دهد که نتایج خروجی با روش قبل قابل مقایسه هستند.

برای مدل مومنتوم القایی در حالت اول مقدار ضریب همبستگی ۰/۹۸۸ و مقدار ضریب معین برابر ۹۷/۶٪ است. اما با روش بهینه سازی این مقادیر به ترتیب برابر با ۰/۹۹ و ۹۸٪ خواهند بود. میانگین مربعات خطا و جذر آن نیز برای حالت اول برابر با ۰/۰۴۶ و ۰/۲۱ می باشد که با روش بهینه سازی این مقادیر برابر با ۰/۱۴ و ۰/۱۲ خواهند بود. افزایش مقادیر همبستگی و کاهش مقادیر خطا، نشان می دهد که مدل مومنتوم القایی با روش ژنتیک مدلی بهتر و دقیق تر است.

برای مدل توان مصرفی نیز در حالت اول مقدار ضریب همبستگی ۰/۹۸۷ و مقدار ضریب معین برابر با ۹۷/۴٪ بوده و در مقابل با روش بهینه سازی این مقادیر به ترتیب برابر با ۰/۹۸۹ و ۹۷/۹٪ می باشد. با اینکه شاهد افزایش مقادیر ضریب همبستگی و ضریب معین هستیم ولی این اعداد برای هر دو حالت نزدیک به هم هستند. اما تفاوت اصلی در بررسی خطا است. میانگین مربعات خطا و جذر آن نیز برای حالت اول برابر با ۰/۰۳ و ۰/۰۹ می باشد که با روش بهینه سازی این مقادیر برابر با ۰/۰۳۳ و ۰/۱۸ خواهد بود. در نتیجه برای مدل توان مصرفی نیز روش ژنتیک مدل بهتر و دقیق تری ارائه کرده است.


در پایان نیز به کمک اجرای آزمون های آزمایشگاهی، قابلیت تعمیم دهی مدل ها به ازای سطوح جدیدی از متغیرهای الکتریکی که به صورت تجربی بررسی شده و در آموزش، اعتبارسنجی و آزمون شبکه عصبی هیچ نقشی نداشته اند، با نتایج خروجی شبکه ی عصبی مورد

با ۰/۱۲ است. با مقدار این پارامتر برای مدل توان الکتریکی مصرفی ۰/۳ و با الگوریتم ژنتیک برابر با ۰/۱۸ می باشد. کمتر شدن مقدار این پارامتر برای هر دو مدل، به دقیق تر شدن آن ها اشاره دارد.


۵- تعمیم دهی مدل به کمک نتایج آزمایشگاهی

سنجش آزمایشگاهی مقادیر نیروی رانش القایی و توان الکتریکی مصرفی به ازای سطح جدید متغیر فرکانس حامل، و مقایسه این مقادیر با خروجی مدل های شبکه عصبی، اساس روش بررسی قابلیت تعمیم دهی مدل ها است. به منظور استخراج داده های تجربی جدید، محرک پلاسمای DBD با مشخصات بیان شده در بخش ۱-۳ ساخته شده است. بازه فرکانس آزمون این محرک، خارج از محدوده فرکانس داده های به کار رفته در مدل سازی شبکه عصبی می باشد. داده ها دارای سطوح فرکانس ۱۲، ۱۴، ۱۶، ۱۸ و ۲۰ کیلوهرتز هستند در صورتیکه برای آزمون تجربی جدید، فرکانس ۱۵ کیلوهرتز مورد ارزیابی قرار گرفته که خارج از محدوده تعلیم و آزمون شبکه عصبی بوده و جزء سطوح در نظر گرفته شده نیست. نتایج مقایسه اجرای آزمون آزمایشگاهی و مقادیر خروجی شبکه عصبی آموزش دیده، در شکل ۱۵ نمایش داده شده است. با توجه به نمودارهای نمایش داده شده در شکل ۱۵ اگرچه مقداری خطا مشهود است (جذر میانگین مربعات خطا به ترتیب برای مدل رانش و مدل توان برابر است با ۰/۳۴ و ۰/۴۵)، اما مدل شبکه عصبی به خوبی توانسته الگوی رفتار مومنتوم القایی و توان الکتریکی مصرفی را در این حالت پیش بینی کند.

(الف)



(ب)



شکل ۱۵- داده های تجربی جدید و مدل شبکه عصبی

(الف) مدل نیروی رانش القایی (ب) مدل توان الکتریکی مصرفی

- [14] Durscher R, Roy S. Evaluation of thrust measurement techniques for dielectric barrier discharge actuators. *Experiments in fluids*. 2012 Oct; 53:1165-76.
 - [15] Durscher R, Roy S. Novel multi-barrier plasma actuators for increased thrust. In 48th AIAA Aerospace Sciences Meeting including the New Horizons Forum and Aerospace Exposition 2010 Jan 4 (p. 965).
 - [16] Cheong M, Greig A, Gibson B, Arjomandi M. An investigation into the effect of electric field on the performance of dielectric barrier discharge plasma actuators. *Experimental Thermal and Fluid Science*. 2011 Nov 1; 35(8):1600-7.
 - [17] Ahangar M, Hoseini A. Experimental investigation on the performance of channel plasma thruster using tri-electrode DBD actuators under magnetic field. *Sensors and Actuators A: Physical*. 2024 Apr 16; 369:115163.
 - [18] Ahangar M, Hoseini A. Experimental study of the performance parameters of a plasma thruster using dielectric barrier discharge with the magnetic field. *Modares Mechanical Engineering*. 2022 May 10; 22(6):393-406.
 - [19] Bishop CM. *Neural networks for pattern recognition*. Oxford University press; 1995.
 - [20] Haykin S. *Neural networks and learning machines*. Pearson Education India; 2009 Nov.
 - [21] Ripley BD. *Pattern recognition and neural networks*. Cambridge university press; 2007.
 - [22] Goodfellow I, Bengio Y, Courville A. *Deep learning*. MIT press; 2016.
 - [23] Schmidhuber J. Deep learning in neural networks: An overview. *Neural networks*. 2015 Jan 1; 61:85-117.
 - [24] LeCun Y, Bengio Y, Hinton G. Deep learning. *nature*. 2015 May 28; 521(7553):436-44.
 - [25] Haykin S. *Neural networks: a comprehensive foundation*. Prentice Hall PTR; 1998 Jul.
 - [26] Rojas R. *Neural networks: a systematic introduction*. Springer Science & Business Media; 2013 Jun 29.
 - [27] Dalvand MS. *Experimental Investigation and Multi-Objective Optimization of the DBD Plasma Actuator Using Artificial Neural Network and Genetic Algorithm*. MSc Thesis, Tarbiat Modares University, 2016.
 - [28] Albadr MA, Tiun S, Ayob M, Al-Dhief F. Genetic algorithm based on natural selection theory for optimization problems. *Symmetry*. 2020 Oct 23; 12(11):1758.
 - [29] Holland JH. *Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence*. MIT press; 1992 Apr 29.
 - [30] Mitchell M. *An introduction to genetic algorithms*. MIT press; 1998 Mar 2.
 - [31] Dalvand S, Pouryoussefi G, Doostmahmoudi A, Hosseini MR. Thrust generation by dielectric barrier discharge plasma actuators in the filamentary discharge regime. *Physics of Fluids*. Accepted paper, 2025.
 - [32] Montgomery DC. *Design and analysis of experiments*. John Wiley & sons; 2017.
- ارزیابی قرار گرفته است. برای این بخش نیز مدل شبکه عصبی توانسته الگوی رفتار مومنوم القایی و توان الکتریکی مصرفی و محدوده تغییرات آن را به خوبی پیش‌بینی نماید. نتیجه تمام بررسی‌ها، اعتبارسنجی‌ها و تعمیم‌دهی‌های صورت گرفته، به عملکرد مناسب و دقت کافی مدل‌های ارائه شده اشاره دارد و روش الگوریتم ژنتیک را برای استفاده و ترکیب در بخش آموزش شبکه عصبی مفید ارزیابی می‌کند. همچنین خلاصه دستاوردهای پژوهش به شرح زیر است:
- برای نیروی رانش القایی و توان الکتریکی مصرفی محرک پلاسمایی DBD به کمک شبکه عصبی مصنوعی مدل‌هایی ارائه شده است که دقت و صحت عملکرد آن‌ها با اعتبارسنجی آماری و تجربی تأیید شده است.
 - با استفاده از الگوریتم ژنتیک در فرآیند آموزش شبکه عصبی، دقت مدل‌ها افزایش پیدا کرده است.
 - تعمیم‌دهی مدل‌ها با نتایج تجربی جدید بررسی شده است.
- ### ۷- مراجع
- [1] Lupo A, Kreinovich V. Dielectric Barrier Discharge (DBD) Thrusters—Aerospace Engines of the Future: Invariance-Based Analysis. In *Uncertainty, Constraints, and Decision Making 2023 Sep 19*. Cham: Springer Nature Switzerland.
 - [2] Erfani R. *Optimisation of Dielectric Barrier Discharge Plasma Actuators and Their Application to Fluid Dynamics*. PhD Thesis, The University of Manchester (United Kingdom), 2012.
 - [3] Moreau E. Airflow control by non-thermal plasma actuators. *Journal of physics D: applied physics*. 2007 Jan 19; 40(3):605.
 - [4] Corke TC, Post ML, Orlov DM. Single dielectric barrier discharge plasma enhanced aerodynamics: physics, modeling and applications. *Experiments in Fluids*. 2009 Jan; 46:1-26.
 - [5] Iqbal MO, Kozlov A, Schatzman D, Othman H, Thomas F, Corke T. Parametric Optimization of Single Dielectric Barrier Discharge (SDBD) Plasma Actuators. In *APS Division of Fluid Dynamics Meeting Abstracts 2006 Nov (Vol. 59, pp. LI-011)*.
 - [6] Townsend Brown T. A method of and an apparatus or machine for producing force and motion. GB Patent. 1928;300311.
 - [7] Masuyama K, Barrett SR. On the performance of electrohydrodynamic propulsion. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*. 2013 Jun 8; 469(2154):20120623.
 - [8] Christenson EA, Moller PS. Ion-neutral propulsion in atmospheric media. *AIAA journal*. 1967 Oct; 5(10):1768-73.
 - [9] Dalvand MS, Pouryoussefi G, Ebrahimi M. Optimization of the Ratio of Induced Flow Velocity to Electrical Power Consumption in the DBD Plasma Actuator Using Artificial Neural Network and Genetic Algorithm. *Modares Mechanical Engineering*. 2018 Jan 10; 17(11):323-32.
 - [10] Van Dyken R, McLaughlin T, Enloe CL. Parametric investigations of a single dielectric barrier plasma actuator. In *42nd AIAA aerospace sciences meeting and exhibit 2004 Jan 5 (p. 846)*.
 - [11] Rosli MF. *Experimental Study on the Impact of DBD Plasma Actuator Geometry and Electrical Input on Thrust Generation*. BS Thesis, University Sains Malaysia, 2022.
 - [12] Thomas FO, Corke TC, Iqbal M, Kozlov A, Schatzman D. Optimization of dielectric barrier discharge plasma actuators for active aerodynamic flow control. *AIAA journal*. 2009 Sep; 47(9):2169-78.
 - [13] Versailles P, Gingras-Gosselin V, Vo HD. Impact of pressure and temperature on the performance of plasma actuators. *AIAA journal*. 2010 Apr; 48(4):859-63.