

Implementation of ResNet-101 Neural Network and Particle Swarm Optimization Algorithm in Modeling Frequency Selective Surfaces with Complex Shapes of Type Sierpiński-Gasket

Amin Mazroei Abkenar¹, Mojtaba Maddah Ali², Marzieh Nasirian³

¹ MSc Graduate, Department of Electrical and Electromagnetic Engineering, Malek Ashtar University of Technology, Shahin Shahr, Iran
aminmazroeiabkenar@gmail.com

² Assistant Professor, Department of Electrical and Electromagnetic Engineering, Malek Ashtar University of Technology, Shahin Shahr, Iran
maddahali@mut-es.ac.ir

³ Assistant Professor, Department of Electrical and Electromagnetic Engineering, Malek Ashtar University of Technology, Shahin Shahr, Iran
mz.nasirian@gmail.com

Abstract :

Modeling fractal frequency selective surfaces (FSS) is one of the primary challenges in designing absorbers and electromagnetic structures based on such surfaces, primarily due to their geometric complexity and the demand for precise simulations, which require significant time and resources. In this project, the main objective is to utilize the ResNet convolutional neural network to predict the reflection coefficient of fractal surfaces based on their images. A notable feature of this study is the incorporation of data extracted from the particle swarm optimization (PSO) algorithm alongside random data for training the network. This approach has not only enhanced the prediction accuracy of the neural network but also improved the quality of the generated dataset. Furthermore, the integration of the PSO algorithm with the ResNet network has resulted in improved model performance in terms of more accurate and faster reflection coefficient predictions. The proposed methodology has the potential to significantly reduce the time and costs associated with modeling fractal frequency selective surfaces, ultimately facilitating the optimization of their design process.

Keywords: Neural network, ResNet neural network, Fractal frequency selective surfaces, Convolutional neural network, Particle swarm optimization algorithm

Article Type: Research

Received: 01. 12. 2025

Revised: 01. 07. 2025

Accepted: 12. 06. 2025

Corresponding author: M. Maddah Ali

Corresponding author's address: Department of Electrical and Electromagnetic Engineering, Malek Ashtar University of Technology, Shahin Shahr, Iran

1. Motivation of the work

Fractal FSSs have attracted considerable attention in modern electromagnetic system design because of their inherent multi-band characteristics, compact size, and angular stability. These properties make fractal FSSs highly suitable for applications such as microwave absorbers, stealth technology, multiband antennas, and electromagnetic shielding. Among various fractal geometries, the Sierpinski-gasket offers self-similarity and geometrical flexibility, enabling enhanced absorption and filtering performance across wide frequency ranges. However, these advantages come at the cost of significant modeling and optimization complexity. Traditional full-wave electromagnetic solvers require extensive computational resources, especially when iterative optimization and parametric sweeps are involved.

In recent years, machine learning and deep learning methods have emerged as promising alternatives for accelerating electromagnetic design tasks. Nevertheless, most deep learning approaches rely on large labeled datasets, which themselves require extensive simulations to generate. This limits the practicality of purely data-driven methods in real-world engineering scenarios. On the other hand, evolutionary optimization algorithms such as PSO can efficiently explore the design space but remain computationally expensive when combined with full-wave solvers. The motivation of this work is to bridge the gap between accuracy, efficiency, and data availability by integrating deep residual networks with PSO. By leveraging the feature extraction power of ResNet-101 and the global search capability of PSO, the proposed framework aims to reduce simulation costs, improve predictive accuracy even with relatively small datasets, and enable rapid optimization of complex fractal FSS structures.

2. Contributions

The main contributions of this work can be summarized as follows. First, a hybrid modeling framework is proposed that combines PSO with a deep ResNet-101 architecture for efficient prediction and optimization of fractal FSS reflection characteristics. Unlike conventional surrogate models, the proposed approach directly processes geometric images of complex fractal patterns, eliminating the need for handcrafted features or equivalent circuit approximations. Second, an effective data generation strategy is introduced in which PSO-generated near-optimal samples are merged with randomly generated designs. This approach significantly enhances dataset quality and diversity while keeping the dataset size relatively small. As a result, the deep

network achieves improved generalization and prediction accuracy compared to models trained solely on random data. Third, the performance of different ResNet variants is investigated, demonstrating that the deeper ResNet-101 architecture outperforms shallower counterparts such as ResNet-18 and ResNet-50 in capturing the intricate electromagnetic behavior of fractal FSSs. Finally, the proposed hybrid PSO–ResNet framework is shown to substantially reduce optimization time while maintaining high accuracy, offering a practical and scalable solution for advanced electromagnetic absorber design.

3. Procedures

The proposed methodology begins with the design of a fractal FSS based on a Sierpinski-gasket geometry. A particle swarm optimization algorithm is employed to generate optimized structural samples by exploring the design space efficiently. In parallel, an additional set of random samples is produced to increase data diversity. The combined dataset is then used to train a ResNet-101 convolutional neural network. The network is trained using standard stochastic optimization techniques, and its performance is evaluated using a separate validation set. This procedure ensures that the trained model can accurately predict reflection characteristics for previously unseen geometries.

4. Findings

The results demonstrate that the hybrid particle swarm optimization and deep learning approach significantly improves prediction accuracy compared to models trained with randomly generated data alone. The ResNet-101 model shows superior performance due to its deep architecture and residual connections, which facilitate effective feature extraction from complex fractal images. Moreover, the proposed framework substantially reduces the overall modeling time, enabling rapid evaluation of design alternatives without the need for extensive electromagnetic simulations.

5. Conclusion

This study presents an efficient and accurate modeling strategy for fractal FSSs by integrating particle swarm optimization with a deep residual neural network. The proposed approach effectively addresses the challenges associated with geometric complexity and high computational cost. By combining optimized and random data for training, the method achieves high predictive accuracy while significantly reducing simulation time. The results confirm that the hybrid framework is a promising solution for the rapid design and optimization of complex electromagnetic structures.

پیاده‌سازی شبکه عصبی رزنت-۱۰۱ و الگوریتم بهینه‌ساز ازدحام ذرات در مدل‌سازی سطوح انتخابگر فرکانس با اشکال پیچیده از نوع مثلث سیرپنسکی

امین مزروعی آبکنار^۱، مجتبی مداح علی^۲، مرضیه نصیریان^۳

۱- دانش‌آموخته کارشناسی ارشد- مجتمع الکترومغناطیس- دانشگاه صنعتی مالک‌اشتر- شاهین‌شهر- ایران

aminmazroeiabkenar@gmail.com

۲- استادیار- مجتمع الکترومغناطیس- دانشگاه صنعتی مالک‌اشتر- شاهین‌شهر- ایران

maddahali@mut-es.ac.ir

۳- استادیار- مجتمع الکترومغناطیس- دانشگاه صنعتی مالک‌اشتر- شاهین‌شهر- ایران

mz.nasirian@gmail.com

چکیده: مدل‌سازی سطوح انتخابگر فرکانس فراکتالی یکی از چالش‌های اصلی در طراحی جاذب‌ها و ساختارهای الکترومغناطیسی مبتنی بر این سطوح است، که به دلیل پیچیدگی‌های هندسی و نیاز به شبیه‌سازی‌های دقیق، زمان و هزینه‌های بسیاری می‌طلبد. در این پروژه، هدف اصلی استفاده از شبکه عصبی هم‌گشتی رزنت است تا با دریافت تصاویر سطوح فراکتالی، ضریب بازتاب متناظر با آن‌ها را پیش‌بینی کند. یکی از ویژگی‌های برجسته این تحقیق، استفاده از داده‌های استخراج‌شده از الگوریتم بهینه‌ساز ازدحام ذرات در کنار داده‌های تصادفی برای آموزش شبکه است؛ این رویکرد نه تنها منجر به افزایش دقت پیش‌بینی شبکه عصبی شده، بلکه کیفیت مجموعه داده تولیدشده را نیز بهبود بخشیده است. همچنین، ترکیب الگوریتم بهینه‌ساز ازدحام ذرات با شبکه رزنت منجر به بهبود عملکرد مدل در پیش‌بینی دقیق‌تر و سریع‌تر ضریب بازتاب شده است. استفاده از این روش می‌تواند زمان و هزینه‌های مدل‌سازی سطوح انتخابگر فرکانس فراکتالی را کاهش داده و در نهایت، بهینه‌سازی طراحی این سطوح را تسهیل کند.

کلمات کلیدی: شبکه عصبی، شبکه عصبی رزنت، سطوح انتخابگر فرکانس فراکتالی، شبکه عصبی هم‌گشتی، الگوریتم بهینه‌ساز ازدحام ذرات

نوع مقاله: پژوهشی

دریافت: ۱۴۰۳/۱۰/۲۳

بازنگری: ۱۴۰۴/۰۴/۱۰

پذیرش: ۱۴۰۴/۰۹/۱۵

نام نویسنده مسئول: دکتر مجتبی مداح علی

نشانی نویسنده مسئول: ایران - اصفهان - شاهین‌شهر - خیابان دانشگاه - دانشگاه صنعتی مالک‌اشتر - مجتمع الکترومغناطیس

۱- مقدمه


سطوح انتخابگر فرکانس (FSS) و به‌ویژه انواع فراکتالی آن، در سال‌های اخیر به عنوان یکی از عناصر کلیدی در طراحی جاذب‌های امواج و ساختارهای الکترومغناطیسی پیشرفته مطرح شده‌اند. این ساختارها قادرند در باندهای فرکانسی مشخص، امواج را عبور داده یا جذب کنند و از این رو در حوزه‌هایی نظیر مخابرات بی‌سیم، رادار، آنتن‌های چندباند و پوشش‌های جاذب مورد استفاده گسترده قرار گرفته‌اند [۱، ۲] ویژگی‌های خاص هندسی در ساختارهای فراکتالی، مانند خودشبه‌مانند و پیچیدگی چندمقیاسی، موجب می‌شود که این سطوح نسبت به نمونه‌های غیرفراکتالی، عملکرد بهتری در باندهای متعدد و شرایط زاویه تابش مختلف داشته باشند [۳].

از مزایای عمده سطوح انتخابگر فرکانس فراکتالی می‌توان به قابلیت کارکرد چندباندی، افزایش کارایی جذب، کاهش اندازه و وزن، و انعطاف‌پذیری بالا در طراحی اشاره کرد. در عین حال، این ساختارها با چالش‌هایی همچون پیچیدگی طراحی، دشواری ساخت، و نیاز به شبیه‌سازی‌های دقیق و زمان‌بر روبه‌رو هستند [۳]. به همین دلیل، استفاده از روش‌های مدل‌سازی و بهینه‌سازی پیشرفته برای طراحی بهینه این سطوح، به یک ضرورت تبدیل شده است.

در تحقیقات پیشین، روش‌های مختلفی برای بهبود عملکرد جاذب‌های مبتنی بر FSS ارائه شده است. به عنوان نمونه، ترکیب شبکه‌های عصبی مصنوعی با مدل‌های مدار معادل (ECM) جهت بهینه‌سازی ساختار جاذب‌های تهرتری، منجر به دستیابی به جذب بیش از ۹۹٪ در فرکانس مرکزی شده است [۴]. همچنین، روش‌های ترکیبی مبتنی بر الگوریتم بهینه‌سازی ازدحام ذرات (PSO) و شبکه‌های عصبی پرسپترون چندلایه (MLP) در طراحی سطوح انتخابگر فرکانس با فیلتر باندتوقف فراکتالی بهبود قابل توجهی در سرعت همگرایی و کاهش هزینه محاسباتی داشته‌اند [۵]. علاوه بر این، چارچوب‌های یادگیری عمیق مانند (FCRM¹) با استفاده از بهینه‌سازی بیزین توانسته‌اند دقت پیش‌بینی را نسبت به روش‌های مرجع افزایش دهند [۶]. مطالعات دیگر نیز از الگوریتم‌های تکاملی مانند کلونی مورچگان برای بهینه‌سازی سه‌بعدی FSS استفاده کرده‌اند [۷] و همچنین طراحی جاذب‌های مایکروویو پهن‌بند با استفاده از ترکیب FSS فراکتالی و مواد کامپوزیتی گزارش شده است [۸، ۹].

با وجود این پیشرفت‌ها، بیشتر روش‌های موجود یا به شبیه‌سازی‌های زمان‌بر وابسته‌اند یا نیازمند حجم بالایی از داده‌های آموزشی برای مدل‌های یادگیری عمیق هستند. از این رو، در این پژوهش رویکردی ترکیبی مبتنی بر الگوریتم PSO و شبکه عصبی ResNet-101 پیشنهاد شده است که هدف آن، مدل‌سازی و پیش‌بینی ضریب بازتاب ساختارهای FSS فراکتالی با حداقل داده آموزشی و حداکثر دقت است. در این روش، داده‌های تولیدشده توسط PSO با داده‌های تصادفی ترکیب شده و به شبکه ResNet-101 آموزش داده می‌شود تا بتواند پاسخ‌های بهینه را با سرعت بیشتر و دقت بالاتر پیش‌بینی کند.

در بخش بعدی، ابتدا درمورد ساختاری که بر روی آن الگوریتم‌ها پیاده‌سازی می‌شوند، توضیحاتی داده خواهد شد و سپس به معرفی الگوریتم PSO و شبکه عصبی رزنت - ۱۰۱ پرداخته می‌شود و پس از آن رویکرد اجرا شده و نتایج آن مورد بررسی قرار می‌گیرد (شکل ۱-۱).



شکل (۱-۱): روندنمای کلی مسیر مقاله

۲- معرفی ساختار جاذب و رویکرد به کار رفته در تحقیق


۲-۱- معرفی ساختار طراحی شده

در طراحی جاذب از شکل هندسی فراکتالی سیرپینسکی-گسکت (Level2) استفاده شده است. (شکل ۲-۱).



شکل (۲-۱): شکل هندسی فراکتالی سیرپینسکی-گسکت (Level2)

سعی بر آن شده که تنها با یک پارامتر متغیر (p نام‌گذاری شده است) جاذب طراحی گردد.



شکل (۲-۲): نمایی جانبی از یک سلول واحد از جاذب طراحی شده

۲-۲- معرفی الگوریتم PSO

PSO که در سال ۱۹۹۵ توسط جیمز کندی و راسل اربهرارت معرفی شد، الهام گرفته از رفتار اجتماعی موجودات زنده‌ای مانند پرندگان است. این الگوریتم با استفاده از یک گروه مجازی از "ذرات"، که هر یک نماینده یک راه‌حل ممکن برای مسئله هستند، تلاش می‌کند تا بهترین راه‌حل را در فضای جستجو پیدا کند. هر ذره دارای موقعیت و سرعت است که به ترتیب نمایانگر یک راه‌حل خاص و جهت حرکت آن در فضای جستجو است. با هر تکرار، ذرات با توجه به بهترین موقعیت‌های فردی ($x^{i,best}$) و گروهی ($x^{g,best}$) به‌روز می‌شوند و به سمت راه‌حل بهینه حرکت می‌کنند [۱۱، ۱۰].

$$v^i[t+1] = wv^i[t] + c_1r_1(x^{i,best}[t] - x^i[t]) + c_2r_2(x^{g,best}[t] - x^i[t]) \quad (1)$$

$$x^i[t+1] = x^i[t] + v^i[t+1] \quad (2)$$


در رابطه ۱ به این نکته اشاره می‌شود که سرعت در لحظه $t+1$ وابسته به چند جمله‌ای متناظر با آن می‌باشد، که اولین عبارت از این چند جمله‌ای سرعت در لحظه قبل (t) و ضریب اینرسی (w) است، ضریب اینرسی معمولاً عددی بین $[0.4, 0.9]$ است که در ادامه به تأثیر انتخاب مقدار w اشاره خواهد شد؛ دومین و سومین عبارت به ترتیب بهترین خاطره شخصی (یا بهترین موقعیت شخصی کسب شده) و بهترین خاطره جمعی (یا بهترین موقعیت کسب شده توسط جمعیت) نام دارد که در آنها r_1, r_2 هردو عدد تصادفی هستند و c_1, c_2 به ترتیب ضریب یادگیری شخصی و ضریب یادگیری جمعی نام دارند که معمولاً مقداری در بازه $[2, 0]$ دارند و این ضرایب در جملات تفاضلی خاطرات (شخصی و جمعی) ضرب می‌گردند؛ علت وجود ضریب اینرسی و ضرایب یادگیری، تعیین رویکرد الگوریتم می‌باشد، که یا به صورت اکتشافی (کشف پاسخ‌های جدید) یا به صورت بهره‌برداری (بهینه‌سازی پاسخ‌های فعلی) است؛ البته لازم به ذکر می‌باشد که می‌توان ضرایب یاد شده را جوری تعیین کرد که رویکرد الگوریتم ترکیبی از هر دو مسیر (اکتشافی و بهره‌برداری) باشد.

۲-۳- شبکه رزنت

شبکه‌های عصبی هم‌گشتی با افزایش تعداد لایه‌ها (افزایش عمق شبکه) می‌توانند جزئیات بیشتری از تصاویر را استخراج کنند و به عبارتی دیگر بر داده‌ها تسلط بیشتری پیدا کنند؛ باین‌وجود این افزایش عمق یک مشکل اساسی را برای این شبکه‌ها، تحت عنوان محوشوندگی گرادیان ایجاد می‌کند. لازم به ذکر است که خطا در شبکه‌های عصبی به‌صورت پس انتشار محاسبه می‌گردد، یعنی روند محاسبه از لایه‌های آخر به سمت لایه‌های اول می‌باشد؛ حال با افزایش عمق شبکه محاسبه گرادیان در لایه‌های نخست به مشکل بر می‌خورد. برای رفع این مشکل مفهومی به نام اتصال پرش یا Skip Connection به وجود آمد، این روش در معماری شبکه عصبی

شکل (۲-۲) نمایشی جانبی از یک سلول واحد از جاذب طراحی شده می‌باشد؛ همانطور که در شکل (۲-۲) مشاهده می‌شود، جاذب فراکتالی از چهار لایه تشکیل شده است (به ترتیب نام برده شده‌اند) و ابعاد آنها به این صورت است که، طول و عرض، هردو برابر با ۲۳ میلی‌متر می‌باشد:

(۱) لایه اول (GND): این لایه از جنس PEC می‌باشد و ضخامت آن صفر در نظر گرفته شده است.
(۲) زیرلایه اول: این زیرلایه از جنس فوم (هوا) می‌باشد و ضخامت آن (H) نام‌گذاری شده است، در فاز اول پروژه برابر با ۷ میلی‌متر است.
(۳) طرح سیرپنسکی گسکت: این طرح بر روی زیرلایه اول قرار دارد و زیرلایه دوم بر روی آن قرار داده شده است، این طرح از مثلث‌های متساوی‌الاضلاع تشکیل شده است که طول هر ضلع آن (p) در بازه بسته $[5/6, 2]$ میلی‌متر توسط الگوریتم بهینه‌ساز PSO تغییر می‌کند و ارتفاع این مثلث‌ها (q) هم متناسب و متناظر با مقداری که p دارد تغییر می‌کنند و ضخامت آن نیز برابر با صفر می‌باشد. شکل (۲-۳) تصویری از نمای جلویی طرح سیرپنسکی گسکت می‌باشد که در آن مقدار p برابر با $5/4736$ میلی‌متر است و ارتفاع مثلث نیز $18/9611$ میلی‌متر است؛ لازم به ذکر است که زیرلایه دوم پنهان از دید شده تا طرح سیرپنسکی گسکت قابل مشاهده گردد. جنس این طرح دارای مقاومت ۵ اهم بر میلی‌متر مربع می‌باشد.



شکل (۲-۳): نمای جلویی جاذب طراحی شده

(۴) زیرلایه دوم که بر روی طرح سیرپنسکی گسکت قرار دارد: این لایه آخرین لایه جاذب طراحی شده می‌باشد. ضخامت این لایه (M) نام‌گذاری شده است) در فاز اول پروژه ۲ میلی‌متر می‌باشد جنس زیرلایه دوم به صورتی تعریف گشته که دارای اپسیلون ۳ و تانژانت تلفات 0.0545 می‌باشد (ماده abs).

گام بعدی پس از طراحی جاذب فراکتالی، طراحی الگوریتم PSO برای بهینه‌سازی ساختار طراحی شده می‌باشد؛ برای پیاده‌سازی الگوریتم بر روی ساختار، از نرم‌افزار متلب استفاده شده است، علت عدم استفاده از الگوریتم بهینه‌ساز موجود در نرم‌افزار CST Studio دلایل زیر می‌باشد:

- امکان قرارگرفتن در کمینه‌های محلی
- کاهش میزان شخصی‌سازی الگوریتم PSO، مانند عدم تعیین جمعیت اولیه، عدم کنترل بر روی ضرایب و...


از این مجموعه، ۱۴۰ داده اول برای آموزش مدل‌های مختلف رزنت استفاده شد و ۳۰ داده آخر برای اعتبارسنجی شبکه‌ها باقی ماند. در رزنت-۱۰۱، با توجه به شکل (۲-۶) تسلط شبکه به دلیل تعداد بیشتر لایه‌های قابل یادگیری، بهتر از رزنت-۱۸ و رزنت-۵۰ است.

تنظیمات آموزش شبکه در محیط MATLAB بر اساس الگوریتم بهینه‌سازی Adam انجام شد. اندازه دسته‌های آموزشی (mini-batch size) برابر با ۱۰، تعداد دوره‌های آموزش (epochs) برابر با ۲۰ و نرخ یادگیری اولیه برابر با 10^{-3} در نظر گرفته شد. نرخ یادگیری طبق روش piecewise در هر ۲۰ دوره با ضریب ۰/۱ کاهش یافت. داده‌ها در هر دوره به صورت تصادفی (every-epoch) جابه‌جا شدند و ارزیابی مدل در فواصل مشخص با استفاده از داده‌های اعتبارسنجی (validation data) انجام گرفت.

در شکل (۲-۵) به مقادیر هاپیرپارامترها و تنظیمات شبکه رزنت-۱۰۱ اشاره شده است.

```
miniBatchSize = 10;
validationFrequency = floor(numel(YTrain)/miniBatchSize);
options = trainingOptions('adam', ...
    'MiniBatchSize', miniBatchSize, ...
    'MaxEpochs', 20, ...
    'InitialLearnRate', 1e-3, ...
    'LearnRateSchedule', 'piecewise', ...
    'LearnRateDropFactor', 0.1, ...
    'LearnRateDropPeriod', 20, ...
    'Shuffle', 'every-epoch', ...
    'ValidationData', {XValidation, YValidation}, ...
    'ValidationFrequency', validationFrequency, ...
    'Plots', 'training-progress', ...
    'Verbose', false);
```

شکل (۲-۵): تنظیمات شبکه رزنت-۱۰۱



شکل (۲-۶): نتیجه مقایسه داده اصلی (اولین داده اعتبارسنجی) با تخمین شبکه رزنت-۱۰۱ (گام اول)

در نهایت، رزنت-۱۰۱ برای ترکیب با الگوریتم PSO انتخاب شد و به عنوان هسته پیش‌بینی‌کننده پاسخ‌های بهینه در الگوریتم ترکیبی قرار گرفت. این الگوریتم ترکیبی با ۳۶ تکرار توانست به پاسخ بهینه

هم‌گشتی رزنت تحت عنوان بلوک باقی‌مانده به کار گرفته شده است. مفهوم این ایده این است که از یک یا چند لایه پرش شود و به نوعی از بیش برآزش شبکه جلوگیری شود.


باتوجه به این اتصال پرش، خروجی لایه با حالت اصلی متفاوت است. بدون استفاده از این اتصال، ورودی x در وزن لایه ضرب می‌شود و سپس یک بایاس به آن اضافه می‌شود؛ سپس این عبارت از یک تابع فعال‌ساز می‌گذرد که خروجی را $H(x)$ در نظر می‌گیریم.

حال با معرفی روش اتصال پرش، خروجی به $H(x)=F(x)+x$ تغییر می‌یابد (شکل (۲-۴)).

با وجود این اتصالات، مدل می‌تواند تابع همانی را یاد بگیرد که تضمین می‌کند لایه‌ی بالاتر حداقل به خوبی لایه‌ی پایین‌تر عمل می‌کند و این عملکرد افت پیدا نکند.

شبکه رزنت - ۱۰۱ یک شبکه با ۳۴۷ لایه است، که از شبکه VGG-19 الهام گرفته شده؛ در حقیقت این اتصالات میان‌بر است که شبکه را به معماری شبکه رزنت تبدیل می‌کند. [۱۲]


شبکه رزنت-۵۰ و رزنت-۱۸ نیز هم‌تایان شبکه رزنت-۱۰۱ می‌باشند اما از عمق کمتری برخوردار هستند، لازم به ذکر است که نام‌گذاری این شبکه‌ها (۱۸ و ۵۰ و ۱۰۱) به ترتیب به تعداد لایه قابل یادگیری آنها اشاره دارد و تعداد کل لایه‌ها نیز در شبکه رزنت-۱۸، ۷۲ لایه و در رزنت-۵۰، ۱۷۷ لایه می‌باشد.



شکل (۲-۴): نمونه یک بلوک Residual


۲-۴- یافته‌های تحقیق

در این پروژه الگوریتم PSO با شبکه رزنت-۱۰۱ ترکیب خواهد شد؛ این روش ترکیبی سرعتی بیشتر را در بهینه‌سازی ساختار ارائه می‌کند. ابتدا ۱۰۰ داده تصادفی با استفاده از الگوریتم تولید داده تصادفی ایجاد شد؛ سپس، ۷۰ داده دیگر با الگوریتم PSO تولید گردید، اما برخلاف تنظیمات پیش‌فرض که تعداد تکرار برابر با تعداد متغیرها ضربدر ۲۰ بود، این بار تعداد تکرار به ۷۰ کاهش یافت تا الگوریتم لزوماً به پاسخ بهینه نرسد. به این ترتیب، مجموعه داده‌ای شامل ۱۷۰ تصویر تولید شد که به مراتب کوچک‌تر از مجموعه داده‌های مورد استفاده در فازهای اصلی پروژه بود و وضعیت پاسخ‌های بهینه در آن مشخص نبود.



شکل (۲-۸): نتیجه مقایسه داده اصلی (اولین داده اعتبارسنجی) با تخمین شبکه رزنت-۱۰۱ (گام دوم)


در گام دوم پروژه تعداد تکرار در الگوریتم PSO برابر با ۱۳۰ تکرار تنظیم شد، که مقایسه جواب بهینه یافت شده در این تعداد تکرار با نتیجه خروجی روش ترکیبی در شکل (۲-۱۰) نشان داده شده است. با توجه به شکل (۲-۱۰) کارآمدی و برتری روش ترکیبی نسبت به الگوریتم PSO کاملاً مشهود است.



شکل (۲-۹): نتیجه تخمین و یافتن جواب بهینه توسط روش ترکیبی

دست یابد، که این موضوع با توجه به شکل (۲-۷) اثبات می‌شود. همچنین، اثبات می‌گردد که این روش، علاوه بر عدم نیاز به مجموعه داده‌های وسیع، نسبت به اجرای الگوریتم PSO در نرم‌افزارهای CST و Studio و متلب بسیار سریع‌تر عمل می‌کند و دقت بالایی نیز دارد. در شکل (۲-۷) بهترین پاسخ یافت شده توسط الگوریتم PSO و روش ترکیبی به این علت هم پوشانی زیادی دارند، چون از ابعاد بهینه (ابعاد زیرلایه اول و دوم) استفاده شده است؛ در گام بعدی برای اثبات کارآمدی این روش تعداد پارامترهای متغیر مسئله به ۳ متغیر H و P و M افزایش یافته است، که به ترتیب طول ضلع هر مثلث (کوچک)، ارتفاع زیرلایه اول، ارتفاع زیرلایه دوم هستند.

به علت پیچیدگی بیشتر مسئله تعداد اعضای مجموعه داده‌ها به ۷۳۰ عضو افزایش یافت، که ۱۳۰ عضو آن به وسیله الگوریتم PSO و ۶۰۰ عضو دیگر آن توسط الگوریتم تصادفی تولید شده‌اند. از شبکه رزنت-۱۰۱ بر روی داده‌ها استفاده شد و ۷۰۰ داده اول برای آموزش و ۳۰ داده آخر برای اعتبارسنجی شبکه مورد استفاده قرار گرفتند. در شکل (۲-۸)، مقایسه پیش‌بینی‌های شبکه با مقادیر واقعی بر روی داده‌های اعتبارسنجی ارائه شده است؛ با توجه به پراکندگی داده‌ها نتیجه حاصل از شبکه رزنت قابل قبول است^۲ در شکل (۲-۹) نتیجه بهترین پاسخ یافت شده توسط الگوریتم PSO در مرحله قبل (زیرا در گام قبلی ابعاد و جذب هردو بهینه بوده‌اند) و روش ترکیبی مشاهده می‌شود؛ همانگونه که از شکل (۲-۹) مشاهده می‌شود نتیجه حاصل از هر دو روش توانسته تقریباً ۷۸٪ از بازه کل را جذب کند و تنها تفاوتی که دارند در این است که در روش ترکیبی مقدار جذب تقریباً پایدارتر است نسبت به مقدار جذب در الگوریتم PSO؛ با توجه به نتایج حاصل از گام دوم اثبات شد که روش ترکیبی (PSORES-101) در مسائل پیچیده نیز عملکرد خوبی از خود نشان می‌دهد و علاوه بر سرعت بالاتر، کارآمدی خود را نیز حفظ می‌کند.



شکل (۲-۷): نتیجه تخمین و یافتن پاسخ بهینه توسط روش ترکیبی


و جمعی کسب شده) آموزش دیده است؛ این روش که برای ایجاد مجموعه داده‌ها استفاده شده است، به‌نوعی توانسته فضایی که الگوریتم بهینه‌ساز ازدحام ذرات قادر به جستجو در آن نبوده را، جستجو کند و به عبارتی دیگر داده‌های تصادفی توانستند نقش بهترین موقعیت همسایگی کسب شده را بازی کنند بدون آن که این عبارت به الگوریتم PSO اضافه گردد و آن را زمان بر کند، از این‌رو شبکه ترکیبی PSORES-101 توانسته بهترین پاسخ (گلوبال) را بیابد (شکل (۲-۹)). این نوآوری می‌تواند علاوه بر افزایش دقت، زمان مدل‌سازی را به شکل قابل‌توجهی کاهش داده و در کنار این اقدام پاسخی بهینه را خروجی دهد.

با استفاده از الگوریتم PSO هشت ساعت برای بهینه‌سازی ساختار طراحی شده سپری شد که این زمان تنها با در نظر گرفتن بهترین موقعیت شخصی و جمعی کسب شده در معادله و بدون احتساب بهترین همسایگی کسب شده بوده است در صورتی که در روش ترکیبی PSO-ResNet-101 حداکثر زمان به ۱۵ دقیقه کاهش پیدا کرد.

مراجع

- [1] T. N. Bitzer, Honeycomb Technology: Materials, Design, Manufacturing, Applications and Testing. Springer Netherlands, 1997.
- [2] B. A. Munk, Frequency Selective Surfaces: Theory and Design. Wiley, 2005.
- [3] J. Romeu and Y. Rahmat-Samii, "Fractal FSS: a novel dual-band frequency selective surface," IEEE Transactions on Antennas and Propagation, vol. 48, no. 7, pp. 1097-1105, 2000.
- [4] V. Chaudhary and R. Panwar, "Neural Network Topology-Based Terahertz Absorber Using Fractal Frequency Selective Surface", IEEE Sensors Journal, vol. 21, no. 21, pp. 24028-24037, 2021.
- [5] P. H. d. F. Silva, R. M. S. Cruz, and A. G. D. Assunção, "Blending PSO and ANN for Optimal Design of FSS Filters With Koch Island Patch Elements," IEEE Transactions on Magnetics, vol. 46, no. 8, pp. 3010-3013, 2010.
- [6] N. Calik, M. A. Belen, P. Mahouti, and S. Koziel, "Accurate Modeling of Frequency Selective Surfaces Using Fully-Connected Regression Model With Automated Architecture Determination and Parameter Selection Based on Bayesian Optimization," IEEE Access, vol. 9, pp. 38396-38410, 2021.
- [7] D. Z. Zhu, P. L. Werner, and D. H. Werner, "Design and Optimization of 3-D Frequency-Selective Surfaces Based on a Multiobjective Lazy Ant Colony Optimization Algorithm," IEEE Transactions on Antennas and Propagation, vol. 65, no. 12, pp. 7137-7149, 2017.
- [8] R. Panwar, S. Puthucheri, V. Agarwala, and D. Singh, "Fractal Frequency-Selective Surface Embedded Thin Broadband Microwave Absorber Coatings Using Heterogeneous Composites," IEEE Transactions on Microwave Theory and Techniques, vol. 63, no. 8, pp. 2438-2448, 2015.

Comparative Analysis of Outputs from PSO and PSORES-101 Algorithms



شکل (۲-۱۰): مقایسه خروجی بهینه یافت شده توسط الگوریتم PSO و روش ترکیبی

۳- جمع‌بندی

این تحقیق باهدف طراحی و بهینه‌سازی سطوح انتخابگر فرکانس فراکتالی از طریق ترکیب الگوریتم بهینه‌سازی ازدحام ذرات (PSO) و شبکه‌های عصبی پیچیده، رویکردی نوین را در این حوزه ارائه می‌دهد. در گام اول پروژه تنها عملکرد این روش ترکیبی و میزان همپوشانی آن با خروجی بهینه الگوریتم PSO مورد مقایسه قرار گرفت؛ در گام دوم پروژه برای اثبات کارآمدی این روش ترکیبی تعداد پارامترهای مسئله افزایش یافت و این افزایش در پیچیدگی سبب شد تا شبکه ترکیبی پاسخ بهینه را با چالشی جدید (نسبت به گام اول) پیدا کند. این نوآوری با به‌کارگیری هم‌زمان الگوریتم بهینه‌سازی و شبکه عصبی، گامی مؤثر در مسیر توسعه سطوح انتخابگر فرکانس با ویژگی‌های بهینه فراهم می‌آورد.

- ترکیب روش‌های بهینه‌سازی و یادگیری عمیق نشان داد که این رویکرد در مقایسه با روش‌های سنتی، توانایی بالاتری در حل مسائل پیچیده FSS دارد.
- استفاده از شبکه‌های عصبی پیچیده و الگوریتم‌های بهینه‌سازی به طور هم‌زمان، راهکاری نوآورانه برای طراحی سطوح انتخابگر فرکانس با ویژگی‌های بهینه ارائه می‌دهد.
- یکی از مزایای الگوریتم بهینه‌ساز ازدحام ذرات افزودن پارامتر بهترین موقعیت همسایگی کسب شده به پارامترهای بهترین موقعیت فردی و جمعی کسب شده در معادله برای یافتن هرچه دقیق‌تر پاسخ بهینه می‌باشد [۱۳]؛ این اقدام با اینکه تضمین‌کننده یافتن بهترین پاسخ می‌باشد؛ اما به‌شدت بر زمان بهینه‌سازی اثر گذاشته و آن را یک پروسه پیچیده‌تر و زمان‌بر تر می‌کند. حال در این تحقیق شبکه رزنت-۱۰۱ با استفاده از داده‌های تصادفی که به‌وسیله الگوریتم تولید داده تصادفی به وجود آمده‌اند، در کنار داده‌های بهینه که توسط الگوریتم بهینه‌ساز ازدحام ذرات به وجود آمده‌اند (بر اساس دو عبارت بهترین موقعیت شخصی

- [9] S. Ji, L. Du, and J. Zhao, "Arbitrary polygon shape optimization applied to multiband frequency selective surface inverse design," *AEU - International Journal of Electronics and Communications*, vol. 159, p. 154476, 2023/02/01/ 2023.
- [10] J. Kennedy and R. Eberhart, "Particle swarm optimization," in *Proceedings of ICNN'95 - International Conference on Neural Networks*, 1995, vol. 4, pp. 1942-1948 vol.4.
- [11] Z. Ghavami, M. Mollaie Emamzadeh, and M. Maghfoori Farsangi, "An intelligent Gradient Method using Particle Swarm Optimization," *Journal of Iranian Association of Electrical and Electronics Engineers*, vol. 22, no. 2, p. 111, 2025.
- [12] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016, pp. 770-778.
- [13] V. Lange, M. Schmitt, and R. Wanka, "Towards a Better Understanding of the Local Attractor in Particle Swarm Optimization: Speed and Solution Quality," in *Adaptive and Intelligent Systems*, Cham, 2014, pp. 90-99: Springer International Publishing.

زیرنویس

¹ Fully Connected Regression Model

$$_2 Cost = \begin{cases} 0, & \text{if } |S_{11}(f)|_{dB} < -10 \quad \forall f \in [2,8]GHz \\ 1, & \text{otherwise} \end{cases}$$

^۳ مقدار میانگین کل SE RM برابر با ۱/۱۷۶۱ است