

İleti dizi birim hücre tasarımı için karınca aslanı optimizasyonu ile geliştirilmiş çok katmanlı algılayıcı modeli eğitimi

Enhanced multi-layer perceptron model training with ant lion optimization for transmitarray unit cell design

Seçkin Karasu¹, Sibel Ünal^{2*}, Muhammed Malkoç²

¹Elektrik Elektronik Mühendisliği Bölümü, Zonguldak Bülent Ecevit Üniversitesi, Zonguldak, Türkiye.
seckin.karasu@beun.edu.tr

²Elektrik Elektronik Mühendisliği Bölümü, Bilecik Şeyh Edebali Üniversitesi, Bilecik, Türkiye.
sibel.unaldi@bilecik.edu.tr, muhammed.malkoc@bilecik.edu.tr

Geliş Tarihi/Received: 02.08.2025
Kabul Tarihi/Accepted: 23.10.2025

Düzeltilme Tarihi/Revision: 17.10.2025

doi: 10.65206/pajes.90467
Araştırma Makalesi/Research Article

Öz

Bu çalışmada, öncelikle bir ileti dizi anten birim hücresi tasarlanmış ve tasarım parametreleri ele alınarak iletim fazı karakteristiği elde edilmiştir. Çalışmanın ikinci adımında ise, standart Çok Katmanlı Algılayıcılar (Multi-Layer Perceptron, MLP), ve Karınca Aslanı Optimizasyonu (Ant Lion Optimization, ALO) ile geliştirilmiş MLP sinir ağı olmak üzere iki farklı model geliştirilmiş ve tasarlanan ileti dizi birim hücre elemanına ait benzetim verileriyle eğitilmiştir. Modellerin performansını değerlendirmek amacıyla kök ortalama kare hata (RMSE) değerleri hesaplanmış ve her iki modelin başarıları karşılaştırılmıştır. Böylece tasarlanan birim hücreye ait tasarım parametreleri ve iletim fazı için yüksek doğruluklu bir model geliştirilmiştir. Çalışma, özellikle 5G ve sonraki nesil iletişim sistemlerinde ileti dizi birim hücre tasarımında yenilikçi ve etkili bir yaklaşım sunmakta, ayrıca yapay zeka ve meta-sezgisel optimizasyon tekniklerinin entegrasyonunun elektromanyetik yapıların tasarım sürecindeki potansiyeli ortaya koymaktadır.

Anahtar kelimeler: Anten, faz, ileti dizi, MLP, karınca aslanı, optimizasyon

Abstract

In the first step of the presented study, a unit cell of the transmitarray antenna is designed, and the transmission phase characteristics are obtained by considering the design parameters. In the second step of the study, two different models, the Multilayer Perceptron (MLP) and AntLion Optimizer (ALO), an enhanced MLP neural network, are developed and trained using the simulated data of the designed unit cell element of the transmitarray. In order to evaluate the performance of the models, root mean square error (RMSE) values were calculated, and the performance of both models was compared. Thus, a high accuracy model was developed for the design parameters and transmission phase of the designed unit cell. The study presents an innovative and effective approach to the design of the unit cell of transmitarray, especially in 5G beyond communication systems, and highlights the potential of optimization and machine learning integration.

Keywords: Antenna, phase, transmitarray, MLP, ant lion, optimization

1 Giriş

Mikroşerit ileti diziler, kaynak antenden gelen dalgayı, ileti dizide yer alan her bir birim hücrenin faz gecikmelerini telafi etmesi prensibi ile manipüle ederek arzu edilen odaklanmış hüzmeye dönüştürmektedirler [1], [2]. Kompakt yapısı, hafifliği, ekonomik oluşu, yüksek kazanç sağlaması ve üretime elverişli olması gibi avantajlı niteliklere sahiptirler. [3], [4]. Ayrıca yansıtıcı dizilerden farklı olarak besleme blokajından etkilenmeyen, yüksek ısıma verimliliği elde etme açısından üstünlüğe sahip geçişli odaklama sistemidirler [5], [6]. Bu avantajlarıyla dikkat çeken güncel çalışmalarda ileti dizilerin tasarımında, açıklık verimi (aperture efficiency), düşük yan lob seviyesi, kazanç bant genişliği ve düşük maliyet gibi çeşitli performans kriterleri önemli tasarım hedefleri arasında yer almaktadır [7]- [9]. Bu belirtilen avantajların yanı sıra kısıtlı bant genişliği gibi bir dezavantaja sahiptir. Sinir ağlarına dayalı veri odaklı yaklaşımların elektromanyetik komponent tasarımında kullanılması son yıllarda güçlü bir araç olarak popülerlik kazandı [10]. Bu kapsamda literatürde ileti dizi tasarımındaki çeşitli dezavantajların üstesinden gelmek, tasarımda performans kriterlerini iyileştirmek ve ayrıca daha az hata ve daha kısa sürede modelleme [11] amacı ile yapay

zekâ ve/veya optimizasyon tekniklerinin tasarımıyla kombine olarak kullanıldığı çalışmalar bulunmaktadır. Çalışma [12] programlanabilir ileti dizilerde faz ve genlik kontrolü sayesinde belirli bir bant genişliğinin başarıldığını göstermiştir. [6] çalışmasında yapay zekâ temelli bir MLP tabanlı model kullanılarak üç farklı frekans bandı için ileti dizi elemanlarının hem iletim fazı hem de genliği yüksek doğrulukla tahmin edilmiştir. Bir başka çalışmada [13] çok bitli ileti dizi tasarımında genlik azalmasıyla ilişkili zorlukları ele alarak performans iyileştirilmesi için Genetik Algoritma tabanlı bir yöntem kullanmıştır. [14] çalışmasında ise ileti dizideki her bir meta-atomun odak uzaklığını ve geometrik boyutunu 1 ms'de hızlı ve doğru bir şekilde belirleyerek dielektrik ileti dizi anteni otomatikleştirmek ve üretmek için tandem sinir ağı önerilmiştir. İletim katsayısını ve faz değerini belirlemek için Res-Net mimarisine dayalı bir derin öğrenme modeli geliştirerek çok sayıda parametre kombinasyonunun oluşturduğu zorluğun üstesinden gelme [15] çalışmasında amaçlanmıştır. İki başlı Res-Net tabanlı bir PSO algoritması kullanılarak, iletim dizi optimize edilmiş ve geleneksel yaklaşıma kıyasla önemli ölçüde daha iyi performans elde edildiği gösterilmiştir.

*Yazışılan yazar/Corresponding author

Önerilen çalışma, anten teorisi ve yapay zekâ tabanlı modellemeyi bütünleştiren disiplinlerarası yaklaşımına sahip bir çalışmadır. Bu çalışmada yapay zekâ kullanılarak, tasarım parametreleri ve frekans ele alınarak tasarlanan iletici dizi birim hücrelerine ait iletim fazı karakteristiği için yüksek doğruluklu bir model geliştirilmiştir. Çalışmada sunulan model, elektromanyetik benzetim programı kullanılarak elde edilen iletim fazı değerlerini ele alan Çok Katmanlı Algılayıcılar (Multi-Layer Perceptron, MLP), kara kutu modeli ile birlikte kullanılmıştır.

Çalışmanın aşamaları: Arzu edilen faz aralığını sağlayan birim hücre tasarımının yapılması, istenilen fazlar için parametrik analizlerin gerçekleştirilmesi, benzetimlerin sonucunda elde edilen verilerin veri setine dönüştürülüp ön işleminin yapılması ve test/egitim olarak bölünmesi, yapay modeli (Karıncı Aslanı Optimizasyonu (Ant Lion Optimization, ALO) yöntemi ile entegre Çok Katmanlı Algılayıcı (MLP) modeli) yöntemlerinin birim hücrenin tasarımında etkinliğinin araştırılması. Bu kapsamda çalışmada tasarlanan iletici dizi birim hücrelerine ait iletim fazı ve tasarım parametrelerinin ele alındığı yüksek doğruluklu, etkili ve hızlı bir yapay zekâ modelinin oluşturulması amaçlanmıştır. Standart MLP ve ALO ile entegre MLP sinir ağı olmak üzere iki farklı model geliştirilerek performansları karşılaştırılmıştır. Yapılan bu kapsamlı çalışma sonucunda elde edilen sonuçlar, aktivasyon fonksiyonu, katman yapısı ve optimizasyon yönteminin model performansı üzerindeki etkisini açıkça ortaya koymuştur. İki katmanlı MLP2(ReLU)-AL modeli, 0.877351 RMSE değeriyle tüm modeller arasında en düşük hata oranını elde ederek en yüksek performansı sergilemiştir.

Bu çalışmanın teknik katkıları şu şekilde özetlenebilir: İletici dizi birim hücre tasarlanması, iletici dizi birim hücrelerinin düşük maliyetli ve yapay zekâ tabanlı modellenmesine yönelik bir yaklaşım sunulması, farklı aktivasyon fonksiyonları ve ağ mimarilerinin karşılaştırmalı olarak incelenmesi, geliştirilen modelin tahmin başarımı, modelin 5G ve ötesi yeni nesil haberleşme sistemlerine yönelik potansiyel uygulamalarla desteklenmesi.

2 Birim hücre tasarımı

Tasarımı yapılan mikroşerit iletici dizi birim hücre elemanı Şekil 1(a)'da ön görünümü verilen birim hücre bir dairesel döngü ve bir modifiye artı geometrilerinde iletken yamalardan oluşmaktadır. Ayrıca tasarlanan birim hücrede, bağıl dielektrik katsayısı $\epsilon_r = 3$ ve kalınlığı 0.508 mm olan RO3003 alt tabaka çok katmanlı olarak kullanılmıştır ve sunulan iletici dizisinin tasarımına ilişkin yan görünüm Şekil 1(c)'de gösterilmiştir. Birim hücreye ait dielektrik tabakanın toplam kalınlığı $z = 3 \times 0.508$ mm olarak tasarlanmıştır. Şekil 1(b)'de görüldüğü üzere üç dielektrik katmandan oluşan birim hücre elemanı 300°'den fazla iletim fazına sahiptir.

y_2 ve l parametreleri değişken, $x = y = 5$ mm, $r_1 = 0.5$ mm, $r_2 = 1$ mm, $r_3 = 2.2$ mm ve $r_4 = 2.4$ mm'dir. Birim hücreye ait değişken tasarım parametrelerine ilişkin bilgiler Tablo 1'de detaylandırılmıştır.


Frekans 14-28 GHz, tasarım parametresi y_2 0.10-1.10, tasarım parametresi l 0.10-1.10 aralığında değişmektedir. İletim fazı -609° ile 68° arasında değişmektedir. Model girişinde min-max normalizasyonu uygulanmıştır. Veri seti, 668 satır ve 4 sütundan oluşan bir boyuta sahiptir. Deney, 22 kere farklı parametreler altında tekrar edilerek çeşitlilik sağlanmıştır.

Tablo 1. Birim hücre tasarım parametrelerine ilişkin aralık ($x = y = 5$ mm, $r_1 = 0.5$ mm, $r_2 = 1$ mm, $r_3 = 2.2$ mm ve $r_4 = 2.4$ mm sabit).

Table 1. Range of design parameters of unit cell ($x = y = 5$ mm, $r_1 = 0.5$ mm, $r_2 = 1$ mm, $r_3 = 2.2$ mm ve $r_4 = 2.4$ mm)

Parametre	Değer Aralığı	Adım Aralığı
y_2	0.1-1.1	0.2
l	0.1-1.1	0.2

Bu çalışmada sunulan iletici dizi birim hücre için değişken parametreler ele alınarak benzetim sonuçları elde edilmiştir. Elde edilen bu sonuçlar ve tasarım parametreleri, modelin eğitiminde kullanılacak veri setini oluşturmada kullanılmıştır.



Şekil 1. Tasarlanan birim hücre (a) Ön görünüm, (b) Perspektif görünüm, (c) Yan görünüm.
Figure 1. Designed unit cell (a) Front view, (b) Perspective view, (c) Side view.

3 MLP ile birim hücre modellemesi

Elektromanyetik benzetim programı kullanılarak tasarımı yapılan ileti dizi birim hücre geometrisi için parametrik tarama (parameter sweep) ile tasarım parametreleri - iletim fazı eğrisi elde edilmiştir. Dairesel döngü ve bir modifiye artı geometrisine sahip ileti dizi birim hücre elemanın yapay sinir ağı tabanlı modelinin oluşturulması için eğitim ve test olmak üzere bölünmüştür. Bu işlem için kfold ile veriler eşit iki parçaya ($K=2$) ayrılmıştır. Bu aşamada eğitim ve test verileri kullanılarak, Yapay sinir ağı tabanlı ileti dizi birim hücresi faz tahmini amacıyla modelin oluşturulması için MLP Ağı kullanılmıştır. Şekil 2'de verilen MLP 'ye ait ağ tasarım parametreleri Tablo 1'deki gibi ele alınmıştır.

3.1 Çok Katmanlı Algılayıcılar

MLP, yapay sinir ağlarının temel yapı taşlarından biri olup; giriş katmanı, bir veya daha fazla gizli katman ve çıkış katmanından oluşan hiyerarşik bir mimariye sahiptir [16]. İnsan beyninin bilgi işleme süreçlerinden esinlenilerek geliştirilen bu yapılar, özellikle derin öğrenme alanındaki ilerlemeler sayesinde, karmaşık ve yüksek boyutlu veri setlerinden anlamlı örüntüler çıkarmada güçlü bir araç hâline gelmiştir [17], [18].

MLP'ler, her katmandaki nöronların bir önceki katmandaki nöronlarla ağırlıklı bağlantılar kurduğu ileri beslemeli (feedforward) bir yapı ile çalışmaktadır. Bu bağlantılar, öğrenme süreci boyunca gradyan inişi tabanlı optimizasyon algoritmaları (örneğin, geri yayılım- backpropagation) aracılığıyla ayarlanan ağırlıklar (w) ve biaslar (b) ile modellenmektedir [19]. Matematiksel olarak, bir nöronun çıktısı, girişlerin ağırlıklı toplamına uygulanan bir aktivasyon fonksiyonu (örneğin ReLU, sigmoid veya tanh) ile hesaplanmaktadır. Bu yapı, ağıın doğrusal olmayan ilişkileri modelleyebilmesini sağlamaktadır [20]. Öğrenme süreci, hata fonksiyonunun minimize edilmesine dayanmaktadır [21]. Geri yayılım algoritması, bu hatayı katmanlar arasında geriye doğru yayarak ağırlıkları güncellerken, Adam gibi modern optimizasyon teknikleri daha hızlı ve etkili bir yakınsama süreci sunmaktadır [22].

MLP'ler; görüntü işleme, doğal dil işleme, otonom sistemler ve finansal analiz gibi çok çeşitli alanlarda başarıyla uygulanmaktadır [23]-[25]. Bu ağların başlıca avantajları arasında karmaşık veri yapılarını modelleyebilme yetisi, büyük veri setlerinde yüksek performans sergileme kapasitesi ve farklı problem türlerine kolayca uyarlanabilirlik yer almaktadır [26]. Ancak MLP'lerin pratik uygulamalarında bazı zorluklar da bulunmaktadır. Yüksek hesaplama maliyeti, aşırı öğrenme riski, hiperparametre ayarlama gereksinimi (örneğin, katman ve nöron sayısı, öğrenme oranı) ve modelin açıklanabilirlik eksikliği gibi sınırlamalar, yaygın kullanım önünde engel teşkil edebilmektedir [27]. Çok katmanlı ağlar, sağlam matematiksel temelleri, esnek yapıları ve geniş uygulama yelpazesi sayesinde yapay zekâ ve derin öğrenme alanlarında dönüştürücü bir rol oynamakta olup, sürekli gelişen teknolojilerle birlikte modern bilişim dünyasının sınırlarını zorlamaya devam etmektedir.

3.2 Karınca Aslanı Optimizasyon Yöntemi

Karınca Aslanı Optimizasyon Algoritması, 2015 yılında Seyedali Mirjalili tarafından geliştirilen, doğadan esinlenen bir meta-sezgisel optimizasyon yöntemidir [28]. Karınca aslanlarının larvalarının kumlu zeminlerde konik çukurlar

kazarak karıncaları avlama davranışından ilham alan bu algoritma, karmaşık ve yüksek boyutlu optimizasyon problemlerine etkili çözümler sunmaktadır. ALO, iki ana popülasyon üzerine kuruludur: karıncalar, çözüm uzayındaki rastgele çözüm adaylarını temsil ederken; karınca aslanları, bu çözümler arasında en iyi uygunluk değerine sahip olanları ifade etmektedir. Algoritma, karıncaların rastgele yürüyüşlerle çözüm uzayında hareket ettiği, karınca aslanlarının ise çukurlar oluşturarak bu karıncaları yakaladığı bir avlanma sürecini simüle etmektedir. Matematiksel olarak, karıncaların konumu, normalleştirilmiş bir rastgele yürüyüş modeli ile güncellenmekte ve bu hareket, karınca aslanlarının çukur etkileriyle sınırlanmaktadır. Çukur etkisi, iterasyon ilerledikçe hareket aralığını daraltan bir mekanizma ile modellenmekte ve bu, karıncaların daha yoğun bir arama yapmasını sağlamaktadır. Elitizm ilkesi, en iyi karınca aslanının her iterasyonda korunmasını ve karıncaların hareketini yönlendirmesini garanti etmektedir, böylece global optimuma yakınsama hızlanmaktadır. ALO'nun temel adımları, popülasyonların rastgele başlatılması, uygunluk değerlerinin hesaplanması, karıncaların konumlarının rastgele yürüyüşle güncellenmesi, çukur etkilerinin uygulanması ve elit karınca aslanının belirlenmesi şeklinde olmaktadır [28]. Algoritma, mühendislik tasarımı [29], makine öğrenmesinde özellik seçimi [30], görüntü işleme [31], enerji sistemlerinin optimizasyonu [32] ve lojistik [33] gibi çok çeşitli alanlarda uygulanmıştır. ALO'nun avantajları arasında basit ve uygulanabilir yapısı, yüksek boyutlu problemlerdeki etkinliği ve hızlı yakınsama yeteneği bulunmaktadır. Genel olarak, ALO'nun esnekliği, gürbüzlüğü ve biyolojik ilhamı, onu akademik araştırmalar ve endüstriyel uygulamalar için değerli bir optimizasyon aracı haline getirmektedir.

Tablo 2. Karınca Aslanı Optimizasyon Algoritması [28].
Table 2. Ant Lion Optimization Algorithm [28].

Algoritma 1 Karınca Aslanı Optimizasyonu Algoritması (ALO)

- 1: **Girdi:** Popülasyon boyutu n , maksimum iterasyon sayısı $MaxIter$, problem boyutu dim , sınırlar lb, ub
- 2: **Çıktı:** En iyi çözüm (*EliteAntLion*) ve uygunluk değeri
- 3: **Başlatma:**
- 4: Karınca aslanı popülasyonunu rastgele başlat: *AntsLions* [$n, dims$]
- 5: Her karınca aslanı için uygunluk değerini hesapla
- 6: En iyi karınca aslanını (*EliteAntLion*) ve uygunluk değerini belirle
- 7: $t \leftarrow 1$
- 8: **while** $t \leq MaxIter$ **do**
- 9: **For** her karınca aslanı $i=1$ **to** n **do**
- 10: Rastgele yürüyüş uygula: $RW(t) = \text{cumsum}(2.\text{rand}(1)-1)$
- 11: Çukur etkisini uygula
- 12: Karınca aslanının konumunu güncelle
- 13: Yeni konum için uygunluk değerini hesapla
- 14: Konumu sınırlar içinde tut
- 15: **if** Karınca arama uzayı dışında ise
- 16: Rastgele arama uzayı içerisine at
- 17: **end if**
- 18: **end for**
- 19: Karınca maliyet değerleri hesapla
- 20: **for** her karınca aslanı $j=1$ **to** n **do**
- 21: **if** karıncanın maliyeti daha iyi ise
- 22: Karınca aslanının konumunu karıncanın konumuyla güncelle
- 23: Yeni uygunluk değeri hesapla
- 24: **end if**
- 25: **end for**
- 26: Elit karınca aslanını güncelle: *EliteAntLion*
- 27: Daralma faktörünü güncelle

28: **end while**
 29: **Döndür:** EliteAntLion ve uygunluk değeri


3.3 Performans Ölçüm Metriği

Bu çalışmada performans ölçüm metriği olarak RMSE kullanılmaktadır. RMSE, özellikle regresyon modellerinde, bir modelin tahmin ettiği değerlerin gerçek değerlere ne kadar yakın olduğunu ölçen bir hata ölçütüdür. Matematiksel eşitliği aşağıdaki gibi verilmektedir [34].

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (1)$$

Bu çalışmada, öncelikle MLP çerçevesinde, tek gizli katman barındıran bir yapay sinir ağı modeli tasarlanmıştır. Model performansını iyileştirmek ve çeşitli parametrelerin etkilerini analiz etmek için, gizli katman nöron sayısı 3-50 arasında değiştirilmiş ve aktivasyon fonksiyonları da sırasıyla ReLU, Tanh ve Sigmoid fonksiyonları kullanılarak simülasyon çalışması yapılmıştır.

Geliştirilmiş çok katmanlı algılayıcı modelinin gizli katman nöron sayısı parametrelerinin bulunması karınca aslanı optimizasyon yöntemi ile yapılmaktadır. Model giriş değişkenleri sırasıyla uygulanan frekans değeri ve tasarlanan birim hücrenin l ve y_2 parametreleri olmaktadır. Model çıkışında birim hücrenin iletim fazı tahmin edilmiştir.




Şekil 2. Karınca aslanı optimizasyonu yöntemi ile geliştirilmiş çok katmanlı algılayıcı modeli eğitimi.

Figure 2. Training of multilayer perceptron model improved with ant lion optimization method.


4 Nümerik Sonuçlar

MLP modelinin farklı aktivasyon fonksiyonları için gizli katman nöron sayısına göre performans değişimi Şekil 3'teki grafikte verilmiştir. Burada her bir nöron sayısı için eğitim ve test süreci 10 kez tekrarlanarak yapıldığı için kutu bıyık grafiği ile gösterilmesi uygun görülmüştür. Performans metriği olarak RMSE değeri kullanılmıştır ve düşük RMSE değeri, modelin daha iyi performans gösterdiği anlamına gelmektedir. Grafiğin yatay ekseninde nöron sayısı, dikey ekseninde ise RMSE değerleri yer alırken, farklı renkler ise üç farklı aktivasyon fonksiyonunu temsil etmektedir. Genel olarak nöron sayısı arttıkça RMSE değerinin her üç aktivasyon fonksiyonu için de azaldığı gözlemlenmektedir. Bu, nöron sayısının artmasının model performansını iyileştirdiğini göstermektedir. Tanh aktivasyon fonksiyonu genellikle diğer iki fonksiyona göre daha yüksek RMSE değerleri üretmektedir ve performans açısından daha zayıf kaldığı söylenebilir. ReLU ise başlangıçta daha yüksek RMSE değerleri göstermesine rağmen, nöron sayısı arttıkça performansı iyileşmekte ve zamanla daha iyi hale gelmektedir. Ancak nöron sayısı 50 olduğunda Sigmoid fonksiyonundan daha kötü performans göstermektedir. Sigmoid fonksiyonu, gizli katman nöron sayısına bağlı olarak en düşük RMSE değerlerine sahip olup, özellikle 20 ve daha fazla nöron içeren durumda diğer iki aktivasyon fonksiyonu içeren modele göre daha iyi performans sergilemektedir. Sonuç olarak, bu grafikten, Sigmoid aktivasyon fonksiyonunun daha istikrarlı ve düşük hata oranları gösterdiği, ReLU'nun ise nöron sayısına bağlı olarak performansının arttığı, ancak Sigmoid'in daha düşük bir performans sergilediği anlaşılmaktadır. Tanh'ın en yüksek RMSE değeri ile en düşük performansa sahip olduğu görülmüştür. En iyi model sonucuna göre aktivasyon fonksiyonlarından elde edilen RMSE değerlerinin değişimi ise Şekil 4'teki gibi verilmiştir. Sigmoid fonksiyonun daha iyi performans sergilediği daha net bir şekilde gözlenmiştir.




Şekil 3. MLP-ReLU, MLP-Tanh, MLP-Sigmoid modellerinin gizli katman nöron sayısına göre RMSE değerine göre değişiminin kutu bıyık grafiği ile gösterimi.

Figure 3. Box-whisker plot showing the change in RMSE value according to the number of hidden layer neurons of MLP-ReLU, MLP-Tanh, MLP-Sigmoid models.



Şekil 4. MLP-ReLU, MLP-Tanh, MLP-Sigmoid modellerinin gizli katman nöron sayısına göre en iyi performansı veren durumun gösterimi.

Figure 4. Representation of the best performance of MLP-ReLU, MLP-Tanh, MLP-Sigmoid models according to the number of hidden layer neurons.




Şekil 5. Farklı aktivasyon fonksiyonlarına sahip MLP modellerinin iterasyon bazlı RMSE performans karşılaştırması.
Figure 5. Iteration-based RMSE performance comparison of MLP models with different activation functions.

İki gizli katman içeren modeller için AL yöntemi ile yapılan optimizasyon işlemi simülasyon sonuçları incelendiğinde Şekil 5'te üç farklı yöntemin (MLP2(Sigmoid)-AL, MLP2(Tanh)-AL ve MLP2(ReLU)-AL) 20 iterasyon boyunca RMSE değerlerini logaritmik ölçekte (Y eksen) karşılaştırılmaktadır. X eksen ise iterasyon sayısını (1'den 20'ye) temsil etmektedir. İlk iterasyonlarda tüm yöntemler yüksek hata oranlarıyla başladığı görülmektedir. RMSE değerleri yaklaşık 10^2 ile 10^1 seviyeleri arasında seyrettiği söylenebilir. Ancak MLP2(ReLU)-AL, diğer iki yöntemle kıyasla biraz daha düşük bir başlangıç hatası sergileyerek erken bir avantaj sağladığı görülmektedir. 2. ve 3. iterasyonlarda MLP2(Sigmoid)-AL, MLP2(Tanh)-AL'nin RMSE değerleri hala 10^1 civarında yüksek kalırken, MLP2(ReLU)-AL'nin hata oranı daha belirgin bir düşüş trendine girdiği gözlemlenmiştir. 4. iterasyondan itibaren tüm yöntemlerde RMSE değerleri azalmaya başlamış ve özellikle MLP2(ReLU)-AL, 6. iterasyona gelindiğinde 10^0 seviyesinin altına yaklaşarak diğer yöntemlere kıyasla daha hızlı bir öğrenme performansı göstermiştir. MLP2(Sigmoid)-AL, MLP2(Tanh)-AL ise bu aşamada hala 10^0 'ın üzerinde kalarak daha yavaş bir iyileşme sergilemiştir. 7-10. iterasyonlar arasında MLP2(ReLU)-AL'nin üstünlüğü daha da belirginleşmiştir. Bu yöntem 10^{-1} seviyesine ulaşarak hata oranını ciddi şekilde düşürmüştür. Aynı dönemde MLP2(Sigmoid)-AL, MLP2(Tanh)-AL, 10^0 üzerinde seyretmeye devam etmiştir. 11. iterasyondan 20. iterasyona kadar olan süreçte RMSE değerleri genel olarak sabitlenme eğilimine girmiştir. MLP2(ReLU)-AL, 10^{-1} 'in altına inerek en düşük hata oranı elde edilmiştir. Buna karşılık, MLP2(Sigmoid)-AL ve MLP2(Tanh)-AL, 10^{-1} civarında kalarak belirgin bir iyileşme gösterememiştir. Genel olarak, MLP2(ReLU)-AL, hem daha hızlı hata azaltma kapasitesi hem de daha düşük nihai hata oranıyla diğer iki yöntemle kıyasla açıkça daha üstün bir öğrenme performansı sergilemiş ve bu süreçte daha etkili bir yöntem olduğunu kanıtlamıştır.

Farklı yapay sinir ağı modellerinin performansını değerlendirmek amacıyla, tek katmanlı (MLP1) ve iki katmanlı

(MLP2) yapılar kullanılarak tasarlanan modeller, Sigmoid, Tanh ve ReLU aktivasyon fonksiyonlarıyla test edilmiş ve RMSE (Root Mean Square Error) metriği üzerinden karşılaştırılmıştır. MLP2 modellerinde, iki katmandaki nöron sayılarının optimizasyonu için Karınca Aslanı (Ant Lion, AL) algoritması kullanılmış ve bu modeller MLP2-AL olarak adlandırılmıştır. Tablo 3'te ve Şekil 6'da oluşturulan modellerin performansları verilmiştir. Elde edilen sonuçlar, modeller arasında belirgin performans farkları olduğunu ortaya koymuş ve özellikle katman yapısı ile optimizasyon yönteminin tahmin doğruluğu üzerindeki etkisini açıkça göstermiştir.

Detaylı sonuçlara bakıldığında, iki katmanlı ve Ant Lion optimizasyonlu MLP2(ReLU)-AL modeli, 0.877351 RMSE değeriyle tüm modeller arasında en düşük hata oranını elde ederek üstün bir performans sergilemiştir. Bu sonuç, ReLU aktivasyon fonksiyonunun doğrusal olmayan ilişkileri modellemedeki başarısını ve Ant Lion algoritmasının iki katmandaki nöron sayılarını etkili bir şekilde optimize ettiğini göstermektedir. İkinci en iyi performansı, 1.065500 RMSE ile MLP2(Sigmoid)-AL modeli sunmuştur; bu, Sigmoid fonksiyonunun iki katmanlı yapıda ve AL optimizasyonu ile hala rekabetçi bir performans sağlayabildiğini, ancak ReLU'nun gerisinde kaldığını ortaya koymaktadır. Tek katmanlı modeller arasında ise MLP1(Sigmoid), 1.264177 RMSE ile en iyi sonucu vermiş, ancak bu değer MLP2-AL modellerinin çoğundan daha yüksek kalarak tek katmanlı yapının sınırlamalarını yansıtmıştır. MLP1(ReLU) modeli, 1.862630 RMSE ile Sigmoid tabanlı tek katmanlı modelden daha zayıf bir performans göstermiş, bu da ReLU'nun tek katmanlı yapıda gradyan optimizasyonunda zorluklar yaşamış olabileceğini düşündürmektedir. Tek katmanlı modeller arasında en kötü performansı ise 3.556544 RMSE ile MLP1(Tanh) sergilemiş; Tanh'ın sıfır merkezli doğasına rağmen, tek katmanlı yapıda veri setinin özelliklerini yeterince öğrenemediği anlaşılmıştır.



Şekil 6. Farklı Aktivasyon Fonksiyonları ve Optimizasyon Yöntemlerine Sahip Çok Katmanlı Perceptron Modellerinin RMSE Performans Karşılaştırması.

Figure 6. RMSE Performance Comparison of Multi-Layer Perceptron Models with Different Activation Functions and Optimization Methods

Tablo 3. Çok Katmanlı Algılayıcı Modellerinin RMSE Performans Tablosu.

Table 3. RMSE Performance Table of Multilayer Perceptron Models.

Modeller	RMSE	Nöron Sayısı
MLP1(Sigmoid)	1.264177	47
MLP1(Tanh)	3.556544	45
MLP1(ReLU)	1.862630	49
MLP2(Sigmoid)-AL	1.065500	26-46
MLP2(Tanh)-AL	5.461710	39-50
MLP2(ReLU)-AL	0.877351	50-44


En çarpıcı sonuçlardan biri, iki katmanlı ve Ant Lion optimizasyonlu MLP2(Tanh)-AL modelinin 5.461710 RMSE ile tüm modeller arasında açık ara en yüksek hata oranına sahip olmasıdır. Bu, Tanh aktivasyon fonksiyonunun iki katmanlı yapıda, özellikle AL optimizasyonu ile birleştiğinde, veri setine veya model konfigürasyonuna uygun olmadığını ve potansiyel olarak gradyan patlaması veya kaybolması gibi ciddi öğrenme sorunlarıyla karşılaştığını göstermektedir. Tanh'ın bu zayıf performansı, veri ölçeklendirme sorunları, AL algoritmasının Tanh ile uyumsuzluğu veya modelin karmaşıklık seviyesinin veri setine uygun olmaması gibi faktörlerden kaynaklanabilir.

Genel olarak, iki katmanlı MLP2-AL modelleri, tek katmanlı MLP1 modellerine kıyasla daha düşük hata oranları üretmiş ve Ant Lion optimizasyonunun, özellikle ReLU ve Sigmoid aktivasyon fonksiyonlarıyla, nöron sayılarını belirlemede

etkili bir katkı sağladığı görülmüştür. ReLU tabanlı MLP2-AL modelinin başarısı, bu yapıdaki öğrenme kapasitesinin ve AL algoritmasının optimizasyon gücünün veri setine uygunluğunu yansıtmaktadır. Buna karşın, Tanh aktivasyon fonksiyonunun hem tek katmanlı hem de iki katmanlı modellerde düşük performans göstermesi, bu fonksiyonun veri setinin özelliklerine veya model mimarisine uygun olmadığını ortaya koymaktadır. Bu bulgular, ReLU tabanlı MLP2-AL modelinin söz konusu problem için en uygun seçim olduğunu ve gelecek çalışmaların bu modelin hiperparametre optimizasyonu (örneğin, öğrenme oranı, katman boyutları veya epoch sayısı) ile veri ön işleme tekniklerine odaklanması gerektiğini göstermektedir.


MLP1(Sigmoid), MLP1(Tanh) ve MLP1(ReLU) için elde edilen en düşük hata değerine karşılık model nöron sayısı sırasıyla 47, 45 ve 49 olarak elde edilmiştir. MLP2(Sigmoid)-AL, MLP2(Tanh)-AL ve MLP2(ReLU)-AL için ise birinci ve ikinci katman nöron sayıları sırasıyla 26-46, 39-50, 50-44 olarak elde edilmiştir. Sonuçlar Tablo 3'te verilmiştir.

Şekil 7 ve Şekil 8'de, seçilen iki farklı tasarım parametresi için parametrik taramadan elde edilen gerçek değerlere karşılık MLP2(ReLU)-AL yöntemiyle yapılan kestirim sonuçları, X ekseninde frekans ve Y ekseninde iletim fazı olacak şekilde çizdirilmiştir. Görüldüğü üzere, önerilen ileti dizi birim hücresi tasarımında seçilen her iki tasarım parametresi kombinasyonu ($l = 0.1mm$, $y2 = 0.1mm$ ve $l = 0.5mm$, $y2 = 0.9mm$) için gerçek değer ve Ant Lion optimizasyonlu MLP2(ReLU)-AL modeli ile elde edilen tahmin değeri oldukça iyi bir uyuma sahiptir. Ayrıca ReLU tabanlı MLP2-AL modelinin birim hücrenin çalışma frekans aralığının (14 GHz-28 GHz) her bölgesinde iletim fazı için genel olarak başarılı bir tahmin yaptığı söylenebilir.



Şekil 7. $l = 0.1\text{mm}$, $y_2 = 0.1\text{mm}$ seçilen tasarım parametreleri için MLP2(ReLU)-AL yönteminin performans sonucu.

Figure 7. The performance result of the MLP2(ReLU)-AL method for the selected design parameters $l = 0.1\text{mm}$, $y_2 = 0.1\text{mm}$.



Şekil 8. $l = 0.5\text{mm}$, $y_2 = 0.9\text{mm}$ seçilen tasarım parametreleri için MLP2(ReLU)-AL yönteminin performans sonucu.

Figure 8. The performance result of the MLP2(ReLU)-AL method for the selected design parameters $l = 0.5\text{mm}$, $y_2 = 0.9\text{mm}$.

5 Sonuçlar

Elektromanyetik benzetim programı kullanılarak tasarımı yapılan ileti dizi birim hücre geometrisi için parametrik tarama (parameter sweep) yöntemiyle veriler elde edilmiştir. Bir dairesel döngü ve bir modifiye artı geometrilerinden oluşan ileti dizi birim elemanın yapay sinir ağı tabanlı modelinin oluşturulması amacıyla, bu veriler eğitim ve test setlerine ayrılmıştır. Veri bölünmesi için k-fold çapraz doğrulama yöntemi kullanılmış ve veriler eşit iki parçaya ($K=2$) bölünmüştür. Modellerin performansı, veri setinin 10 farklı rastgele bölünmesiyle 2-fold çapraz doğrulama kullanılarak daha güvenilir bir şekilde tahmin edilmiştir. 10 tekrar, modelin genelleme performansını daha gürbüz bir şekilde değerlendirme imkânı sunmaktadır. Bu aşamada, ileti dizi birim hücresi faz tahmini amacıyla model oluşturmak için tek katmanlı (MLP1) ve iki katmanlı (MLP2) yapay sinir ağı

modelleri, Sigmoid, Tanh ve ReLU aktivasyon fonksiyonlarıyla test edilerek RMSE metriği üzerinden performansları değerlendirilmiştir. MLP2 modellerinde, nöron sayılarının optimizasyonu için ALO sezgisel optimizasyon algoritması kullanılmış ve bu modeller MLP2-AL olarak adlandırılmıştır. Elde edilen sonuçlar, aktivasyon fonksiyonu, katman yapısı ve optimizasyon yönteminin model performansı üzerindeki etkisini açıkça ortaya koymuştur.

İki katmanlı MLP2(ReLU)-AL modeli, 0.877351 RMSE değeriyle tüm modeller arasında en düşük hata oranını elde ederek en yüksek performansı sergilemiştir. Bu, ReLU'nun doğrusal olmayan ilişkileri modellemedeki başarısını ve AL algoritmasının nöron sayılarını etkili bir şekilde optimize ettiğini göstermektedir. MLP2(Sigmoid)-AL modeli, 1.065500 RMSE ile ikinci en iyi performansı sunmuş, Sigmoid'in iki katmanlı yapıda rekabetçi olduğunu, ancak ReLU'nun gerisinde kaldığını göstermiştir. Tek katmanlı modeller arasında MLP1(Sigmoid), 1.264177 RMSE ile en iyi sonucu vermiş, ancak iki katmanlı modellerin çoğundan daha yüksek hata oranıyla tek katmanlı yapının sınırlamalarını yansıtmıştır. MLP1(ReLU) 1.862630 ve MLP1(Tanh) 3.556544 RMSE değerleriyle daha zayıf performans sergilemiştir, özellikle Tanh'ın tek katmanlı yapıda veri özelliklerini öğrenmekte zorlandığı anlaşılmıştır.

En çarpıcı sonuç, MLP2(Tanh)-AL modelinin 5.461710 RMSE ile tüm modeller arasında en yüksek hata oranına sahip olmasıdır. Bu, Tanh'ın iki katmanlı yapıda ve AL optimizasyonu ile veri setine uygun olmadığını, gradyan patlaması veya kaybolması gibi sorunlarla karşılaşmış olabileceğini düşündürmektedir. Tanh'ın düşük performansı, veri ölçeklendirme eksiklikleri, AL algoritmasıyla uyumsuzluk veya modelin veri setine uygun olmayan karmaşıklığı gibi faktörlerden kaynaklanabilir.

Genel olarak, iki katmanlı MLP2-AL modelleri, tek katmanlı MLP1 modellerine kıyasla daha düşük hata oranları üretmiş ve AL optimizasyonunun, özellikle ReLU ve Sigmoid ile, performansı artırdığı görülmüştür. ReLU tabanlı MLP2-AL, veri setine en uygun model olarak öne çıkarken, Tanh hem tek hem de iki katmanlı modellerde zayıf performans göstermiştir. Bu bulgular, ReLU tabanlı MLP2-AL modelinin hiperparametre optimizasyonu (örneğin, öğrenme oranı, katman boyutları) ve veri ön işleme teknikleriyle daha da geliştirilebileceğini göstermektedir. Ayrıca, MLP2(Tanh)-AL'nin düşük performansının nedenleri (veri normalizasyonu, AL-Tanh etkileşimi veya optimizasyon instabilitesi) detaylı olarak incelenmelidir. Farklı optimizasyon algoritmaları veya veri ön işleme yöntemlerinin denenmesi, Tanh tabanlı modellerin performansını iyileştirebilir. Ayrıca gelecek çalışmalarda anten tasarımlarında yapay sinir ağı modellerinin optimizasyon zamanlarını düşürmesi üzerine etkileri incelenebilir [35]. Bu çalışma, anten tasarımında kullanılmak üzere yapay sinir ağı tasarımında aktivasyon fonksiyonu ve optimizasyon yönteminin entegrasyonunun kritik rolünü vurgulamakta ve gelecek çalışmalar için yol gösterici bir temel sunmaktadır. Oluşturulan modellerin başarımı, eğitim veri setinin kapsamına ve kalitesine doğrudan bağlıdır. İleriki çalışmalarda transfer öğrenimi yaklaşımı ile önceden eğitilmiş modeller, yeni frekans bantları veya geometrilere uyarlanarak genelleme yeteneği güçlendirilebilir.

6 Conclusions

Data was obtained using the parameter sweep method for the unit cell geometry of the designed transmitarray using an

electromagnetic simulation program. These data were divided into training and test sets for the purpose of creating an artificial neural network-based model of the unit cell of the transmitarray, which consists of a circular loop and a modified cross geometry. The k-fold cross-validation method was used for data splitting, and the data were divided into two equal parts (K=2). The performance of the models was estimated more reliably using 2-fold cross-validation with 10 different random splits of the dataset. 10 repetitions provide a more robust assessment of the model's generalization performance. At this stage, single-layer (MLP1) and two-layer (MLP2) artificial neural network models were tested with Sigmoid, Tanh, and ReLU activation functions to create a model for the transmission phase estimation of the designed unit cell, and their performance was evaluated using the RMSE metric. In the MLP2 models, the ALO heuristic optimization algorithm was used to optimize the number of neurons, and these models were named MLP2-AL. The obtained results clearly demonstrated the effect of the activation function, the structure of the layer, and the optimization method on model performance.

The two-layer MLP2(ReLU)-AL model demonstrated the highest performance, achieving the lowest error rate among all models with an RMSE value of 0.877351. This demonstrates the success of ReLU in modeling non-linear relationships and the effectiveness of the AL algorithm in optimizing the number of neurons. The MLP2(Sigmoid)-AL model delivered the second-best performance with an RMSE of 1.065500, demonstrating that Sigmoid is competitive in a two-layer structure but lags behind ReLU. Among single-layer models, MLP1(Sigmoid) achieved the best result with an RMSE of 1.264177, but it reflected the limitations of the single-layer structure with a higher error rate than most two-layer models. MLP1(ReLU) and MLP1(Tanh) showed weaker performance with RMSE values of 1.862630 and 3.556544, respectively, with Tanh particularly struggling to learn data features in a single-layer structure.

The most impressive result is that the MLP2(Tanh)-AL model has the highest error rate among all models, with an RMSE of 5.461710. This suggests that Tanh may not be suitable for the data set in a two-layer structure and with AL optimization, and may have encountered problems such as gradient explosion or vanishing. The poor performance of Tanh may be due to factors such as data scaling deficiencies, incompatibility with the AL algorithm, or the model's complexity being unsuitable for the dataset.

In general, two-layer MLP2-AL models produced lower error rates compared to single-layer MLP1 models, and AL optimization, especially with ReLU and Sigmoid, was found to improve performance. ReLU-based MLP2-AL emerged as the most suitable model for the dataset, while Tanh showed poor performance in both single- and two-layer models. These findings suggest that the ReLU-based MLP2-AL model can be further improved through hyperparameter optimization (e.g., learning rate, layer sizes) and data preprocessing techniques. Additionally, the reasons for the low performance of MLP2(Tanh)-AL (data normalization, AL-Tanh interaction, or optimization instability) should be investigated in detail. Testing different optimization algorithms or data preprocessing methods could improve the performance of Tanh-based models. Furthermore, future studies may examine the effects of artificial neural network models on reducing optimization time in antenna designs [35]. This study

highlights the critical role of integrating the activation function and optimization method in artificial neural network design for use in antenna design and provides a guiding foundation for future studies. The performance of the generated models is directly dependent on the scope and quality of the training dataset. With the Transfer Learning approach, pre-trained models can be adapted to new frequency bands or geometries, strengthening their generalization ability for future works.

7 Yazar katkı beyanı

Gerçekleştirilen çalışmada birinci yazar modelin tasarımı ve sonuçların elde edilip değerlendirilmesinde, ikinci yazar konseptin oluşturulması, literatür taraması, tasarımların ve sonuçların incelenmesi- değerlendirilmesi ve birim hücre tasarımında, üçüncü yazar birim hücre tasarımında katkı sunmuşlardır.

8 Etik kurul onayı ve çıkar çatışması beyanı

"Hazırlanan makalede etik kurul izni alınmasına gerek yoktur."

"Hazırlanan makalede herhangi bir kişi/kurum ile çıkar çatışması bulunmamaktadır."

9 Kaynaklar

- [1] Aziz A, Yang F, Xu S, Li M, Chen HT. "A high-gain dual-band and dual-polarized transmitarray using novel loop elements". *IEEE Antennas and Wireless Propagation Letters*, 18(6), 1213-1217, 2019.
- [2] Reis JR, Vala M, Caldeirinha RFS. "Review paper on transmitarray antennas". *IEEE Access*, 7, 94171-94188, 2019.
- [3] Abdelrahman AH, Yang F, Elsherbeni, AZ, Nayeri, P. Analysis and design of transmitarray antennas. San Francisco, CA, USA, Morgan & Claypool, 2017
- [4] Malkoç M, Ünalı S, Çimen, S. "Düşük profil mm-dalga bandı 5g uygulamaları için iletici anten tasarımı". In 5th. International Congress on Contemporary Scientific Research, (846-856), Kayseri, Türkiye, Nisan 2024.
- [5] Yang S, Yan Z, Liu P, Li XA. "Linearly-polarized-feed dual-circularly polarized dual-beam transmitarray with independent beam control". *IEEE Antennas and Wireless Propagation Letters*, 21(7), 1497-1501, 2022.
- [6] Belen MA, Caliskan, Koziel S. et al. "Optimal design of transmitarray antennas via low-cost surrogate modelling". *Scientific Reports* 13, 15044, 2023.
- [7] Malkoç M, Ünalı S, Çimen S. "Low-Cost Transmitarray Design with High Gain Bandwidth and Suppressed SLL". *Electronics*, 14(20), 4044, 2025.
- [8] Song L, Wang Y, Guo L. "A low-cost ultrathin metal-only transmitarray antenna at x-band," *IEEE Antennas and Wireless Propagation Letters*, 23(5), 1443-1447, 2024.
- [9] Khan MI, Loconsole AM, Anelli F, Francione VV, Khan AU, Simone M, Sorbello G, Prudeniano F. "A low-profile dual-polarized transmitarray with enhanced gain and beam steering at Ku band". *Applied Sciences* 15(9), 4656, 2025.
- [10] Goudos SK, Diamantoulakis PD, Matin MA, Sarigiannidis P, Wan S, Karagiannidis GK. "Design of antennas through artificial intelligence: State of the art and challenges". *IEEE Communication Magazine*, (12), 96-102, 2022.
- [11] Gayatri T. et al. "A review on optimization techniques of antennas using ai and ml/dl algorithms". *International*

- Journal of Advances in Microwave Technology 7(2), 288-295, 2022.
- [12] Li H. et al. "Design of programmable transmitarray antenna with independent controls of transmission amplitude and phase". IEEE Transactions on Antennas and Propagation, 70(9), 8086-8099, 2022.
 - [13] Nouredine M. et al. "Wideband transmitarray with independent phase/amplitude control for millimeter-wave vehicular sensing and communication". AEU-International Journal of Electronics and Communications 195 (2025): 155771, 2025.
 - [14] Deng, WQ, Xu S, Xu Z, and Zhu SY. "Automated design of millimeter-wave dielectric transmitarray antenna using tandem network". IEEE Antennas and Wireless Propagation Letters, 23(11), 3549-3553, 2024.
 - [15] Huang, Q, Leung, KW. "Transmitarray design of dielectric resonator antennas using deep learning", In 2024 IEEE International Workshop on Antenna Technology (iWAT), Sendai, Japan, (32-35), 2024.
 - [16] Murtagh F. "Multilayer perceptrons for classification and regression". Neurocomputing, 2(5-6), 183-197, 1991.
 - [17] Sze V, Chen, YH, Yang TJ, Emer JS. "Efficient processing of deep neural networks: A tutorial and survey". Proceedings of the IEEE, 105(12), 2295-2329, 2017.
 - [18] Dong S, Wang P, Abbas K. "A survey on deep learning and its applications". Computer Science Review, 40, 100379, 2021.
 - [19] Ojha VK, Abraham A, Snášel V. "Metaheuristic design of feedforward neural networks: A review of two decades of research". Engineering Applications of Artificial Intelligence, 60, 97-116, 2017.
 - [20] Silver RA. "Neuronal arithmetic". Nature Reviews Neuroscience, 11(7), 474-489, 2010.
 - [21] Abuqaddom I, Mahafzah BA, Faris H. "Oriented stochastic loss descent algorithm to train very deep multi-layer neural networks without vanishing gradients". Knowledge-Based Systems, 230, 107391, 2021.
 - [22] Singarimbun RN, Nababan EB, Sitompul OS. "Adaptive moment estimation to minimize square error in backpropagation algorithm". In 2019 International Conference of Computer Science and Information Technology (ICoSNiKOM) 1-7, November 2019,
 - [23] Ramchoun H, Ghanou Y, Ettaouil M, Janati Idrissi MA. "Multilayer perceptron: Architecture optimization and training".
 - [24] Reddy BNK, Jogi S. "Design and Implementation of an FPGA-based Emulator Circuit for MLP using Memristors". In 2024 28th International Symposium on VLSI Design and Test (VDATE) 1-6, September 2024.
 - [25] Zhang M, Wen G, Zhong J, Chen D, Wang C, Huang X, Zhang S. "MLP-like model with convolution complex transformation for auxiliary diagnosis through medical images". IEEE Journal of Biomedical and Health Informatics, 27(9), 4385-4396, 2023.
 - [26] Hong Y, Zhang M, WQ. "Big data and reliability applications: The complexity dimension". Journal of Quality Technology, 50(2), 135-149, 2018.
 - [27] Liu R, Li Y, Tao L, Liang D, Zheng H T. "Are we ready for a new paradigm shift? a survey on visual deep mlp". Patterns, 3(7), 2022.
 - [28] Mirjalili S. "The ant lion optimizer". Advances in engineering software, 83, 80-98, 2015.
 - [29] Li L, Wu WY. "Antlion algorithm based on immune cloning and its truss optimization", 2017.
 - [30] Emary E, Zawbaa H M, Hassanien A E. "Binary ant lion approaches for feature selection". Neurocomputing, 213, 54-65, 2016.
 - [31] Giveki D, Zaheri A, Allahyari N. "Designing CNNs with optimal architectures using antlion optimization for plant leaf recognition". Multimedia Tools and Applications, 84(8), 4625-4654, 2025.
 - [32] Mouassa S, Bouktir T, Salhi A. "Ant lion optimizer for solving optimal reactive power dispatch problem in power systems". Engineering science and technology, an international journal, 20(3), 885-895, 2017.
 - [33] Wang Y, Shi Q. "Spare parts closed-loop logistics network optimization problems: Model formulation and meta-heuristics solution". IEEE Access, 7, 45048-45060, 2019.
 - [34] Karasu S, Ünalı S. "Estimating the bandwidth of the metamaterial antenna with machine learning and feature importance methods". In 4th International Scientific Research and Innovation Congress 1017-1027, December 2022.
 - [35] Özkaya U, Seyfi L, Öztürk Ş. "Dimension optimization of multi-band microstrip antennas using deep learning methods". Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi, 27(2), 229-233, 2021.