T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

YAPAY ZEKA ARACILIĞIYLA ANTEN PARAMETRELERİNİN VEKİL MODELLEMESİ VE SİMÜLASYONU

Yekta Onur EREN

DANIŞMAN
Doç. Dr. Ahmet Arif ULUSLU
(danışman imzalı olacaktır)

Savunma Teknolojileri Anabilim Dalı (Disiplinlerarası)

Savunma Teknolojileri, Tezli Yüksek Lisans Programı

Haziran, 2025

TEZ KABUL VE ONAYI

Yekta Onur EREN tarafından, **Doç. Dr. Ahmet Arif ULUSLU** danışmanlığında hazırlanan **"YAPAY ZEKA ARACILIĞIYLA ANTEN PARAMETRELERİNİN VEKİL MODELLEMESİ VE SİMÜLASYONU"** başlıklı bu çalışma, jürimiz tarafından **13/06/2025** tarihinde yapılan sınav sonucunda **oy birliği** ile başarılı bulunarak **Yüksek Lisans Tezi** olarak kabul edilmiştir.

Tez Jürisi

		İmza	**Sonuç**
DANIŞMAN	Doç. Dr. Ahmet Arif ULUSLU İstanbul Üniversitesi-Cerrahpaşa Savunma Teknolojileri Anabilim Dalı		☐ Kabul ☐ Ret
ÜYE	Dr. Öğr. Üyesi Hasan Kemal SÜRMEN İstanbul Üniversitesi-Cerrahpaşa Savunma Teknolojileri Anabilim Dalı		☐ Kabul ☐ Ret
ÜYE	Doç. Dr. Peyman MAHOUTİ Yıldız Teknik Üniversitesi Havacılık Elektroniği Bölümü		☐ Kabul ☐ Ret

Annem ve Babama ithaf ediyorum.

BÜTÇE DESTEKLERİ

YAPAY ZEKA ARACILIĞIYLA ANTEN PARAMETRELERİNİN VEKİL MODELLEMESİ VE SİMÜLASYONU

Bu tez çalışması için herhangi bir kurumdan bütçe desteği alınmamıştır.

TEŞEKKÜR

Tez çalışma süresi boyunca desteğini esirgemeyen ve tez sürecinin başarı ile tamamlanmasında büyük katkılarından ötürü tez danışmanım değerli Doç. Dr. Ahmet Arif ULUSLU ’ya teşekkür ederim.

Haziran 2025 **Yekta Onur EREN**

İÇİNDEKİLER

Sayfa No

TEZ KABUL VE ONAYI ..... **ii**
BEYAN ..... **iii**
BÜTÇE DESTEKLERİ ..... **v**
TEŞEKKÜR ..... **vi**
İÇİNDEKİLER ..... **vii**
ŞEKİL LİSTESİ ..... **ix**
TABLO LİSTESİ ..... **x**
SİMGE VE KISALTMA LİSTESİ ..... **xii**
ÖZET ..... **xiii**
ABSTRACT ..... **xv**
1. GİRİŞ **1**
2. KAVRAMSAL ÇERÇEVE **4**
2.1. TEMEL KAVRAMLAR 4
2.1.1. Vivaldi Anten ve "Cavity-backed" Tipi 4
2.1.2. Geniş Bant 5
2.1.3. Yapay Sinir Ağı 5
2.2. TEORİK YAKLAŞIMLAR VE MODELLER 5
2.2.1. Vivaldi Anten Yapısı ve EM Teori Temelleri 5
2.2.2. S_{11} Parametresi 6
2.2.3. Veri Odaklı Modelleme ve ÇKA Temelli Yaklaşım 6
2.2.4. Latin Hiperküp Örnekleme 7
2.3. LİTERATÜR DEĞERLENDİRMESİ 7
2.3.1. Giriş 7
2.3.2. Yapay Zekâ Tabanlı Anten Modellemesinde Genel Eğilimler 8
2.3.3. Makine Öğrenimi Tabanlı Yöntemler ve Uygulamaları 10
2.3.4. Geniş Bantlı Anten Tasarımı, Tersine Tasarım ve Optimizasyon 13
2.3.5. Ku-Bant Ofset Boşluklu Vivaldi Antenler: Durum ve Araştırma Boşlukları 15
2.4. KAVRAMLAR ARASI İLİŞKİLER 17
2.5. ARAŞTIRMA PROBLEMİ İLE BAĞLANTI 17

3. YÖNTEM 18
3.1. MATEMATİKSEL MODEL 18
3.1.1. Temel Vivaldi Anteni Tasarım Denklemleri 18
3.1.2. Ofset Besleme (Offset Feed) 18
3.1.3. Boşluk (Slot) Etkisi 19
3.2. ANTEN TASARIMI 19
3.3. ÖNERİLEN YÖNTEM 20
3.3.1. Katmanlar 21
3.3.2. Öğrenme Süreci 22
3.4. ÖNERİLEN MODEL 22
4. BULGULAR 23
4.1. KULLANILAN AĞ YAPISI VE EĞİTİM PARAMETRELERİ 23
4.2. VERİ SETİ VE ÖRNEKLEME YÖNTEMİ 26
4.3. FREKANS ADIM ARALIKLARINA GÖRE MODELLEME PERFORMANSI 29
4.3.1. 40 Mhz Frekans Adım Aralığı 29
4.3.2. 80 MHz Frekans Adım Aralığı 30
4.3.3. 100 MHz Frekans Adım Aralığı 30
5. TARTIŞMA 36
6. SONUÇ VE ÖNERİLER 39
KAYNAKLAR 40
İNTİHAL RAPORU İLK SAYFASI 44
ETİK KURUL İZİN YAZISI 45
KURUM İZNİ YAZILARI 46
ÖZGEÇMİŞ 47

ŞEKİL LİSTESİ

Sayfa No

Şekil 1.1.(a) Doğrusal polarize Vivaldi anten;i-ön yüz, ii-arka yüz [8]. (b) "Cavity backed" Vivaldi anten; i-Port 1, ii-Port 2, iii-Antenin entegre edilmiş boşluklu hali [6].....2

Şekil 3.1. Ofset boşluklu Vivaldi anten için model [43]. 20

Şekil 3.2.Önerilen ÇKA yapısı ve giriş - çıkışlar. 22

Şekil 4.1. 40 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden Bayesian regularization back-propagation (trainbr) algoritmalı ÇKA modellemesi sonucu oluşan S_{11} (dB) simülasyonu (a) 70-50 eğitim-doğrulma verisi (b) 80-40 eğitim-doğrulma verisi (c) 90-30 eğitim-doğrulma verisi (d) 100-20 eğitim-doğrulma verisi.....26

Şekil 4.2. 50 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden Bayesian regularization backpropagation (trainbr) algoritmalı ÇKA modellemesi sonucu oluşan S_{11} (dB) simülasyonu (a) 70-50 eğitim-doğrulma verisi (b) 80-40 eğitim-doğrulma verisi (c) 90-30 eğitim-doğrulma verisi (d) 100-20 eğitim-doğrulma verisi.....29

Şekil 4.3. 80 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden Bayesian regularization backpropagation (trainbr) algoritmalı ÇKA modellemesi sonucu oluşan S_{11} (dB) simülasyonu (a) 70-50 eğitim-doğrulma verisi (b) 80-40 eğitim-doğrulma verisi (c) 90-30 eğitim-doğrulma verisi (d) 100-20 eğitim-doğrulma verisi.....33

Şekil 4.4. 100 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden Bayesian regularization back propagation (trainbr) algoritmalı ÇKA modellemesi sonucu oluşan S_{11} (dB) simülasyonu (a) 70-50 eğitim-doğrulma verisi (b) 80-40 eğitim-doğrulma verisi (c) 90-30 eğitim-doğrulma verisi (d) 100-20 eğitim-doğrulma verisi.....35

TABLO LİSTESİ

Sayfa No

Tablo 3.1. Eğitim ve doğrulama veri seti detayları.....20

Tablo 4.1. 40 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden 70-50 eğitim-doğrulama datası ile ÇKA modellemesi için performans sonuçları. 24

Tablo 4.2. 40 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden 80-40 eğitim-doğrulama datası ile ÇKA modellemesi için performans sonuçları. 24

Tablo 4.3. 40 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden 90-30 eğitim-doğrulama datası ile ÇKA modellemesi için performans sonuçları. 25

Tablo 4.4. 40 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden 100-20 eğitim-doğrulama verisi ile ÇKA modellemesi için performans sonuçları. 25

Tablo 4.5. 50 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden 70-50 eğitim-doğrulama datası ile ÇKA modellemesi için performans sonuçları. 27

Tablo 4.6. 50 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden 80-40 eğitim-doğrulama datası ile ÇKA modellemesi için performans sonuçları. 27

Tablo 4.7. 50 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden 90-30 eğitim-doğrulama datası ile ÇKA modellemesi için performans sonuçları. 28

Tablo 4.8. 50 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden 100-20 eğitim-doğrulama datası ile ÇKA modellemesi için performans sonuçları. 28

Tablo 4.9. 80 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden 70-50 eğitim-doğrulama datası ile ÇKA modellemesi için performans sonuçları. 31

Tablo 4.10. 80 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden 80-40 eğitim-doğrulama datası ile ÇKA modellemesi için performans sonuçları. 31

Tablo 4.11. 80 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden 90-30 eğitim-doğrulama datası ile ÇKA modellemesi için performans sonuçları. 32

Tablo 4.12. 80 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden 100-20 eğitim-doğrulama datası ile ÇKA modellemesi için performans sonuçları. 32

Tablo 4.13. 100 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden 70-50 eğitim-doğrulama datası ile ÇKA modellemesi için performans sonuçları. 33

Tablo 4.14.100 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden 80-40 eğitim-doğrulama datası ile ÇKA modellemesi için performans sonuçları. 34

Tablo 4.15. 100 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden 90-30 eğitim-doğrulama datası ile ÇKA modellemesi için performans sonuçları. 34

Tablo 4.16. 100 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden 100-20 eğitim-doğrulama datası ile ÇKA modellemesi için performans sonuçları. 34

SİMGE VE KISALTMA LİSTESİ

Simgeler **Açıklama**

$w(z)$: Slot genişliği
w_0 : Slotun başlangıç genişliği
k : Üstel açılma sabiti
z : Anten boyu boyunca konum
Z_s : Dielektrik kalınlığı
e_{eff} : Etkin dielektrik sabiti
Z_{in} : Anten giriş empedansı
Z_0 : Karakteristik sistem empedansı
S_{11} : Geri dönüş kaybı
x_i : Giriş değerleri
w_i : Çarpan etken ağırlığı
b : Bias
f : Aktivasyon fonksiyonu (tansig, logsig, ReLU vb.)

Kısaltmalar **Açıklama**

AVA : Antipodal Vivaldi Anten
BDK : Baskı Devre Kartı (Printed Circuit Board (PCB))
ÇKA : Çok Katmanlı Algılayıcı (Multi Layer Perceptron (MLP))
DVR : Destek Vektör Regresyonu (Support Vector Regression (SVR))
FTYSA : Fizik Tabanlı Yapay Sinir Ağları (Physics Based Neural Network (PINN)
GP : Gaussian Prosesleri (Gaussian Process (GP))
KSA : Konvolusyon Sinir Ağı ((KSA), Convolutional Neural Network (CNN))
LHÖ : Latin Hiperküp Örnekleme (Latin Hypercube Sampling (LHS))
YSA : Yapay Sinir Ağı (Artificial Neural Network (ANN))
YZ : Yapay Zeka (Artificial Intelligence (AI))

ÖZET

YÜKSEK LİSANS TEZİ

YAPAY ZEKA ARACILIĞIYLA ANTEN PARAMETRELERİNİN VEKİL MODELLEMESİ VE SİMÜLASYONU

Yekta Onur EREN

İstanbul Üniversitesi-Cerrahpaşa

Lisansüstü Eğitim Enstitüsü

Savunma Teknolojileri Anabilim Dalı (Disiplinlerarası)

Savunma Teknolojileri, Tezli Yüksek Lisans Programı

Danışman: Doç. Dr. Ahmet Arif ULUSLU

Modelleme problemlerinde kullanılan veri miktarının, model performansını her zaman doğrudan olumlu etkilemediği gözlemlenmektedir. Giriş verilerinin belirlenmesinde gelişmiş Latin Hiperküp Örneklemesi (LHÖ) gibi istatistiksel yöntemler tercih edilse de, veri setinin hem çok küçük hem de aşırı büyük olması durumunda model performansı olumsuz yönde etkilenebilmektedir. Bu tez çalışması, söz konusu karmaşık etkileşimi daha derinlemesine anlamak amacıyla, Ku-band (12–18 GHz) frekans aralığında çalışan, ofset boşluklu (cavity-backed) bir Vivaldi antenin veri odaklı modellenmesini ele almaktadır. Ku-band antenler, bölgesel çekim kuvveti ve üstün atmosferik geçirgenlik avantajları sayesinde özellikle uydu haberleşme sistemlerinde yaygın olarak tercih edilmektedir. Ancak, bu tür antenlerin doğasında bulunan çok geniş bantlı çalışma karakteristiği, doğru ve güvenilir veri odaklı modellerin oluşturulması açısından ciddi bir zorluk teşkil etmektedir. Buna ek olarak, antenin yapısal tasarımında yer alan çok sayıda giriş parametresi, modelin eğitilmesi sürecinde "boyutluluk laneti" (curse of dimensionality) olarak bilinen önemli bir sorunu ortaya çıkarmaktadır. Bu nedenle, modelin etkinliğini ve verimliliğini sağlamak amacıyla giriş parametrelerinin seçiminde titizlikle LHS yöntemi kullanılmıştır. Çalışmada, 10 GHz ile 20 GHz frekans

aralığında bir çok katmanlı algılayıcı (ÇKA) modeli gösterilmiştir. Bu modelin çıktısı olarak, tam dalga elektromanyetik (EM) simülasyonlarla elde edilen S11 parametresinin frekansa bağlı değişiminin doğru bir şekilde tahmin edilmesi hedeflenmiştir. Elde edilen sonuçlar, geliştirilen MLP modelinin tahminlerinin, gerçek simülasyon çıktıları ile yüksek düzeyde uyum içinde olduğunu açıkça göstermiştir. Bu başarılı modelleme metodolojisi, sadece incelenen Vivaldi anten tipi için değil, aynı zamanda farklı anten konfigürasyonları ve genel elektromanyetik modelleme problemleri için de uyarlanabilir ve değerli bir yaklaşım sunmaktadır.

Haziran 2025 , 63 sayfa.

Anahtar Kelimeler: Latin Hiperküp, Vivaldi Anten, Ku Bandı

ABSTRACT

M.Sc. THESIS

SURROGATE MODELING AND SIMULATION OF ANTENNA PARAMETERS VIA ARTIFICIAL INTELLIGENCE

Yekta Onur EREN

İstanbul University-Cerrahpaşa

Institute of Graduate Studies

Department of Engineering Sciences

Defense Technologies, Thesis Master's Program

Supervisor: Assoc. Prof. Dr. Ahmet Arif ULUSLU

It is observed that the amount of data used in modeling problems does not always directly and positively affect modeling performance. Although advanced statistical sampling methods like Latin Hypercube Sampling (LHS) are preferred for determining input data, model performance can be negatively impacted when the dataset is either too small or excessively large. This thesis aims to better understand this interaction by focusing on the data-driven modeling of a cavity-backed Vivaldi antenna operating in the Ku-band (12–18 GHz) frequency range, specifically within the 10 GHz to 20 GHz range, using a multi-layer perceptron (MLP) model. Ku-band antennas are widely preferred in satellite communication systems due to their advantages in regional attractive force and atmospheric permeability. However, the inherently wideband operating characteristic of such antennas poses a significant challenge for accurate and reliable data-driven model creation. Furthermore, the presence of numerous input parameters in the antenna's structural design introduces the significant problem known as the "curse of dimensionality" during the model training process. For this reason, the LHS method was meticulously employed for the selection of input parameters to ensure model effectiveness and efficiency. In this study, an MLP model was developed for the 10 GHz to 20 GHz frequency

range. The model's output aimed to accurately predict the frequency-dependent variation of the S11 parameter, obtained through full-wave electromagnetic (EM) simulations. The results obtained have clearly demonstrated that the model's predictions are in high agreement with the actual simulation outputs. This successful modeling methodology is adaptable and offers a valuable approach not only for the Vivaldi antenna type examined but also for different antenna configurations and general electromagnetic modeling problems.

July 2025, 63 pages.

Keywords: Latin Hypercube, Vivaldi Antenna, Ku Band

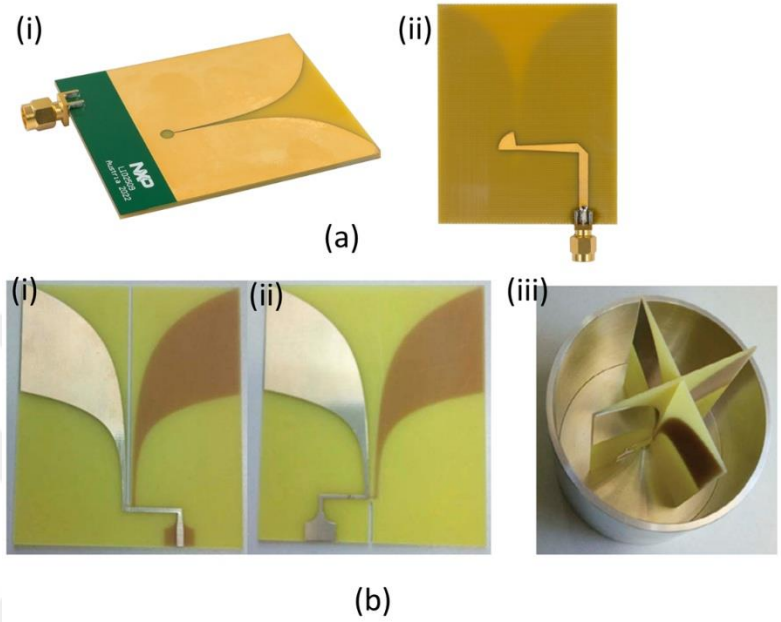
1. GİRİŞ

Havacılık, uzay ve savunma teknolojilerindeki hızlı gelişmeler, hem farklı türde hava platformlarının performanslarının iyileştirilmesini hem de uzay tabanlı sistemlerin sayısının artmasını zorunlu hale getirmiştir. Bu gelişmelere paralel olarak modern radar sistemlerinin karşı karşıya olduğu temel zorluklar artmış; elektronik karşı tedbirler, anti-radyasyon füzeleri, düşük ve çok düşük irtifa hedeflerinin saptanması ve görünmezlik teknolojileri radar sistemlerinin kabiliyetlerini sınırlandırmaya başlamıştır. Geniş bantlı ve ultra geniş bantlı radar sistemleri, söz konusu tehditlere karşı dirençli olmanın yanı sıra, yeni nesil radar teknolojilerinin geliştirilmesinde de kritik bir role sahiptir. Bu sistemler, sadece elektromanyetik parazitlere karşı bağışıklık sağlamakla kalmayıp, yüksek mesafe çözünürlüğü, çoklu hedef ayrımı ve daha doğru menzil ölçümü gibi avantajlar da sunmaktadır [1].

Radar sistemleri; görüntüleme, hedef sınıflandırma, tanıma ve düşük irtifa hedef takibi gibi birçok askeri ve sivil alanda temel teknolojilerden biri haline gelmiştir. Bu bağlamda, geniş bantlı Vivaldi antenler, artan radar sistem ihtiyaçlarını karşılamak üzere öne çıkan bir anten türü olmuştur. “End-fire” yönünde çalışan bu antenler, üstel olarak açılan yarık boyunca yayılan gezgin dalga prensibiyle çalışır ve %100’e varan bant genişliklerine ulaşabilir [1, 2]. Konik yarıklı (tapered slot) yapısıyla üretilen Vivaldi antenler, 5–8 dBi aralığında kazanç değerleriyle radar ve elektronik harp sistemlerinde geniş kullanım alanı bulmuştur [3]. Özellikle konik yarıklı ve antipodal versiyonları literatürde geniş yer tutmakta olup, 5–30 GHz gibi yüksek frekans aralıklarında çalışabilecek şekilde optimize edilmişlerdir. Milimetre dalga bandına uygun dengeli antipodal konfigürasyonları da raporlanmıştır [4]. Tüm bu yapılar, sade geometrik formları, üretim kolaylığı ve geniş bant performansları sayesinde radar sistemlerinin ihtiyaç duyduğu çok yönlü uygulamalara olanak sağlamaktadır.

Vivaldi antenler, geleneksel olarak baskılı devre (Printed circuit board-PCB) teknolojisiyle üretilmektedir (Şekil 1.1-a). Ancak bu yöntem, bazı dezavantajları da beraberinde getirmektedir: yüksek mikroşerit kayıpları, zayıf mekanik dayanım ve karmaşık montaj süreçleri gibi zorluklar antenin uzun süreli kullanımını ve sistem entegrasyonunu sınırlamaktadır [5]. Bu problemlerin çözümüne yönelik olarak, literatürde ofset boşluklu (cavity-backed) Vivaldi anten tasarımları geliştirilmiştir. Bir örnek, Şekil 1.1-b’de verilmiştir

[6]. Bu antenlerde kullanılan metalik boşluk yapısı, özellikle yüksek frekanslı uygulamalarda kayıpları azaltmakta ve mekanik kararlılığı artırmaktadır. Bu sayede ofset boşluklu yapı, klasik antipodal yapının sınırlamalarını aşarak yüksek performanslı radar ve haberleşme sistemleri için alternatif bir çözüm sunmaktadır [7].



Şekil 1.1.(a) Doğrusal polarize Vivaldi anten;i-ön yüz, ii-arka yüz [8]. (b) "Cavity backed" Vivaldi anten; i-Port 1, ii-Port 2, iii-Antenin entegre edilmiş boşluklu hali [6].

Mevcut literatürde geniş bant antenlerin tasarımı, özellikle Vivaldi türleri açısından oldukça zengindir [5, 9, 10]. Ancak 10–20 GHz frekans aralığında çalışan, Ku bandında yer alan ofset boşluklu Vivaldi antenlerin sayısal modellemesine ilişkin doğrudan çalışma sayısı oldukça azdır. Bu bağlamda, özellikle veri odaklı yaklaşımlarla bu tür antenlerin modellenmesi önemli bir ihtiyaç haline gelmiştir. Tam-dalga elektromanyetik (EM) simülasyon yöntemleri yüksek doğruluk sunsa da hesaplama maliyetleri ve zaman açısından önemli sınırlılıklar barındırır [11]. Bu nedenle, özellikle Çok Katmanlı Algılayıcı ((ÇKA) / Multi-Layer Perceptron (MLP)) gibi yapay sinir ağı modelleriyle anten davranışının öngörülmesi, tasarım sürecini ciddi biçimde kolaylaştırabilecek bir yöntem olarak öne çıkmaktadır [12].

Veri odaklı modelleme yöntemleri, geleneksel yöntemlere alternatif olarak; parametre optimizasyonu, istatistiksel analiz ve çok amaçlı tasarım çalışmalarında giderek daha sık kullanılmaktadır [13]. Bu yöntemler arasında ÇKA tabanlı yapay sinir ağları, doğrusal olmayan çok boyutlu fonksiyonların öğrenilmesinde sağladığı avantajlar sayesinde öne çıkmaktadır. Özellikle, Latin Hiperküp Örnekleme (LHÖ-Latin Hypercube Sampling (LHS)) gibi gelişmiş

örnekleme yöntemleri ile birlikte kullanıldığında, anten tasarımı için gerekli veri setlerinin etkin bir şekilde oluşturulmasına imkân tanır. Literatürde mikrodalga yapıların vekil (surrogate) modellerle analizinde; polinom regresyon, kriging enterpolasyonu, radyal baz fonksiyonları, destek vektör regresyonu ((DVR), Support Vector Regression (SVR)), polinom kaos genişlemesi ve yapay sinir ağları gibi birçok yöntem başarıyla uygulanmıştır. Ancak, bu yöntemlerin ofset boşluklu Vivaldi antenlerin modellemesine özgü kullanımına dair örnekler oldukça sınırlıdır.

Bu tez çalışması, Ku bandında (12–18 GHz) çalışan ofset boşluklu Vivaldi antenin 10–20 GHz aralığındaki yansıma katsayısı (S_{11}) davranışının, gelişmiş bir ÇKA modeli ile modellenmesini konu almaktadır. Bu kapsamda antenin fiziksel parametreleri, LHÖ yöntemiyle örneklenmiş; elde edilen giriş parametrelerine karşılık gelen çıkış verileri, 3 boyutlu elektromanyetik simülasyonlarla elde edilmiştir. Bu veri seti kullanılarak eğitilen ÇKA modeli, anten parametreleri ile frekansa bağlı S_{11} çıktısı arasında yüksek doğruluklu bir tahmin gerçekleştirmiştir. Böylece, zaman ve kaynak açısından maliyetli olan tam-dalga EM analizlerinin yerine kullanılabilecek güvenilir bir vekil model önerilmiştir.Çalışmanın içeriği şu şekilde özetlenebilir:

- Ku bandı uygulamalarına özel olarak geliştirilmiş, ofset boşluklu Vivaldi antenin modellemesi ilk kez gelişmiş ÇKA ile analiz edilmiştir.

- Farklı frekans adım aralıklarının modelleme başarımına etkisi; veri sayısı, mimari yapı ve algoritma düzeyinde ayrıntılı olarak değerlendirilmiştir.

- Modelleme sonuçları, EM simülasyon verileriyle hedef/tahmin biçiminde karşılaştırılmış; S_{11} (dB) parametresinin frekansa bağlı değişimi üzerinden yorumlanmıştır.
- Anten geometrisine ilişkin çok sayıda değişkenin bulunması ve S_{11} çıktısındaki dalgalı yapı, modeli daha karmaşık hale getirmiştir.
- Çalışma, yalnızca Ku bandı uygulamaları için değil, geniş bantlı tüm anten modelleme problemlerine kolaylıkla uyarlanabilecek bir yöntem önermektedir.

Tezin ilerleyen bölümlerinde, ikinci bölümde literatür taraması ve kavramsal temel sunulacak; üçüncü bölümde modelleme yöntemi ve simülasyon süreçleri anlatılacak; dördüncü bölümde deneysel bulgular ve model çıktıları değerlendirilecek; beşinci ve son bölümde ise elde edilen sonuçlar ile geleceğe yönelik önerilere yer verilecektir.

2. KAVRAMSAL ÇERÇEVE

Bu bölümde, araştırmanın temelini oluşturan kavramlar tanımlanacak, araştırmanın dayandığı teorik yaklaşımlar ve modeller açıklanacak, literatürdeki mevcut çalışmalar değerlendirilecek ve kavramlar arasındaki ilişkiler kısaca tartışılacaktır.

2.1. TEMEL KAVRAMLAR

Araştırmada kullanılan anahtar kavramlar (örneğin: Vivaldi anten, S_{11} parametresi, geniş bant, yapay sinir ağı vb.) bu alt başlıkta tanımlanmıştır.

2.1.1. Vivaldi Anten ve "Cavity-backed" Tipi

Vivaldi anten, geniş bantlı uygulamalar için tasarlanmış, düzlemsel (planar) yapıya sahip, üstel olarak açılan yarık (tapered slot) yapısıyla karakterize edilen bir antendir. Bu antenler, baskılı devre kartları ((BDK) / Printed Circuit Board (PCB)) üzerinde kolayca üretilebilir ve yüksek yönlülük ile geniş frekans aralığında çalışabilirler. Peter Gibson tarafından 1979 yılında IEEE Avrupa Mikrodalga Konferansı'nda tanıtılmıştır [14].

Vivaldi antenlerde "cavity-backed" ifadesi, antenin arka tarafına (radyasyon yönünün tersine) yerleştirilmiş metal bir boşluk (kavite (cavity)) yapısını ifade eder. Bu yapı, Vivaldi antenin klasik (yani düz, baskılı BDK üzerinde) versiyonlarına kıyasla hem elektromanyetik hem de mekanik avantajlar sağlar. Bu boşluk yapısı, yayılan elektromanyetik enerjinin arka yöne kaçmasını engeller. Işımanın sadece öne doğru (end-fire yönünde) yönlenmesini sağlar ve radyasyon yönlülüğünü artırır. Belli başlı Vivaldi anten örnekleri aşağıda verilmektedir [15]:

- **"Conventional Vivaldi (CV)"**: Baskılı devre kartı üzerinde yapılan klasik yapı.
- **"Antipodal Vivaldi (AVA)"**: Karşılıklı iki metal katman kullanılarak iletkenlik artırılır.
- **"Balanced Antipodal Vivaldi (BAVA)"**: Antipodal yapı üzerine çapraz polarizasyon sorununu çözmek için geliştirilmiştir.
- **"Cavity-backed Vivaldi (CBVA)"**: Arka yönü kapalı, yönlülüğü yüksek.
- **"Corrugated Vivaldi"**: Slot çevresinde oluklar (corrugation) ile yan lob bastırma amaçlanır.
- **"Dielectric-loaded Vivaldi"**: Slot içine dielektrik materyal eklenerek miniaturizasyon veya kazanç kontrolü sağlanır.

2.1.2. Geniş Bant

Geniş bant terimi, bir antenin veya sistemin, merkez frekansının belirli bir yüzdesinden daha büyük bir bant genişliğinde etkili bir şekilde çalışabildiğini ifade eder. Genellikle, %20'den fazla bant genişliğine sahip antenler "geniş bantlı" olarak sınıflandırılır.

2.1.3. Yapay Sinir Ağı

Yapay sinir ağı, biyolojik sinir ağlarından esinlenerek geliştirilen, giriş verileri ile çıkışlar arasındaki karmaşık ilişkileri modelleyebilen hesaplama modelleridir. Bu ağlar, özellikle doğrusal olmayan ve çok boyutlu fonksiyonların öğrenilmesinde etkilidir. ÇKA ise, birden fazla gizli katmana sahip, ileri beslemeli bir yapay sinir ağı türüdür.

2.2. TEORİK YAKLAŞIMLAR VE MODELLER

Veri odaklı modelleme, ÇKA yapısı, elektromanyetik teori, vekil modelleme (“surrogate modeling”) gibi teorik altyapılar burada açıklanmıştır.

2.2.1. Vivaldi Anten Yapısı ve EM Teori Temelleri

Vivaldi antenler, üstel olarak genişleyen konik yarıklı bir yapıya sahiptir. Bu slot boyunca TEM-benzeri bir gezgin elektromanyetik dalga yayılır ve "end-fire" yönünde ışınım oluşturur. Antenin slot genişliği Denklem 2.1’deki gibi modellenir:

$$w(z) = w_0 e^{kz} \tag{2.1}$$

- $w(z)$: slot genişliği
- w_0: slotun başlangıç genişliği
- k: üstel açılma sabiti
- z: anten boyu boyunca konum

Bu fonksiyon sayesinde yapı, empedans uyum hattı gibi davranarak geri dönüş kaybını azaltır.

Antenin teorik empedans Denklem 2.2’de ifade edilir:

$$Z_s \approx \frac{60\pi}{e_{eff}} \ln\left(\frac{4h}{w}\right) \tag{2.2}$$

Burada:

- Z_s: dielektrik kalınlığı
- w: slot genişliği
- e_{eff}: etkin dielektrik sabiti

2.2.2. S_{11} Parametresi

S_{11} parametresi, bir mikrodalga devresinin giriş portuna uygulanan sinyalin ne kadarının yansıdığını gösteren saçılma (scattering) parametresidir. Bu parametre, antenin empedans uyumunu değerlendirmek için kullanılır; düşük S_{11} değeri, iyi bir empedans uyumunu ve dolayısıyla daha az yansıma olduğunu gösterir.

Geri dönüş kaybı (S_{11}) ise aşağıdaki Denklem 2.3'teki gibi tanımlanır:

$$S_{11}(dB) = 20 \log \left| \frac{Z_{in} - Z_0}{Z_{in} + Z_0} \right| \tag{2.3}$$

- Z_{in}: anten giriş empedansı
- Z_0: karakteristik sistem empedansı (genellikle 50 Ω)

2.2.3. Veri Odaklı Modelleme ve ÇKA Temelli Yaklaşım

Veri odaklı modelleme yaklaşımları, özellikle elektromanyetik (EM) simülasyonlar gibi yüksek hesaplama maliyetine sahip mühendislik süreçlerinde, daha hızlı ve verimli çözümler sunma potansiyeline sahiptir. Bu yaklaşımda, sistemin fiziksel davranışı doğrudan çözülmek yerine, gözlemsel veya simülasyon verilerinden öğrenilen matematiksel bir model aracılığıyla temsil edilir. Anten tasarımı gibi çok parametreli ve doğrusal olmayan problemlerde, bu yöntemler tasarım süresini önemli ölçüde kısaltmakta ve kaynak tüketimini azaltmaktadır.

Bu bağlamda kullanılan ÇKA, yapay sinir ağlarının en yaygın türlerinden biridir. ÇKA, bir giriş katmanı, bir veya daha fazla gizli katman ve bir çıkış katmanından oluşan ileri beslemeli bir ağ yapısıdır. Her bir katmandaki nöronlar, bir önceki katmandan gelen sinyalleri ağırlıklarla çarpar, "bias" terimi ekler ve doğrusal olmayan bir aktivasyon fonksiyonu ile işleyerek sonraki katmana aktarır. Bu yapı, doğrusal olmayan ve çok boyutlu fonksiyonların öğrenilmesinde son derece etkilidir.

Anten modelleme uygulamalarında ÇKA, tasarım parametreleri (örneğin; slot açıklığı, boy, açı) ile performans çıktıları (örneğin geri dönüş kaybı S_{11}) arasındaki karmaşık ilişkileri modellemek için kullanılır. Böylece, her yeni tasarım için tekrar tekrar EM çözümlemeleri yapmak yerine, eğitilmiş bir ÇKA modeli ile milisaniyeler içinde öngörü yapılabilir. Bir ÇKA'daki nöronun matematiksel modeli aşağıdaki Denklem 2.4'teki gibidir:

$$y = f\left(\sum_{i=1}^{n} w_i x_i + b\right) \quad (2.4)$$

- x_i: giriş değerleri
- w_i: ağırlıklar
- b: bias terimi
- f: aktivasyon fonksiyonu (tansig, logsig, ReLU vb.)

Eğitim aşamasında kullanılan hata fonksiyonları Denklem 2.5 ve 2.6'da verilmektedir:

$$\text{Ortalama karesel hata (MSE): } \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y_i})^2 \quad (2.5)$$

$$\text{Ortalama mutlak hata (MAE): } \frac{1}{n}\sum_{i=1}^{n}|y_i - \hat{y_i}| \quad (2.6)$$

Bu yapı sayesinde, antenin tasarım parametreleri ile frekansa bağlı geri dönüş kaybı (S_{11}) arasındaki ilişki doğrulukla öğrenilebilir ve yeni tasarımlar için hızlı tahminler yapılabilir.

2.2.4. Latin Hiperküp Örnekleme

MLP modelini eğitmek için gerekli olan giriş ve çıkış verileri, parametre uzayını homojen şekilde kapsayacak şekilde Latin Hiperküp Örnekleme (LHÖ-Latin Hypercube Sampling (LHS)) ile oluşturulmuştur. Bu istatistiksel örnekleme yöntemi, her bir değişkenin değer aralığını belirli bölgelere ayırarak her kombinasyondan tek bir örnek seçer. Bu sayede, parametre alanının kapsamlı ve dengeli şekilde örneklenmesi sağlanır. Bu teorik altyapı sayesinde hem elektromanyetik davranış hem de yapay sinir ağı temelli tahmin modeli birlikte kullanılarak anten performansı öngörülmüştür.

2.3. LİTERATÜR DEĞERLENDİRMESİ

Anten modelleme, YSA uygulamaları, LHÖ literatürü burada özet olarak verilmiştir.

2.3.1. Giriş

Ku-bandında (yaklaşık 10–20 GHz) çalışan ofset boşluklu Vivaldi antenler, geniş bantlı çalışmaları ve yönlülükleri sayesinde radar, haberleşme ve görüntüleme gibi alanlarda ilgi çekmektedir. Bu anten yapısında, Vivaldi açıklığı bir oyuk (cavity) içinde ofset konumlandırılarak daha iyi kazanç ve yönlendirme elde edilmeye çalışılır. Ancak böyle karmaşık ve geniş bantlı bir yapının tasarımı, klasik elektromanyetik benzetimlerle zaman alıcı olabilir.

Son yıllarda yapay zekâ (YZ) ve makine öğrenimi tabanlı modelleme yaklaşımları, anten performans tahminini hızlandırmak ve tersine tasarım ile optimizasyon süreçlerini kolaylaştırmak için yoğun olarak kullanılmaya başlanmıştır [16].

Özellikle 2020–2025 döneminde yayımlanan akademik çalışmalara odaklanarak, Ku-band ofset boşluklu Vivaldi antenlere yönelik YZ tabanlı modelleme teknikleri, bunların başarıları ve kısıtları ele alınmıştır. Makine öğrenimi yöntemleri (çok katmanlı yapay sinir ağları, Gaussian süreç regresyonu, DVR vb.), aktif öğrenme yaklaşımları, örnekleme stratejileri (Latin hiperküp gibi) ve Fizik-Tabanlı Yapay Sinir Ağları ((YTYSA) / Physics-Informed Neural Networks (PINN)) bu bağlamda ele alınmalı; geniş bantlı anten tasarımı, tersine tasarım (inverse design), optimizasyon ve üretim toleransı analizi gibi uygulamalardaki kullanımlarının altı çizilmelidir.

Vivaldi antenler, konik yarıklı (“tapered slot”) yapıları ve çok geniş bant karakteristikleriyle radar ve haberleşme sistemleri gibi çeşitli uygulamalarda yaygın olarak tercih edilmektedir. Geleneksel baskılı devre kartı teknolojisiyle üretilen bu antenler, sade yapılarına rağmen yüksek mikro-şerit kayıpları, mekanik dayanım düşüklüğü ve karmaşık entegrasyon gibi zorluklar taşımaktadır. Bu sorunlara çözüm olarak geliştirilen Antipodal Vivaldi antenler (AVA), besleme uçları arasında simetrik şekilde çalışan ve daha geniş bant aralığı sunabilen yapılardır. Ancak AVA'lar, bazen çapraz polarizasyon gibi problemler ortaya çıkardığı için dengeli antipodal tasarımlar (BAVA) da literatüre girmiştir [5].

Son yıllarda Ku-band (yaklaşık 12–18 GHz) uygulamaları için geliştirilen AVA dizileri, çok bantlı çalışma kapasitesi ve yüksek kazancıyla dikkat çekmektedir. Araştırmacılar, 14,44–20,98 GHz aralığında çalışan sekiz elemanlı bir dizi tasarlamış [17], Prouza & Raida ise çift katmanlı arayüzler kullanarak hem mekanik kararlılık hem de dizi performansını iyileştirmiştir [18]. Yine bu kapsamdaki çalışmalarda tam-metal, oluklu (corrugated) yapılar [19] ve cavity-backed konfigürasyonlar da rapor edilmiştir [20].

2.3.2. Yapay Zekâ Tabanlı Anten Modellemesinde Genel Eğilimler

Literatüre bakıldığında, bu anten türlerinin 5–30 GHz aralığında çok geniş bant kapsaması sağladığı ve radar ile elektronik harp sistemlerinde sık kullanıldığı görülmektedir [21]. Ancak bu çalışmalarda anten karakteristiklerinin öngörülmesi için genellikle tam dalga elektromanyetik (EM) simülasyonlara başvurulmuştur [22]. Bu yöntemler her ne kadar yüksek doğruluk sunsa da, hem hesaplama süreci uzun hem de kaynak tüketimi yoğun olması nedeniyle

tasarım süreci üzerinde kısıtlayıcı etkiler oluşturmaktadır [23]. Bu nedenle son yıllarda anten performansını tahmin etmek için Yapay Zeka (YZ) temelli vekil (surrogate) modelleme yöntemleri öne çıkmıştır.

Makine öğrenimi teknikleri, anten tasarım ve analizinde vekil model oluşturarak tam dalga elektromanyetik analiz yükünü azaltmak amacıyla hızla yaygınlaşmıştır. Literatürde popüler veri-tabanlı modelleme yöntemleri arasında YSA**,** Kriging (Gaussian süreç regresyonu)**,** DVR ve türevleri sayılabilir [24]. Bu yöntemler, anten geometrik parametrelerini giriş, performans ölçütlerini (örn. yansıma katsayısı, kazanç, bant genişliği) çıkış olarak alıp hızlı tahminler yapabilen "kara-kutu" modeller üretir. Son yıllarda pek çok çalışma bu tür vekil modeller ile anten analizi yaparak optimizasyon süreçlerini önemli ölçüde hızlandırmıştır. Örneğin, literatürde E-şekilli yama antenin rezonans frekansını hesaplamak için derin sinir ağları kullanıldığı [16], çift T biçimli monopole antenin optimum boyutlarını belirlemek için Lasso regresyon, çok katmanlı yapay sinir ağı ve k-en yakın komşu algoritmalarının uygulandığı gösterilmiştir. Bu çalışmalar, yeterli doğruluk korunurken hesaplama süresinin tam dalga benzetimlere kıyasla büyük ölçüde azaldığını ortaya koymaktadır. Nitekim, makine öğrenimi yöntemleri doğru bir model kurulduğunda herhangi bir giriş parametre kombinasyonu için anında sonuç üretebildiği için anten tasarım verimliliğini ciddi oranda artırmaktadır

Bununla birlikte, geniş bantlı ve karmaşık anten yapılarında veri-tabanlı modellerin kurulması çeşitli zorluklar barındırır [25]. Anten davranışı genellikle tasarım parametrelerinin yüksek boyutlu bir fonksiyonu olup doğrusal olmayan ve çok modlu (multi-modal) karakterdedir. Özellikle bir antenin farklı bantlardaki yansıma, kazanç, polarizasyon gibi birden çok performans çıktısını birlikte öngörmek gerektiğinde, modelleme güçleşir. Literatürde, geniş frekans aralıklarını ve birden fazla çıktıyı kapsayan güvenilir modellere ulaşmanın zor olduğu, birçoğunun dar parametre uzayları ile sınırlı kaldığı belirtilmektedir [24]. Bu nedenle 2020 sonrası çalışmalarda "performans odaklı modelleme" gibi yeni yaklaşımlar geliştirilmiş; modelleme çabasını tasarım uzayının en yüksek performanslı bölgelerine yoğunlaştırarak geniş uzaylarda doğruluğu artırma, aynı zamanda çok hedefli optimizasyon ve sağlam tasarım (robust design) analizlerini hızlandırma hedeflenmiştir. Örneğin performans odaklı yöntemler, antenin istenen bantlarındaki rezonans noktaları veya tepe kazanç gibi cevap özelliklerini (response features) tespit edip amacı bu özellikler üzerinden tanımlayarak, optimizasyon sürecini düzenlemekte ve daha az örnekle güvenilir modeller elde edilmesini sağlamaktadır. Sonuç

olarak, güncel eğilim literatürde klasik yaklaşımların ötesine geçip hem veri odaklı hem fizik odaklı yöntemlerle anten tasarımını daha akıllı ve hızlı hale getirmeye yöneliktir.

2.3.3. Makine Öğrenimi Tabanlı Yöntemler ve Uygulamaları

Yapay sinir ağları (YSA), özellikle ÇKA yapısı, EM davranışlarını modellemede kullanılmış ve literatürde yaygınlaşmıştır. Wang ve diğ. [26], BP (back-propagation) tabanlı YSA kullanarak çok amaçlı anten optimizasyonu gerçekleştirmiştir. Ayrıca, araştırmacılar, ÇKA, SVM, KSA, kriging ve topluluk (ensemble) öğrenme modellerini karşılaştırmış, modifiye ÇKA yapısı ile %4 gibi düşük hata oranlarına ulaşmıştır. Bu modellerin ortak avantajı, EM simülasyonları yerine milisaniyeler içinde tahmin sunabilmeleridir [27].

Bunun yanı sıra, Gaussian süreçleri (Kriging), DVR ve hibrit modeller de veri odaklı anten analizinde kullanılmıştır [28]. Bu yöntemler, özellikle belirsizlik analizi ve tolerans bazlı tasarım senaryolarında tercih edilmektedir. Vekil modellemelerde başarının kilit unsurlarından biri de sağlıklı bir veri setidir. Bu kapsamda LHÖ gibi teknikler, parametre uzayını homojen ve kapsayıcı şekilde örneklemek için kullanılmaktadır. Farklı araştırmacılar, LHÖ ile seçilen tasarım noktaları üzerinden EM verisi üretmiş ve bu verilerle model eğitimi gerçekleştirmiştir [23, 28].

YZ tabanlı anten modellemesinde kullanılan başlıca makine öğrenimi yaklaşımları ve bunların literatürdeki uygulamaları aşağıda özetlenmiştir:

- **Çok Katmanlı Algılayıcı (ÇKA) ve Yapay Sinir Ağları (YSA):** YSA, karmaşık ve doğrusal olmayan anten davranışlarını öğrenmede başarılı olduğu için mikrodalga komponent modellemelerinde yaygın tercih edilmektedir [29]. Örneğin, YSA modellerinin klasik yöntemlere kıyasla daha az veriye karşın yüksek doğrulukla sonuç verdiğini gösterilmiştir [29]. YSA'lar genellikle anten geometrisinin belirli parametrelerini giriş vektörü, istenen performans çıktısını (örneğin rezonans frekansı veya S-parametresi) hedef olarak alır. Bir çalışmada, *E*-şekilli bir yama anten için bir derin sinir ağı modeli, antenin rezonans frekansını başarıyla tahmin edilmiş ve hesaplamalı tasarım süresini ciddi oranda azaltılmıştır [16]. Benzer şekilde, yapay sinir ağları tersine tasarım problemlerinde de kullanılmıştır: 2022 yılında sunulan bir yöntemde, konvolüsyonel bir sinir ağı modeli kullanılarak neredeyse rastgele şekilli bir yama antenin tersine tasarımı gerçekleştirilmiş; istenen frekans cevabına sahip anten geometrisi otomatik olarak elde edilmiştir [30]. Yine 2022'de, dikdörtgen yamalı bir

antenin hedeflenen yansıma eğrisine göre boyutlarının ÇKA tabanlı ters tasarım ile bulunabildiği rapor edilmiştir [31]. Bu örnekler, çok katmanlı sinir ağlarının hem ileri (forward) performans tahmininde hem de hedef performansa göre anten boyutlarını tersine hesaplamada başarılı biçimde uygulanabildiğini göstermektedir.

- **Gaussian Prosesleri (Gaussian Process, GP) Tabanlı Modeller:** GP regresyonu (Kriging olarak da bilinir), sınırlı sayıdaki örnek üzerinden olasılıksal bir model öğrenerek anten parametre-çıktı ilişkisinin sürekli bir kestirimini sunar. Gaussian süreç modelleri anten optimizasyonunda uzun zamandır kullanılagelmiştir [24]; özellikle belirsizlik tahmini yapabilmesi ve az sayıda örnekle yüksek doğruluk sunabilmesi avantajdır. Ancak tasarım değişkeni sayısı arttıkça ve veri boyutu büyüdükçe GP eğitim süresi hızla artabilmektedir. Bu sorunu ele alan araştırmacılar, kendi uyarlamalı (self-adaptive) bir GP modeli ve diferansiyel evrim tabanlı hibrit bir yöntem geliştirerek kompleks anten optimizasyonunu hızlandırmıştır [32]. Önerdikleri yaklaşımla, yüksek değişken sayısına sahip (45 parametreli 5G baz istasyonu anteni gibi) zor problemler için dahi GP modelinin eğitim süresi ciddi ölçüde düşürülmüştür. Makalede bildirildiğine göre, sunulan TR-SADEA yöntemi ile benzer yöntemlere kıyasla vekil model eğitim süresinde %90'ı aşan azalma sağlanmış ve toplam optimizasyon iterasyon sayısı %20 civarında azaltılabilmiştir [32]. Bu, GP tabanlı modellerin karmaşık anten tasarımlarında pratikliğini artırmak adına önemli bir gelişmedir. Güncel diğer çalışmalarda da iki seviyeli GPR veya çoklu sadakatli (multi-fidelity) GP yaklaşımları ile daha az yüksek doğruluklu örnek kullanarak modellemeyi iyileştirme araştırmaları yapılmaktadır. GP'lerin belirsizlik kestirimi sunması, aktif öğrenme döngülerinde yeni örneklerin akıllıca seçilmesi (en belirsiz bölgeye yeni simülasyon ekleme gibi) için de avantaj sağlamaktadır.
- **Destek Vektör Regresyonu ((DVR) / Support Vector Regression (SVR)):** DVR, çekirdek (kernel) alt uygulamalarını kullanarak yüksek boyutlu uzayda doğrusal bir regresyon yapan güçlü bir yöntemdir. Anten tasarım problemlerinde DVR, çıkış değişkeni ile giriş parametreleri arasındaki kapalı formül bulunamadığında veri üzerinden öğrenme amacıyla kullanılmaktadır [33]. Örneğin, araştırmacılar, üç adet T-şekilli yarığa sahip kompakt bir yama antenin boyutları ile rezonans frekansı arasındaki ilişkiyi DVR ile modellemiştir [16]. Bu çalışmada 108 farklı anten örneği tam dalga benzetimle elde edilmiş, %70'i (75 örnek) eğitim için, kalanı test için kullanılmıştır. Gaussian çekirdekli DVR modeli eğitim verisinde R^2=0,9736 (testte R^2=0,9116) gibi

yüksek bir doğruluk yakalamıştır. Aynı problemde karşılaştırma için eğitilen diğer yöntemlerin (doğrusal regresyon, "Random Forest", *k*-NN) test başarımları DVR'den belirgin ölçüde düşük kalmıştır (örn. doğrusal model R^2=yaklaşık 0,82, "Randam Forest" yöntemi ile R^2=yaklaşık 0,79). Bu da DVR'ın anten parametre kestiriminde güçlü bir yöntem olduğunu gösterir. DVR modeli kullanılarak anten tasarımında hedeflenen frekansa minyatürleştirme yapılabilmiş; sonuçta önerilen antenin boyutu klasik tasarıma kıyasla %19 oranında küçültülmüş ve istenen frekansa ayarlanmıştır. Ayrıca DVR modeliyle tek bir anten örneğinin frekans hesaplaması sadece ~0,3 saniye sürmekte olup, bir tam dalga EM simülasyonun ~30 saniye aldığı göz önüne alınırsa optimizasyon döngüsünü büyük ölçüde hızlandırmaktadır. Bu örnek, DVR gibi yöntemlerin anten geometrisi->performans haritalamasında başarıyla kullanılabildiğini ve fiziksel sezgiyle zor elde edilecek tasarımların makine öğrenimi yardımıyla keşfedilebildiğini göstermektedir.

- **Aktif Öğrenme ve Örnekleme Stratejileri:** Anten problemlerinde makine öğrenimi modelinin başarısı, eğitim veri setinin kalitesine ve kapsadığı tasarım uzayına bağlıdır. Bu nedenle, uygun örnekleme yöntemleri ve gerektiğinde aktif öğrenme döngüleri kritik rol oynar. LHÖ, karmaşık anten uzayında az sayıda deneme noktasıyla geniş kapsama elde etmek için sıkça kullanılan bir tekniktir [34]. Monte Carlo gibi rastgele örneklemeye kıyasla LHÖ, tasarım alanını daha eşit ve temsil edici şekilde tarayarak modelin genelleme kabiliyetini artırır [29]. Nitekim literatürde LHÖ ve diğer örnekleme yöntemlerinin vekil modelleme performansına etkisi üzerine çalışmalar yapılmış; LHÖ'nün daha düşük hata ile sonuç verdiği gösterilmiştir [29]. Aktif öğrenme yaklaşımları ise, başlangıçta bir model eğittikten sonra modelin en emin olmadığı veya performansın iyileştirilebileceği bölgeleri saptayarak oralarda yeni simülasyonlar çalıştırmayı öngörür. Böylece veri seti adaptif olarak genişletilir ve her adımda model giderek iyileştirilir. Güncel anten tasarım optimizasyonlarının birçoğu, iteratif infill (doldurma) stratejileriyle çalışan makine öğrenimi çerçeveleri şeklindedir [24]. Bu yaklaşımlarda vekil model, geçici olarak küresel optimum noktayı tahmin eder, ardından bu tahmini doğrulamak veya model belirsizliğini azaltmak üzere EM simulasyon yapılır; yeni veri modele eklenerek süreç tekrarlanır. Bu döngü, gereksiz noktalarda hesaplama yapmadan en kritik bölgelerde veri yoğunluğunu artırarak daha az toplam simülasyonla optimum tasarıma ulaşmaya imkân tanır. Aktif öğrenme ve

uygun örnekleme stratejileri birlikte kullanıldığında, antenlerin hem küresel optimizasyonu hızlanmakta hem de üretilen modelin güvenilirliği artmaktadır.

- **Fizik-Temelli Yapay Sinir Ağları (FTYSA (PINN)) ve Fiziksel Bilgi Entegrasyonu:** Klasik makine öğrenimi modelleri tamamen veriye dayalı "kara kutu" yaklaşımı benimserken, FTYSA'lar antenler gibi elektromanyetik sistemlerin modellemesinde Maxwell denklemleri gibi fizik kanunlarını öğrenme sürecine dâhil etmeyi amaçlar. Bu sayede daha az veriyle daha doğru ve genellenebilir sonuçlara ulaşmak mümkün olabilir. FTYSA'lar 2020'li yıllarda elektromanyetik problemler üzerinde araştırılmaya başlanmıştır. Örneğin 2023 yılında bir çalışmada, bir FTYSA modeli 2B elektromanyetik saçılma problemini çözmek için kullanılmış; gelen düzlem dalga alanını doğrudan saçılan alana haritalayarak klasik sayısal yöntemlere yakın doğrulukta sonuç üretmiştir [35]. Benzer şekilde, FTYSA yaklaşımları zaman domeninde iletim hattı ve dalga kılavuzu problemine veya rezonatör problemlere uygulanarak Maxwell denklemlerinin çözümüne yakın sonuçlar elde edilmiştir. FTYSA'ların anten tasarımına uygulanması henüz başlangıç aşamasındadır; ancak potansiyel uygulamalar arasında, bir antenin giriş empedansını ve yakın alan dağılımını sınır koşullarını ihlal etmeden tahmin etmek veya anten yayılım desenini kısmi diferansiyel denklemlere uyacak şekilde öğrenmek sayılabilir [36, 37]. Ayrıca, FTYSA benzeri fizik-bazlı vekil modeller optimizasyon süreçlerinde de kullanılabilir. Literatürde, anten optimizasyonunu hızlandırmak için elektromanyetik teoriye dayalı asimptotik modellerin veya fiziksel genelleştirmelerin entegre edildiği yöntemlerin özellikle yerel aramalarda başarıyla uygulandığı belirtilmiştir [24]. FTYSA yaklaşımları bu fikirleri derin öğrenmeyle birleştirerek, veri olmadan veya az veriyle anten davranışını "öğrenebilen" araçlar sunma potansiyeline sahiptir. Önümüzdeki yıllarda FTYSA'ların antenlerin hızlı analizi, filtre/anten ortak optimizasyonu ya da karmaşık malzemeli (örn; meta-malzeme destekli) anten yapılarının tasarımında önemli rol oynaması beklenmektedir.

2.3.4. Geniş Bantlı Anten Tasarımı, Tersine Tasarım ve Optimizasyon

Geniş bantlı antenler (Ultra Wide Band (UWB) antenler) yüksek veri hızları ve çoklu uygulama desteği için kritik önemdedir; ancak geleneksel tasarımları ölçeklendirildiğinde genellikle kazanç düşüşü, düzensiz desen veya verim düşüşü gibi sorunlar ortaya çıkmaktadır [38]. Vivaldi antenleri ultra geniş bantta çalışabilmeleri sayesinde birçok uygulamada kullanılsa da özellikle yüksek frekanslara çıktıkça kazanç performansının azalma eğilimi, uzun menzilli

iletişim veya odaklanmış sinyal iletimi gereken durumlar için bir kısıt teşkil eder [38]. Bu nedenle araştırmacılar, Vivaldi antenlerde bant genişliğini korurken kazanç ve desen performansını iyileştirmek üzere yeni yöntemler denemektedir. Son dönemde makine öğrenimi bu alanda da devreye girmiştir [39].

Araştırmacılar, yarıklarla kazancı artırılmış ve belirli frekansları bastırılmış bir antipodal Vivaldi anten tasarımını ele alarak makine öğrenimi yardımıyla performans optimizasyonu gerçekleştirmiştir. Bu çalışmada antenin kazanç, VSWR, bant genişliği ve dönüş kaybı (S_{11}) gibi çıktılarını tahmin eden bir ML modeli kurulmuş; farklı model konfigürasyonları için hatalar karşılaştırılarak en iyi tahmin kabiliyeti elde eden parametreler seçilmiştir [38]. Model, anten geometrisindeki oyuk (notch) ve diğer parametrelerin bu performans ölçütlerine etkisini "öğrenerek" tasarımcının optimum dengeyi bulmasına yardımcı olmuştur. Sonuçta yazarlar, makine öğrenimi tabanlı kestirim ile klasik deneme-yanılma yöntemlerine kıyasla çok daha az sayıda simülasyon yaparak anten kazancını yüksek frekanslarda belirgin biçimde iyileştirmişlerdir. Ayrıca elde edilen model sayesinde, her bir performans ölçütü için en uygun model karmaşıklığı tespit edilerek minimum hata sağlanmıştır. Bu çalışma, geniş bantlı bir Vivaldi anteninin hem performans analizinin hem de optimizasyonunun ML ile desteklenebileceğini göstermektedir [38].

Bant genişliği ve çoklu parametre optimizasyonu gerektiren anten problemlerinde, makine öğrenimi destekli yaklaşımlar önemli avantajlar sunar. Örneğin, 2025 yılında yayımlanan bir UWB Vivaldi anten çalışmasında, antenin açıklık geometrisine oyuklar, yarıklar ve yardımcı yapı elemanları eklenerek bant genişliği artırılırken; bu yapıların boyut ve konumları bir makine öğrenimi algoritması ile optimize edilmiştir. Bu sayede daha önce FR4 gibi maliyeti düşük bir malzemeyle ulaşılamayan geniş bir bant (3,66–20,42 GHz) ve yüksek kazanç elde edilmiştir [40]. Yazarlar, geleneksel tasarım yöntemlerinin aksine bu öğrenme destekli optimizasyon sayesinde hem anten boyutunu küçültüp hem bant genişliğini %36 oranında artırabildiklerini rapor etmişlerdir. Bu tür başarılar, geniş bantlı anten tasarımında makine öğreniminin doğrudan geometrik ince ayar yaparak tersine tasarım hedefine ulaştığını göstermektedir. Nitekim, klasik Vivaldi antenlerinin karşılaştığı boyut-bant genişliği ödünleşimi, yapay zekâ sayesinde daha etkin yönetilebilmiştir. Tersine tasarım (inverse design) alanında da 2020 sonrası önemli gelişmeler kaydedilmiştir. Tersine tasarım, istenen hedef performanslardan yola çıkarak anten geometrisinin otomatik türetilmesini ifade eder. Bu problem, doğrudan çözülmesi son derece zor bir problem iken derin öğrenme teknikleriyle

yaklaşılabilir hale gelmiştir. Literatürde 2023 yılında yayınlanan bir Nature makalesi, çok girişli/çıkışlı karmaşık EM yapılar için evrensel bir ters tasarım yöntemi önermiş; derin öğrenme modeli sayesinde kullanıcının belirlediği saçılım/yayılım karakteristiğine sahip yapılar otomatik olarak sentezlenebilmiştir [41]. Anten özelinde, birden fazla frekansta çalışan çoklu portlu bir yapının (örneğin MIMO antenin) hedef parametrelerine ulaşacak şekilde boyutlandırılması, klasik yöntemlerle uzun optimizasyonlar gerektirirken, veriye dayalı bir model ile anlık tahmin ve arama yapılması mümkün olmuştur. Ayrıca yukarıda bahsedilen Konvolusyon Sinir Ağı ((KSA), Convolutional Neural Network (CNN)) tabanlı çalışma [30], neredeyse herhangi bir planar anten şeklini (piksellenmiş şekil temsili kullanarak) doğrudan elde etmeyi başarmıştır ki bu, ileriye dönük olarak üretici (generative) modellerin anten tasarımında kullanılabileceğine işaret etmektedir.

Makine öğrenimi aynı zamanda üretim toleransı analizi ve sağlam (robust) tasarım optimizasyonlarında da değere sahiptir. Anten üretiminde kaçınılmaz olan boyutsal hatalar veya malzeme sapmaları, performansta istenmeyen değişimlere yol açabilir. Bu nedenle, tasarım aşamasında bu toleransların etkisini hızlıca analiz edebilmek önemlidir. Yüksek hesaplama maliyetli Monte Carlo benzetimleri yerine, eğitilmiş bir vekil model kullanarak yüzlerce/binlerce rastgele varyasyonu neredeyse anında değerlendirmek mümkündür [42]. Literatürde, sağlam tasarım için performans odaklı vekil modellerin kullanıldığı ve üretim varyasyonlarına karşı performansı istatistiksel olarak garanti eden optimizasyonların çok daha hızlı yapıldığı bildirilmektedir [24]. Örneğin, bu çalışmada çok-amaçlı bir anten optimizasyonunda her tasarımın en kötü durum performansını (min. kazanç, maks. S_{11} gibi) da hesaba katan bir hedef fonksiyon tanımlanmış; bu fonksiyonun öğrenilmesi için kullanılan model, tasarım uzayının sadece yüksek performanslı bölgelerini yoğun örnekleyerek işlemi verimli hale getirmiştir. Sonuç olarak, makine öğrenimi destekli yaklaşımlar sayesinde üretim toleransı analizleri hızlıca yapılıp, anten tasarımında toleranslardan en az etkilenen (yani üretim hatalarına karşı duyarsız) çözümler bulunabilmektedir. Bu da özellikle yüksek frekanslı ve hassas anten sistemlerinde, teori-pratik uyumunu artıran önemli bir avantajdır.

2.3.5. Ku-Bant Ofset Boşluklu Vivaldi Antenler: Durum ve Araştırma Boşlukları

Yukarıdaki incelemeden görüldüğü üzere, makine öğrenimi teknikleri geniş bantlı antenlerin tasarım ve optimizasyonunda giderek kritik bir rol oynamaktadır. Ancak literatürde özel olarak Ku-band ofset boşluklu Vivaldi anten yapısına odaklanan çalışma sayısı oldukça

sınırlıdır. Vivaldi antenlerine ilişkin genel çalışmalar mevcut olsa da (özellikle antipodal veya çift kutuplu geniş bant Vivaldi tasarımları üzerine), bunların büyük kısmı ya doğrudan klasik yöntemlerle tasarıma odaklanmakta ya da makine öğrenimi uygulamaları farklı anten tiplerine (yama antenler, yansıtıcı yüzeyler, vs.) yönelmektedir. Ku-bant aralığı (~12–18 GHz), Vivaldi antenlerin tipik kullanım alanlarından biri olmasına rağmen, ofset boşluk destekli yapı özgül bir tasarım olduğu için her makalede ele alınmamıştır. Bu anten yapısının kendine özgü zorlukları bulunmaktadır: Boşluk (cavity) eklentisi, Vivaldi antenin geri lobunu bastırıp kazancını artırırken; anten boyutlarını büyütebilir ve besleme empedansını karmaşıklaştırabilir. Ayrıca ofset besleme, simetriyi bozarak analiz ve optimizasyonu klasik Vivaldi'ye göre daha karmaşık hale getirebilir. Dolayısıyla bu spesifik yapının performans tahmininde YZ tabanlı modeller kurmak, diğer düz antenlere kıyasla daha zorlu ancak bir o kadar da faydalı bir hedeftir. Mevcut literatürde, boşluklu Vivaldi antenlerin makine öğrenimi ile modellenmesi konusunda bazı dolaylı bulgular vardır. Örneğin, araştırmacılar boşluk desteği ile ultrageniş bant bir Vivaldi anteni tasarlayıp klasik yöntemlerle analiz etmiştir [20]; bu çalışma ofset kavramını içermese de, boşluk kullanımıyla Vivaldi antenlerin bant genişliği ve yönlülüğünün iyileştirilebileceğini göstermiştir. Öte yandan diğer bir grup, çalışmasında ise Ku-bandın alt kısmına denk gelen 8–12 GHz civarı bir antipodal Vivaldi tasarımını ele almıştır ve makine öğrenimiyle kazanç arttırma çalışmışlardır [38]; fakat bu da ofset boşluklu versiyon yerine düz antipodal yapıdadır.

Bu bulgular ışığında, Ku-band ofset boşluklu Vivaldi antenler konusunda belirgin bir araştırma boşluğu olduğu söylenebilir. Henüz literatürde bu spesifik yapıyı ele alan, yapay zekâ destekli kapsamlı bir modelleme çalışmasına rastlanmamıştır. Bu durum, mevcut yöntemlerin bu antene kolay uygulanamadığından değil, daha ziyade konunun özel ve yeni olmasından kaynaklanıyor olabilir. Ofset boşluklu Vivaldi, klasik Vivaldi anteninin tüm geniş bantlı karakterini taşırken üzerine eklenen oyuk yapısıyla özgün bir optimizasyon problemidir ve bu probleme yönelik makine öğrenimi modellerinin geliştirilmesi, tez çalışmaları için yenilikçi bir katkı potansiyeli taşımaktadır. Özellikle Ku-bandında, anten boyut toleransları milimetre mertebesinde olduğundan ve üretim varyasyonlarına duyarlılık arttığından, üretim toleransı odaklı YZ modelleri bu anten yapısına uygulanarak hem tasarım hem üretim aşamasında güvenli marjlar sağlanabilir.

Sonuç olarak, 2020–2025 döneminde YZ tabanlı modelleme anten alanında ciddi ilerlemeler kaydedilmiş; ÇKA, GP, DVR gibi yöntemlerle çeşitli anten tipleri başarıyla

modellenmiş, optimizasyon ve ters tasarım problemleri çözülmüştür. Geniş bantlı antenler için makine öğrenimi kullanımı bant genişliği, kazanç ve boyut optimizasyonunda önemli faydalar sunmaktadır. Ku-band ofset boşluklu Vivaldi antenler ise bu genel eğilimin özel bir alt alanı olarak ortaya çıkmakta ve literatürde henüz yeterince çalışılmamıştır. Bu alanda yapılacak çalışmalar, mevcut literatürdeki boşluğu doldurarak hem teorik katkı sağlayacak hem de pratik uygulamalarda (örneğin uydu haberleşmesi, 5G/6G milimetre dalga sistemleri, radar sensörleri) kullanılabilecek hızlı tasarım araçlarının geliştirilmesine olanak tanıyacaktır. Bu tez kapsamında gerçekleştirilecek literatür araştırması ve potansiyel yeni çalışmalar, tam da bu noktada konumlanarak, ofset boşluklu Vivaldi antenlerin YZ destekli modellenmesi ve optimizasyonu konusunda öncü katkılar sunabilir.

2.4. KAVRAMLAR ARASI İLİŞKİLER

Bu çalışmada kullanılan temel kavramlar arasındaki ilişkiler çok katmanlıdır. Giriş parametreleri olan geometrik boyutlar (örneğin anten açıklığı, yarık profili, slot uzunluğu) doğrudan antenin empedans yapısını ve dolayısıyla geri dönüş kaybı (S_{11}) davranışını etkiler. Bu fiziksel ilişki, elektromanyetik simülasyon verileriyle doğrulanmakta ve bu veriler ÇKA modeliyle öğrenilmektedir. Örnekleme yöntemi olarak LHÖ kullanılması, veri setinin homojen dağılmasını sağlayarak modelin genelleme başarısını doğrudan etkilemektedir. Ayrıca ÇKA modelinde kullanılan katman ve nöron sayısı gibi hiper-parametreler, modelin doğruluğu ve hata düzeyleri (MSE, MAE) üzerinde kritik rol oynamaktadır. Tüm bu unsurlar birlikte değerlendirilerek, anten tasarımı ile performans çıktısı arasında doğrusal olmayan çok boyutlu bir ilişki haritalanmıştır.

2.5. ARAŞTIRMA PROBLEMİ İLE BAĞLANTI

Yukarıda açıklanan kavramlar, bu tezin ana araştırma problemi olan "Ku-bandında çalışan ofset boşluklu bir Vivaldi antenin geri dönüş kaybı (S_{11}) davranışının ÇKA modeli ile tahmin edilmesi" konusuna doğrudan hizmet etmektedir. Literatürde Ku-bandı frekans aralığında çalışan Vivaldi antenlerin tam-dalga çözümlemesi dışında, veri odaklı modelleme ile öngörülmesine dair sınırlı sayıda çalışma bulunmaktadır. Bu çalışma, LHÖ ile oluşturulmuş EM veri setleri üzerinden eğitim alan bir ÇKA modeli ile yüksek doğrulukta S_{11} tahmini yaparak bu boşluğu doldurmayı amaçlamaktadır. Böylece, yüksek hesaplama maliyetine sahip simülasyonlara alternatif olarak, hızlı ve güvenilir bir modelleme yaklaşımı sunulmuştur.

3. YÖNTEM

3.1. MATEMATİKSEL MODEL

Bu çalışmada, ofset boşluklu Vivaldi anteninin matematiksel modeli oluşturulmuştur. Anten, dikdörtgen veya dairesel bir ofset boşluğa sahip, üstel veya doğrusal konik bir toprak düzlemi üzerinde tasarlanmıştır. Bu yapı, yaklaşık 16 GHz civarında rezonans gösteren bir Vivaldi anteni elde edilmesini sağlar. Antipodal antenlerde karşılaşılan yüksek mikroşerit kaybı ve karmaşık entegrasyon gibi sorunlar, bu tasarımla minimize edilmiştir. Geniş bant özellikleri sayesinde, anten havacılık ve uzay teknolojilerinde kullanılan faz dizili uygulamalar için uygundur. Antenin tasarım parametreleri ve özellikleri Tablo 3.1'de detaylı olarak sunulmuştur. Anten, 10 GHz ile 20 GHz frekans aralığında çalışacak şekilde tasarlanmıştır.

3.1.1. Temel Vivaldi Anteni Tasarım Denklemleri

Konik Açıklık (Taper Profile): Vivaldi anteninin en önemli özelliği, genellikle üstel (exponential) bir eğri ile tanımlanan konik açıklığıdır. Bu eğri, antenin empedans geçişini ve dolayısıyla bant genişliğini belirler. Üstel konik profil için genel denklem şu şekilde ifade edilebilir: $y=c_1e^{Rx}+c_2$ Burada; y, açıklığın yarım genişliğidir. x, antenin boyuna (uzunlamasına) ekseni boyunca mesafedir. R, açılma oranıdır (taper rate) ve antenin performansını önemli ölçüde etkiler. c_1 ve c_2, başlangıç ve bitiş açıklıklarını belirleyen sabitlerdir. Bu sabitler, $y(0)=w_1/2$ (besleme noktasındaki yuva genişliğinin yarısı) ve $y(L)=w_2/2$ (antenin ucundaki açıklığın yarısı) gibi sınır koşulları kullanılarak belirlenir. L antenin uzunluğudur.

Dalga Boyu ve Frekans İlişkisi: Antenin boyutları, hedeflenen çalışma frekans aralığındaki dalga boyları (λ) ile doğrudan ilişkilidir. $\lambda=c/f$ ile dalga boyu elde edilirken; c, ışık hızıdır (yaklaşık 3×10^8 m/s). f, çalışma frekansıdır.

3.1.2. Ofset Besleme (Offset Feed)

Ofset besleme, besleme noktasının antenin simetri ekseninden kaydırılması anlamına gelir. Bu, belirli modların uyarılmasını optimize etmek ve empedans uyumunu iyileştirmek için yapılabilir. Ofset beslemenin matematiksel modellemesi genellikle şu şekilde ele alınır:

- **Empedans Değişimi:** Besleme noktasının konumu, antenin giriş empedansını doğrudan etkiler. Bu etki, genellikle elektromanyetik simülasyon yazılımları (örn. CST, HFSS, FEKO) kullanılarak analiz edilir, çünkü analitik olarak kesin bir formül çıkarmak oldukça zordur.
- **Akım Dağılımı:** Besleme noktasının kaydırılması, anten yüzeyindeki akım dağılımını değiştirir. Bu da radyasyon paternini etkiler. Maxwell denklemlerinin sayısal çözümleri (örneğin, Moment Metodu - MoM) bu akım dağılımlarını modellemek için kullanılır.

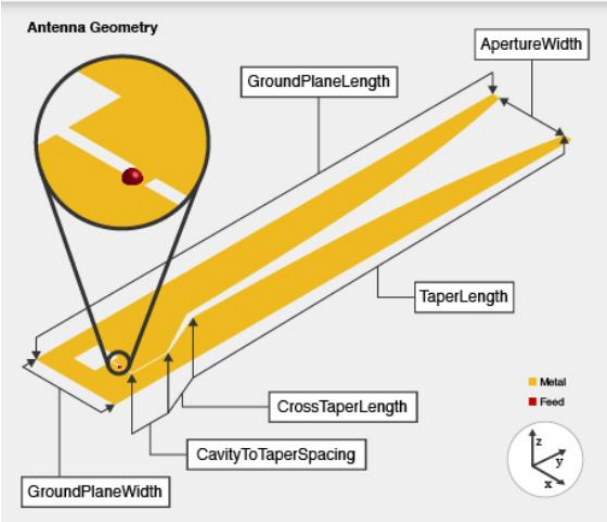
3.1.3. Boşluk (Slot) Etkisi

Anten yapısına eklenen slotlar, genellikle belirli frekanslarda rezonans oluşturmak, bant genişliğini artırmak veya radyasyon paternini şekillendirmek amacıyla kullanılır.

- **Rezonans Frekansları:** Boşluğun geometrisi (uzunluğu, genişliği, şekli) ve konumu, etkilediği rezonans frekanslarını belirler. Basit geometriler için (örn. dar bir dikdörtgen boşluk), boşluğun uzunluğu genellikle yaklaşık yarım dalga boyu ($\lambda/2$) veya çeyrek dalga boyu ($\lambda/4$) rezonatörü gibi davranır. Ancak Vivaldi anteni gibi karmaşık yapılarda bu etkileşim daha kompleks olabilir.
- **Kapasitif ve Endüktif Etkiler:** Boşluklar, yerel olarak kapasitif veya endüktif yükleme etkisi yaratarak antenin empedansını değiştirebilir. Bu etkilerin modellenmesi yine genellikle sayısal yöntemlerle yapılır.
- **Alan Dağılımı Modifikasyonu:** Boşluklar, antenin yakın alan (near-field) dağılımını değiştirerek uzak alan (“far-field”) radyasyon paternini etkileyebilir.

3.2. ANTEN TASARIMI

Antenin geometrik yapısı Şekil 3.1'de gösterilmiştir. Anten, konik bir yarık hat yapısından oluşmaktadır. Geniş bant uyumu sağlamak amacıyla, sabit yarık hattı ile dikdörtgen bir boşluk doldurulmuştur. Merkez iletken hattın diğer ucuna bir koaksiyel hat bağlanmıştır. Mekanik dayanımı artırmak için yan ve arka duvarlar yapıya dahil edilmiştir. Antenin açıklık boyutu değişken olarak belirlenmiş, yan duvarlar ise sabit tutulmuştur. Anten tasarımına ilişkin detaylı parametreler Tablo 3.1'de verilmiştir. Önerilen model, 6'sı değişken olmak üzere toplam 14 parametre içermektedir. Hesaplama ve modelleme işlemleri MATLAB R2023B sürümünde bulunan Antenna Toolbox kullanılarak gerçekleştirilmiştir.



Şekil 3.1.Ofset boşluklu Vivaldi anten için model **[43]**.

Tablo 3.1. Eğitim ve doğrulama veri seti detayları.

Parametre	Değer Aralığı	Örnekleme Yöntemi	Örnek sayısı (Bölüm 4.1)	Örnek sayısı (Bölüm 4.2)	Örnek sayısı (Bölüm 4.3)	Örnek sayısı (Bölüm 4.4)
TaperLength (mm)	105 ±%10	LHÖ	Eğitim: 70-80-90-100 Doğrulama: 20-30-40-50 Toplam:120			
ApertureWidth (mm)	20 ±%10					
CrossTaperLength (mm)	13,1 ±%10					
CavityToTaperSpacing (mm)	10,7 ±%10					
GroundPlaneLength (mm)	140 ±%10					
GroundPlaneWidth (mm)	24 ±%10					
Frekans (GHz)	10 – 20	Lineer	251	201	126	101
Toplam Örnek	-	-	120x251	120x201	120x126	100x100

3.3. ÖNERİLEN YÖNTEM

Bu çalışmada, belirlenen parametre aralıklarında LHÖ yöntemi kullanılarak veri setleri oluşturulmuş ve ÇKA ile modelleme gerçekleştirilmiştir. Çalışmanın temel amacı, farklı frekans adım aralıklarının modelleme performansı üzerindeki etkisini incelemektir. 10 GHz – 20 GHz aralığında dört farklı frekans adımı (40 MHz, 50 MHz, 80 MHz ve 100 MHz) için analizler yapılmış, her bir durumda farklı eğitim ve doğrulama veri setleri kullanılarak performans karşılaştırmaları sunulmuştur. Bu bölümde LHÖ ve ÇKA yöntemlerine dair temel bilgiler verilmiş, ardından önerilen modelleme yapısı açıklanmıştır.

3.4. LATİN HİPERKÜP ÖRNEKLEMESİ

Latin Hiperküp Örnekleme (LHÖ), çok boyutlu bir dağılımdan rastgele ancak dengeli örnekler üretmeye yarayan istatistiksel bir yöntemdir. Bilgisayar destekli deneyler ve Monte Carlo entegrasyonlarında sıkça tercih edilir. LHÖ, örneklerin parametre uzayında dengeli dağılmasını sağlayarak her eksen boyunca yalnızca bir örnek noktasına izin verir. Her değişken, eşit olasılığa sahip M aralığa bölünerek örnekleme gerçekleştirilir. Bu yöntem, örnekleme sayısını büyük tutmadan giriş değişkenlerinin dağılımını iyi temsil eder.

Örnekleme yöntemlerinin karşılaştırılması:

1. **Rastgele Örnekleme**: Önceden seçilen noktalar dikkate alınmaksızın örnek seçimi yapılır.
2. **LHÖ**: Önceden belirlenen örnek sayısı kadar nokta seçilir; her satır ve sütunda yalnızca bir örnek olacak şekilde yerleştirilir.
3. **Ortogonal Örnekleme**: Örnekleme uzayı eşit alt bölgelere ayrılır ve her bölge aynı yoğunlukta örneklenir.

3.5. ÇOK KATMANLI ALGILAYICI

Çok Katmanlı Algılayıcı (ÇKA), doğrusal olmayan aktivasyon fonksiyonlarına sahip, ileri beslemeli yapay sinir ağı yapısıdır. Geri yayılım algoritması ile eğitilir ve günümüzde birçok alanda başarıyla uygulanmaktadır.

3.5.1. Aktivasyon Fonksiyonları

Doğrusal aktivasyon fonksiyonu kullanıldığında katmanlar arası ilişki indirgenebilir. Ancak, sigmoid, tanh, ReLU ve softplus gibi doğrusal olmayan aktivasyonlar, karmaşık yapıları öğrenmede avantaj sağlar. Derin öğrenme uygulamalarında ReLU fonksiyonu yaygın şekilde tercih edilmektedir.

3.3.1. Katmanlar

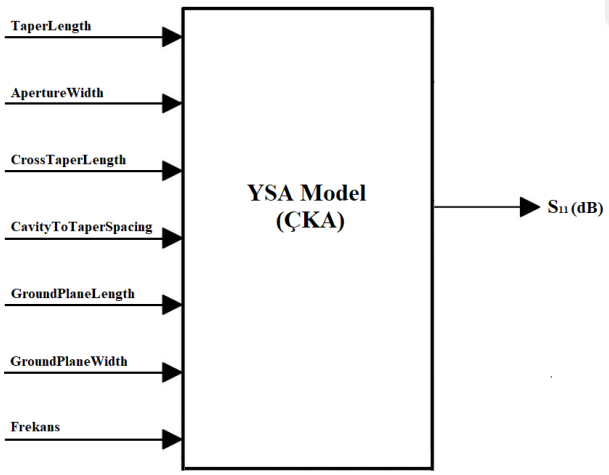
ÇKA'lar, bir giriş katmanı, bir veya birden fazla gizli katman ve bir çıkış katmanından oluşur. Tüm katmanlar arasında tam bağlantı bulunmaktadır.

3.3.2. Öğrenme Süreci

ÇKA, her veri örneği işlendiğinde, beklenen sonuç ile model çıktısı arasındaki farkı minimize edecek şekilde ağırlıklarını günceller. Bu süreç genellikle geri yayılım yöntemi ile gerçekleştirilir.

3.4. ÖNERİLEN MODEL

Ofset boşluklu Vivaldi antenin modellenmesi için önerilen ÇKA yapısı; iki, üç ve dört gizli katmandan oluşmakta, her katman 5, 10, 15, 20, 25 veya 30 nöron içerecek şekilde farklı kombinasyonlar denenmiştir. Bu mimariler, literatürde benzer çalışmalarda başarıyla uygulanmıştır. Katmanlar arasında farklı aktivasyon fonksiyonları kullanılmış; son gizli katmanda logsig, diğerlerinde tansig fonksiyonu tercih edilmiştir. Modelde, 6 tasarım parametresi ve frekans olmak üzere toplam 7 giriş parametresi yer almakta, çıkış olarak ise S_{11} (dB) parametresi kullanılmaktadır. Şekil 3.2'de önerilen yapay sinir ağının kara kutu modellemesi sunulmaktadır.



Şekil 3.2.Önerilen ÇKA yapısı ve giriş - çıkışlar.

4. BULGULAR

Bu bölümde, geliştirilen ÇKA modelinin performansı, farklı frekans adım aralıkları ve eğitim-doğrulama veri oranları altında değerlendirilmiştir. Kullanılan kara kutu model, daha önce Şekil 3.2'de sunulmuştur. Kullanılan eğitim ve doğrulama veri seti detayları da daha önce Tablo 3.1'de verilmiştir.

4.1. KULLANILAN AĞ YAPISI VE EĞİTİM PARAMETRELERİ

Çalışmada, dört farklı geri yayılım algoritması değerlendirilmiştir: Bayesian Regularization Backpropagation (trainbr), Levenberg-Marquardt Backpropagation (trainlm), Resilient Backpropagation (trainrp) ve Scaled Conjugate Gradient Backpropagation (trainscg). Bu algoritmalar arasında, en yüksek doğruluk ve genelleme yeteneği gösteren Bayesian Regularization Backpropagation (trainbr) seçilerek detaylı analizler gerçekleştirilmiştir.

Ağ mimarisi, 2, 3 ve 4 ara katmanlı yapılarla tasarlanmış; her bir ara katman için 5, 10, 15, 20, 25 ve 30 nöron sayıları denenmiştir. Bu yapıların her biri, daha geniş bir model havuzundan seçilerek en iyi performans gösteren kombinasyonlar olarak belirlenmiştir. Farklı frekans adım aralıkları için üretilen veri setleri ve ilgili hatalar Tablo 4.1, 4.2, 4.3 ve 4.4'te verilmiştir. Şekil 4.1'de 40 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden Bayesian regularization back-propagation (trainbr) algoritmalı ÇKA modellemesi sonucu oluşan S_{11} (dB) simülasyonu eğri çıktıları farklı eğitim doğrulama veri sayısına göre verilmiştir.

Tablo 4.5, 4.6, 4.7 ve 4.8'de farklı eğitim ve doğrulama verisi üzerinden ÇKA modellemesi sonuçları ve hata değerleri verilmektedir. Şekil 4.2'de 50 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden Bayesian regularization back-propagation (trainbr) algoritmalı ÇKA modellemesi sonucu oluşan S_{11} (dB) simülasyonu eğri çıktıları farklı eğitim doğrulama veri sayısına göre verilmiştir.

Tablo 4.1. 40 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden 70-50 eğitim-doğrulama datası ile ÇKA modellemesi için performans sonuçları.

Algoritma Mimarisi	Eğitim Hata (MSE)	Doğrulama Hata (MSE)	Eğitim Hata (MAE)	Doğrulama Hata (MAE)
[10 15]	4,82977	6,22209	1,82202	2,01215
[15 20]	0,25800	1,18027	0,36666	**0,70268**
[20 15]	0,23800	4,67481	0,35476	0,84881
[20 20]	3,00861	36,25579	1,40366	4,53255
[20 25]	0,18219	1,38449	0,30514	0,82857
[25 20]	0,21989	2,44395	0,33461	1,10543
[25 25]	0,14295	2,46438	0,26907	1,09132
[30 20]	0,16353	4,03268	0,28987	1,18268
[10 15 20]	0,19100	2,57464	0,31741	0,96232
[10 20 25]	0,90626	65,63416	0,67282	4,17663
[15 20 25]	0,13295	9,88911	0,25930	2,37490
[20 15 10]	0,17317	1,46459	0,30483	0,77679
[25 20 10]	0,12076	2,53661	0,25153	1,08735
[25 20 15]	0,14307	4,57601	0,27548	1,33194
[10 15 20 25]	0,58364	14,86233	0,57311	2,70481
[20 15 10 5]	1,57219	79,11950	0,89813	3,72761
[20 15 15 10]	0,18654	26,73972	0,32144	3,32455
[25 20 20 15]	0,07113	6,58745	0,19441	1,46455

Tablo 4.2. 40 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden 80-40 eğitim-doğrulama datası ile ÇKA modellemesi için performans sonuçları.

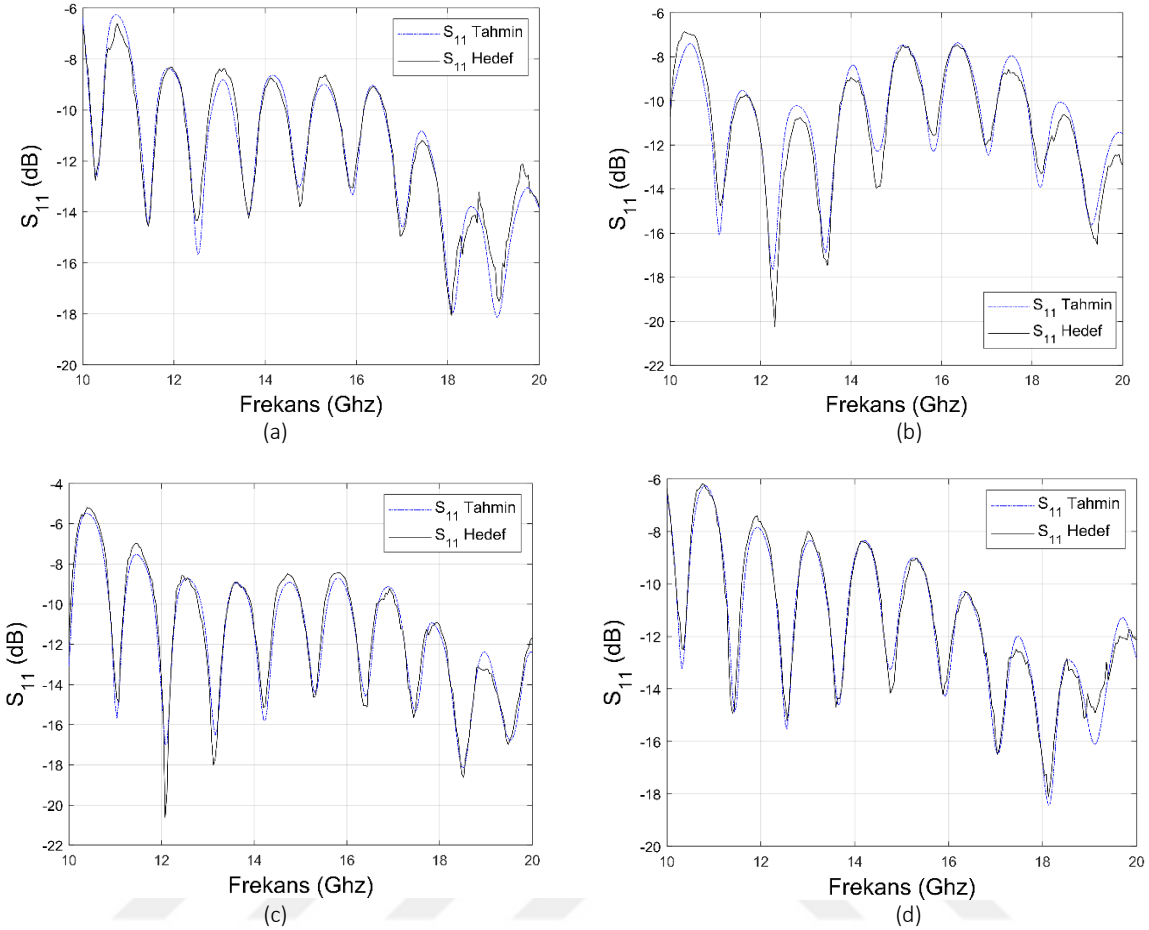
Algoritma Mimarisi	Eğitim Hata (MSE)	Doğrulama Hata (MSE)	Eğitim Hata (MAE)	Doğrulama Hata (MAE)
[10 15]	0,52323	2,09862	0,53408	0,82480
[15 20]	0,30608	1,38306	0,40700	0,75219
[20 15]	0,30324	4,38539	0,40238	0,86084
[20 20]	0,19694	0,47523	0,31116	**0,47586**
[20 25]	0,18461	1,36300	0,30558	0,71727
[25 20]	0,19292	1,60874	0,31761	0,86262
[25 25]	0,24175	1,86184	0,34601	0,93157
[30 20]	0,15307	2,09862	0,28024	0,99426
[10 15 20]	0,29680	4,55983	0,40529	0,93556
[10 20 25]	0,14634	1,53820	0,28087	0,67218
[15 20 25]	1,36225	27,80770	0,87271	3,56555
[20 15 10]	0,17116	1,50324	0,29955	0,76299
[25 20 10]	0,13630	3,85957	0,27191	0,98808
[25 20 15]	0,11286	1,55772	0,23678	0,82016
[10 15 20 25]	0,13168	22,32674	0,26067	1,57745
[20 15 10 5]	1,93856	11,89824	1,06025	2,63079
[20 15 15 10]	0,13055	14,23371	0,25917	2,73980
[25 20 20 15]	0,36312	70,21033	0,44865	5,65104

Tablo 4.3. 40 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden 90-30 eğitim-doğrulama datası ile ÇKA modellemesi için performans sonuçları.

Algoritma Mimarisi	Eğitim Hata (MSE)	Doğrulama Hata (MSE)	Eğitim Hata (MAE)	Doğrulama Hata (MAE)
[10 15]	0,44320	0,67248	0,48481	0,58292
[15 20]	0,23931	0,49519	0,35442	0,48827
[20 15]	0,22251	0,78823	0,34397	0,56579
[20 20]	0,23033	1,83269	0,34964	0,84874
[20 25]	0,20252	3,21279	0,33092	1,18781
[25 20]	0,19649	1,62055	0,32355	0,87058
[25 25]	0,17215	2,26622	0,29902	1,07193
[30 20]	0,15207	3,04239	0,28223	1,10889
[10 15 20]	0,17537	0,56383	0,30083	**0,47137**
[10 20 25]	0,13678	0,53931	0,25997	0,48778
[15 20 25]	4,70021	9,15239	1,79822	2,38650
[20 15 10]	0,18066	1,19923	0,31210	0,70690
[25 20 10]	0,14159	1,95135	0,27662	0,86481
[25 20 15]	0,13424	4,71142	0,26612	1,37170
[10 15 20 25]	0,11380	0,65094	0,23764	0,51791
[20 15 10 5]	3,04097	13,73523	1,37981	2,75324
[20 15 15 10]	0,12676	9,14197	0,25647	2,24266
[25 20 20 15]	0,09713	5,88648	0,22234	1,38191

Tablo 4.4. 40 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden 100-20 eğitim-doğrulama verisi ile ÇKA modellemesi için performans sonuçları.

Algoritma Mimarisi	Eğitim Hata (MSE)	Doğrulama Hata (MSE)	Eğitim Hata (MAE)	Doğrulama Hata (MAE)
[10 15]	4,24609	7,88273	1,69045	2,16453
[15 20]	0,25661	0,35738	0,35753	**0,43008**
[20 15]	0,23693	0,36910	0,34774	0,43038
[20 20]	0,24132	0,41360	0,34767	0,46670
[20 25]	0,17919	0,51278	0,29653	0,46244
[25 20]	0,19897	0,57304	0,31959	0,52678
[25 25]	0,16132	0,44032	0,28058	0,47874
[30 20]	0,18038	0,80966	0,30162	0,63619
[10 15 20]	0,21114	0,42885	0,33003	0,43985
[10 20 25]	0,16195	1,21064	0,28369	0,65617
[15 20 25]	0,15190	1,44900	0,27780	0,63182
[20 15 10]	0,40429	17,01665	0,46525	3,02273
[25 20 10]	0,15068	0,93591	0,27703	0,59296
[25 20 15]	0,14262	1,30025	0,27137	0,68655
[10 15 20 25]	0,12678	0,46293	0,24686	0,45422
[20 15 10 5]	0,33373	144,76444	0,42567	3,76506
[20 15 15 10]	0,13588	0,40998	0,25869	0,43563
[25 20 20 15]	0,74766	22,43690	0,63098	3,54940



Şekil 4.1. 40 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden Bayesian regularization back-propagation (trainbr) algoritmalı ÇKA modellemesi sonucu oluşan S_{11} (dB) simülasyonu (a) 70-50 eğitim-doğrulma verisi (b) 80-40 eğitim-doğrulma verisi (c) 90-30 eğitim-doğrulma verisi (d) 100-20 eğitim-doğrulma verisi.

4.2. VERİ SETİ VE ÖRNEKLEME YÖNTEMİ

Tüm deneylerde kullanılan veri setleri, LHÖ yöntemi ile oluşturulmuş ve her bir model için aynı örnekler kullanılarak karşılaştırılabilirlik sağlanmıştır. Literatürde en düşük örnekleme boyutu 144 olarak raporlanmışken [44] bu çalışmada 120 örnekleme boyutu kullanılarak daha düşük veri ile yüksek performans elde edilmiştir.

Eğitim ve doğrulama veri setleri dört farklı oranla oluşturulmuştur: 70-50, 80-40, 90-30 ve 100-20. Bu oranlar sırasıyla %70, %66,7, %75 ve %83,3 eğitim verisine karşılık gelmektedir. Veri setlerinin ayrımı, literatürde yaygın olarak kullanılan rastgele seçim yöntemi ile gerçekleştirilmiştir.

Modelleme performansı, ortalama kare hata (MSE) ve ortalama mutlak hata (MAE) metrikleri ile değerlendirilmiştir. Ayrıca, her bir model için hedef ve tahmin değerlerinin karşılaştırıldığı grafikler sunulmuştur. Tüm modelleme işlemleri toplamda 33 dakikada tamamlanmış olup, bu süre model başına ortalama iki dakikaya tekabül etmektedir.

Tablo 4.5. 50 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden 70-50 eğitim-doğrulama datası ile ÇKA modellemesi için performans sonuçları.

Algoritma Mimarisi	Eğitim Hata (MSE)	Doğrulama Hata (MSE)	Eğitim Hata (MAE)	Doğrulama Hata (MAE)
[10 15]	0,46594	1,55513	0,51994	0,79152
[15 20]	0,20142	1,31351	0,33661	0,65205
[20 15]	0,19078	0,93762	0,32747	0,62707
[20 20]	0,14695	1,01917	0,28313	0,61029
[20 25]	0,14217	1,04318	0,27681	0,67538
[25 20]	0,15201	1,28120	0,28814	0,73495
[25 25]	0,13606	2,19684	0,27186	1,01232
[30 20]	0,11744	2,90089	0,25281	0,88318
[10 15 20]	2,17442	14,15584	1,15380	2,66898
[10 20 25]	4,77384	5,98531	1,82415	1,99516
[15 20 25]	0,10704	0,99217	0,24343	0,60365
[20 15 10]	0,15117	0,88214	0,28896	**0,57426**
[25 20 10]	0,10532	1,82424	0,24467	0,83132
[25 20 15]	0,09186	2,94149	0,22811	1,10229
[10 15 20 25]	1,47811	43,38250	0,90779	4,37556
[20 15 10 5]	0,12967	19,08410	0,27530	2,65300
[20 15 15 10]	0,11543	1,72268	0,25296	0,86440
[25 20 20 15]	0,06006	6,57869	0,18267	1,31656

Tablo 4.6. 50 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden 80-40 eğitim-doğrulama datası ile ÇKA modellemesi için performans sonuçları.

Algoritma Mimarisi	Eğitim Hata (MSE)	Doğrulama Hata (MSE)	Eğitim Hata (MAE)	Doğrulama Hata (MAE)
[10 15]	4,82567	5,57334	1,83231	1,92206
[15 20]	0,19961	1,45583	0,33101	0,61976
[20 15]	0,22056	0,61350	0,34346	0,52564
[20 20]	0,18563	4,33553	0,32008	0,92732
[20 25]	0,15091	0,94573	0,28476	0,58624
[25 20]	0,14886	1,63471	0,28340	0,57792
[25 25]	0,13957	1,59691	0,27373	0,78511
[30 20]	0,13306	1,54078	0,27020	0,85876
[10 15 20]	0,17260	0,89777	0,31212	0,59451
[10 20 25]	0,13519	1,16180	0,27447	0,66449
[15 20 25]	0,11905	1,43676	0,25712	0,68618
[20 15 10]	0,14515	0,60932	0,28323	**0,51242**
[25 20 10]	0,11388	2,84864	0,25069	0,79785
[25 20 15]	0,09961	1,09700	0,23414	0,64521
[10 15 20 25]	0,10816	1,25240	0,24370	0,71950
[20 15 10 5]	0,14521	60,73510	0,28972	1,62474

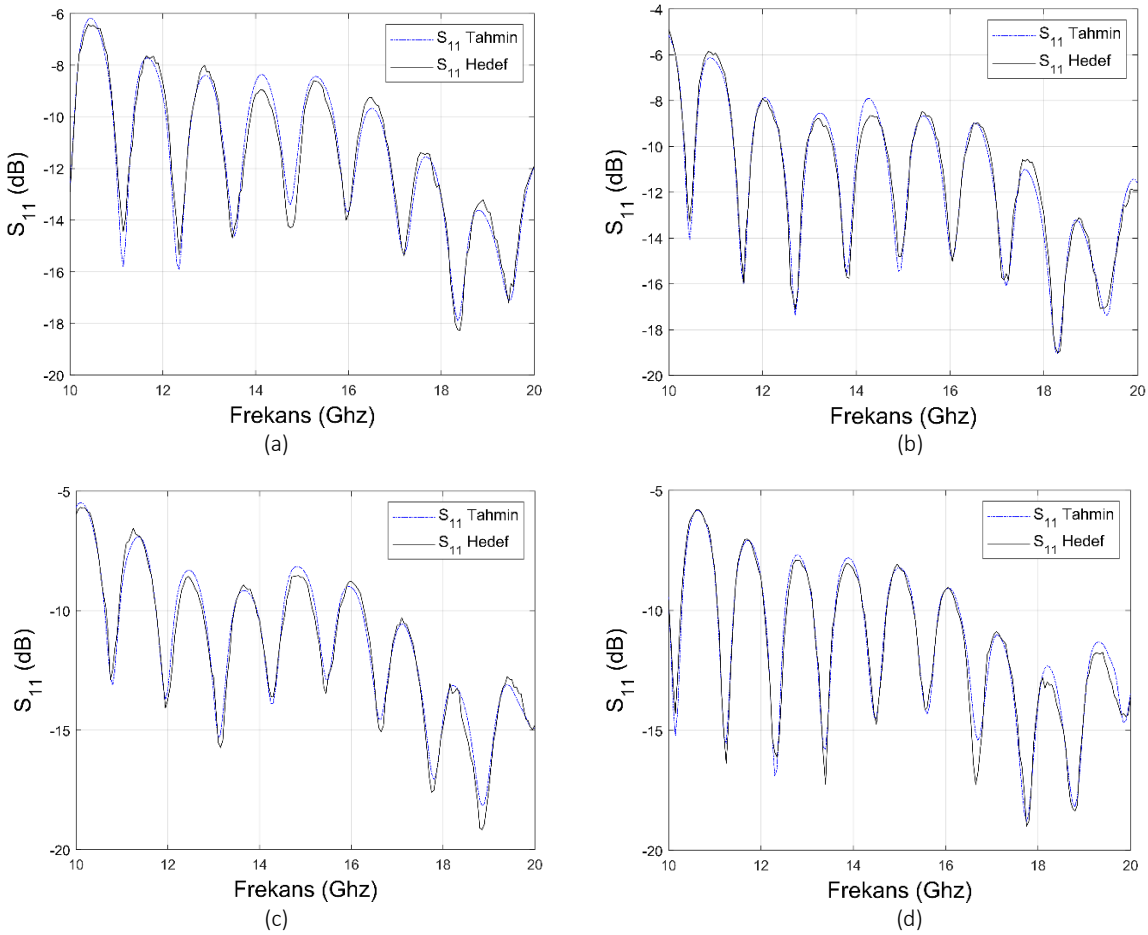
[20 15 15 10]	0,12075	1,84604	0,26313	0,80047
[25 20 20 15]	0,06999	2,62115	0,19670	1,00294

Tablo 4.7. 50 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden 90-30 eğitim-doğrulama datası ile ÇKA modellemesi için performans sonuçları.

Algoritma Mimarisi	Eğitim Hata (MSE)	Doğrulama Hata (MSE)	Eğitim Hata (MAE)	Doğrulama Hata (MAE)
[10 15]	4,73582	5,34122	1,81511	1,90791
[15 20]	0,23563	1,46212	0,36713	0,67584
[20 15]	0,21560	1,06901	0,34898	0,60597
[20 20]	0,16428	0,49670	0,29810	**0,48372**
[20 25]	0,16464	2,22319	0,30199	0,91930
[25 20]	0,14495	1,42480	0,27949	0,61921
[25 25]	0,14508	15,40811	0,28339	1,28140
[30 20]	0,14473	1,31668	0,28531	0,77588
[10 15 20]	0,16313	0,56006	0,29843	0,49187
[10 20 25]	2,13827	15,51701	1,13080	2,88653
[15 20 25]	0,11361	1,19803	0,24856	0,57759
[20 15 10]	0,15554	2,06209	0,29376	0,73951
[25 20 10]	0,11670	1,25346	0,25665	0,76091
[25 20 15]	0,14465	3,13182	0,28368	0,90217
[10 15 20 25]	0,11734	2,41050	0,25446	0,77731
[20 15 10 5]	0,13163	1,52761	0,27017	0,74202
[20 15 15 10]	0,12069	1,75032	0,26108	0,73330
[25 20 20 15]	0,24364	22,21559	0,37774	2,59031

Tablo 4.8. 50 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden 100-20 eğitim-doğrulama datası ile ÇKA modellemesi için performans sonuçları.

Algoritma Mimarisi	Eğitim Hata (MSE)	Doğrulama Hata (MSE)	Eğitim Hata (MAE)	Doğrulama Hata (MAE)
[10 15]	0,45804	7,61885	0,50574	0,77907
[15 20]	0,19549	1,10707	0,32450	0,50241
[20 15]	0,19716	0,33692	0,32706	**0,40787**
[20 20]	0,18637	1,05348	0,32210	0,61657
[20 25]	0,17481	1,18322	0,31389	0,67388
[25 20]	0,15507	0,61681	0,28831	0,49583
[25 25]	0,13695	0,47222	0,27115	0,48193
[30 20]	0,14778	0,95607	0,28539	0,65209
[10 15 20]	0,17615	0,46133	0,31007	0,46100
[10 20 25]	0,13931	0,52043	0,27335	0,44809
[15 20 25]	0,13148	1,37673	0,27170	0,77740
[20 15 10]	0,19018	3,08847	0,32884	0,70978
[25 20 10]	0,13000	0,67702	0,27130	0,50332
[25 20 15]	0,11685	0,91004	0,25528	0,56327
[10 15 20 25]	0,11631	1,25839	0,24965	0,57997
[20 15 10 5]	0,14806	0,48496	0,28851	0,49650
[20 15 15 10]	0,11512	1,60257	0,25071	0,58546
[25 20 20 15]	0,07981	1,04780	0,20999	0,61394



Şekil 4.2. 50 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden Bayesian regularization backpropagation (trainbr) algoritmalı ÇKA modellemesi sonucu oluşan S_{11} (dB) simülasyonu (a) 70-50 eğitim-doğrulma verisi (b) 80-40 eğitim-doğrulma verisi (c) 90-30 eğitim-doğrulma verisi (d) 100-20 eğitim-doğrulma verisi.

4.3. FREKANS ADIM ARALIKLARINA GÖRE MODELLEME PERFORMANSI

4.3.1. 40 Mhz Frekans Adım Aralığı

Bu bölümde, 10 GHz ile 20 GHz arasındaki frekans aralığında 0,04 GHz (40 MHz) adım ile elde edilen 251 veri noktası üzerinden modelleme yapılmıştır. Toplamda 120 örnek kullanılarak, dört farklı eğitim-doğrulama oranı için modeller oluşturulmuştur. Elde edilen sonuçlar Tablo 4.3, Tablo 4.4, Tablo 4.5 ve Tablo 4.6'da sunulmuştur.

Analizler, 2 ve 3 ara katmanlı mimarilerin en iyi performansı gösterdiğini ortaya koymuştur. Özellikle, 70-50 ve 80-40 veri oranlarında 2 ara katmanlı, 15 ve 20 nöronlu yapılar; 90-30 oranında ise 3 ara katmanlı, 10, 15 ve 20 nöronlu yapılar en başarılı sonuçları vermiştir. Genel olarak, ara katman ve nöron sayısının artışı modelleme süresini uzatmakta, ancak

performansa anlamlı bir katkı sağlamamaktadır. Şekil 4.1-a, -b, -c ve -d, her bir eğitim-doğrulama oranı için en iyi performans gösteren modellerin hedef ve tahmin değerlerini karşılaştırmaktadır.

4.3.2. 50 MHz Frekans Adım Aralığı

Bu bölümde, 0,05 GHz (50 MHz) adım ile elde edilen 201 veri noktası kullanılarak modelleme yapılmıştır. Sonuçlar Tablo 4.7, Tablo 4.8, Tablo 4.9 ve Tablo 4.10'da sunulmuştur.

Analizler, 70-50 ve 80-40 veri oranlarında 3 ara katmanlı, 20, 15 ve 10 nöronlu yapılar; 90-30 ve 100-20 oranlarında ise 2 ara katmanlı, 20 ve 15 nöronlu yapılar en iyi performansı göstermiştir. Bu sonuçlar, önceki bölümde elde edilen bulgularla tutarlıdır. Şekil 4.2-a, -b, -c ve -d, her bir eğitim-doğrulama oranı için en iyi performans gösteren modellerin hedef ve tahmin değerlerini karşılaştırmaktadır.

4.3.2. 80 MHz Frekans Adım Aralığı

Bu bölümde, 0,08 GHz (80 MHz) adım ile elde edilen 126 veri noktası kullanılarak modelleme yapılmıştır. Sonuçlar, Tablo 4.9 ve Tablo 4.10'da sunulmuştur.

Analizler, 70-50 veri oranında 2 ara katmanlı, 10 ve 15 nöronlu yapılar; 80-40 ve 90-30 oranlarında 3 ara katmanlı, 10, 15 ve 20 nöronlu yapılar; 100-20 oranında ise 2 ara katmanlı, 20 nöronlu yapılar en iyi performansı göstermiştir. Bu sonuçlar, önceki bölümlerle genel bir uyum göstermektedir. Şekil 4.3-a, -b, -c ve -d, her bir eğitim-doğrulama oranı için en iyi performans gösteren modellerin hedef ve tahmin değerlerini karşılaştırmaktadır.

4.3.3. 100 MHz Frekans Adım Aralığı

Bu bölümde, 0,10 GHz (100 MHz) adım ile elde edilen 101 veri noktası kullanılarak modelleme yapılmıştır. Sonuçlar, Tablo 4.13, Tablo 4.14, Tablo 4.15 ve Tablo 4.16'da sunulmuştur.

Analizler, 70-50 ve 80-40 veri oranlarında 2 ara katmanlı, 10, 15 ve 20 nöronlu yapılar; 90-30 oranında 3 ara katmanlı, 10, 15 ve 20 nöronlu yapılar; 100-20 oranında ise 4 ara katmanlı, 20, 15, 15 ve 10 nöronlu yapılar en iyi performansı göstermiştir. Bu sonuçlar, daha önceki bulgularla genel bir uyum içerisindedir. Şekil 4.4-a, -b, -c ve -d her bir eğitim-doğrulama oranı için en iyi performans gösteren modellerin hedef ve tahmin değerlerini karşılaştırmaktadır.

Tablo 4.9. 80 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden 70-50 eğitim-doğrulama datası ile ÇKA modellemesi için performans sonuçları.

Algoritma Mimarisi	Eğitim Hata (MSE)	Doğrulama Hata (MSE)	Eğitim Hata (MAE)	Doğrulama Hata (MAE)
[10 15]	0,44304	0,61681	0,47527	**0,53932**
[15 20]	4,82898	6,45517	1,82085	2,05862
[20 15]	4,81575	6,75587	1,81763	2,06051
[20 20]	0,23824	9,02957	0,34530	1,70824
[20 25]	4,82372	6,73808	1,82010	2,09094
[25 20]	4,80896	6,75257	1,81735	2,07845
[25 25]	4,82533	6,40450	1,82004	2,03171
[30 20]	4,80354	6,31254	1,81610	2,00363
[10 15 20]	2,33465	15,27276	1,19834	2,82654
[10 20 25]	4,79745	6,48710	1,81422	2,06002
[15 20 25]	4,80541	7,04168	1,81641	2,13135
[20 15 10]	4,77111	6,54905	1,81005	2,07146
[25 20 10]	0,15026	1,93934	0,28331	0,87590
[25 20 15]	0,12365	3,01054	0,25720	1,16675
[10 15 20 25]	0,12882	2,28518	0,25970	0,81389
[20 15 10 5]	0,18300	2,36405	0,31422	0,93635
[20 15 15 10]	1,15625	38,32364	0,79120	3,77662
[25 20 20 15]	0,12643	120,39095	0,25810	5,05583

Tablo 4.10. 80 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden 80-40 eğitim-doğrulama datası ile ÇKA modellemesi için performans sonuçları.

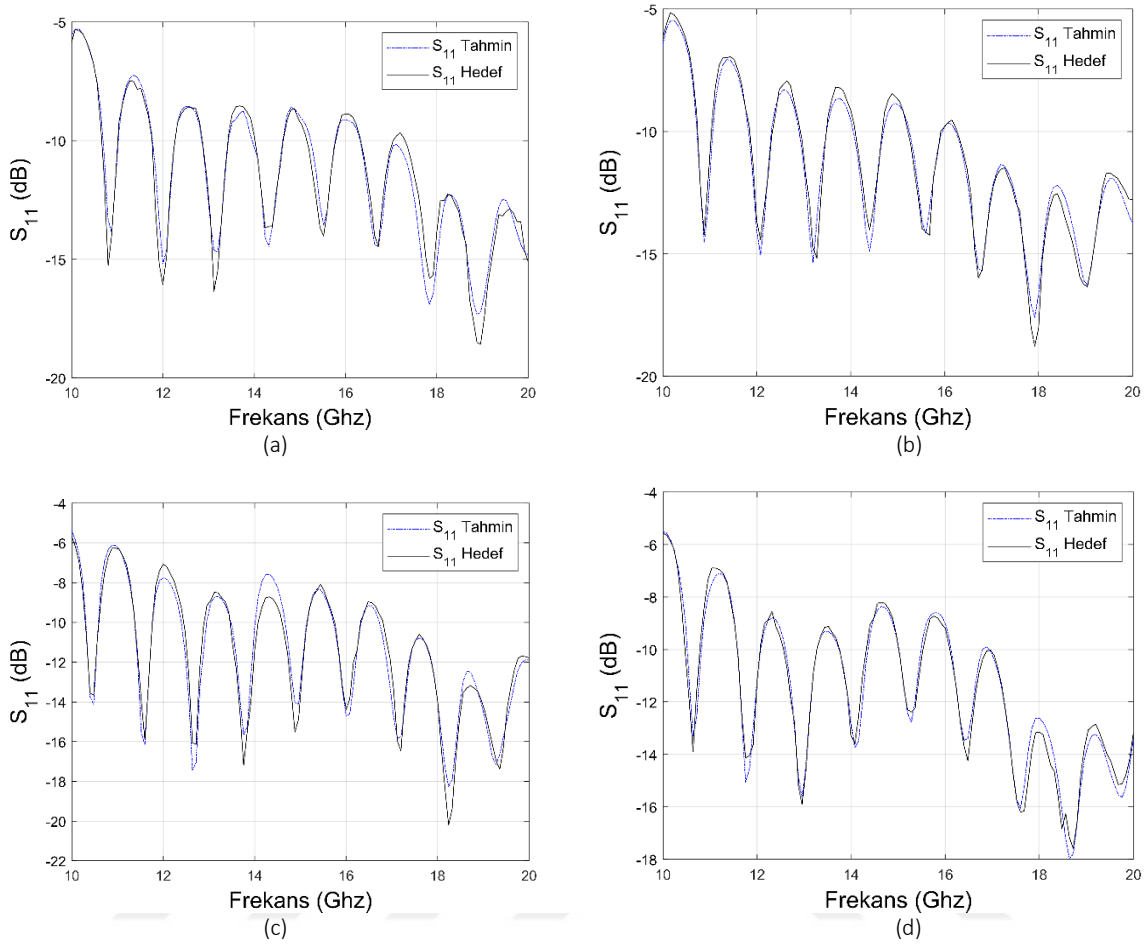
Algoritma Mimarisi	Eğitim Hata (MSE)	Doğrulama Hata (MSE)	Eğitim Hata (MAE)	Doğrulama Hata (MAE)
[10 15]	4,85069	5,02261	1,83049	1,85106
[15 20]	0,33059	2,53019	0,40817	0,74065
[20 15]	0,32751	1,04089	0,41029	0,67522
[20 20]	0,50280	4,42523	0,51909	1,33767
[20 25]	0,20006	2,81929	0,31556	1,15273
[25 20]	0,21341	6,99449	0,33463	1,55586
[25 25]	0,19843	15,90586	0,32420	1,38197
[30 20]	0,20872	12,09095	0,32205	1,50596
[10 15 20]	0,21535	0,63687	0,33117	**0,51815**
[10 20 25]	0,22634	32,61557	0,33844	1,94822
[15 20 25]	0,15571	13,24768	0,28771	1,60398
[20 15 10]	0,19969	1,42199	0,31879	0,76451
[25 20 10]	0,13894	10,42534	0,27195	1,15660
[25 20 15]	0,13666	1,18300	0,26212	0,71547
[10 15 20 25]	0,16095	1,56648	0,28899	0,68465
[20 15 10 5]	0,16739	1,85813	0,29248	0,82674
[20 15 15 10]	0,12884	2,24128	0,26589	0,82077
[25 20 20 15]	0,07446	4,24074	0,20538	1,32899

Tablo 4.11. 80 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden 90-30 eğitim-doğrulama datası ile ÇKA modellemesi için performans sonuçları.

Algoritma Mimarisi	Eğitim Hata (MSE)	Doğrulama Hata (MSE)	Eğitim Hata (MAE)	Doğrulama Hata (MAE)
[10 15]	0,47279	0,55508	0,50214	0,54652
[15 20]	2,66243	11,18280	1,28971	2,35188
[20 15]	0,32520	1,50245	0,40649	0,63812
[20 20]	0,28166	1,25169	0,37729	0,61307
[20 25]	4,75822	6,10187	1,80899	2,00677
[25 20]	0,22322	0,76438	0,32992	0,62033
[25 25]	0,19838	3,55278	0,31729	1,17034
[30 20]	0,19571	1,82651	0,30662	0,99503
[10 15 20]	0,21696	0,39280	0,34105	**0,45450**
[10 20 25]	0,16524	2,28646	0,27424	0,74220
[15 20 25]	0,15987	0,91561	0,29089	0,59272
[20 15 10]	0,23193	2,35099	0,34204	0,92112
[25 20 10]	0,16290	1,77266	0,29679	0,92433
[25 20 15]	0,13561	1,49358	0,26950	0,85514
[10 15 20 25]	0,74597	15,20358	0,64676	2,84817
[20 15 10 5]	0,16752	2,05714	0,29811	0,81811
[20 15 15 10]	0,63867	15,44905	0,58665	2,88322
[25 20 20 15]	0,13741	19,02931	0,26647	2,93085

Tablo 4.12. 80 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden 100-20 eğitim-doğrulama datası ile ÇKA modellemesi için performans sonuçları.

Algoritma Mimarisi	Eğitim Hata (MSE)	Doğrulama Hata (MSE)	Eğitim Hata (MAE)	Doğrulama Hata (MAE)
[10 15]	4,83469	4,91336	1,82627	1,84361
[15 20]	0,29460	7,21839	0,38562	0,91390
[20 15]	0,27390	1,58104	0,37149	0,64202
[20 20]	0,22649	0,62580	0,33092	**0,47565**
[20 25]	0,26902	1,62670	0,36956	0,88087
[25 20]	0,23699	0,90593	0,34380	0,63415
[25 25]	0,23079	4,33435	0,33968	1,28839
[30 20]	0,22322	4,60841	0,33016	1,36287
[10 15 20]	0,31742	2,54145	0,40808	0,78194
[10 20 25]	0,17589	0,81409	0,30622	0,54122
[15 20 25]	0,21629	12,13937	0,33293	1,28884
[20 15 10]	0,23146	1,10326	0,34715	0,72767
[25 20 10]	0,17011	0,99031	0,29220	0,67639
[25 20 15]	0,14256	1,52376	0,27549	0,69544
[10 15 20 25]	0,13182	0,63526	0,25944	0,50499
[20 15 10 5]	0,22017	9,48161	0,34159	1,02565
[20 15 15 10]	0,33775	18,99167	0,42521	2,73826
[25 20 20 15]	0,09036	5,24002	0,22522	0,81790



Şekil 4.3. 80 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden Bayesian regularization backpropagation (trainbr) algoritmalı ÇKA modellemesi sonucu oluşan S_{11} (dB) simülasyonu (a) 70-50 eğitim-doğrulma verisi (b) 80-40 eğitim-doğrulma verisi (c) 90-30 eğitim-doğrulma verisi (d) 100-20 eğitim-doğrulma verisi.

Tablo 4.13. 100 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden 70-50 eğitim-doğrulama datası ile ÇKA modellemesi için performans sonuçları.

Algoritma Mimarisi	Eğitim Hata (MSE)	Doğrulama Hata (MSE)	Eğitim Hata (MAE)	Doğrulama Hata (MAE)
[10 15]	0,61749	2,68853	0,59026	**0,94796**
[15 20]	4,84117	5,97659	1,82455	1,99530
[20 15]	4,80462	6,54311	1,81998	2,09978
[20 20]	4,79749	6,79486	1,81740	2,09018
[20 25]	4,78208	6,01598	1,81720	2,00942
[25 20]	4,79637	6,31744	1,81859	2,05545
[25 25]	4,79351	7,52263	1,81645	2,20191
[30 20]	4,79105	6,32146	1,81611	2,04705
[10 15 20]	4,79106	5,44924	1,81785	1,91853
[10 20 25]	4,77492	5,61244	1,81511	1,96327
[15 20 25]	4,77251	6,17633	1,81299	2,03243
[20 15 10]	4,77132	7,27227	1,81298	2,17819
[25 20 10]	4,74387	6,58290	1,80725	2,08463
[25 20 15]	4,76073	7,11217	1,81154	2,17114
[10 15 20 25]	4,77434	5,60488	1,81648	1,96327

[20 15 10 5]	0,14193	2,49496	0,27498	1,05068
[20 15 15 10]	4,76746	6,84867	1,81369	2,08439
[25 20 20 15]	0,06377	7,33881	0,18929	1,66543

Tablo 4.14.100 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden 80-40 eğitim-doğrulama datası ile ÇKA modellemesi için performans sonuçları.

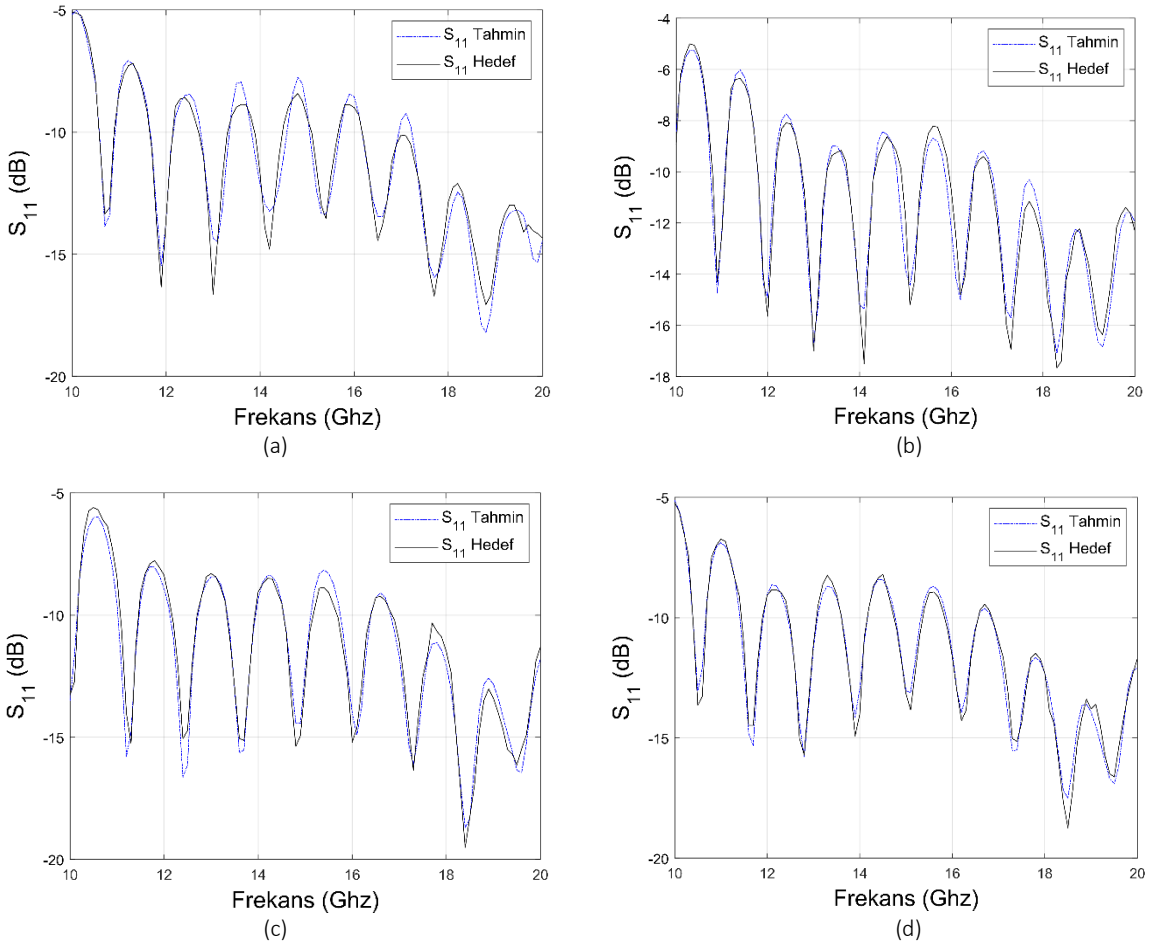
Algoritma Mimarisi	Eğitim Hata (MSE)	Doğrulama Hata (MSE)	Eğitim Hata (MAE)	Doğrulama Hata (MAE)
[10 15]	4,83076	5,36944	1,82688	1,92039
[15 20]	0,22369	0,68520	0,34126	**0,50538**
[20 15]	0,21075	5,61841	0,33317	0,70210
[20 20]	4,82715	6,85099	1,82258	2,11787
[20 25]	4,84711	6,63125	1,82852	2,09202
[25 20]	4,82575	6,40473	1,82514	2,06331
[25 25]	4,82019	6,90237	1,82322	2,11902
[30 20]	4,82272	6,90854	1,82443	2,12257
[10 15 20]	0,47310	1,62191	0,49147	0,74880
[10 20 25]	0,13995	1,02712	0,26934	0,57214
[15 20 25]	0,14640	7,59202	0,28233	1,41663
[20 15 10]	4,79511	6,51240	1,81938	2,07521
[25 20 10]	4,79439	6,51340	1,81822	2,07113
[25 20 15]	4,79992	6,03795	1,82110	2,00810
[10 15 20 25]	0,27885	0,93822	0,38679	0,61238
[20 15 10 5]	0,14951	1,82387	0,28289	0,76055
[20 15 15 10]	4,79673	6,47413	1,81970	2,07913
[25 20 20 15]	0,07511	13,34225	0,20183	1,91920

Tablo 4.15. 100 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden 90-30 eğitim-doğrulama datası ile ÇKA modellemesi için performans sonuçları.

Algoritma Mimarisi	Eğitim Hata (MSE)	Doğrulama Hata (MSE)	Eğitim Hata (MAE)	Doğrulama Hata (MAE)
[10 15]	4,84640	5,02906	1,82864	1,86339
[15 20]	4,88169	6,73800	1,83218	2,08026
[20 15]	4,83073	5,13839	1,82395	1,88191
[20 20]	4,84896	6,72070	1,82692	2,09151
[20 25]	4,85292	6,91876	1,82640	2,11496
[25 20]	4,83446	6,69988	1,82303	2,09331
[25 25]	4,85185	7,60459	1,82646	2,17950
[30 20]	4,84611	7,03421	1,82541	2,13524
[10 15 20]	0,19557	0,54852	0,32152	**0,50987**
[10 20 25]	4,84659	5,27929	1,82790	1,90024
[15 20 25]	4,83089	7,21464	1,82311	2,13828
[20 15 10]	4,83399	5,72933	1,82518	1,95548
[25 20 10]	0,13057	3,34097	0,26326	0,99126
[25 20 15]	0,16463	1,47911	0,29739	0,82020
[10 15 20 25]	0,12993	1,62881	0,26614	0,66770
[20 15 10 5]	0,16229	3,23049	0,29818	0,91546
[20 15 15 10]	4,81390	7,33768	1,81954	2,20192
[25 20 20 15]	0,08691	5,96345	0,21426	1,43091

Tablo 4.16. 100 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden 100-20 eğitim-doğrulama datası ile ÇKA modellemesi için performans sonuçları.

Algoritma Mimarisi	Eğitim Hata (MSE)	Doğrulama Hata (MSE)	Eğitim Hata (MAE)	Doğrulama Hata (MAE)
[10 15]	4,85807	5,11019	1,83183	1,89212
[15 20]	0,32764	0,71336	0,40939	0,49534
[20 15]	4,83750	4,98697	1,82603	1,86292
[20 20]	0,29090	1,17484	0,38546	0,73704
[20 25]	4,85950	7,65936	1,82873	2,21239
[25 20]	4,86389	6,65855	1,83063	2,08955
[25 25]	4,85646	6,65311	1,82797	2,09614
[30 20]	4,84925	8,25005	1,82588	2,24488
[10 15 20]	4,85410	5,16145	1,83074	1,88159
[10 20 25]	4,84247	5,38954	1,82884	1,92958
[15 20 25]	0,38332	0,41084	0,45142	0,47708
[20 15 10]	4,82970	5,73879	1,82448	1,96307
[25 20 10]	4,84071	5,18597	1,82707	1,89764
[25 20 15]	4,82229	5,86893	1,82441	1,97696
[10 15 20 25]	0,36091	14,20957	0,43989	2,84777
[20 15 10 5]	0,16626	6,85070	0,30197	1,35468
[20 15 15 10]	0,12638	0,35663	0,25660	**0,42705**
[25 20 20 15]	4,82761	6,09895	1,82554	2,00046



Şekil 4.4. 100 MHz frekans adım aralığı kullanılarak oluşturulan 120 örnek veriden Bayesian regularization back propagation (trainbr) algoritmalı ÇKA modellemesi sonucu oluşan S_{11} (dB) simülasyonu (a) 70-50 eğitim-doğrulma verisi (b) 80-40 eğitim-doğrulma verisi (c) 90-30 eğitim-doğrulma verisi (d) 100-20 eğitim-doğrulma verisi.

5. TARTIŞMA

Bu tez kapsamında, Ku-band (12–18 GHz) frekans aralığında çalışan ofset boşluklu bir Vivaldi antenin geri dönüş kaybı (S_{11}) parametresinin frekans ile değişimi, ÇKA yapısına sahip bir YSA modeli ile modellenmiştir. Modelleme süreci boyunca LHÖ yöntemiyle oluşturulmuş veri seti kullanılarak, anten parametreleri ile çıkış performansı arasındaki doğrusal olmayan ilişkilerin öğrenilmesi sağlanmıştır. Elde edilen sonuçlar, hem hedef (simülasyon) hem de tahmin (ÇKA) verileri arasında oldukça yüksek uyum göstererek modelin başarımını ortaya koymuştur. Bu bölümde, elde edilen bulgular detaylı olarak ele alınmakta, benzer çalışmalarla karşılaştırılmakta ve önerilen modelleme yaklaşımının literatürdeki konumu tartışılmaktadır.

Wang ve diğ. [22], bir YSA modeli kullanarak çok amaçlı anten optimizasyonu gerçekleştirmiş ve %5 altı hata oranlarıyla yüksek doğrulukta S_{11} tahminleri yapabilmiştir. Bu tez çalışmasında ise ortalama karesel hata (MSE) ve ortalama mutlak hata (MAE) değerleri oldukça düşük çıkmış; bazı frekans noktalarında hedef ve tahmin değerlerinin neredeyse birebir örtüştüğü gözlenmiştir. Bu bağlamda, önerilen model Wang ve diğ. çalışmasındaki hata oranları ile benzer doğrulukta sonuçlar vermiştir. Palandöken ve diğ. [27], modifiye edilmiş ÇKA (Ç2KA) yapısını kullanarak çoklu parametrelerin etkisini analiz etmiş ve %4 seviyesinde genel hata oranı raporlamıştır. Bu tezde kullanılan klasik ÇKA yapısının, modifikasyon yapılmamış olmasına rağmen benzer doğrulukta sonuçlar verebilmesi, örnekleme yönteminin başarısı (LHS) ve modelin yeterli eğitilmesi ile ilişkilendirilebilir. Dong ve diğ. [28] ve Pietrenko-Dabrowska & Koziel [23], LHS ile oluşturulmuş veri kümelerinin, özellikle anten tasarımında geniş parametre uzayını temsil etmekte daha etkili olduğunu vurgulamıştır. Bu tez çalışmasında da LHS yönteminin kullanımı, farklı parametre kombinasyonlarının dengeli biçimde örneklenmesini sağlamış ve bu sayede ÇKA modelinin genelleme yeteneği artmıştır.

Literatürde yer alan çalışmaların çoğunda ya konvansiyonel düzlemsel Vivaldi antenler ya da simetrik antipodal yapılara odaklanılmışken, bu tezde özel olarak ofset boşluklu bir yapı ele alınmıştır. Bu yapı, hem mekanik kararlılık hem de anten kazancı açısından avantajlar sunmakla birlikte, savunma ve havacılıkta radar uygulamaları için kritik bir alanı temsil eder. Modelleme açısından daha karmaşık bir geometriye sahiptir. Literatürde bu tür ofset yapılar için doğrudan veri odaklı modelleme uygulamaları oldukça sınırlıdır. Tianang ve diğ. [20] ve Pashaki ve diğ. [19], “cavity-backed” yapıların geniş bantlılık ve yönlülük gibi özelliklerini vurgulamış olsa da bu yapıların YSA temelli kestirimi üzerine derinlemesine çalışmalar henüz

yaygınlaşmamıştır. Bu yönüyle tez, literatürdeki boşluğu doldurmakta ve bu tür geometriler için MLP temelli kestirimlerin uygulanabilirliğini göstermektedir. Jaiswal & Bhattacharya [38], yarıklı antipodal Vivaldi anten üzerinde makine öğrenmesi ile kazanç ve S_{11} optimizasyonu gerçekleştirmiştir. Bu çalışmada farklı MLP konfigürasyonlarının başarımı test edilmiş ve en iyi parametre kümesi seçilmiştir. Bu yaklaşımla benzer şekilde bu tezde de anten geometrisine ait parametrelerin (slot genişliği, konik eğri parametresi, boşluk genişliği vb.) S_{11} üzerindeki etkisi başarıyla öğrenilmiştir.

Bu tez çalışmasında hedeflenen 10–20 GHz frekans aralığı, yalnızca Ku-bandı kapsamakla kalmamakta, daha geniş bir spektruma yayılarak modelleme sürecini zorlaştırmaktadır. Bu geniş frekans aralığında yüksek doğruluklu modelleme gerçekleştirmek, çoğu zaman çok sayıda eğitim verisi gerektirmekte ve modelin aşırı öğrenme (overfitting) riski artmaktadır. Ancak bu çalışmada, hem örnekleme yapısının uygunluğu hem de modelin mimarisi sayesinde bu problem büyük ölçüde önlenmiştir. Yine de, literatürde KSA tabanlı modellerin de [30] özellikle piksel bazlı tersine tasarımda daha yüksek genelleme performansı gösterdiği bilinmektedir. Bu açıdan bakıldığında, gelecekteki çalışmalarda klasik ÇKA modelleri yerine hibrit ya da KSA tabanlı modellere geçilmesi, modelleme doğruluğunu artırabilir. Karahan ve diğ. [41] tarafından yayımlanan çalışmada, çoklu çıkışlı ters tasarım problemleri için bir KSA temelli üretici model kullanılmıştır. Bu model, hedeflenen saçılım parametrelerine göre anten geometrisini sentezleyebilmiş; bu durum tasarım sürecinde yapay zekâ tabanlı bir paradigma değişikliğini temsil etmiştir. Bu tezde tersine tasarım gerçekleştirilmemekle birlikte, kurulan modelin doğrudan tersine çevrilmesi durumunda, belirli bir S_{11} karakteristiği için uygun giriş parametrelerinin belirlenmesi mümkün olabilecektir. Bu da modeli, ileriye dönük bir tersine tasarım aracına dönüştürebilir. Ayrıca Koziel ve diğ. [24], üretim toleransları ve belirsizlik altında sağlam (robust) anten tasarımı gerçekleştirmiştir. Bu tezde yer alan modelleme yaklaşımı da benzer biçimde, üretim varyasyonlarını değerlendirme potansiyeline sahiptir. Eğitim sonrası model yardımıyla farklı parametrelerde varyasyonlar simüle edilebilir ve performans analizleri hızlıca gerçekleştirilebilir.

Çalışmanın sınırlılıkları arasında, kullanılan örnekleme boyutunun literatürdeki bazı çalışmalara göre daha düşük olması ve sadece belirli bir anten yapısının incelenmiş olması bulunmaktadır. Gelecekteki çalışmalarda, farklı anten tipleri ve daha geniş örnekleme boyutları ile benzer modelleme yaklaşımları değerlendirilebilir. Ayrıca, farklı YZ algoritmalarının karşılaştırmalı analizleri yapılabilir. Kullanılan model mimari tasarımı kişisel tecrübe veya

deneme yanılma yöntemi ile yapılmıştır. İleriki çalışmalarda bu kısımlar için optimizasyon yöntemlerine başvurulabilir. Çalışma ileriki aşamalarda S_{11} (dB) parametresinin yanına diğer parametreler konularak birden fazla parametrenin modellenmesi olarak da yapılabilir. Farklı alan çalışmalarda bu kaynak atıf gösterilerek adım aralığı seçim kısmı atlanarak çalışmalar daha hızlı bir şekilde götürülebilir.

Sonuç olarak bu tez, literatürdeki benzer çalışmalara kıyasla hem modelleme başarımı hem de hedeflenen anten yapısının özgünlüğü bakımından önemli katkılar sunmaktadır. Ofset boşluklu bir Vivaldi antenin geniş bantlı frekans aralığında, çok sayıda parametreye bağlı olarak S_{11} eğrisinin başarıyla kestirilebilmesi, bu yöntemin sadece araştırma düzeyinde değil, uygulamalı tasarım süreçlerinde de kullanılabileceğini göstermektedir. Bu bağlamda, tez bulguları, literatürdeki gelişmelerle tutarlı olup bazı yönleriyle mevcut yaklaşımların da ötesine geçmiştir.

6. SONUÇ VE ÖNERİLER

Bu çalışmada, Ku bandında çalışan ofset boşluklu Vivaldi antenin 10 GHz ile 20 GHz frekans aralığında geliştirilmiş ÇKA ile modelleme performansı detaylı bir şekilde incelenmiştir. Giriş verileri, LHÖ yöntemi kullanılarak belirlenmiş ve bu sayede örnekleme çeşitliliği artırılmıştır. Çıkış parametresi olarak, 3D elektromanyetik simülasyonlar yardımıyla elde edilen S_{11} (dB) değerleri kullanılmıştır.

Modelleme sürecinde, Bayesian Regularization Back-propagation (trainbr), Levenberg-Marquardt Back-propagation (trainlm), Resilient Back-propagation (trainrp) ve Scaled Conjugate Gradient Back-propagation (trainscg) algoritmaları değerlendirilmiş; ancak en başarılı sonuçlar trainbr algoritması ile elde edilmiştir. Ağ mimarileri, 2, 3 ve 4 ara katmanlı yapılarla ve farklı nöron sayılarıyla test edilmiştir. Genel olarak, daha sade mimarilerin (örneğin, 2 ara katmanlı ve 15-20 nöronlu yapılar) daha yüksek modelleme performansı sağladığı gözlemlenmiştir.

Farklı frekans adım aralıkları (40 MHz, 50 MHz, 80 MHz ve 100 MHz) için yapılan analizlerde, eğitim ve doğrulama veri setlerinin oranlarının modelleme başarısını etkilediği tespit edilmiştir. Özellikle, 100-20 eğitim-doğrulama veri seti oranı ile en yüksek doğruluk elde edilmiştir. Bu durum, eğitim verisinin artırılmasının modelin genelleme yeteneğini olumlu yönde etkilediğini göstermektedir.

Sonuç olarak, bu çalışma, Ku bandı antenlerin modellemesinde geliştirilen ÇKA yapısının etkinliğini ortaya koymuş ve literatüre katkı sağlamıştır. Elde edilen bulgular, benzer mühendislik problemlerinde YZ tabanlı modelleme yaklaşımlarının uygulanabilirliğini göstermektedir. Gelecek çalışmalarda, tersine tasarım, tolerans analizi ve hiperparametre optimizasyonu gibi ileri düzey yöntemlerin dahil edilmesi planlanmaktadır.

KAYNAKLAR

[1]. Cheraghinia, M., Shahid, A., Luchie, S., Gordebeke, G.J., Caytan, O., Fontaine, J., Van Herbruggen, B., Lemey, S. and De Poorter, E., 2024, A comprehensive overview on uwb radar: Applications, standards, signal processing techniques, datasets, radio chips, trends and future research directions, *IEEE Communications Surveys and Tutorials*.

[2]. Rittiplang A. ve Phasukkit P., 2020, 1-Tx/5-Rx through-wall UWB switched-antenna-array radar for detecting stationary humans, *Sensors*, 20(23), 6828.

[3]. Kerarti, D. Z., Marouf, F. ve Meriah, S., 2012, New tapered slot vivaldi antenna for UWB applications, *24th International Conference on Microelectronics (ICM)*, 16-20 Aralık 2012, Algiers, Cezayir, IEEE, 1-4.

[4]. Razib, M. H. R., Das, D., Murshed, A. H., Hossain, M. A., Paul, L. C. ve Hossain, M. A., 2024, A high gain microwave and millimeter-wave-based balanced antipodal Vivaldi antenna with a parasitic patch and a half-spherical shaped dielectric lens, *Heliyon*, (10)21.

[5]. Amador, M., Rouco, A., Albuquerque, D. ve Pinho, P., 2024, Overview of Vivaldi Antenna Selection for Through-Wall Radar Applications, *Sensors*, (24)20, 6536.

[6]. Zhang, M., Zhang, J., Wang, L. ve Song, L., 2020, A dual-polarized cavity-backed Vivaldi antenna with simple feeding structure for telemetry system application, *Electromagnetics*, (40)4, 286-302.

[7]. Abushakra, F., Jeong, N., Awasthi, A.K., Kolpuke, S., Simpson, C., Reyhanigalangashi, O., Elluru, D.N., Bhandari, A., Taylor, D. and Gogineni, S.P., 2022, Ultra-wideband coplanar Vivaldi antenna array with dielectric patch antenna for grating lobes suppression, *IEEE Access*, 10, 54410-54420.

[8]. *Vivaldi Antenna for UWB Applications*, https://www.nxp.com/design/design-center/development-boards-and-designs/LID2509, [Ziyaret tarihi: 4 Nisan 2025].

[9]. Abdulhameed, A. A., Alnahwi, F. M. ve Kubík, Z., 2024, Design and Modelling of a Modified High Gain Printed Vivaldi Antenna for EMC Measurements, *Wireless Personal Communications.*, 138(1), 525-545.

[10]. Muchhal, N., Vintimilla, R. Z., Fares, Y. ve Elkhouly, M., 2023, Review on Recent Trends and Applications of Vivaldi Antenna in the Range of 1 GHz–40 GHz, *The Fifteenth International Conference on Advances in Satellite and Space Communications*, 24-28 Nisan 2023, Venedik, İtalya, 15-21.

[11]. Sagar, M.S.I., Ouassal, H., Omi, A.I., Wisniewska, A., Jalajamony, H.M., Fernandez, R.E. and Sekhar, P.K., 2021, Application of machine learning in electromagnetics: Mini-review, *Electronics*, 10(22), 2752.

[12]. Kumar, J. V. ve Shaby, S. M., 2022, Design of H-shaped MPA using reptile search algorithm based multilayer perceptron neural network, 04 Ağustos 2022, *Preprint (Version 1).*

[13]. Chakraborty, M., Pal, W., Bandyopadhyay, S. ve Maulik, U., 2023, A Survey on Multi-Objective based Parameter Optimization for Deep Learning, *ArXiv Prepr. ArXiv230510014*.

[14]. Gibson, P. J., 1979, The vivaldi aerial, *9th European Microwave Conference*, IEEE, 17-20 Eylül 1979, Brighton, Britanya, 101-105.

[15]. Bhattacharjee, A., Bhawal, A., Karmakar, A., Saha, A., ve Bhattacharya, D., 2021, Vivaldi antennas: a historical review and current state of art, *International Journal of Microwave Wireless Technologies*, 13(8), 833-850.

[16]. Dai, X. W., Da Li, M., Wu, H. T. ve Zhang, Y. H., 2022, Design of Compact Patch Antenna Based on Support Vector Regression, *Radioengineering*, 31(3).

[17]. Ullah, R., Ullah, S., Faisal, F., Ullah, R., Choi, D.Y., Ahmad, A. and Kamal, B., 2021, High-gain vivaldi antenna with wide bandwidth characteristics for 5G mobile and Ku-Band radar applications, *Electronics*, 10(6), 667.

[18]. Prouza, J. ve Raida, Z., 2020, Practical design of Ku band Vivaldi antenna array, *Journal of Electrical Engineering*, 71(5), 347-352.

[19]. Pashaki, M. M., Ghamsari, M. H. K., Mallahzadeh, A., Gradoni, G., ve Khalily, M., 2025, A Corrugated All-Metal Vivaldi Antenna for 5G Phased Array Applications, *ArXiv Preprint,* ArXiv250203002.

[20]. Tianang, E. G., Elmansouri, M. A., ve Filipovic, D. S., 2017, Ultra-wideband lossless cavity-backed Vivaldi antenna, *IEEE Transactions on Antennas and Propagation*, 66(1), 115-124.

[21]. Latha, T., Ram, G., Kumar, G. A., ve Chakravarthy, M., 2021, Review on ultra-wideband phased array antennas, *IEEE Access*, 9, 129742-129755.

[22]. Shan, J., Xu, A., ve Lin, J., 2017, A parametric study of microstrip-fed Vivaldi antenna, *3rd IEEE International Conference on Computer and Communications (ICCC*), 13-16 Aralık 2017, Chengdu, Çin, IEEE, 1099-1103.

[23]. Pietrenko-Dabrowska, A. ve Koziel, S., 2020, Reliable surrogate modeling of antenna input characteristics by means of domain confinement and principal components, *Electronics,* 9(5), 877.

[24]. Koziel, S., Pietrenko-Dabrowska, A., Szczepanski, S., ve Leiffson, L., 2025, Rapid global antenna design by simplex regressors and multi-resolution simulations, *Scientific Reports*, 15(1), 11631.

[25]. Sarker, N., Podder, P., Mondal, M. R. H., Shafin, S. S. ve Kamruzzaman, J., 2023, Applications of machine learning and deep learning in antenna design, optimization, and selection: a review, *IEEE Access*, 11, 103890-103915.

[26]. Wang, Z., Qin, J., Hu, Z., He, J., ve Tang, D., 2022, Multi-objective antenna design based on BP neural network surrogate model optimized by improved sparrow search algorithm, *Applied Science*, 12(24), 12543.

[27]. Palandöken, M., Belen, A., Tari, O., Mahouti, P., Mahouti, T. ve Belen, M. A., 2024, Computationally Efficient Design Optimization of Multiband Antenna Using Deep Learning–Based Surrogate Models, *International Jornal of RF Microwave Compututer-Aided Engineering*, 2024(1), 5442768.

[28]. Dong, J., Qin, W., ve Mo, J., 2019, Low-cost multi-objective optimization of multiparameter antenna structures based on the L1 optimization BPNN surrogate model, *Electronics*, 8(8), 839.

[29]. Uluslu, A., 2022, Farkli Örnekleme Yöntemlerinin Yapay Sinir Ağlarinda Performansının Karşılaştırılması, *Mühendis. Bilimleri Ve Tasarım. Dergisi*, 10(2), 412-428.

[30]. Karahan, E. A., Gupta, A., Khankhoje, U. K., ve Sengupta, K., 2022, Deep learning based modeling and inverse design for arbitrary planar antenna structures at RF and millimeter-wave, *IEEE International Symposium on Antennas and Propagation and USNC-URSI Radio Science Meeting (AP-S/URSI)*, 10-25 Temmuz 2022, Denver, ABD, IEEE, 499-500.

[31]. Su, Y., Su, Z., Chen, H., Zhao, H. ve Yin, X., 2022, Inverse Design of Rectangular Microstrip Patch Antenna using Neural Network Combining with Time-Domain Representation of S-parameters, *16th European Conference on Antennas and Propagation (EuCAP)*, 27 Mart-1 Nisan 2022, Madrid, İspanya, IEEE, 1-4.

[32]. Liu, B., Akinsolu, M.O., Song, C., Hua, Q., Excell, P., Xu, Q., Huang, Y. and Imran, M.A., 2021, An efficient method for complex antenna design based on a self adaptive surrogate model-assisted optimization technique, *IEEE Transactions of Antennas Propagation*, 69(4), 2302-2315.

[33]. Angiulli, G., Cacciola, M. ve Versaci, M., 2007, Microwave devices and antennas modelling by support vector regression machines, *IEEE Transactions on Magnetics*, 43(4), 1589-1592.

[34]. Shields, M. D. ve Zhang, J., 2016, The generalization of Latin hypercube sampling, *Reliability Engineering and System Safety*, 148, 96-108.

[35]. Wang, J.-Y., Li, Y., Xue, B.-W., ve Pan, X.-M., 2022, Physics-informed deep learning to solve electromagnetic scattering problems, *IEEE Conference on Antenna Measurements and Applications (CAMA)*, 14-17 Aralık 2022, Guangzhou, Çin, IEEE, 1-3.

[36]. Chen, Y. ve Dal Negro, L., 2022, Physics-informed neural networks for imaging and parameter retrieval of photonic nanostructures from near-field data, *APL Photonics*, 7, 1.

[37]. Liu, Y.-H., Liu, J.-P., Wang, B.-Z. ve Wang, R., 2024, A PINN framework for inverse physical design of metal-loaded electromagnetic devices, *AIP Advances*, 14, 12.

[38]. Jaiswal, P. K. ve Bhattacharya, R., 2023, Impact analysis and optimization of notched high-gain Antipodal Vivaldi antenna using machine learning, *AEU- International Journal of Electronics and Communications*, 171, 154870.

[39]. Hossain, A. ve Pham, A.-V., 2023, A novel gain-enhanced miniaturized and lightweight Vivaldi antenna, *IEEE Transactions on Antennas and Propagation*, 71(12), 9431-9439.

[40]. Saleh, S., Saeidi, T., Timmons, N., Alali, B., Razzaz, F. ve Althuwayb, A. A., 2025, High-Performance UWB Vivaldi Antenna on FR4: A Cost-Effective Solution for Wearable Technologies, *Results in Engineering*, 25, 104230.

[41]. Karahan, E.A., Liu, Z., Gupta, A., Shao, Z., Zhou, J., Khankhoje, U. and Sengupta, K., 2024, Deep-learning enabled generalized inverse design of multi-port radio-frequency and sub-terahertz passives and integrated circuits, *Nature Communications*, 15(1), 10734.

[42]. Pietrenko-Dabrowska, A. ve Koziel, S., 2022, Optimization-based robustness enhancement of compact microwave component designs with response feature regression surrogates, *Knowledge-Based Systems*, 240, 108161.

[43]. Mathworks, 2021, *VivaldiOffsetCavity - Create Vivaldi antenna with rectangular cavity, Slot Antennas*, https://www.mathworks.com/help/antenna/ref/vivaldioffsetcavity.html, [Ziyaret tarihi: 1 Mayıs 2025].

[44]. Akdagli, A., Toktas, A., Kayabasi, A. ve Develi, I., 2013, An application of artificial neural network to compute the resonant frequency of E-shaped compact microstrip antennas, *Journal of Electrical Engineering*, 64(5), 317.