T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

MİKRODALGA DEVRELERİNDE İYİLEŞTİRME TEMELLİ TOPLULUK ÖĞRENMESİ YAKLAŞIMI

Hakan KALAYCI

DOKTORA TEZİ
Elektronik ve Haberleşme Mühendisliği Anabilim Dalı
Haberleşme Programı

Danışman
Doç. Dr. Umut Engin AYTEN

Eş-Danışman
Doç. Dr. Peyman MAHOUTI

Şubat, 2022

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

MİKRODALGA DEVRELERİNDE İYİLEŞTİRME TEMELLİ TOPLULUK ÖĞRENMESİ YAKLAŞIMI

Hakan KALAYCI tarafından hazırlanan tez çalışması 10.02.2022 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektronik ve Haberleşme Mühendisliği Anabilim Dalı Haberleşme Programı **DOKTORA TEZİ** olarak kabul edilmiştir.

Doç. Dr. Umut Engin AYTEN
Yıldız Teknik Universitesi
Danışman

Doç. Dr. Peyman MAHOUTI
İstanbul Cerrahpaşa Üniversitesi
Eş-Danışman

Jüri Üyeleri

Doç. Dr. Umut Engin AYTEN, Danışman
Yıldız Teknik Universitesi _____

Doç. Dr. Nihan Kahraman, Üye
Yıldız Teknik Universitesi _____

Doç. Dr. Hamid Torpi, Üye
Yıldız Teknik Universitesi _____

Prof. Dr. Sedef KENT, Üye
Istanbul Teknik Universitesi _____

Doç. Dr. Mehmet Ali Belen, Üye
İskenderun Teknik Üniversitesi _____

Danışmanım Doç. Dr. Umut Engin AYTEN sorumluluğunda tarafımca hazırlanan Mikrodalga Devrelerinde İyileştirme Temelli Topluluk Öğrenmesi Yaklaşımı başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Hakan KALAYCI

İmza

.....

Sevgili Eşim
ve Aileme

TEŞEKKÜR

Çalışmalarımda bana yol gösteren, destek ve emeklerini esirgemeyen, beni bu zorlu süreçte yüreklendiren, öğrencisi olmaktan mutluluk duyduğum tez danışmanım Sayın Doç.Dr. Umut Engin AYTEN'e sonsuz teşekkür ederim.

Araştırmalar sırasında her türlü desteği esirgemeyen ve dikkat edilmesi gereken noktalar ve araştırmalarda oluşan fikirlerim konusunda, günün hangi saati olursa olsun, bıkmadan ve usanmadan yardımıma koşan eş danışmanım Sayın Doç.Dr. Peyman MAHOUTİ'ye, doktora süresi boyunca her türlü desteğiyle sürekli yanımda olan Sayın Prof.Dr. Filiz GÜNEŞ'e buradan teşekkür ederim. Ayrıca zorlu doktora süreçinde, yanımda olduğunu her fırsatta dile getiren ve desteğini hissettiren, en zor zamanlarda bile devam etmem için cesaretlendiren, fedakarlığını ödeyemeyeceğim sevgili eşim Gökçe KALAYCI'ya, hayatım boyunca beni her konuda destekleyen ve haklarını ödeyemeyeceğim annem Hülya KALAYCI'ya, babam Hayati KALAYCI'ya ve kardeşim Hande Nur KALAYCI'ya teşekkürü bir borç bilirim.

Hakan KALAYCI

İÇİNDEKİLER

SİMGE LİSTESİ viii

KISALTMA LİSTESİ x

ŞEKİL LİSTESİ xiii

TABLO LİSTESİ xv

ÖZET xvii

ABSTRACT xix

1 GİRİŞ 1

1.1 Literatür Özeti 1

1.2 Tezin Amacı 8

1.3 Hipotez 9

2 İYİLEŞTİRME TABANLI TOPLULUK ÖĞRENMESİ 10

2.1 İyileştirme Mantığı ve Regresif İyileştirme 10

2.1.1 Adaptif İyileştirme (AdaBoost) 11

2.1.2 Gradyan İyileştirme Makinesi(GBM) 13

2.1.3 Aşırı Gradyan İyileştirme Makinesi (XGBoost ya da XGBM) . . . 15

2.1.4 Hafif Gradyan İyileştirme Makinesi (LGBM) 20

2.2 İleri Topluluk Öğrenmesi Teknikleri 22

2.2.1 Harmanlama (Blending) 22

2.2.2 İyileştirme Tabanlı Otomatik-Harmanlama (Boosting Based Auto-Blending) 23

2.2.3 Uygulamalarda Kullanılan Parametreler 24

3 TOPLULUK ÖĞRENMESİ YÖNTEMİNİN LİTERATÜRDEKİ PROBLEMLERE UYGULANMASI 25

3.1 Doğrulama Çalışması 1: Uniform Olmayan Bir Yansıtıcı Dizi Öğesinin Yansıma Fazı Özelliklerinin Modellenmesi Üzerine Yapay Zeka Algoritmalarının Uygulanması 25

3.2 Doğrulama Çalışması 2: Kapasitif Besleme Anteninin Hassas Saçılma Parametre Tahmini İçin Derin Öğrenme Tabanlı Modifiye MLP Modeli 29

4 TOPLULUK ÖĞRENMESİ KULLANARAK MİKRODALGA ELEMANLARININ MODELLENMESİ 34

4.1 Yarım Küresel Dielektrik Antenin Modellenmesi 34

4.2 Toplululuk Öğrenmesi Kullanarak Frekans Seçici Yüzey Modelleme 37

4.2.1 Doğrulama Vaka Çalışmaları ve Kıyaslama 38

5 İYİLEŞTİRME TABANLI OTOMATİK-HARMANLAMA TEKNİĞİ KULLANARAK MİKRODALGA TRANZİSTÖRÜ MODELLENMESİ 41

5.1 İTOH Tekniğinin Literatürdeki Problemler İle Doğrulanması 41

5.2 İTOH Tabanlı Mikrodalga Tranzistör Modellenmesi 44

6 SONUÇ VE ÖNERİLER 54

KAYNAKÇA 56

A GBM REGRESYON AĞAÇ ALGORİTMASI 65

B XGBM REGRESYON AĞAÇ ALGORİTMASI 66

C BÖLÜNME İÇİN TAM AÇGÖZLÜ ALGORİTMA (EXACT GREEDY ALGORITM FOR SPLIT FINDING 67

D BÖLÜNMÜŞ BULMA İÇİN YAKLAŞIK ALGORİTMA (APPROXIMATE ALGORITM FOR SPLIT FINDING 68

E SEYREKLİĞE DUYARLI BÖLÜNMÜŞ BULMA (SPARSITY-AWARE SPLIT FINDING) 69

F HİSTOGRAM ALGORİTMASI 70

G GRADYAN TABANLI TEK TARAFLI ÖRNEKLEME (GOSS) 71

H AÇGÖZLÜ (GREEDY) PAKETLEME 72

I ÖZEL ÖZELLİKLERİ (EXCLUSIVE FEATURES) BİRLEŞTİRME 73

TEZDEN ÜRETİLMİŞ YAYINLAR 74

SİMGE LİSTESİ

Δx	(x-a) Artık (Residual)
$r_m.\beta_m$	AdaBoost Öğrenme Kontrol Parametresi
$G_m(x)$	Ağaç Eğitim Fonksiyonu
w	Ağırlık
r_i	Artık (Residual)
T	Ayrım Sayısı
$\widetilde{L}^{(t)}$	Basitleştirilmiş Amaç Fonksiyonu
F_{m-1}	Bir Önceki Tahmin Değer İçin Kayıp Fonksiyonu
D	Data Örnekleri
ϵ_r	Dielektrik Geçirgenlik
$\Omega\ (f_t)$	Düzenlileştirme terimi
fr	Frekans
i	Gözlem numarası
yi	Gözlemlenen Değer
$R_{j,m}$	Kare Kaybı
$Loss(y_,F(x))$	Kayıp Fonksiyonu
g_i	Kayıp Fonksiyonu 1. Türevi
G	Kayıp Fonksiyonu 1. Türevleri Toplamı
h_i	Kayıp Fonksiyonu 2. Türevi
H	Kayıp Fonksiyonu 2. Türevleri Toplam
m	Kurulan Ağacın numarası
γ	L1 düzenlileştirmesi kontrol parametresi
λ	L2 düzenlileştirmesi kontrol parametresi

α	Öğrenme Oranı
(α)	Öğrenme Oranı
$\|\|w\|\|^2$	Öklidsel yaklaşım
G_R	Sağ Yaprak Kayıp Fonksiyonu 1. Türevleri Toplamı
H_R	Sağ Yaprak Kayıp Fonksiyonu 2. Türevleri Toplamı
r_k	Sıralama Fonksiyonu
$sign(f(x))$	Signum Fonksiyonu
G_L	Sol Yaprak Kayıp Fonksiyonu 1. Türevleri Toplamı
H_L	Sol Yaprak Kayıp Fonksiyonu 2. Türevleri Toplamı
h	Substrate Yüksekliği
$F(X)$	Tahminlenen Değer
$b(x; r_m)$	Temel Öğrenici
$\sum$	Toplam
$P(y = 1\|x)$	X'in 1 olma olasılığı
$P(y = -1\|x)$	X'in -1 olma olasılığı
ϵ	Yaklaşım faktörü
T	yaprak sayısı
η	Yenileme Sayısı

KISALTMA LİSTESİ

AdaBoost	Adaptif İyileştirme
AGİ	Aşırı Gradyan İyileştirme
I	Akım
AC / DC	Alternatif Akım / Doğru Akım
A	Amper
XGBoost	Aşırı Gradyan İyileştirme Makinesi
XGBM	Aşırı Gradyan İyileştirme Makinesi
PLA	Biopolimer Polilaktik Asit
FPS	Bir Saniyedeki Çerceve Sayısı
R	Çap
MLP	Çok Katmanlı Algılayıcı
DDOS	Dağıtılmış Hizmet Kesintisi
DMTK	Dağıtılmış Makine Öğrenimi Araç Seti
M2LP	Değiştirilmiş Çok Katmanlı Algılayıcı
DRN	Derin Regresyon Ağı
DFS	Derinlik öncelikli arama
dB	Desibel
SVRM	Destek Vektor Regresyon Makinesi
DH	Dieletrik Yükseklik
DC	Doğru Akım
EIT	Elektrik Empedans Tomografisi
EM	Elektromanyetik
FSS	Frekans Seçici Yüzey

GPR	Gauss süreç regresyonu
GP	Genetik Programlama
BFS	Genişlik öncelikli Arama
GHz	GigaHertz
GBM	Gradyan İyileştirme Makinesi
GOSS	Gradyan Tabanlı Tek Taraflı Örnekleme
HGİ	Hafif Gradyan İyileştirme
LightGBM	Hafif Gradyan İyileştirme Makinesi
LGBM	Hafif Gradyan İyileştirme Makinesi
İTOH	İyileştirme Tabanlı Otomatik-Harmanlama
KNN	K-En yakın Komşu
LHS	Latin-Hiperküp Örnekleme
LGS	Logaritmik Örnekleme
LASSO	Least Absolute Shrinkage and Selection Operator
ML	Makine Öğrenmesi
MRI	Manyetik rezonans (MR) görüntüleme
CPU	Merkezi İşlem Birimi
mA	miliAmper
mm	Milimetre
MSE	Ortalama Kare Hatası
MAE	Ortalama Mutlak Hata
EFB	Özel Özellik Paketleme
RBF	Radial Bazlı Fonksiyonlar
RF	Radyo Frekansı
RFID	Radyo Frekansı ile Tanımlama
RAM	Rasgele erişim belleği
RS	Rasgele Örnekleme
SR	Sembolik Regresyon
SMAPE	Simetrik Ortalama Mutlak Yüzde Hatası

3B	Üç Boyutlu
V	Volt
YSA	Yapay Sinir Ağları
YZ	Yapay Zeka

ŞEKİL LİSTESİ

Şekil 2.1 İyileştirme Yönteminin Genel Şeması 10
Şekil 2.2 İyileştirme Yönteminin Çalışma Prensibi 11
Şekil 2.3 Histogram Algoritması genel gösterimi 20
Şekil 2.4 Harmanlama Yöntemi 23
Şekil 3.1 Bir non-uniform yansıtıcı dizi elemanının şeması 26
Şekil 3.2 (1.sıra-sol) $\epsilon_r = 1$, H=0.5mm, (1.sıra-sağ) $\epsilon_r = 3.5$, H=10mm, (2.sıra-sağ) $\epsilon_r = 5$,H=15mm, (2.sıra-sağ) H=5mm, *fr*= 10GHz, (3.sıra-sol) H=10mm, *fr*= 10GHz, (3.sıra-sağ) H=15mm, at 10GHz, (4.sıra-sol) ϵ_r=3.5, *fr*= 8GHz, (4.sıra-sağ) ϵ_r=3.5, *fr*= 10GHz, (5.sıra) $\epsilon_r = 3.5$, *fr*= 12GHz için Aşırı Gradyan İyileştirme Yöntemi algoritmasının performans sonuçları 28
Şekil 3.3 (a) Yan, (b) Üst, kapasitif besleme anteni şematik görüntüsü 30
Şekil 3.4 Aşırı Gradyan İyileştirme yöntemi performans sonucu 32
Şekil 3.5 S_{11} Simülasyonu ve Ölçümü 33
Şekil 4.1 Yarım Küresel Dielektrik Antenin Şeması 34
Şekil 4.2 Eğitim ve test veri setlerinden seçilen bir anten modeli (Dielektrik yükseklik 35, dielektrik sabiti 2,7 ve yarıçap 27 mm) için LHS200 kullanılarak eğitilen Aşırı Gradyan İyileştirme'nin performans sonucu 35
Şekil 4.3 Dielektrik anten örneğinin 3 boyutlu görünümü 36
Şekil 4.4 (sol) FSS birimi elemanının 3B görünümü, (sol orta) sınır koşulu ayarlarıyla birim öğeleri, (sağ ikisi) birim elemanın şeması 38
Şekil 4.5 Tasarım parametreleri ile 3B yazıcı (PLA malzemesi) kullanan fabrikasyon FSS üniteleri $[L1 = 2, L2 = 6, L3 = 8, \varepsilon_r = 2.5]$. 40
Şekil 4.6 FSS tasarım ölçülen ve tahmin edilen saçılma karakteristiği 40
Şekil 5.1 Senaryo 1 (Interpolasyon): 2V , 4mA için Smith diyagramı aracılığıyla S_{11} gerçek değerleri ve İTOH tahmini 46
Şekil 5.2 Senaryo 1 (Interpolasyon): 2V , 4mA için Smith diyagramı aracılığıyla S_{12} gerçek değerleri ve İTOH tahmini 46
Şekil 5.3 Senaryo 1 (Interpolasyon): 2V , 4mA için Smith diyagramı aracılığıyla S_{21} gerçek değerleri ve İTOH tahmini 47

Şekil 5.4 Senaryo 1 (Interpolasyon): 2V , 4mA için Smith diyagramı aracılığıyla S_{22} gerçek değerleri ve İTOH tahmini 47
Şekil 5.5 Senaryo 2 (Interpolasyon): 2V , 4mA için Smith diyagramı aracılığıyla S_{11} gerçek değerleri ve İTOH tahmini 48
Şekil 5.6 Senaryo 2 (Interpolasyon): 2V , 4mA için Smith diyagramı aracılığıyla S_{12} gerçek değerleri ve İTOH tahmini 48
Şekil 5.7 Senaryo 2 (Interpolasyon): 2V , 4mA için Smith diyagramı aracılığıyla S_{21} gerçek değerleri ve İTOH tahmini 49
Şekil 5.8 Senaryo 2 (Interpolasyon): 2V , 4mA için Smith diyagramı aracılığıyla S_{22} gerçek değerleri ve İTOH tahmini 49
Şekil 5.9 Senaryo 1 (Interpolasyon): 2 V , 4mA için frekans bazında gerçek değerleri ve İTOH tahmini 51
Şekil 5.10 Senaryo 2 (Extrapolasyon): 3V , 10mA için frekans bazında Ggerçek değerleri ve İTOH tahmini 53

TABLO LİSTESİ

Tablo 3.1 Değişken aralıkları 26
Tablo 3.2 Aşırı Gradyan İyileştirme ve muadili regresyon algoritmalarının karşılaştırılması 27
Tablo 3.3 Farklı senaryolar için Aşırı Gradyan İyileştirme yöntemi modellerinin performans karşılaştırması 29
Tablo 3.4 Eğitim ve test özellikleri (mm) 30
Tablo 3.5 Aşırı Gradyan İyileştirme ve M2LP karşılaştırması 31
Tablo 3.6 Bazı seçili durumlar için Aşırı Gradyan İyileştirme yöntemi uygulamaları 33
Tablo 4.1 Vaka çalışmasının veri seti 35
Tablo 4.2 Yarı küresel dielektrik anten için Aşırı Gradyan İyileştirme modelinin S_{11} performansı karşılaştırması 36
Tablo 4.3 FSS birimi elemanının değişken aralığı 37
Tablo 4.4 Modellerin en iyi hiperparametre listesi 39
Tablo 4.5 K-katlama ve test doğrulama setleri için her modelin performans sonuçları 39
Tablo 5.1 Literatürdeki üniform olmayan bir yansıtıcı dizi öğesinin yansıma fazı ile ilgili çalışma üzerine İyileştirme Tabanlı Otomatik-Harmanlama ve Aşırı Gradyan İyileştirme parametreleri ve karşılaştırılması 42
Tablo 5.2 Kapasitif besleme anteninin hassas saçılma parametre tahmini ile ilgili çalışma üzerine İyileştirme Tabanlı Otomatik-Harmanlama ve Aşırı Gradyan İyileştirme parametreleri 42
Tablo 5.3 Kapasitif besleme anteninin hassas saçılma parametre tahmini ile ilgili çalışma üzerine İyileştirme Tabanlı Otomatik-Harmanlama ve Aşırı Gradyan İyileştirme karşılaştırılması 42
Tablo 5.4 Yarım küre dielektrik anten ile ilgili çalışma modellenmesi üzerine İyileştirme Tabanlı Otomatik-Harmanlama ve Aşırı Gradyan İyileştirme parametreleri 43

Tablo 5.5 Yarım küresel dielektrik anten modellemesi için en iyi model olan Aşırı Gradyan İyileştirme ile İyileştirme Tabanlı Otomatik-Harmanlama S_{11} SMAPE cinsinden performansı karşılaştırması 43
Tablo 5.6 Frekans seçici yüzey ile ilgili çalışma modellenmesi üzerine İyileştirme Tabanlı Otomatik-Harmanlama ve Aşırı Gradyan İyileştirme parametreleri 43
Tablo 5.7 Frekans seçici yüzey ile ilgili çalışma modellenmesi üzerine İyileştirme Tabanlı Otomatik-Harmanlama ve Aşırı Gradyan İyileştirme karşılaştırılması 44
Tablo 5.8 Eğitim ve test senaryoları 45
Tablo 5.9 İTOH ve rakip algoritmalara ait senaryo 1 S_{11} saçılma parametresi performans sonuçları 45
Tablo 5.10 İTOH ve rakip algoritmalara ait senaryo 2 için S_{11} Saçılma Parametresi performans sonuçları 45
Tablo 5.11 İTOH ve rakip algoritmalara ait senaryo 1 gürültü saçılma parametresi performans sonuçları 50
Tablo 5.12 İTOH ve rakip algoritmalara ait senaryo 2 gürültü saçılma parametresi performans sonuçları 50

ÖZET

Mikrodalga Devrelerinde İyileştirme Temelli Topluluk Öğrenmesi Yaklaşımı

Hakan KALAYCI

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı
Doktora Tezi

Danışman: Doç. Dr. Umut Engin AYTEN
Eş-Danışman: Doç. Dr. Peyman MAHOUTI

Bu tez kapsamında, mikrodalga devrelerin davranışlarını, mikrodalga devrelerin çeşitli değişkenleri ile mikrodalga devrelere ait performans kriterleri arasındaki doğrusal ve/veya doğrusal olmayan ilişkilerin tahmini, topluluk öğrenmesi yöntemlerinden olan İyileştirme yöntemi kullanılarak gerçekleştirilmiştir. Oluşturulacak olan modeller ile, mikrodalga devrelerin tasarım optimizasyon süreçlerinde en çok işlem gücüne ve işlem zamanına ihtiyaç duyulan 3 boyutlu elektromanyetik simülatör programlarına olan bağımlılığı azaltmanın yanı sıra, mikrodalga tranzistörlerinin modellenmesi gibi bazı problemlerde, verinin oldukça az ve de elde edilmesi maliyetli olduğu problemlerde de etkin bir modelleme elde edilmesi sağlanmıştır. Bu tez çalışmasında ilk olarak, bir yansıtıcı dizi anten yapısına ait yansıma açısının birim hücresinin geometrik değişkenlerine göre değişiminin modellenmesi yapılmıştır. İkinci olarak, bir mikro şerit yama antenin saçılma parametrelerinin tasarımına ait geometrik değişkenlere göre değişimi incelenmiştir. Üçüncü olarak, yarı küresel bir dielektrik yüklü anten yapısına ait ışıma ve saçılma parametrelerinin modellenmesi gerçekleştirilmiştir. Dördüncü olarak, frekans seçici yüzeye ait saçılma parametrelerinin tahmini için model geliştirilmesi yapılmıştır. Son olarak ise aktif mikrodalga devre elemanlarından olan bir mikrodalga transistor elemanın farklı DC besleme koşullarındaki saçılma parametrelerinin modellenmesi gerçekleştirilmiştir. Ele alınan her bir problemde önerilen algoritmanın doğruluğu ve başarısının gözlemlenmesi için literatürde yayınlanmış ve genel kabul görmüş olan en son yöntemler ile kıyaslanması hedeflenmiştir.

Anahtar Kelimeler: Topluluk Öğrenmesi, Anten Tasarımı, Harmanlama, İyileştirme Yaklaşımı

ABSTRACT

Boosting Based Ensemble Learning Approach in Microwave Circuits

Hakan KALAYCI

Department of Electric and Electronics Engineering
Doctor of Philosophy Thesis

Supervisor: Assoc. prof. Umut Engin AYTEN
Co-supervisor: Assoc. prof. Peyman MAHOUTI

Within the scope of this thesis, the linear and/or non-linear relationships between the behaviors of microwave circuits and various variables of the circuits and the performance criteria of the circuit with the boosting method, which is an ensemble learning method, have been estimated. By using these models to be created, in addition to reducing the dependency on 3D Electromagnetic Simulator programs, which needs the most processing power and processing time in the design optimization processes of microwave circuits, an effective modeling can be achieved in some problems, such as the modeling of microwave transistors, which have very little data and are costly to obtain.Firstly, the variation of the reflection angle of a reflective array antenna structure according to the geometric variables of the unit cell has been modeled. Secondly, the variation of the scattering parameters of a microstrip patch antenna according to the geometrical variables of the design has been investigated. Thirdly, the modeling of the radiation and scattering parameters of a hemispherical dielectric-loaded antenna structure has been achieved. In the fourth example, a model has been developed for the estimation of the scattering parameters of the frequency selective surface. And in the last one, the modeling of the scattering parameters of a microwave transistor element, which is one of the active microwave circuit elements, in different DC supply conditions has been discussed. In order to observe the accuracy and success of the proposed algorithm in each problem discussed, it is aimed to compare it with the developed ("State of the Art") methods published in recent years.

Keywords: Ensamble Learning,Antenna Design,Boosting,Blending

YILDIZ TECHNICAL UNIVERSITY
GRADUATE SCHOOL OF SCIENCE AND ENGINEERING

1
GİRİŞ

1.1 Literatür Özeti

Kökleri İkinci Dünya Savaşı'na, 1950'lere uzanan makine öğrenme sistemleri, 1950'de Alan Turing, Turing Testini bilgisayarın bir insanı geçip geçmeyeceğini görmek için tasarlanmasıyla başlamıştır. İlk olarak da Reading Üniversitesi'nde Eugene adında bir chatbot, Turing testini geçmiştir. Böylece öğrenme kabiliyetine sahip ilk yapay sinir ağları tasarlanmıştır. Ayrıca 1967'de K-en yakın komşuları algoritması (KNN) makine öğrenmesi oluşması ile birlikte 1980 ve 1990'larda beynimizin yapısından ilham alarak bir tür makine öğrenme modeli olan yapay sinir ağlarını eğitmek için yeni bir algoritma sınıfı oluşturmuştur [1].

Zaman geçtikçe, gelişen bilgisayarlar ile birlikte yapay zeka teknolojileri de gelişmiş ve son yirmi yılda veri kullanılabilirliği bin kata, temel algoritmaların gelişmişlik seviyesi yüz kata ve donanım hızının en az yüz kata kadar artması ile birlikte günümüzde veri miktarındaki artış, çok geliştirilmiş algoritmalar ve daha güçlü bilgisayar donanımları yapay zeka teknolojilerinin önünü epey açmaktadır. 2011 yılından başlayarak internette, büyük veri kavramı makine öğrenmesinden daha çok aranırken, 2017 yılında makine öğrenmesi aranması ile büyük veri aranması eşitlenmiştir. Sadece Amerika Birleşik Devletleri ile sınırlandırılıp araştırıldığında ise 2016 yılında makine öğrenmesi, büyük veri aramalarını zaten geçmiş olduğu gözlenmektedir.

Günümüzün önde gelen kuruluşları, karar süreçlerini otomatik hale getirmek için makine öğrenmesi tabanlı araçları kullanmaktadır. Dijital dönüşüm için yapay zekanın (YZ) daha gelişmiş versiyonlarının kullanılmaya başlaması ile birlikte, bir çok şirket, daha karlı ve rekabetçi bir hale gelmek, şirket büyümesini iyileştirmek, süreçleri optimize etmek, ve en önemlisi müşteri memnuniyetini iyileştirmek için makine öğrenmesi algoritmalarından yararlanmaktadır.

İletişim teknolojisindeki son gelişmeler, yüksek performansa ve kompleks mikrodalga tasarımlarında olan gereksinimi de artmakta, tam dalga elektromanyetik analiz

araçları, gerekli tasarımları oluşturmak için olmazsa olmaz hale gelmiştir [2–5]. Ancak, tekrarlayan tasarımlar ya da yüksek sayılardaki model değerlendirmelerini gerektiren optimizasyon süreçleri bakımından hesaplama yeterliliği anlamında bu araçlar sıkıntı çekmektedir [6–11].

İletişim teknolojinde sıkça kullanılan yapay zeka tabanlı regresyon yöntemleri, yapay sinir ağı (YSA), genetik programlama (GP), sembolik regresyon (SR) veya Makine öğrenimi algoritmaları (ML) gibi yöntemlerle hızlı ve yüksek doğruluğa sahip elektromanyetik modeller ile mikrodalga cihazlarının tasarımı için günümüzde pek çok çalışmalar yapılmıştır. Sayısal ve analitik yöntemleri sağlayan YSA modeli, yüksek hassasiyetli elektromanyetik modellerin mikrodalga cihazlarının tasarımı için, yaygın olarak kullanılan yöntemlerin başında gelmektedir [12–14]. Basitçe, insan beyninin sayısal bir modeli olarak tanımlanan YSA, verilen girdiler ve çıktılar arasındaki doğrusal veya doğrusal olmayan ilişkileri tahmin etmek üzere eğitilir ve genellikle bir mikrodalga tasarımı için, saçılma parametreleri, yansıma fazı, karakteristik empedansı, rezonans frekansları, herhangi bir boyutsal tasarım parametresi, uzunluk veya genişlik gibi ölçülen ve ya simüle edilen özellikler kullanılarak oluşturulur.

YSA modellemesi için eğitim ve test verilerinin toplanması süreci önemli bir işlem olsa da, YSA modeli elde edildikten sonra, özellikle tekrarlanan tasarım analizi veya tasarım optimizasyon işlemi durumunda, toplam simülasyon veya tahmin hesaplama süresi göz ardı edilebilir. YSA, simülasyon veya ölçülen verilere dayalı, hızlı ve doğru sonuçları tahmin etmek için, giriş ve çıkış verileri arasında bir bağıntı kurarak tasarım optimizasyonu sorunlarına etkili bir çözüm sağlar. Son yıllarda, YSA modelleri, mikrodalga devre tasarımında aktif cihazların küçük ve büyük sinyal modellemesi [15], mikrodalga transistörlerinin sıcaklığa dayalı modelleri [16], mikroşerit hattının modellenmesi [17], minkowski yansıma dizisi anteninin modellenmesi [18] [19], bir mikrodalga transistörün saçılma parametrelerinin DC sapma koşullarına göre gerilemesi [20] gibi regresyon problemlerinde yaygın olarak kullanılmıştır. Son zamanlarda, GP veya SR kullanılarak, RFID uygulamaları için AC / DC doğrultucuları [21], bir mikroşerit iletim hattının karakteristik empedans hesaplaması için bir doğru analitik formül türetilmesi [22] ve düzlemsel olmayan bir yansıma dizi antene ait yansıma faz karakteristiğinin tahminini [23] yapabilen modellerinin oluşturulması ele alınmıştır.

Regresyon problemleri için diğer yenilikçi yapay zeka tabanlı sayısal yöntemi olan Derin Öğrenme yöntemi, günümüzde örneklerdeki mobil sensörler aracılığıyla insan davranışını tanıma [24], zaman serisi sınıflandırması [25], bir alt sistemin kalan yararlı ömrünün tahminine yönelik yaklaşım veya sensör verilerini kullanan bir bileşen [26], 100 FPS'de derin regresyon ağları ile nesneleri izleme [27],

finansal zaman serileri [28], rüzgar enerjisi veya rüzgar hızı tahmini [29], elektrik empedans tomografisi (EIT) görüntüleme [30] tam dalga doğrusal olmayan ters saçılma sorunları [31] gibi birçok problemde yaygın olarak kullanılmaktadır. Yapay zeka tabanlı mikrodalga tasarımları genellikle ölçülen veya üç boyutlu elektromanyetik tabanlı benzetim veriler kullanılarak modellenmektedir. Yapay zeka tabanlı modelleme için eğitim ve doğrulama veri setlerinin oluşturulması, yorucu bir işlem olsa da, bu işlem tamamlandığında, genel anlamda tasarım sürecinin verimliliğine büyük ölçüde iyileştirme sağlamakta, özellikle iteratif tasarım analizi veya tasarım optimizasyonu sürecinde görülmektedir. Yapay zeka tabanlı modeller, tasarım optimizasyonu sorunlarında, geometrik tasarım parametreleri, çalışma frekansı, malzeme seçimi gibi modellerin girişi ile karakteristik empedans, yansıma aşaması, kazanç ve saçılma parametresi vb. gibi istenen çıktı arasında bir eşleme oluşturabildikleri için etkili bir çözümdür.

Mikrodalga devre tasarım optimizasyonu problemleri için hızlı ve kesin bir modele sahip olmak, hesaplama anlamında etkili bir süreç için en büyük öneme sahiptir. Son on yılda, tasarım optimizasyonu sürecine uygun, kesin, stabil ve hesaplama anlamında etkili çözümler için numerik modelleme geliştirmeye yönelik metodlar üzerine çeşitli çalışmalar yapılmaktadır. Sözü geçen metodlar, hassaslaştırılmış Gradyan bazlı optimizasyon algoritmaları [32], seyrek duyarlılık güncellemeleri aracılığıyla yerel yöntemler [33, 34], makine öğrenmesi yöntemleri [35], data içeren surrogate yardımlı yöntemler [36–39], fizik bazlı yöntemler [40], kriging [41, 42], radial bazlı fonksiyonlar (RBF) [43], Gaussian süreç regresyonu (GPR) [44], sinir ağları [45–49], destek vektör regresyonu [50–52], polinominal cevap yüzeyleri [53] ya da fuzzy modeller [54] şeklinde adlandırılabilir.

YSA ve Derin Öğrenme yöntemlerinin yanı sıra, son yıllarda sıkça adından söz ettiren, gerek literatürdeki araştırmalardan gerekse makine öğrenmesini ilgilendiren yarışmalarda fazlasıyla kullanılan, stratejik olarak birçok modelden oluşan Topluluk Öğrenmesi (Ensemble Learning), temelinde bir modelin etkinliğini (sınıflandırma, tahmin vs.) iyileştirmek ya da hata riskini düşürmek için kullanılmaktadır. İletişim teknolojileri alanında diğer yöntemlere nazaran daha az örneği bulunmaktadır.

Topluluk Öğrenmesi, modelleri toplu olarak kullanma özelliği ile kötü bir performansa sahip bir modeli seçme riskini azaltır. Topluluk Öğrenmesi kullanılan sistemler, büyük miktarda ya da gereğinden daha az veri ile çalışabilmektedir. Aynı zamanda, stratejik bir biçimde daha küçük parçalara ayrılmış veri ile öğrenicileri eğitmek için kullanılabilmektedir. Burada amaç, en iyi kararı sağlayan bir modeli elde etmeye çalışmaktır. Son yıllarda, Topluluk Öğrenmesi'nin eğitim süresinin kısa olmasıyla birlikte artan hesaplama gücü sebebiyle bu konuyla ilgili örnek sayıları katlanarak

artmaktadır. Artan hesaplama gücü ile Topluluk Öğrenmesi çeşitli disiplinlerde de kullanılmaya başlanmıştır. Bunlara örnek olarak, uzaktan algılama ve jeo-uzamsal verileri kullanarak hedef alanların yüzeyine yerleştirilen materyalleri ve nesneleri tanımlamak ve dünyayı gözlemlemek için uydu sensörlerinin ana uygulamalarından biri olan arazi örtüsü haritalaması [55–57], arazi örtüsünün kademeli olarak değiştiği yerlerin tanınmasından oluşan bir bilgisayar görme problemi olan değişim tespiti, büyük ölçüde nüfus artışı, bitki örtüsü ve peyzaj desenleri, arazi kullanımı ve afet izleme gibi konuların haricinde [58], bir internet hizmeti sağlayıcısının başına gelebilecek en büyük siber tehditlerden biri olan dağıtılmış hizmet kesintisi (DDOS), genel algılama ve ayrım hatalarını azaltırma [59, 60] ve MRI veri setlerine dayanan nöro-bilişsel hastalık (yani Alzheimer veya miyotonik distrofi) tespiti gibi sinirbilim, proteomik ve tıbbi teşhiste başarıyla [61–63] kullanılmaktadır. Ayrıca, regresyon problemleri için Topluluk Öğrenmesi, veri tahmini kontrolü [64], elektrik tüketiminin tahmini [65], çimentolu betonun basınç dayanımı tahmini [66], enerji performans tahmini [67] gibi konularda yapılan çalışmalarla hayatımızı yakından etkilemektedir.

Topluluk Öğrenmesi'nin en önemli yöntemlerinden biri olan İyileştirme (Boosting) yöntemi, Topluluk Öğrenmesi doğasında olan zayıf öğrenicileri bir araya getirme fikrine dayanmaktadır. Bu fikrin algoritmik karşılığı ise tek bir tahminsel model formunda olan modeller serisi oluşturmaktır. Bu yaklaşım daha sonra (1996–1999) Schapires ve Freund [68] tarafından hayata geçirilmiş olup, daha sonra, Dasarth ve Sheela'nın 1979 [69] tarihli çalışması ile geliştirilmiştir.

Son yirmi yıldır, Hansen ve Solomon, Topluluk Öğrenmesi sisteminin çeşitlilik azaltma özelliğine ve nöral bir ağın genelleştirme performansına benzer şekilde konfigure edilerek geliştirilebileceğini göstermiştir [70]. Ancak, Topluluk Öğrenmesi sistemlerini, makine öğrenmesi konularında ilgi noktası haline getiren Schapire'in çalışması ile birlikte, İyileştirme olarak adlandırılan bir prosedür yoluyla zayıf öğrenicileri birleştirerek daha güçlü modeller oluşturulabileceği kanıtlanmıştır [71]. Bu sayede, adaptif öğrenme ailesinin öncülü olan İyileştirme, en popüler makine öğrenmesi algoritmalarından biri haline gelmiştir. Bu yenilikçi çalışmalardan bu yana, topluluk sistem çalışmaları hızla artmış, sınıflandırma sistemleri [69], en iyi öğrenicilerin karışımı [72], yığın ile genelleştirme [73], çoklu sınıflandırıcıların kombinasyonu [74–77], dinamik sınıflandırıcı seçimi [77], sınıflandırma kombinasyonu [78] [79] gibi daha birçok çalışmada kullanılarak başarısını kanıtlamıştır.

Gelişmekte olan Topluluk Öğrenmesi'nin en önemli yöntemlerinden olan İyileştirme yönteminin en çok kullanılan algoritmaları kronolojik sırayla AdaBoost (Adaptif İyileştirme), GBM (Gradyan İyileştirme Makinesi - Gradient Boosting Machine),

XGBoost (Aşırı Gradyan İyileştirme Makinesi - Extreme Gradient Boosting Machine), LGBM (Hafif Gradyan Makinesi - Light Gradient Boosting Machine) olarak adlandırılmaktadır. Türün ilk örneği olan AdaBoost, öğrenme için çeşitli algoritma türleri ile birlikte kullanılabilen, daha çok sınıflandırma problemleri için uyarlanabilir bir algoritma olarak tanımlanmaktadır. Uyarlanabilir olduğu için, daha sonraki zayıf öğreniciler, önceki zayıf öğreniciler tarafından yanlış tahminlenen durumları lehine değiştirir. Her öğrenicinin performansı rastgele tahmine kıyasla daha iyi olduğu sürece, nihai model, bireysel öğrenicilerin ne kadar zayıf olduğuna bakılmaksızın, güçlü bir öğreniciye yakınsama prensibine dayalıdır [80–82]. Adaboost'un ardılı olarak gösterilen Gradyan İyileştirme ise zayıf tahmin modellerinin bir topluluğu şeklinde tahmin modeli üreterek, regresyon ve sınıflandırma problemleri için kullanılmaktadır. Diğer İyileştirme modellerinin yaptığı gibi, aşamalı olarak bir model inşa eder. Gelişigüzel farklılaştırılabilir kayıp fonksiyonunun optimizasyonuna izin verir. Gradyan İyileştirme fikri, zayıf bir öğrenicinin daha iyi olmak için modifiye edilip edilemeyeceği fikrine göre hareket eder. Leo Breiman [83], Jerome H. Friedman [84, 85], Liew Mason, Jonathan Baxter, Peter Bartlett ve Marcus Frean [86] gibi bilim insanları tarafından geliştirilmiş bir teknik olan Gradyan İyileştirme [87, 88] fikri, uygun bir maliyet fonksiyonunda optimizasyon algoritması olarak yorumlanabilmektedir.

İyileştirmenin fonksiyonel gradyan bakışı, regresyon ve sınıflandırmanın ötesinde, makine öğrenmesi ve istatistiğin birçok alanında İyileştirme algoritmalarının gelişmesine yol açmıştır. Gradyan İyileştirme yönteminin çalışması sırasında orijinal veri kümesinden bir alt küme oluşturulup, başlangıçta, tüm veri noktalarına eşit ağırlık verilir ve oluşturulan alt kümede öğrenici performansı en azından rastgele durumdan biraz daha iyi performansa sahip olarak tanımlanır. Amacı, model kaybını, gradyan alçalma benzerlik prosedürü kullanan zayıf öğreniciler ekleyerek en aza indirmek olan bu algoritma sınıfı, aşamalı ekleme modeli olarak tanımlanır. Regresyon, sınıflandırma ve diğer problemler için, İyileştirme, genellikle karar ağaçları olmak üzere zayıf tahmin modelleri topluluğu şeklinde bir tahmin modeli oluşturur. Gradyan İyileştirme, birçok modeli aşamalı, eklenebilir ve ardışık bir biçimde eğitir. Gradyan İyileştirme'nin öncülü olan Adaptif İyileştirme'ye benzer şekilde, modeli aşamalı bir şekilde geliştirir ve rastgele bir türevlenebilir kayıp fonksiyonunun optimizasyonunu sağlayarak bunları genelleştirir.

Adaptif İyileştirme ve Gradyan İyileştirme arasındaki büyük fark, iki algoritmanın zayıf öğrenicilerin eksikliklerini (karar ağaçları gibi) nasıl tanımladığıdır. Adaptif İyileştirme modeli, eksikliklerine yüksek ağırlık verirken, Gradyan İyileştirme ise kayıp fonksiyondaki gradyanları kullanarak aynısını yapmaktadır. Modelin katsayılarının veriyi eğitmekte ne kadar iyi olduğunu gösteren bir ölçü olan kayıp fonksiyonunun

mantıksal bir kavrayışı, neyi optimize etmeye çalıştığına bağlıdır.

Gradyan İyileştirme kullanmadaki en büyük motivasyonlardan biri, gerçek hayat uygulamalarıyla bağdaşmayan ve daha az kontrol imkanı sunan bir kayıp fonksiyon yerine, kullanıcı tanımlı maliyet fonksiyonunu optimize etmeye izin vermesidir. İşlev alanı boyunca bir maliyet işlevini optimize etmek için negatif gradyan yönünde yönlendiren Gradyan İyileştirme, Makine öğrenimi ve istatistikteki bir dizi alanda, bu işlevsel gradyan perspektifi nedeniyle regresyon veya sınıflandırmanın ötesine geçen güçlendirme yaklaşımları yaratmıştır.

Adaptif İyileştirme, üstel kayıp kullanımı nedeniyle aykırı değerlere karşı daha hassas olmasına karşın, sürekli türevlenebilir olmasından dolayı Gradyan İyileştirme, daha efektif bir kayıp işlevi kullanabilmektedir. Optimize edilecek bir kayıp fonksiyonu, çözülen problemin türüne göre değişmesi ve farklaşıtırabilir olması nedeniyle, regresyon uygulamalarında hata kareler yöntemi kullanmaktadır. Tahmin yürütecek bir zayıf öğrenici, Gradyan İyileştirme'de zayıf öğrenici olarak tanımlanır ve özellikle, veri parçaları için gerçek değerleri üreten ve oluşan sonuçları bir araya toplanabilen regresyon ağaçları kullanılmaktadır. Ardışık model çıktılarının eklenmesine ve tahminlerde keskin sonuçlar veren artıkların olmasına izin veren bu ağaçlar, saflık skorlarına dayalı olarak en iyi veri parçalarını seçerek açgözlü algoritmasını kullanır. Böylece, Kayıp fonksiyonu minimize edilir.

Gradyan İyileştirme yöntemini yenilikçi yaklaşımı ile efektif hale getiren Aşırı Gradyan İyileştirme (AGİ) ilk olarak Tiangi Cheng'in bir araştırma projesi [89] ve distributed machine learning community grubunun bir parçası olarak hayata geçmiştir. AGİ, Higgs Makine öğrenmesi meydan okuma'sının kazanan çözümünde kullanımından sonra makine öğrenmesi yarışması kapsamında tanınır gelmekte, kısa zamanda, python ve R paketleri inşa edilmiştir. AGİ, şu anda java, scala, julia, perl, ve diğer dillerde kütüphanelerine sahip halde bulmaktadır. Bu durum, daha fazla geliştiriciye kütüphaneyi kullanma şansı verirken, kaggle topluluğundaki popülerliğine katkı sağlamıştır. Şu anda, python kullanıcıları için scikit learn ve R kullanıcıları için caret paketlerine entegre durumdadır. AGİ'nin Gradyan İyileştirme'e göre avantaji, hem sistem (donanim ve yazilim) optimizasyonu hem de algoritmik geliştirme olarak tanımlanmaktadır. AGİ'nin standart gradyan İyileştirmelere göre avantajlarının başında, karar ağaçlarını oluştururken paralelizasyon yaparak çok daha hızlı çalışmasını sağlarken, bunu yapabilmesinin altında ana-öğrenicileri (base-learners) oluşturarak, iç ve dış döngüler arasında geçiş yapabiliyor olması gelmektedir. Normal şartlarda dış döngüler, karar ağacının yapraklarını oluştururken iç döngüler öznitelikleri hesaplar. Ancak, iç döngüler bitmeden dış döngüler tamamlanamayacağı için yani öznitelikler

hesaplanmadan ağacın yaprakları oluşmayacağı için paralelizasyon sınırlanır. AGİ, iç ve dış döngülere ayrılan hesaplama gücünü değiştirerek çalışma zamanını azaltmaktadır. Öte yandan, Gradyan İyileştirmelerde ağaç dallarını ayırırken negatif-kayıp kriterine göre ayırmayı durdururken, AGİ, bunun aksine en başından maksimum derinlik parametresi ile ağacın derinliğini belirleyerek, eğer ağaç aşağı yönde fazla ilerler ise geriye doğru budama yapmakta, bu özellik sayesinde, AGİ derinliğe öncelik vermektedir. AGİ İyileştirme, geliştirilirken donanım kaynaklarını daha iyi kullanmak üzere tasarlanmış olup, her işlem kendi içinde bir tampon ve bu tamponda eğim istatistiklerini (gradient statistics) tutarak, önbelleğin doluluğunu göz önünde bulundurmaktadır. Bunun dışında, "çekirdek dışı" hesaplama gibi iyileştirmeler sayesinde disk alanını optimize ederek daha büyük verileri belleğe sığdırabilmektedir. Hem LASSO (Least Absolute Shrinkage and Selection Operator) hem de Ridge regülarizasyonu kullanarak aşırı öğrenmeyi engelleyebilen AGİ yöntemi, eğitim kaybına bakarak en doğru şekilde öğrenebildiği için, agaçları ayırırken en doğru noktadan ayırabilmek için veri setindeki gözlem noktalarını ağırlıklandırarak kullanıyor olmasından dolayı daha efektif sonuçlar verebilmektedir.

Microsoft tarafından AGİ'ye rakip olarak oluşturulan Hafif Gradyan İyileştirme (HGİ), 2017 yılında Microsoft DMTK (Dağıtılmış Makine Öğrenimi Araç Seti) projesiyle geliştirilen İyileştirme temelli bir algoritmadır. Bununla birlikte, diğer algoritmalara kıyasla yüksek işlem hızı, büyük verileri işleyebilmesi, daha az kaynak (RAM) kullanımı, yüksek tahmin oranı, paralel öğrenme ve GPU öğrenimini desteklemesi gibi özellikleriyle beraber modelin tanıtıldığı [90] makalesinde, diğer modellerden 20 kat daha hızlı olduğu sonucu ortaya atılmaktadır. HGİ, histogram tabanlı çalışan bir algoritma olmakla beraber, sürekli değere sahip olan değişkenleri, kesikli hale getirerek hesaplama maliyetini azaltır. Bu durumu, ağaçların hesaplama ve bölünme sayısı ile doğru orantılı olduğu için hem eğitim süresi kısalmakta hem de kaynak kullanımı düşmektedir. Histogram algoritması ile ilgili sözde kod EK-6'te verilmiştir. Sıralama, sınıflandırma ve diğer birçok makine öğrenmesi alanında kullanılan karar ağacı algoritmasına dayanan hızlı, dağıtılmış, yüksek performanslı bir Gradyan İyileştirme yöntemi olan, HGİ, AGİ'nin eğitim süresi performansını arttırmaya yönelik geliştirilen bir Gradyan İyileştirme yöntemidir. Seviye odaklı büyüme stratejisi yerine yaprak odaklı büyüme stratejisini ve genişlik öncelikli arama (BFS) yerine ise derinlik öncelikli arama (DFS) kullanır. Seviye odaklı büyüme stratejisinde, büyüme sırasında ağacın dengesi korunurken, yaprak odaklı büyüme stratejisinde ise kaybı azaltan yapraklarda bölünme işlemi devam eder. HGİ bu özelliği sayesinde diğer İyileştirme yöntemlerinden ayrılmakla birlikte, oluşturulan model, yaprak odaklı büyüme strateji ile daha az hata oranına sahip olmaktadır. Böylece daha hızlı öğrenmektedir. Fakat yaprak odaklı büyüme stratejisi veri sayısının az olduğu durumlarda modelin aşırı

öğrenmeye yatkın olmasına neden olmaktır. Bu nedenle algoritma büyük verilerde kullanılmak için daha uygundur.

HGİ'nin resmi internet sitesine göre, yaprak sayısı sabit tutulduğunda yaprak bazlı yöntemler, seviye bazlı yöntemlerden daha küçük kayıplar elde etme eğilimindedir. Nitekim HGİ'deki Histogram Algoritması, GOSS (Gradyan Tabanlı Tek Taraflı Örnekleme) ve EFB (Özel Özellik Paketleme) yöntemleri yalnızca eğitim hızını ve RAM kullanımını arttırmakla kalmaz, aynı zamanda doğal aşırı öğrenme önleme mekanizması olarak da işlev görmektedir. Sonuç olarak, modelin veri toplamadaki küçük değişikliklere duyarlılığını azalttıkları için, HGİ'deki yaprak odaklı ağaç büyüme tekniği düzgün çalışır.

Genel anlamda İyileştirme algoritmaları kıyaslanacak olursa, Adaptif İyileştirme, yanlış tahminlenmiş örneklere ağırlık ekler ve örnekleri başarıyla tahminlendiğinde bu örneklerin ağırlıklarını azaltır. Negatif gradyan kullanabilen Gradyan İyileştirme, önceki temel öğrenicilerin hatalarının bir göstergesi olarak kayıp fonksiyonu kullanmakta ve bunun bir sonucu olarak, bir sonraki temel öğrenici, önceki temel öğrenicilerin negatif gradyanını doğru sonuca yaklaşmak için kullanmaktadır. AGİ, hem birinci türevi hem de ikinci türevi kullanırken Gradyan İyileştirme yönteminde ise, her aşamada en iyi temel öğrenicileri bulmak için yalnızca ilk türevi kullanmaktadır. Gradyan İyileştirme'nin ilk sürümü, kayıp işlevinde bir düzenleme terimi içermemekte iken, düzenlileştirme adımı, AGİ tarafından kayıp işlevine eklenir. Regresyon için Gradyan İyileştirme, optimal temel öğrenicileri belirlemek için puanlayıcı olarak MSE(Mean Square Error)'yi kullanır. Ayrıca Gradyan İyileştirme'de seyrek veri kümeleri ile kullanılmamasına karşın, AGİ seyrek veri kümelerini doğrudan destekler. AGİ için daha iyi puanlama oluştururken aşırı eğitime dikkat etmektedir. Gradyan İyileştirme'de ön budama ile aşırı öğrenme önlenirken, AGİ, fazla öğrenme önlemeye ek olarak, yetersiz öğrenmeyi önlemek için de budama kullanır. HGİ, aşırı öğrenme sonucunu Histogram tabanlı Tek Taraflı Örnekleme/Özel Özellik Paketleme ile çözümlemektedir. Ayrıca AGİ, Düzey odaklı yetiştirme stratejisini kullanırken, HGİ yaprak odaklı ağaç yetiştirme tekniği kullanılır.

1.2 Tezin Amacı

Bu tez kapsamında, Mikrodalga devrelerinin davranışlarını, devrelerin çeşitli değişkenleri (geometrik parametreleri, çalışma frekansı, besleme akımı ve gerilimi vb.) ile devreye ait performans kriterleri arasındaki doğrusal ve/veya doğrusal olmayan ilişkilerin tahminini Topluluk Öğrenmesi yöntemi olan İyileştirme metodu ile gerçekleştirmesi amaçlanmıştır. Oluşturulacak olan bu modeller ile, mikrodalga

devrelerin tasarım optimizasyon süreçlerinde en çok işlem gücüne ve işlem zamanına ihtiyaç duyulan 3B Elektromanyetik Simülator programlarına olan bağımlılığı azaltılması amaçlanmaktadır. Mikrodalga tranzistörlerinin modellenmesi gibi verinin oldukça az ve de elde edilmesi maliyetli olduğu durumlarda etkin bir model oluşturulması hedeflenmiştir. Bu sayede yüksek performanslı mikrodalga devrelerin tasarım optimizasyon süreçlerinde tekrar-tekrar kullanılabilir, hızlı, işlemsel maliyeti düşük, yüksek doğruluğa sahip numerik modeller oluşturulacaktır. Bu kapsamda öncelikle literatürde daha önceden ele alınan çeşitli mikrodalga devre yapılarının önerilen yöntem ile modellenmesi ve de literatürdeki rakip algoritmalar ile performans karşılaştırılması hedeflenmiştir. Bu amaç doğrultusunda, yansıtıcı dizi anten yapısındaki yansıma açısının birim hücreye ait geometrik değişkenlere göre değişiminin modellenmesi ve bir mikroşerit yama antenin saçılma parametrelerinin tasarıma ait geometrik değişkenlere göre değişimi, ayrıca yarı küresel bir dielektrik yüklü anten yapısı için özgün bir model oluşturulması, bu antene ait ışıma ve saçılma parametrelerinin modellenmesi, frekans seçici yüzeye ait saçılma parametrelerin tahminlemesi, pasif devre elemanları dışında bir problemin ele alınması adına, bir mikrodalga tranzistör elemanın farklı DC besleme koşullarındaki saçılma ve gürültü parametrelerinin modellenmesi ele alınmıştır. Ele alınan her bir problemde önerilen yöntemin doğruluğu ve başarısının gözlemlenmesi için son yıllarda geliştirilmiş (“State of the Art”) yöntemlerle kıyaslanması hedeflenmiştir. Literatürde çalışılmış bazı problemleri İyileştirme yaklaşımı ile daha az hatayla çözmek hedeflenmekte, daha sonra özgün çalışmalar ile İyileştirme yaklaşımının başarılı olması öngörülmektedir.

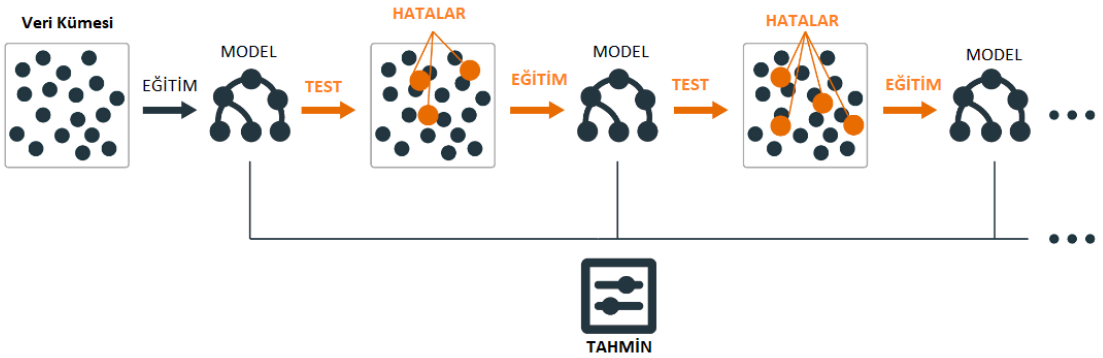
1.3 Hipotez

Amaç doğrultusunda, İyileştirme yöntemiyle mikrodalga teknolojilerindeki problemlerin, literatürdeki çalışmalara göre, hata metriklerine göre daha az hata ile ve daha hızlı olacak şekilde çözülebileceği önerisi, bu doktora tez çalışmasının hipotezi olarak oluşturulmuştur.

2
İYİLEŞTİRME TABANLI TOPLULUK ÖĞRENMESİ

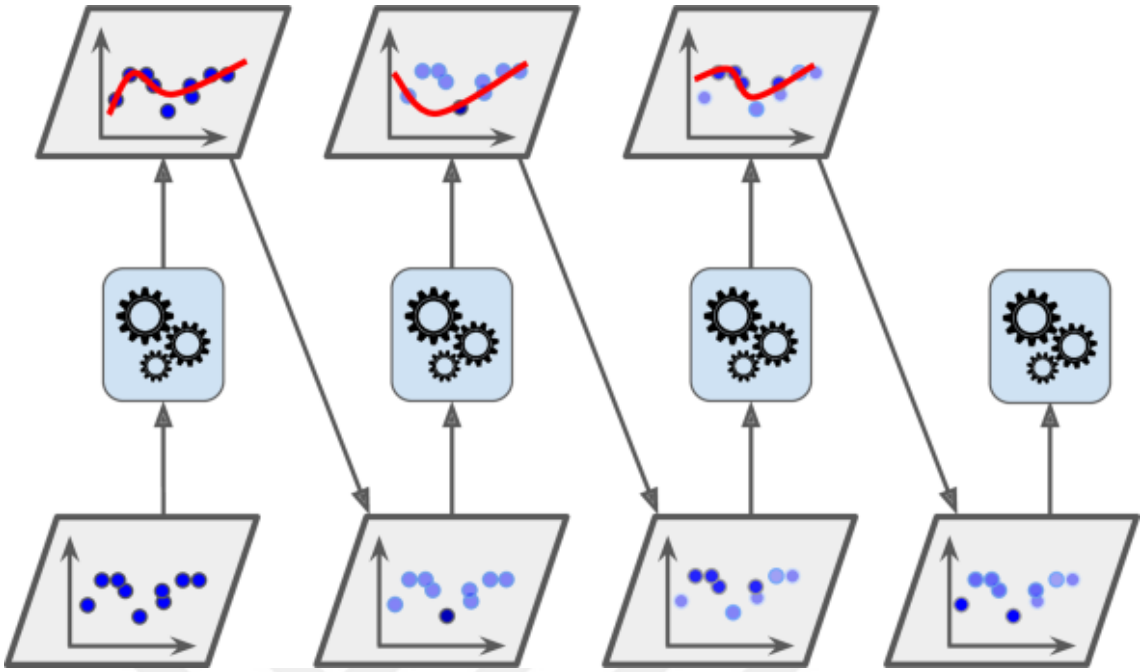
2.1 İyileştirme Mantığı ve Regresif İyileştirme

Zayıf öğrenicileri, kuvvetli öğrenicilere dönüştürme esasına dayanan ve ardışık bir teknik olan İyileştirme Yönteminde, önce ilk öğrenici, elverişli eğitim verisinin rastgele bir alt kümesi ile eğitilir. Başlangıçta tüm gözlemler eşit ağırlığa sahip olup ağaç topluluğu büyümeye başladıkça, problem bilgisine dayalı olarak ağırlıklandırmalar düzenlenir. Diğer öğreniciler, ilk öğrenicinin artıklarına göre eğitilir ve önceki modeldeki yanlış tahminlenen gözlemlerin ağırlığı arttırılırken, doğru tahminlenen gözlemlerin ağırlığı azaltılır. Bu işlem iteratif olarak yapılarak, adaptif bir şekilde model kurulur. Hata değerlendirmesi kümülatif olarak yapılır. Ana fikrin algoritmik karşılığı ise bir öğrenici ile modeli eğitmek yerine, birden fazla öğrenici ile modeli oluşturmayı sağlayan öğrenme yani başka bir deyiş ile tek bir temel öğrenici (base learner) model kullanmak yerine birden fazla modelleyici algoritmanın birlikte kullanılmasıyla yeni bir ana bir model oluşturulmasıdır [91].



Şekil 2.1 İyileştirme Yönteminin Genel Şeması

İyileştirme yöntemlerini ise tek bir cümle ile ifade edecek olursak; artık(residual) optimizasyonuna dayalı olarak performans iyileştirmeye çalışırlar. Yani modeller adaptiftir. İyileştirme Yöntemi'nin genel çalışma prensibi Şekil 2.2'de verilmiştir.



Şekil 2.2 İyileştirme Yönteminin Çalışma Prensibi

Topluluk öğrenmede başarı iki temel kurgu üzerine olmalıdır; temel öğrenicilerin performansı (accuracy) yüksek olmalıdır. Yani, ne kadar başarılı öğrenici kullanılırsa topluluk başarısı o kadar yüksek olur. Temel öğrenicilerin kararları birbirinden farklı, çeşitlilik (diversity) olmalıdır.

2.1.1 Adaptif İyileştirme (AdaBoost)

İyileştirme Yönteminin öncülü konumunda yer alan AdaBoost, $b(x;r_m)$ 'nın, $r_m.\beta_m$ parametresi tarafından kontrol edilen bir temel öğrenme yöntemidir. Zayıf temel öğrenicilerin eklenmesini kontrol ettiği varsayıldığında, M tane zayıf temel öğrenicinin son modeli $f(x)$ şu şekilde olacaktır: $f_0(x) = 0$ ve $sign(\bullet)$ değerleri sınıflara dönüştüren fonksiyondur. Bu fonksiyonun çıktısı ağaç tabanlı yapıdır:

$$G(x) = sign(f(x)) = sign\left(\sum_{m=1}^{M} \beta_m * b(x;r_m)\right) \tag{2.1}$$

$D = (x_1,y_1),(x_2,y_2),...,(x_N,y_N)$ N tane örnekle, global optimal ve aşağıdaki kayıp fonksiyonunu minimize eder.

$$(\beta_m, r_m) = Min_{\beta_r,r_m}\left(\sum_{i=1}^{N} Loss(y, \sum_{m=1}^{M} \beta_m * b(x;r_m)\right) \tag{2.2}$$

Bu global optimum, mevcut temel öğrenme için β ve r değerleri bulunarak her adımda yaklaşık olarak hesaplanabilir. Ardından işlevi günceller:

$$f_m(x) = F_{m-1}(x_i) + \beta_m * b(x; r_m) \tag{2.3}$$

Son çıktı modeli $f(x)$ aşağıdaki gibidir:

$$f(x) = argMin_{\beta_r, r_m}(\sum_{i=1}^{N} Loss(y, F_{m-1}(x_i) + \beta_m * b(x; r_m))) \tag{2.4}$$

Her yinelemede üstel kaybımızı en aza indirmek için en iyi β_m ve $b_m(x; r_m)$ değeri ($b_m(x)$ olarak basitleştirilmiştir) belirlenir. y'nin $-1, 1$'e ait olduğu varsayıldığında, üstel kayıp fonksiyonu aşağıdaki gibidir:

$$Loss(y, f(x)) = E(e^{y*f(x)}|x) = P(y = 1|x) * e^{f(x)} + P(y = -1|x) * e^{f(x)} \tag{2.5}$$

Türevi alınır ve 0'a eşitlendiğinde, üstel kayıp fonksiyonunu en aza indirirken, aslında $y = log\frac{P(y=1|x)}{P(y)=-1|x)}$ lojistik regresyon işlemine benzer bir işlem yapılmaktadır. Ve böylece optimal Bayes hata oranına ulaşılır.

$$\frac{\partial E(e^{y*f(x)}|x)}{\partial f(x)} = \left[-P(y = 1|x) * e^{-f(x)} + P(y = -1|x) * e^{f(x)}\right] * f(x) = 0 \tag{2.6}$$

$$\frac{\partial E(e^{y*f(x)}|x)}{\partial f(x)} = 0 \rightarrow f(x) = \frac{1}{2} * log\frac{P(y = 1|x)}{P(y = -1|x)} \tag{2.7}$$

$$sign(f(x)) = sign\left(\frac{1}{2} * log\frac{P(y = 1|x)}{P(y = -1|x)}\right) \begin{cases} 1 \text{ P(y=1|x) > P(y=-1|x)} \\ -1 \text{ P(y=1|x) < P(y=-1|x)} \end{cases} \tag{2.8}$$

$$argmax_{y \in \{1,-1\}} P(y|x) \left\{ \text{Optimal Bayes Hata Oranı} \right. \tag{2.9}$$

$$sign = \begin{cases} 1 \; if \; x > 0 \\ -1 \; if \; x < 0 \end{cases} \tag{2.10}$$

2.1.2 Gradyan İyileştirme Makinesi(GBM)

Adaptif İyileştirme'ye yeni bir soluk getiren Gradyan yaklaşımı, ağaçlar eklenirken oluşan kaybı en aza indirmek için ve bir sinir ağındaki ağırlıklar ya da regresyon denklemlerindeki katsayılar gibi parametre setini en aza indirmek için kullanılır. Hata ya da kaybı hesapladıktan sonra, ağırlıklar hatayı en aza indirmek için güncellenir. Regresyon için Gradyan İyileştirme, ileri yönlü olarak ek bir model inşa eder ve gelişigüzel farklılaştırılabilir kayıp fonksiyonlarının optimizasyonuna olanak sağlar. Her aşamada, bir regression ağacı, verilen kayıp fonksiyonun negatif Gradyanı üzerine eğitilir. Matematiksel olarak; GBM algoritmasında bir kayıp fonksiyonu (loss function) tanımlanır. Kayıp fonksiyonu, modelin katsayılarının, kullanılan veri ile uyumunun ne kadar yüksek olduğunu göstermesi için, oluşturulan fonksiyon anlamına gelmekte birlikte, $L(y_i, F(x))$ ile gösterilir.

$$L(y_i, F(x)) = \frac{1}{2}(\text{Gerçek} - \text{tahmin edilen})^2 \tag{2.11}$$

ifadesi ile elde edilmiştir. Gradyan İyileştirme hesaplamasında sıklıkla türev işlemi kullanılmaktadır. Bahsedilen fonksiyonun tahminlenen değerine göre türev işlemi uygulandığında $\frac{1}{2}$ değeri yok olur ve "-(gözlem - tahmin)" ifadesine ulaşılır. Bu kullanımın sağladığı kolaylıktan dolayı fonksiyonun başına $\frac{1}{2}$ getirilmektedir. Kayıp fonksiyonu belirlendikten sonra, sabit değişken belirlenir.

$$F_o(x) = argmin_\gamma \sum L(y_i, F(x)) \tag{2.12}$$

y_i gözlemlenen değer, $F(x)$ tahminlenen değeridir. Tüm gözlemler için kayıp fonksiyonu toplama işlemi uygulanacak ve daha sonra değerinin minimum hali hesaplanacaktır. Bunun için kayıp fonksiyonuna türev işlemi uygulanır ve oluşan değerler toplanır ve sıfıra eşitlenir. Yapılan işlemlerle beraber, başlangıç yaprağı bulunur. Bu değer hedef değişkendeki tüm değerlerin ortalamasına eşittir.

$$r_{im} = \left[\frac{\partial L(y_i, F(x))}{\partial F(x_i)}\right]_{F(x)=F_{m-1}(x)} \Big\{ i = 1, ..., n \tag{2.13}$$

Önceki tahmine göre hatalar hesaplanır. Fonksiyonda r_i residual (artık) anlamına gelmektedir. i gözlem numarası, m kurulan ağacın numarasını işaret ederken, parantez içinde yer alan türevi alınmış kayıp fonksiyonu olmakla beraber, Parantez dışından bakıldığında $F(x)$ değerinin bir önceki ağacın değerini işaret ettiği görülmektedir. Bu fonksiyon ile tüm gözlemler için artıklar hesaplanır. Sonraki

aşamada, artıklar için karar ağacı yapısı inşa edilmekle beraber, her yaprağın değeri bulunur.

$$\gamma_{jm} = argmin_{F(x)} \sum_{x \epsilon R_{ij}} L(y_i, F_{m-1}(x_i) + F(x)) \Big\{ j = 1, ..., j_m \tag{2.14}$$

Fonksiyon, her yaprak için hatayı minimize eder. İkinci adımda işaret edildiği gibi, burada fonksiyon F_{m-1} 'i başka bir ifade ile, bir önceki tahmin değerini kullanır ve aynı şekilde kayıp fonksiyonu türev işlemine alınır. Oluşan değerler toplanıp sıfıra eşitlenir. Çıkan sayı diğer yaprağın değeridir. Bu şekilde her gözlem için tahmin değerleri üretilir.

$$F_m(x) = F_{m-1}(x) + \alpha \sum_{j=1}^{j_m} F(x)_{jm} I(x \epsilon R_{jm}) \tag{2.15}$$

Fonksiyon incelendiğinde genel anlamda,

$$\text{F(x)} = \text{önceki ağacın sonuçları} + \text{öğrenme oranı} * \text{yeni ağaç} \tag{2.16}$$

olduğu görülmektedir. Tüm ağaçlarda uygulanacak bir döngüdür. Son birkaç yılda, verinin çeşitliği ve boyutunun dramatik bir hızla artması ile algoritma optimizasyonlarına verilen önem gittikçe artmaktadır. Bu nedenle Gradyan İyileştirme algoritması'na alternatif olarak Aşırı Gradyan İyileştirme, Hafif Gradyan İyileştirme gibi Gradyan İyileştirme'nın versiyonları kabul edilebilecek algoritmalar geliştirilmiştir. Bu algoritmalar ile daha hızlı eğitim ve daha yüksek doğruluk elde edilmesi amaçlanmıştır. Kaybı azaltmak için AdaBoost'a:

$$Min_{\beta_r, r_m}(\sum_{i=1}^{N} Loss\left(y_{,}, f_m(x)\right) \rightarrow Min_{\beta_r, r_m}(\sum_{i=1}^{N} Loss(y_{,}, F_{m-1}(x_i) + \beta_m * b(x)) \tag{2.17}$$

şeklinde eklenir. Sadece bu durum Adaptif İyileştirme'den farklı olmakta, kayıp fonksiyonu (üstel kayıp) bilindiği için, tam optimum $b_m(x)$ Adaptif İyileştirme Yönteminde belirlenebilmektedir. β_m, Adaptif İyileştirme'de olduğu gibi burada da kontrol parametresi olarak verilmiştir. Gradyan İyileştirme'deki herhangi bir kayıp fonksiyonunu çözmek için, ancak, kayıp fonksiyonunun türevlenebilir olması gerekmektedir. Tam optimal değeri olan $b_m(x)$ değerini belirlemek için, negatif

gradyan yönüne $b_m(x)$ atayarak gradyan inişine benzer bir yöntem kullanmak gerekmektedir. α parametresi öğrenme oranıdır, ancak bu durumda negatiftir.

$$Min_{\beta_r, r_m}(\sum_{i=1}^{N} Loss(y_, F_{m-1}(x_i) + \beta_m * b(x) \tag{2.18}$$

$$b_m(x) = a * \frac{\partial Loss(y_, F_{m-1}(x))}{\partial F_{m-1}(x)} \tag{2.19}$$

$$f_m(x) = F_{m-1} + a * \frac{\partial Loss(y_, F_{m-1}(x))}{\partial F_{m-1}(x)} \tag{2.20}$$

m iterasyon olarak ifade edildiğinde;

$$f_m(x) = F_{m-1} + \beta_m * b_m(x) \tag{2.21}$$

GBM regresyon ağacı algoritmasının sözde kodu EK-1' de sunulmuştur.

2.1.3 Aşırı Gradyan İyileştirme Makinesi (XGBoost ya da XGBM)

Gradyan İyileştirme Yönteminin gelişmiş versiyonu olan Aşırı Gradyan İyileştirme Yöntemi'nde ise matematiksel olarak; fonksiyon uzayında gradyan inişi olarak çalışan Gradyan İyileştirme'den farklı olarak, Aşırı Gradyan İyileştirme'nin fonksiyon uzayında Newton-Raphson'a bağlamak için ikinci bir Taylor yaklaşımı kullanılır [89] [86]. Gradyan İyileştirme'de ise kaybı en aza indirmek ve uygun boyutu seçmek için sadece birinci türev bilgisi kullanılmasına karşın, Aşırı Gradyan İyileştirme hem birinci hem de ikinci türevleri kullanarak, diğer iki yöntemden daha doğru sonuçlar verir. Aşırı Gradyan İyileştirme'de kullanılan her öğrenici için, uygun ayrımı elde etmek için kullanılabilecek dört aşamadan oluşan ayrım bulma yöntemi vardır. Bu yöntem Aşırı Gradyan İyileştirme regresyon ağacı algoritmasının tanımı olarak EK-2'de sunulmuştur;

Eğer geleneksel optimizasyon teknikleri kullanılmak isteniyorsa, orijinal amaç fonksiyonunun, Taylor teoremi ile öklidsel domainindeki bir fonksiyona dönüştürülmesi gerekmektedir. Algoritmanın daha anlaşılır olması açısından; amaç fonksiyonundaki (kayıp fonksiyonu ve düzenlileştirme) iterasyon değeri olan t

minimize edilmesi gerekmektedir;

$$\Omega(f_t) = \gamma T + \frac{1}{2}\lambda||w||^2 \begin{cases} \Omega\ (f_t) = \text{Düzenlileştirme terimi} \\ \gamma = \text{L1 düzenlileştirmesi kontrol parametresi} \\ \text{T= yaprak sayısı} \\ \lambda = \text{L2 düzenlileştirmesi kontrol parametresi} \\ ||w||^2 = \text{Öklidsel yaklaşım} \end{cases} \tag{2.22}$$

$$L^t = \sum_{i=1}^{n} l(y_i, F_{m-1}^{(t-1)}(x_i) + f_t(x_i)) + \Omega(f_t) \begin{cases} y_i = \text{Gözlenen değerler} \\ \Omega(f_t) = \text{Düzenlileştirme terimi} \\ F_{m-1}^{(t-1)}(x_i) = \text{Bir önceki tahminlenen değer} \end{cases} \tag{2.23}$$

$f(x)$ fonksiyonun en basit lineer yaklaşımı;

$$f(x) \approx f(y) + f'(y)(x-y) \tag{2.24}$$

$$(x-y) = \Delta x = f_t(x_i) \tag{2.25}$$

Başlangıç fonksiyonu sadece Δx fonksiyonu olarak yazılabilmekte, buradan hareket ile, f(x) fonksiyonunu, belli bir noktadaki en basit Δx fonksiyonuna Taylor teoremi kullanarak dönüştürebilmektedir. Böylece, *f(x)* kayıp fonksiyonu l, y ise bir önceki aşama $(t-1)$ tahmini değeri için, ve Δx adımına t'de eklememiz gereken yeni öğrenici olarak tanımlanır. Her bir yinelemede yukarıdaki fonksiyon kullanılarak, amaç (kayıp) fonksiyonu yeni eklenmiş öğrenici olarak yazılır. Sonuç olarak öklid uzay optimizasyon tekniği uygulamak için kullanılır. İkinci dereceden Taylor yaklaşımı (denklem 2.23 ve 2.24 aracılığıyla) kullanılır.;

$$g_i = \partial_{y_{(t-1)}} l(y_i, F_{m-1}^{(t-1)}(x_i)) \left\{ g_i = \text{Kayıp fonksiyonunun 1. türev fonksiyonu} \right. \tag{2.26}$$

$$h_i = \partial^2_{y_{(t-1)}} l(y_i, F_{m-1}^{(t-1)}(x_i)) \left\{ h_i = \text{Kayıp fonksiyonunun 2. türev fonksiyonu} \right. \tag{2.27}$$

Buradan hareket edildiğinde;

$$f(x) \approx f(y) + f'(y)(x-y) + \frac{1}{2}f''(y)(x-y)^2 \tag{2.28}$$

$$L^{(t)} \simeq \sum_{i=1}^{n}[l(y_i, F_{m-1}^{(t-1)}(x_i)^{(t-1)}) + g_i f_t(x_i) + \frac{1}{2}h_i f_t^2(x_i)] + \Omega(f_t) \tag{2.29}$$

Sabit katsayıları çıkarıldığında, t adımda hatayı en aza indirmek için sıradaki basitleştirilmiş amaç fonksiyonu elde edilir;

$$\widetilde{l^t} = \sum_{i=1}^{n}[g_i f_t(x_i) + \frac{1}{2}h_i f_t^2(x_i)] + \Omega(f_t) \tag{2.30}$$

Yukarıdaki fonksiyon, bir değişkenin basit kuadrik fonksiyonlarının toplamıdır ve bilinen teknikler kullanılarak en aza indirilebilir. Böylece bir sonraki hedef olan, t iterasyondaki kayıp fonksiyonunu en aza indiren öğreniciyi bulmak hedeflenir;

$$argmin_x G_x + \frac{1}{2}H_x^2 = -\frac{G}{H}, H > 0 \begin{cases} G_i = \text{Kayıp fonksiyonunun 1. türevi hata toplamı} \\ H_i = \text{Kayıp fonksiyonunun 2. türevi hata toplamı} \end{cases} \tag{2.31}$$

$$min_x G_x + \frac{1}{2}H_x^2 = -\frac{G^2}{H} \tag{2.32}$$

Minimize edilmiş basitleştirilmiş kuadrik fonksiyonu ($\widetilde{L}^{(t)}(q)$) bulunmuş olmakta, sıradaki öğrenicisi ise t iterasyonda, kaybın olası en yüksek azaltımını sağlayan bir öğrenici inşa edilmesi gerekirken, optimal yeni öğreniciyi bulmanın ve belirli bir öğreniciyi ekledikten sonra, kazancı (kayıp azaltımı) hesaplamanın bir yolu aranmaktadır. Ağaç yapısı, q'nun kalitesini ölçmenin bir yolu yani puanlama

fonksiyonu;

$$\widetilde{L}^{(t)}(q) = -\frac{1}{2}\sum_{j=1}^{T}\frac{(\sum_{i\epsilon I_j} g_i)^2}{(\sum_{i\epsilon I_j} h_i + \lambda)} + \gamma T \begin{cases} g_i = \text{Kayıp fonksiyonunun 1. türev fonksiyonu} \\ h_i = \text{Kayıp fonksiyonunun 2. türev fonksiyonu} \\ \gamma = \text{L1 kontrol parametresi} \\ \text{T= yaprak sayısı} \\ \lambda = \text{L2 kontrol parametresi} \end{cases} \tag{2.33}$$

şeklindedir.

2.1.3.1 Tam Açgözlü Algoritması

En doğru ayrımı yapmak için kullanılan aç gözlü algoritması ise; $(\sum_{i\epsilon I_j} g_i)^2$ T. yaprak ile eşleşen örnek olarak tanımlanır. Gerekli hesaplamalar açısından tüm olası ağaç yapılarını sıralamak ve böylece maksimum kayıp azalmasını beklemek işlemsel açıdan zor bir durumdur. Pratikte, yeni öğreniciyi inşa etmek için yapılanlar tek yönlü ile başlar ve tüm eğitim örneklerini içermekle birlikte, her bir özellik için tüm özellikler ve değerler üzerinde yineleme yapılır. Bu algoritma ile ilgili genel denklem Denklem 2.34'te verilmiştir.

Kazanç=Diğer örnek kayıpları− (sol yaprak kaybı +sağ yaprak kaybı) (2.34)

En iyi ayrım için kazanç, pozitif ve minimum ayrım kazanç parametresinden büyük olmalı, aksi takdirde dalda büyümeyi durdurulması gerekmektedir. Her bir temel öğrenicinin her ayrımın bir sonucu olarak, kazanç aşağıdaki gibidir.Algoritmaya ait sözde kod EK-3'de verilmiştir.

$$\text{Kayıp}_{\text{Önceki Ayrım}} = \sum_{j=1}^{T}(-\frac{1}{2} * \frac{(G_L + G_R)^2}{H_L + H_L + \lambda}) + \gamma * T_{\text{ayrımsız}} \tag{2.35}$$

$$\text{Kayıp}_{\text{sonraki Ayrım}} = \sum_{j=1}^{T}(-\frac{1}{2} * \left[\frac{(G_L + G_R)^2}{H_L + H_L + \lambda}\right]) + \gamma * (T_{\text{ayrımsız}} + 1) \tag{2.36}$$

G_L, H_L ifadeleri sol yaprak için kayıp fonksiyonunun birinci türevininin toplamını, G_R,

H_R ise sağ yaprak için kayıp fonksiyonunun birinci türevininin toplamını verir

$$\text{Kazanç} = \text{Kayıp}_{\text{Önceki Ayrım}} - \text{Kayıp}_{\text{Sonraki}} = \frac{1}{2} * \left[\frac{G_L^2}{H_L + \lambda} + \frac{G_R^2}{H_R + \lambda} - \frac{(G_L + G_R)^2}{H_L + H_L + \lambda} \right] - \gamma \tag{2.37}$$

Bu, tam açgözlü yöntemin esas amacı, en yüksek faydayla sonuçlanan özelliği ve ayrım noktasını keşfetmek olmakla beraber, karmaşıklığı $O(n*m)$'dir, burada n, eğitim örneklerinin sayısı ve m ise özellik boyutudur.

2.1.3.2 Ağırlıklı Niceliksel Çizimi Kullanan Yaklaşık Algoritma

Büyük bir veri kümesi durumunda, açgözlü yöntem çok yavaş ve her bir kombinasyonun faydası, olası her özellik ve ayrım noktası üzerinden geçilerek hesaplanmakta, bu yöntem, veriler her potansiyel nokta yerine önceden ayarlanmış yüzdelik dilimlere bölündüğü için daha hızlı ve daha verimli olmaktadır. Yüzdelik dilimleri hesaplamak için ikinci türevin ağırlığı kullanılılır. Bölünmüş Bulma için Yaklaşık Algoritma ile ilgili sözde kod EK-4 de verilmiştir. D_k'ın, tüm eğitim örneklerinin k^{th} özellik değerlerini ve ikinci dereceden Gradyan istatistiklerini içeren bir çoklu küme olduğu varsayıldığında;

$$D_k = \left\{ (x_{1k,h_{1k}}),\ (x_{2k,h_{2k}}), ..., (x_{1n,h_{1n}}) \right\} \tag{2.38}$$

Bunu, yüzdelik dilimini hesaplamak için ağırlıklı ikinci türevi kullanan r_k sıralama fonksiyonunun tanımı üzerine;

$$r_k = \frac{1}{\sum_{(x,k) \in D_k} h} \sum_{(x,k) \in D_k, x < Z} w \left\{ w = \text{ağırlık} \right. \tag{2.39}$$

Dilimlerin boyutunu belirtmek için rank fonksiyonunu kurduktan sonra, ϵ ile ifade edilen yaklaşım faktörü, büyüdükçe daha büyük paketler ve yüzdelikler kullanılır.

$$\text{Ayrım Nokta Adayları} = \{S_{k1}, S_{k2}, ..., S_{kl}\} \tag{2.40}$$

Ayrım noktası adaylarını bulabilmek için aşağıdaki yaklaşım denkleminden

yararlanılır.

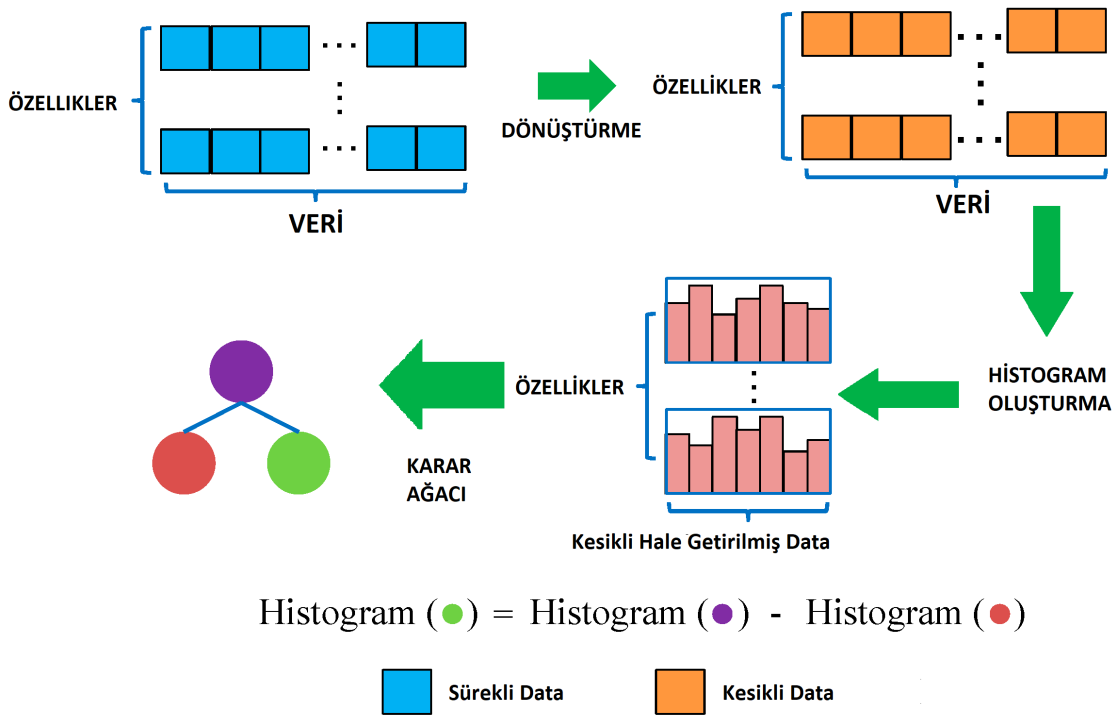
$$\left|r_k(S_{k,j} - r_k(S_{k,j+1})\right| < \epsilon, S_{k1} = min_i x_{ik},\ S_{k1} = max_i x_{ik} \tag{2.41}$$

2.1.3.3 Seyrekliğe Duyarlı Bölünmüş Bulma

Eksik değerler, Aşırı Gradyan İyileştirme'den önceki birçok ağaç algoritması için sorunludur. Aşırı Gradyan İyileştirme'de ayrımlar ve ayırma noktaları oluşturulduğunda yalnızca eksik olmayan numune verileri toplanır ve ardından eksik değerlere sahip numuneler yerleştirildiğinde ağacın hangi tarafının en büyük artışı sağlayacağı kontrol edilir. Seyrekliğe Duyarlı Bölünmüş Bulma ile ilgili sözde kod EK-5'te verilmiştir.

2.1.4 Hafif Gradyan İyileştirme Makinesi (LGBM)

Hız açısından Aşırı Gradyan İyileştirme algoritması'nın bir nebze önünde yer alan Hafif Gradyan İyileştirme algoritması,Aşırı Gradyan İyileştirme'nın Ağırlıklı Nicel Çizim Kullanan Yaklaşık Algoritması'na benzer olan Histogram Algoritması'na oldukça kullanırken, veri kümesindeki her özellik, kümelere bölünür [90]. İlgili Histogram Algoritması'nın genel gösterimi Şekil 2.3'de verilmiştir.



Şekil 2.3 Histogram Algoritması genel gösterimi

Hafif Gradyan İyileştirme'nin, her bir bölünmenin kârını hesaplamada verimliliği arttırmak için kullanılan histogram çıkarma işlemi, hız kazanmak için, kullanılan RAM miktarını azaltmak ve paralel çalışırken iletişim maliyetini azaltmak gibi dört temel avantajı vardır. Ücretsiz ve açık kaynaklı bir dağıtılmış Gradyan İyileştirme yapısıdır ve sıralama, sınıflandırma ve diğer makine öğrenimi görevleri için karar ağacı algoritmalarına dayanır. Ayrıca Hafif Gradyan İyileştirme'de seyrek optimizasyon ve paralel eğitim gibi bir dizi Aşırı Gradyan İyileştirme avantajı mevcut olmakla birlikte, Hafif Gradyan İyileştirme'yı diğerlerinden ayıran şey, optimum ayırım noktasını belirlemek için tüm potansiyel özelliklere ve ayırım noktalarına bakmak zorunda olmasıdır. Bunun için Hafif Gradyan İyileştirme algoritması, Gradyan Tabanlı Tek Taraflı Örnekleme (GOSS) ve Özel Özellik Paketleme (EFB) adı verilen ve algoritmanın yüksek düzeyde doğruluk sağlayan, aynı zamanda daha hızlı çalışmasına olanak tanıyan iki yeni teknik kullanır [90].

2.1.4.1 Gradyan Tabanlı Tek Taraflı Örnekleme

Geleneksel Gradyan İyileştirme her farklı özellik (feature) için bilgi kazancını (information gain) hesaplamak adına tüm veri örneklerini tarar. Hafif Gradyan İyileştirme, Gradyan İyileştirme Karar Ağaçları'nın veri örnekleri için farklı bir ağırlığı olmadığından, Karar ağaçlarının doğruluk oranını muhafaza ederken, veri sayısını azaltmayı amaçlayan GOSS özelliğini kullanır. Böylece, verinin dağılımını fazla değiştirmeden veri miktarı azaltılır. Daha büyük bir Gradyan, çeşitli Gradyanlara sahip veri örneklerinin oynayacağı farklı roller olduğundan, bilgi kazanımının hesaplanmasına daha fazla katkıda bulunacaktır. Sonuç olarak, GOSS'ta yüksek Gradyanlı örnekler tutulur. Aynı zamanda düşük Gradyanlı rastgele örnekleme durumları için, yalnızca bir seçimin etkisini telafi etmek için bilgi kazancını hesaplar. Küçük Gradyanlı veri örnekleri için sabit bir çarpan sağlar. Bu nedenle GOSS, bilgi toplamanın doğruluğunu korumak için yüksek Gradyanlı örnekleri tutar ve küçük Gradyanlı örnekleri rastgele yok eder. Ayrıca, RAM kullanımını daha da aza indirmek, optimal özellikleri ve ayrım noktalarını belirlemek, hesaplama süresinden tasarruf etmek için GOSS yöntemini kullanır. Optimum bölünmeleri belirlerken zamanı azaltmak için düşük Gradyanlı örnekleri hariç tutar. Gradyan Tabanlı Tek Taraflı Örnekleme ile ilgili sözde kod EK-7'te verilmiştir.

2.1.4.2 Özel Özellik Paketleme

Özel Özellik Paketleme, doğruluk oranını korurken, değişken sayısını azaltmayı ve buna bağlı olarak modelin verimliliğini arttırmayı amaçlamakla birlikte EFB'nin, paket oluşturmak ve değişkenleri aynı pakette birleştirmek şeklinde iki işlem adımında

gerçekleşir. Özel Özellik Paketleme ile seyrek özellikleri birleştirip daha yoğun özellikler oluşturur. Öğrenmeyi hızlandırır ve buna bağlı olarak bazı özellikleri tek bir özellik haline getirerek karmaşıklığı azaltır. Daha düşük bellek tüketimi ile birlikte daha hızlı eğitim süreci sağlar. Başka bir deyişle verimliliği artırmak için Özel Özellik Paketleme, yüksek doğruluk derecesini korurken boyutsallığı azaltarak çeşitli özellikleri birleştirmektedir. Hangi özelliklerin birlikte paketlenmesi gerektiğini belirlemek ve paketin nasıl oluşturulacağını belirlemek gibi önemli görülmesi gereken konular olmasıyla beraber, Hafif Gradyan İyileştirme algoritmasında, veriye Özel Özellik Paketleme uygulandıktan sonra ağaç oluşturmakta ve klasik Gradyan İyileştirme'deki mantık ile öğrenme başlamaktadır. Fakat Gradyan İyileştirme işleminde GOSS yaklaşımı uygulanır. Özetlemek gerekirse, GOSS daha az öneme sahip verileri ihmal ederek bilgi kazanımını hesaplamak için veri boyutunu azaltır. Özel Özellik Paketleme boyutsallığı azaltmak için değişkenleri bir araya getirir. Bu iki özellik, Hafif Gradyan İyileştirme eğitim sürecinin verimliliğini arttırır. Açgözlü Paketleme ve Özel Özellikleri Birleştirme ile ilgili sözde kodlar EK-8 ve EK-9'da verilmiştir.

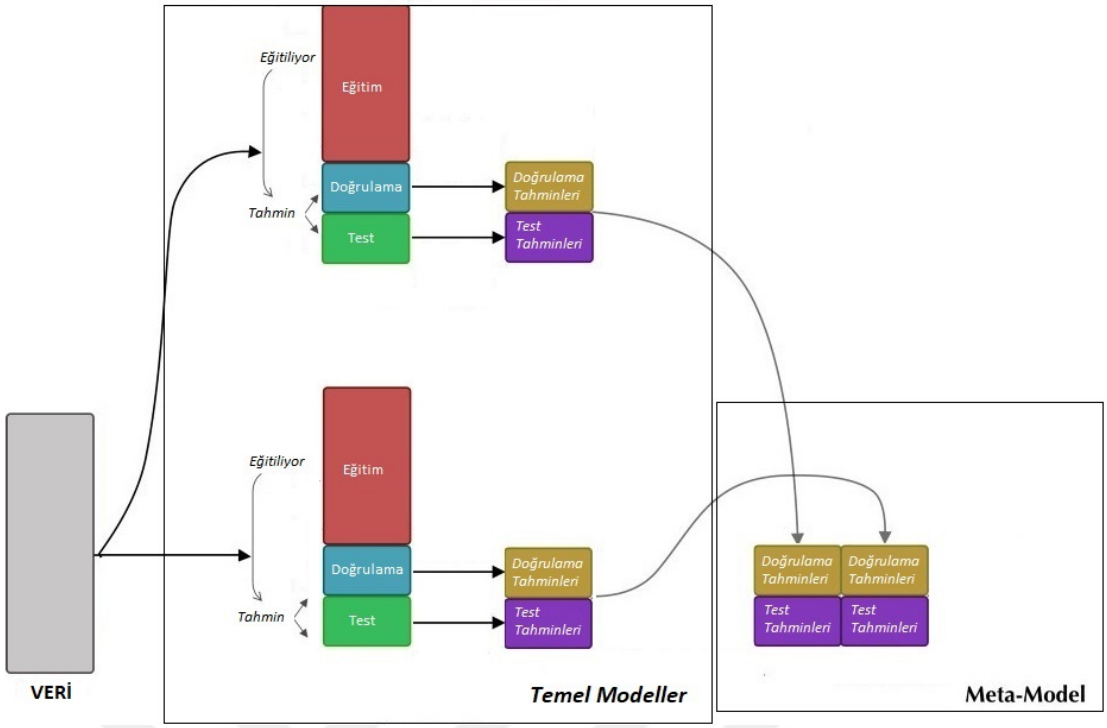
2.2 İleri Topluluk Öğrenmesi Teknikleri

Geleneksel Topluluk Öğrenmesi tekniklerinin yanı sıra; son zamanlarda birçok yarışmada kendini gösteren bir diğer tür Harmanlama(Blending) tekniğidir. 2009'daki Netflix ödülü sırasında öğrenicileri Topluluk Öğrenmesi mantığı ile eğitmek için kullanılan yöntem olan Harmanlama Yöntemi, mevcut Netflix algoritmasından daha iyi performans göstererek film önerisi tahminlerinde yüzde 10 performans artışı elde etmiş ve bu başarı ile algoritma 1 milyon ABD doları ödül kazandırmıştır [92].

2.2.1 Harmanlama (Blending)

Harmanlama, katkıda bulunan birden çok öğreniciden gelen tahminlerin en iyi şekilde nasıl birleştirileceğini belirlemek için kullanılan bir topluluk makine öğrenimi tekniği olmakla birlikte, uydu üzerine yapılan çalışmalardan [93], güneş enerjisi güç tahminine [94] değin geniş kullanım alanına sahiptir.

Meta-modelin bir test (Hold-out) veri kümesinde yapılan tahminler üzerinde eğitildiği Topluluk Öğrenmesi yöntemi olan Harmanlama Yöntemi, nihai tahminleri oluşturmak için tahminciler arasında fikir birliğini kullanan bir birleştirme yöntemi olup, arkasındaki fikir, farklı makine öğrenimi algoritmalarını birleştirmek ve nihai sonucu tahmin etmek için bir çoğunluk oyu veya sınıflandırma durumunda ortalama tahmin edilen olasılıkları kullanmak olarak tanımlanmaktadır.



Şekil 2.4 Harmanlama Yöntemi

Eğitim verilerini tahminleyen temel modeller ve tahminlenen değerlerin artıklarıyla eğitilen Meta-Model, temel modellerin tahminlerini en iyi şekilde nasıl birleştireceğini belirler. Harmanlama mimarisi Şekil 2.4 gösterilmiştir. Genel harmanlama modelinde Şekil 2.4'te görüldüğü üzere iki katman vardır. Temel Modeller seviyesinde, orijinal eğitim setini eğitim verisi olarak ve doğrulama seti ise eğitilen temel modelleri test etmek için kullanılır. Doğruluğu kanıtlanan model için, test (Hold-out) seti kullanılarak doğruluk kanıtlanması yapılır. Oluşan doğrulama tahminleri ve test tahminleri, modelin ikinci katmanındaki Meta-Modeli eğitmek için eğitim seti olarak kullanır.

2.2.2 İyileştirme Tabanlı Otomatik-Harmanlama (Boosting Based Auto-Blending)

Genel anlamda literatürdeki kullanılan geleneksel temel modellerin aksine İyileştirme Tabanlı Otomatik-Harmanlama Yöntemi'nde, İyileştirme Tabanlı algoritmalar kullanılmış olup, kullanılan İyileştirme algoritmalarının hata metriğine göre en iyi parametreleri belirlenip, en az hatalı olan parametrelerle temel modeller eğitilir. Temel model eğitimi sonrasında, oluşacak olan meta modelde ise İyileştirme Yönteminin en ileri yöntemleri olan Aşırı Gradyan İyileştirme ve Hafif Gradyan İyileştirme yöntemleri kıyaslanır. En düşük hatalı olan ile Meta-Model eğitimi yapılır ve yukarıda anlatılan süreç, İyileştirme Temelli Harmanlama Yöntemi

olarak adlandırılabilir. Ayrıca meta-model eğitiminde, literatürde genel anlamda lineer regresyon ve lojistik regresyon gibi regresyon türevleri kullanılırken, İyileştirme-tabanlı harmanlamada meta-model eğitimi sırasında Aşırı Gradyan İyileştirme ile Hafif Gradyan İyileştirme yöntemlerinden meta-modele göre en iyi performanslı olanı kullanılmış olup, oluşturulan modelin başarısı Bölüm-5'teki sonuçlarla kanıtlanmıştır.

2.2.3 Uygulamalarda Kullanılan Parametreler

Genel anlamda Topluluk Öğrenmesi algoritmalarında eğitim sırasında kullanılan parametreler aşağıdaki verilmiş ve hiper parametre araması için ilkel yöntemlerden olan grid arama algoritması kullanılmıştır.

(I) Yenileme Sayısı (Number of Estimator) (η) Temel olarak İyileştirme ağaç modellerinde eğitim sürecinin yineleme sayısıdır. Bu değerin arttırılması modelin performansını da artırabilir. Ancak yüksek bir değer sadece eğitim süresini uzatmakla kalmaz, aynı zamanda modeli aşırı öğrenmeye de götürebilir. Bunu engellemek için doğrulama datası kullanılması gerekmektedir.

(II) Öğrenme Oranı (Learning Rate) (α) değerinin küçük olması ve dolayısıyla aşırı öğrenmeye sorunuyla karşı karşıya kalmaları, Gradyan destekli yöntemlerle ilgili bir sorun olara gözükmektedir.Bunu önlemenin etkili bir yolu, öğrenme hızı veya küçülme parametresi olarak adlandırılan eğitimi yavaşlatmak için bir katsayı kullanmaktır. Bu değerler genellikle 0.1'den küçük alınır.

(III) Maksimum Derinlik (Max Depth) Bir modelin maksimum derinliği için kullanılan (ϕ), daha yüksek derinliğe sahip modelleri kullanarak modeli aşırı öğrenmedan kontrol edebilir. Daha yüksek derinlik konfigürasyonlarına sahip modeller, eğitim örneklerine özgü ilişkileri öğrenmede daha başarılıdır.

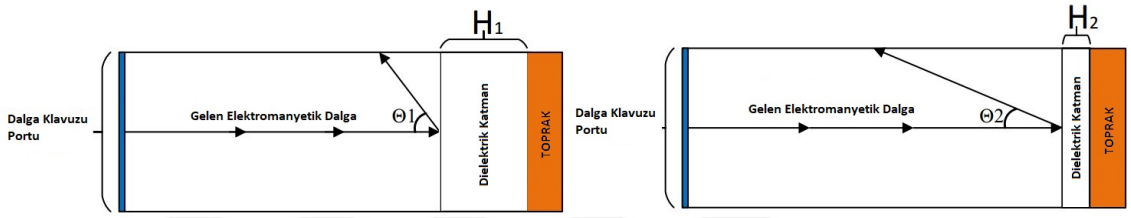
3
TOPLULUK ÖĞRENMESİ YÖNTEMİNİN LİTERATÜRDEKİ PROBLEMLERE UYGULANMASI

Literatürde mevcut yaklaşımlardan farklı olarak, Topluluk Öğrenmesinin Aşırı Gradyan İyileştirme Yöntemi algoritması regresyon yönteminin performansını ölçmek için mevcut çalışmaların dataları ile ilerlenmiştir ve algoritma başarısı test edilmiştir. Mevcut çalışma örneklerinde, yakın zamanda yayınlanan [95], [96] referanslı çalışmaları, saçılma parametrelerinin modellenmesinin ve mikrodalga aşamalarının yansıma fazının son teknoloji tekniklerle modellendiği referans çalışmaları olarak alınmıştır. Böylece, bu yolla Aşırı Gradyan İyileştirme Yöntemi'nin performansı, çalışma durumları Bölüm 3.1 ve Bölüm 3.2 kullanılarak mevcut çalışmalarla karşılaştırılmıştır. Tüm çalışma durumları ve Aşırı Gradyan İyileştirme Yöntemi regresyon modellerini oluşturmak için Intel Core(TM) $i5-8365U$ CPU @ 1.6 GHZ, RAM 8 GB donanıma sahip bilgisayarlar kullanılmıştır.

3.1 Doğrulama Çalışması 1: Uniform Olmayan Bir Yansıtıcı Dizi Öğesinin Yansıma Fazı Özelliklerinin Modellenmesi Üzerine Yapay Zeka Algoritmalarının Uygulanması

Bu bölümde [95] referanslı makalede üzerinde çalışılan, Aşırı Gradyan İyileştirme Yöntemi algoritmasının performansını ölçmek için Şekil 3.1'deki uniform olmayan bir Yansıtıcı dizi elemanının modellenmesi çalışmasında kullanılan S parametreleri model girdisi olarak kullanılmıştır. Yansıtıcı dizi antenler, yüksek performanslı antenler elde etmek için yaygın olarak kullanılan tasarımlardan biri olup, yansıtıcı dizi tasarımlarının en ilginç özelliklerinden biri, hem geleneksel parabolik reflektörün hem de faz dizili antenlerin faydalarını besleme ağı olmadan birleştirme yeteneğidir. Yansıtıcı dizi tasarımında, farklı birim elemanları dizisi, gelen EM dalgalarını yansıtmak, besleme anteni tarafından üretilen küresel bir dalgayı düzlem dalgaya dönüştürmek ve belirli bir yönde bir ışını oluşturmak için özenle seçilmiş kombinasyonlardan oluşmaktadır [97]. Yansıtıcı dizi tasarımlarındaki problemlerin

başında, yüksek performanslı bir donanım ihtiyacı veya uzun simülasyon süreleri gerektiren tasarım optimizasyon süreci gelmektedir [98, 99]. Hızlı tasarım optimizasyonuna sahip olmak için etkili çözümlerden biri olarak da, birim elemanın geometrik tasarım parametreleri ile yansıyan EM dalga fazı arasında bir eşleme oluşturan veriye dayalı vekil modellerin kullanılması gelmektedir. Bu makalede, geometrik tasarım parametreleri, operasyon sıklığı ve işleyişine göre mikroşerit tek biçimli olmayan yansıtıcı dizinin yansıma aşaması özelliklerinin bir temsili modelini oluşturmak için sembolik regresyon, yapay sinir ağları ve derin öğrenme algoritmaları gibi yapay zeka tabanlı algoritmalar kullanılmıştır.[95] referanslı makale sonucunda, derin öğrenme tabanlı modellemenin, diğer yöntemlere göre en iyi genel performansı elde ettiği gösterilmiştir [95].



Şekil 3.1 Bir non-uniform yansıtıcı dizi elemanının şeması

Çalışmada kullanılan veri seti Tablo 3.1'de sunulmakta olup, burada grid örnekleme yöntemi kullanılarak bağıl dielektrik geçirgenliği, substrat yüksekliği ve frekans gibi tasarım değişkenlerinden toplam 11152 örnek üretilmiştir.

Tablo 3.1 Değişken aralıkları

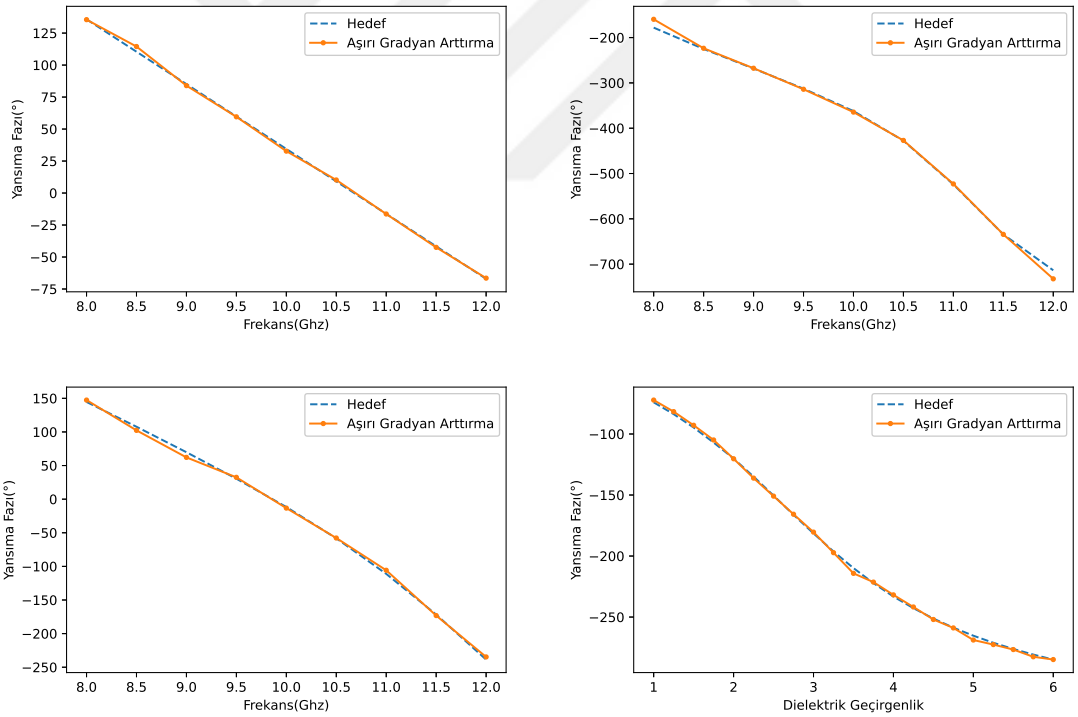
Parametre	Örnek Aralığı	Örnek Adımı
Dielektrik Geçirgenlik ϵ_r	[1 , 6]	0.25
substrat Yüksekliği h (mm)	[0.5 , 15]	0.25
Frekans fr (GHz)	[8 , 12]	0.5
Veri Boyutu	11152	

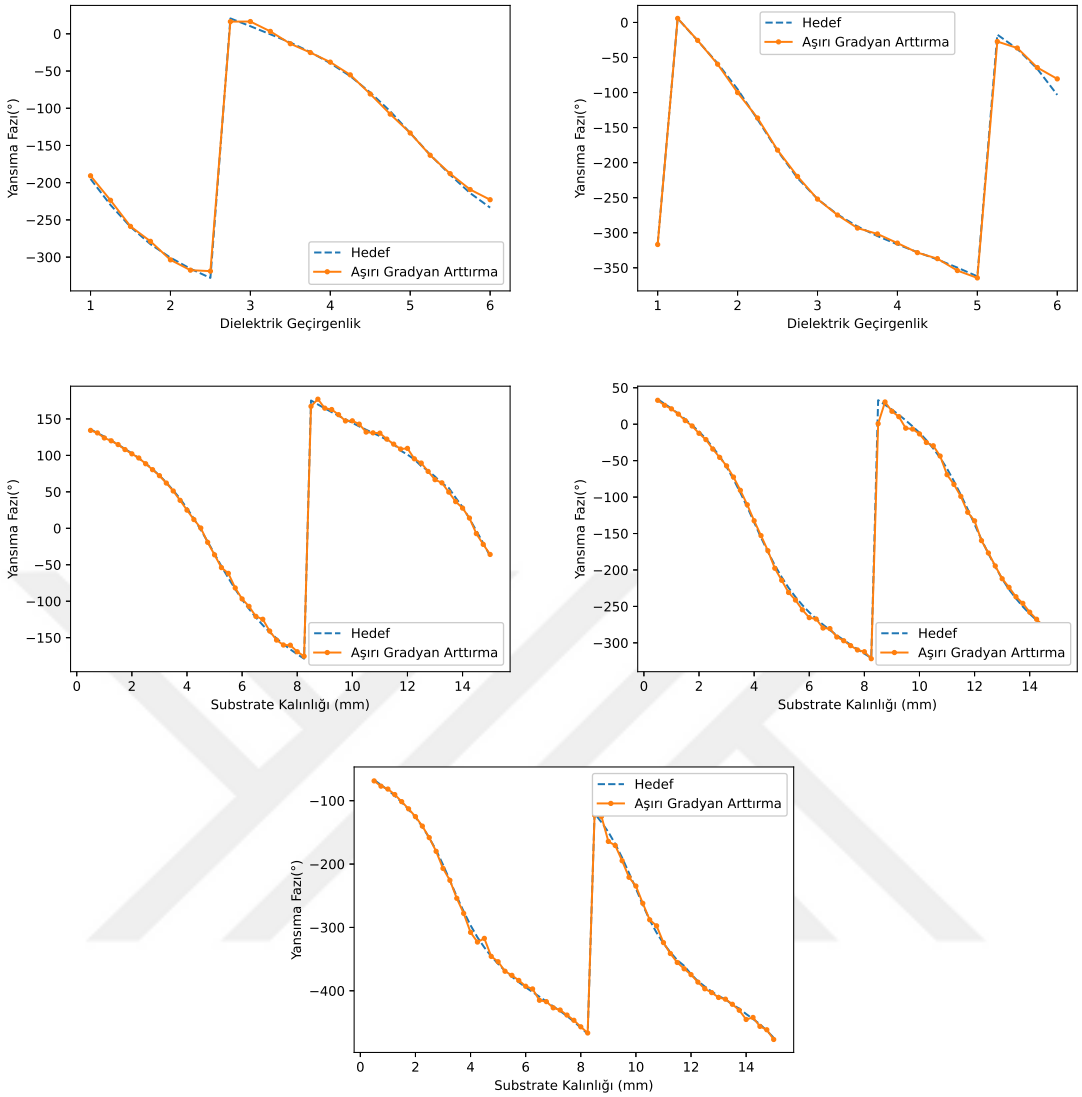
[95] referanslı makaledeki modellere benzer şekilde, önerilen yöntemin performans değerlendirmesi için $k = 2$ işlemiyle K-katlı çapraz doğrulama kullanılmıştır. Derin öğrenme tabanlı model, literatürdeki muadil yöntemlere kıyasla çok daha iyi bir performans elde etmekle kalmayıp aynı zamanda çok daha kararlı bir regresyon performansına sahip olmasıyla dikkat çekici bir performans sunmuştur. Bu çalışmada, Aşırı Gradyan İyileştirme Yöntemi'nin performansı, [95] içinde verilen çalışma durumu için aynı koşullar altında test edilmiştir. Verilen donanım için Aşırı Gradyan İyileştirme Yöntemi regresyon modelinin genel eğitim süresi yaklaşık 70 saniyedir ve performans sonuçları Tablo 3.2'deki [95] adlı makalenin sonuçlarıyla karşılaştırılır. Tablo 3.2'de görüldüğü gibi, önerilen Aşırı Gradyan İyileştirme Yöntemi regresyon yöntemi, IBK (17.87), Kstar (15.01) ve DRN'nin (4.57) karşılık gelen yöntemlerine

kıyasla daha iyi Ortalama Mutlak Hata performansı (3.77) elde eder. Ayrıca, seçilen tasarımlar için bazı görselleştirilmiş sonuçlar (Şekil 3.2), önerilen Aşırı Gradyan İyileştirme Yöntemi algoritmasının tahmin duyarlılığının her bir değişken için çalışıldığında elde edilen sonuçlar Tablo 3.3'te sunulmuştur.

Tablo 3.2 Aşırı Gradyan İyileştirme ve muadili regresyon algoritmalarının karşılaştırılması

Yöntem	**Kullanıcı Tanımlı Parametreler**	**Ortalama Mutlak Hata**
IBK [95]	KNN:2, Batch Boyutu:100, Arama Algoritması: Doğrusal Arama (Manhattan Uzaklığı)	17.87
Kstar [95]	Global Bend: 1	15.01
DRN [95]	Blok Derinliği: 3 Nöron Sayısı : 64	**4.57**
Aşırı Gradyan İyileştirme[100]	Öğrenme Oranı: 0.4 Maksimum Derinlik: 4 Yenileme Sayısı:2000	**3.77**





Şekil 3.2 (1.sıra-sol) $\epsilon_r = 1$, H=0.5mm, (1.sıra-sağ) $\epsilon_r = 3.5$, H=10mm, (2.sıra-sağ) $\epsilon_r = 5$,H=15mm, (2.sıra-sağ) H=5mm, fr= 10GHz, (3.sıra-sol) H=10mm, fr= 10GHz, (3.sıra-sağ) H=15mm, at 10GHz, (4.sıra-sol) ϵ_r=3.5, fr= 8GHz, (4.sıra-sağ) ϵ_r=3.5, fr= 10GHz, (5.sıra) $\epsilon_r = 3.5$, fr= 12GHz için Aşırı Gradyan İyileştirme Yöntemi algoritmasının performans sonuçları

Tablo 3.3 Farklı senaryolar için Aşırı Gradyan İyileştirme yöntemi modellerinin performans karşılaştırması

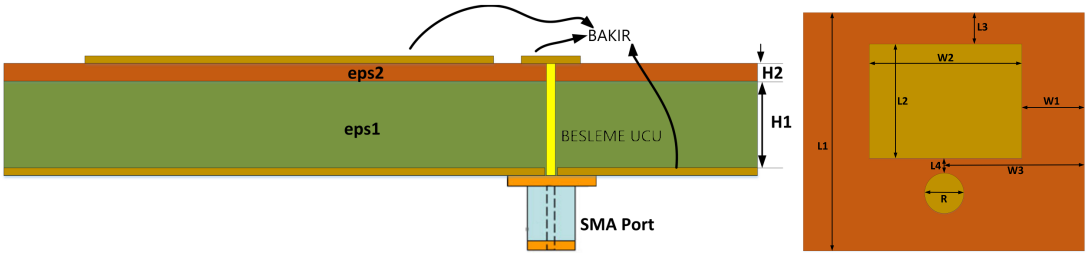
Giriş Parametreleri	Dielektrik Geçirgenlik	substrat Yüksekliği	Frekans	Ortalama Mutlak Hata
a	1	0.5	[8, 12] Adım Sayısı:0.5	1.1934
b	5	15	[8, 12] Adım Sayısı:0.5	2.2234
c	3.5	10	[8, 12] Adım Sayısı:0.5	4.2094
d	[1,6] Adım Sayısı:0.25	5	10	1.6506
e	[1,6] Adım Sayısı:0.25	10	10	3.6956
f	[1,6] Adım Sayısı:0.25	15	15	3.6373
g	3.5	[0.5,15] Adım Sayısı:0.25	8	2.2521
h	3.5	[0.5,15] Adım Sayısı:0.25	10	2.6045
i	3.5	[0.5,15] Adım Sayısı:0.25	12	2.6283

Sonuçlardan da görülebileceği gibi, önerilen Aşırı Gradyan İyileştirme Yöntemi tabanlı regresyon modeli, aşırı öğrenme sağlamadan iyi bir performans elde etmiştir. Bu nedenle, Aşırı Gradyan İyileştirme Yöntemi'nin benzer sistemler için yansıtıcı dizi elemanlarının yansıma fazını modellemek için verimli bir araç olarak kullanılabileceği sonucuna varılabilir. Bir sonraki alt bölümde, bir mikroşerit yama anten tasarımının saçılma özelliklerinin gerçek ve sanal kısımlarının tahmini için Aşırı Gradyan İyileştirme Yöntemi'nin regresyon performansını analiz etmek için ikinci bir çalışma durumu incelenmiştir.

3.2 Doğrulama Çalışması 2: Kapasitif Besleme Anteninin Hassas Saçılma Parametre Tahmini İçin Derin Öğrenme Tabanlı Modifiye MLP Modeli

Mikroşerit yama tasarımları, kablosuz iletişim sistemlerinin düşük profilli, yüksek kazançlı, spesifik radyasyon paterni veya geniş çalışma bandı gibi yüksek gereksinimlerine akıllı çözümler sunma potansiyeline sahip en yaygın kullanılan anten tasarımlarındandır.Radyasyon elemanının geometrik tasarım değişkenleri ve şekli, optimal tasarım değişkenlerinin belirlenmesinin zorlu birçok boyutlu optimizasyon problemi haline geldiği yüksek performanslı anten aşamalarının tasarımında anahtar unsurları arasında gösterilmektedir.

Diğer herhangi bir RF tasarımında olduğu gibi, geometrik tasarım değişkenleri ile istenen çıktı özellikleri (Kazanç, Geri Dönüş kaybı vb.) arasındaki ilişkiler doğrusal ve doğrusal olmayan bileşenlerden oluşmaktadır. [96] referanslı makaledeki mikrodalga aşamalarının hesaplamalı olarak verimli tasarım optimizasyon sürecini gerçekleştirmek için literatürde birçok çalışma yapılmıştır.



Şekil 3.3 (a) Yan, (b) Üst, kapasitif besleme anteni şematik görüntüsü

[96] referanslı makalede, kapasitif beslemeli bir antenin modellenmesi için değiştirilmiş birçok katmanlı algılayıcı (M2LP) modeli önerilmiştir. Çalışılan anten şeması Şekil 3.3'te, eğitim ve test veri setleri ile birlikte Tablo 3.4'te sunulmuş olup verilen değişken aralıkları içinde hem eğitim hem de test veri setlerini oluşturmak için ızgara örnekleme yöntemi kullanılmıştır. Bu çalışma durumunda, antenin (Şekil 3.3) S_{11} karakteristiği için Tablo 3.4'te verilen geometrik tasarım değişkenlerine göre bir regresyon modeli oluşturulması amaçlanmıştır. Regresyon modelinin çıktısı, anten portunun saçılma parametresinin gerçek ve sanal kısımlarıdır.

Tablo 3.4 Eğitim ve test özellikleri (mm)

	Eğitim		**Test**	
Parametre	**Aralık**	**Adım Boyutu**	**Aralık**	**Adım Boyutu**
R	{4 , 6 , 8}	2	{5 , 7}	2
L4	[0.5 , 2.5]	0.5	[0.5 , 2.5]	0.5
L2	[20 , 60]	5	[20 , 60]	5
H1	[10 , 20]	5	[10 , 20]	5
H2	[0.25 , 1]	0.25	[0.25 , 1]	0.25
f : Frekans (GHz)	[1,10]	0.5	[1,10]	0.5
Toplam Örnek	30780		20520	

Aşırı Gradyan İyileştirme Yöntemi regresyon modeli için [96] referanslı makalede uygulanan eğitim ve test prosedürlerinin aynısı alınmış olup, Optimum olarak seçilen hiperparametreler, öğrenme oranı: 0.2, maksimum derinlik: 10, yenileme sayısı: 200 olarak alınır ve modelin genel eğitim süresi yaklaşık 2 dakika 32 saniyedir. Modelin performans sonuçlarının, [96] referanslı makalede elde edilen sonuçlarla karşılaştırılması Tablo 3.5'te sunulmuştur.

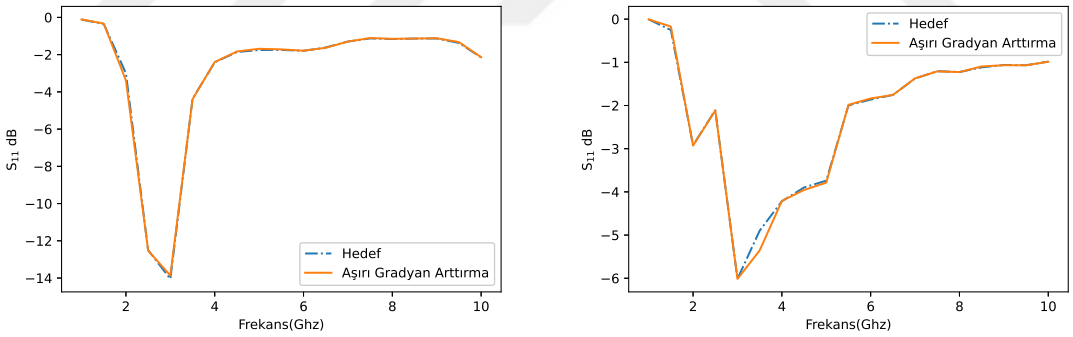
Önerilen algoritmanın tek çıktının bir dezavantajı olduğu ve çıktıların reel ve imajiner kısımları için farklı modeller gerektirdiği unutulmamalıdır ve görüldüğü gibi Aşırı

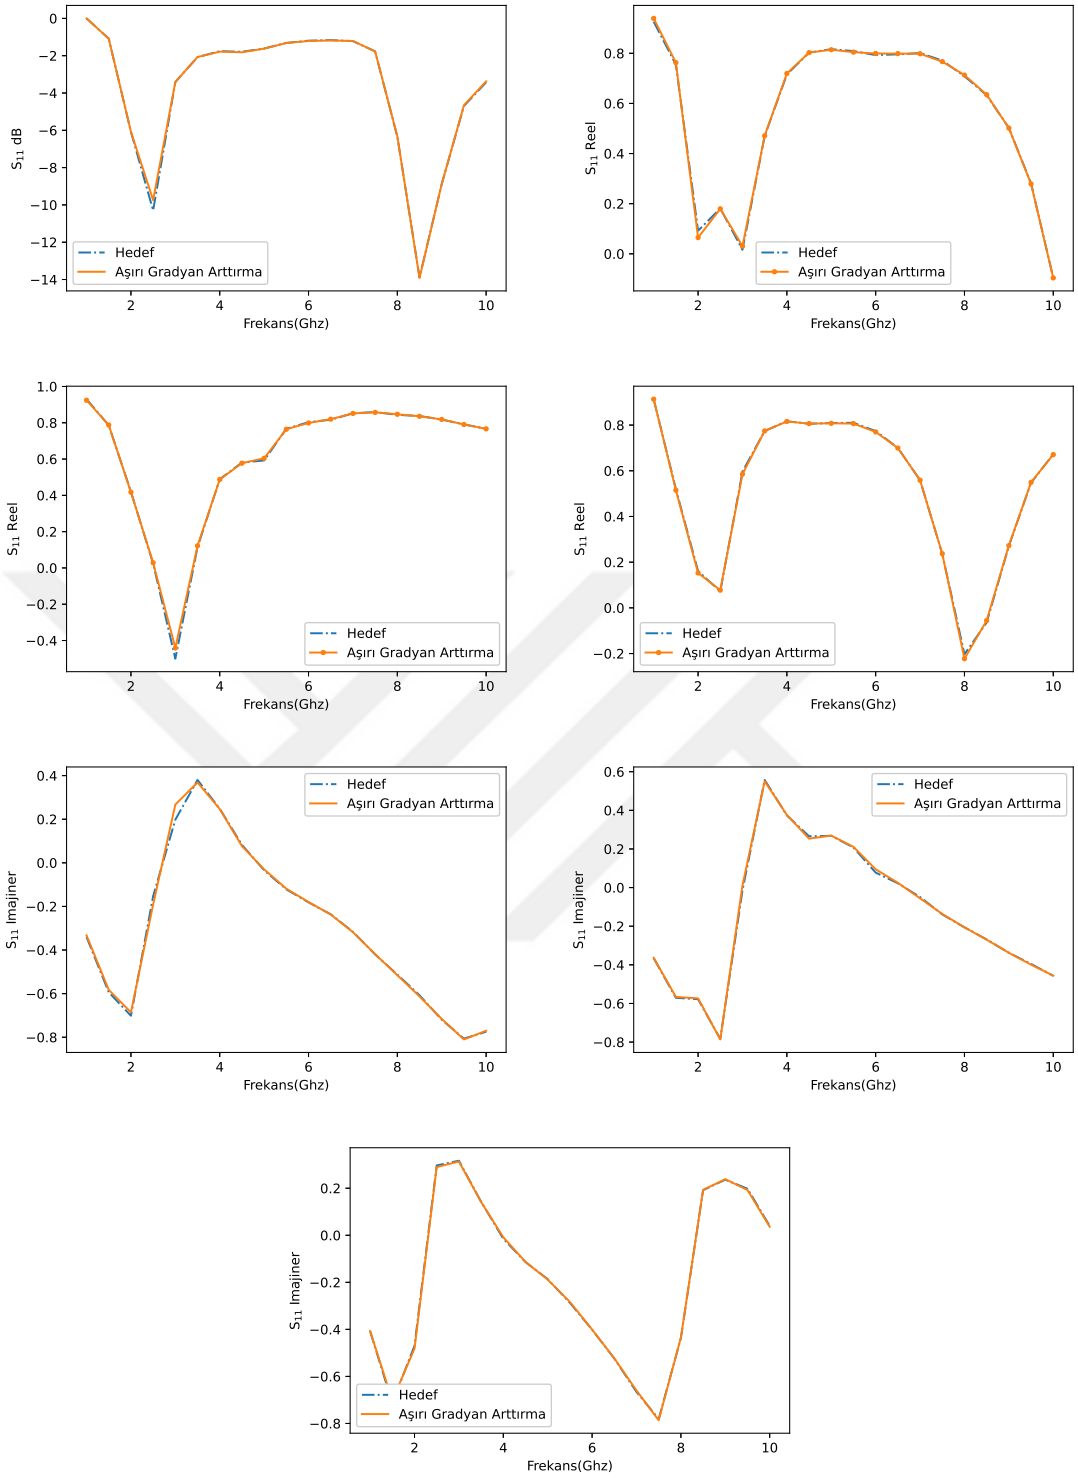
Gradyan İyileştirme ($10.2\times\times10^{-3}$), genel olarak karşılık gelen algoritmaya kıyasla ($11.7\times\times10^{-3}$) daha iyi bir performans elde etmektedir.

Tablo 3.5 Aşırı Gradyan İyileştirme ve M2LP karşılaştırması

MAE Aşırı Gradyan İyileştirme ve M2LP karşılaştırması ($\times10^{-3}$)							
	REAL			**IMAGE**			**Ortalama**
Algoritmalar	**min**	**max**	**ort.**	**min**	**max**	**ort.**	**0.5x (Real+ imajiner)**
ML2P[96]	11.800	14.300	12.700	11.600	13.200	12.200	11.700
Aşırı Gradyan İyileştirme[100]	10.434	11.41	10.967	10.007	11.033	10.626	10.221

Aşırı Gradyan İyileştirme Yöntemi regresyon modelinin performansını görselleştirmek için Şekil 3.4'te önceki çalışma durumuna benzer şekilde, Tablo 3.6'de seçilen bazı geometrik tasarımlar genişletilmiş test verileri olarak alınmıştır. Tablo 3.6 ve Şekil 3.4'dan görüldüğü gibi, önerilen Aşırı Gradyan İyileştirme Yöntemi modelinin hedeflenen saçılma özellikleri ve tahmini elden ele verilmektedir. Dolayısıyla seçilen bu çalışma durumu ve benzerleri için önerilen modelin verimli ve etkili bir çözüm olduğu söylenebilmektedir.



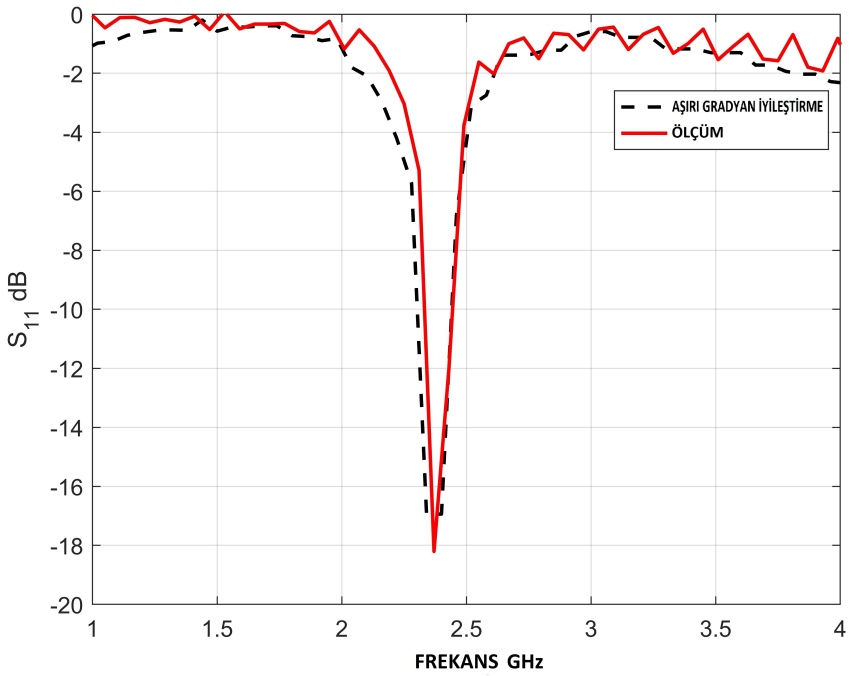


Şekil 3.4 Aşırı Gradyan İyileştirme yöntemi performans sonucu

Tablo 3.6 ve Şekil 3.4'dan görüldüğü gibi, önerilen Aşırı Gradyan İyileştirme Yöntemi modelinin hedeflenen saçılma özellikleri ve tahmini elde edilmektedir. Dolayısıyla seçilen bu çalışma durumu ve benzerleri için önerilen modelin verimli ve etkili bir çözüm olduğu söylenebilmektedir. Ayrıca, Şekil 3.5'de modelin performansı, bir prototip antenin deneysel sonuçlarıyla da karşılaştırılmıştır. Prototip antenin geometrik tasarım parametreleri [mm] olarak şu şekildedir: L1=112,L2=W2=40.3, L3=35.3, L4=2.0, R=6.35, W1=32, W3=51.3, H1=0.7, H2=10.25[96]. Bir sonraki bölümde, önceki iki çalışma durumuna göre daha az eğitim ve test verisi örneklerine sahip Aşırı Gradyan İyileştirme Yöntemi modelinin regresyon performansını ölçmek için başka bir anten tasarımı ele alınmıştır.

Tablo 3.6 Bazı seçili durumlar için Aşırı Gradyan İyileştirme yöntemi uygulamaları

Case Number	**Giriş Parametreleri**						**Ortalama Mutlak Hata ($\times 10^{-3}$) (M2LP[96])**	**Ortalama Mutlak Hata ($\times 10^{-3}$) Aşırı Gradyan İyileştirme**
	R	**L4**	**L2**	**H1**	**H2**	f	**Reel imajiner**	**Reel imajiner**
a	5	1,5	40	15	0.25	[1,10]	8.8 6.7	7.7 8.8
b	7	2,5	55	10	0.25	[1,10]	7.1 7.3	3.2 6.3
c	5	2,5	55	20	0.25	[1,10]	11.6 9.5	4.3 4.3

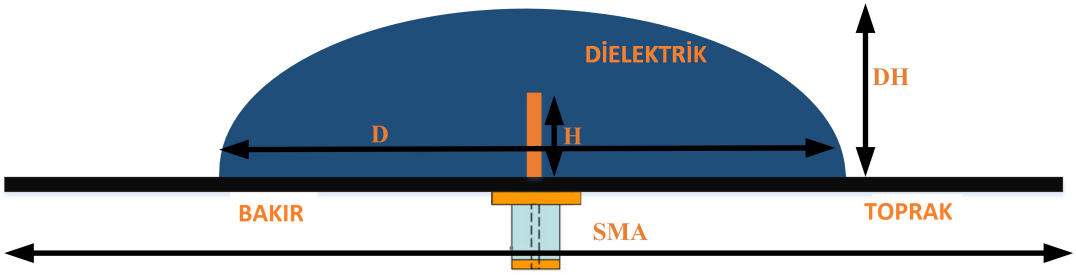


Şekil 3.5 S_{11} Simülasyonu ve Ölçümü

4
TOPLULUK ÖĞRENMESİ KULLANARAK MİKRODALGA ELEMANLARININ MODELLENMESİ

4.1 Yarım Küresel Dielektrik Antenin Modellenmesi

Bu bölümde, seyrek veri setleri ile modelleme problemlerinde Aşırı Gradyan İyileştirme algoritmasının performansını araştırmak için çok daha küçük örneklem büyüklüğü ile benzersiz bir anten tasarımı dikkate alınmıştır. Önerilen regresyon modeli için Şekil 4.1'de verilmiş olan yarım küresel dielektrik anten tasarımı incelemeye alınmıştır. Yüksek kazanç özelliklerine sahip anten tasarımları elde etmek için yaygın olarak kullanılan çözümlerden biri, tasarım süreçleri doğru ve güvenilir bir optimizasyon süreci gerektiren dielektrik yüklü antenler olup, [101] referanslı çalışma için benzersiz bir 3B yazdırılabilir anten tasarımı, Şekil 3.5'deki tasarım parametreleriyle birlikte sunulmuştur. Bu çalışmada, daha önceki çalışmalara kıyasla çok daha seyrek veri setleri kullanılarak, anten saçılım parametrelerinin geometrik tasarım parametreleri varyasyonuna dayalı vekil tabanlı bir modelinin oluşturulması amaçlanmıştır.



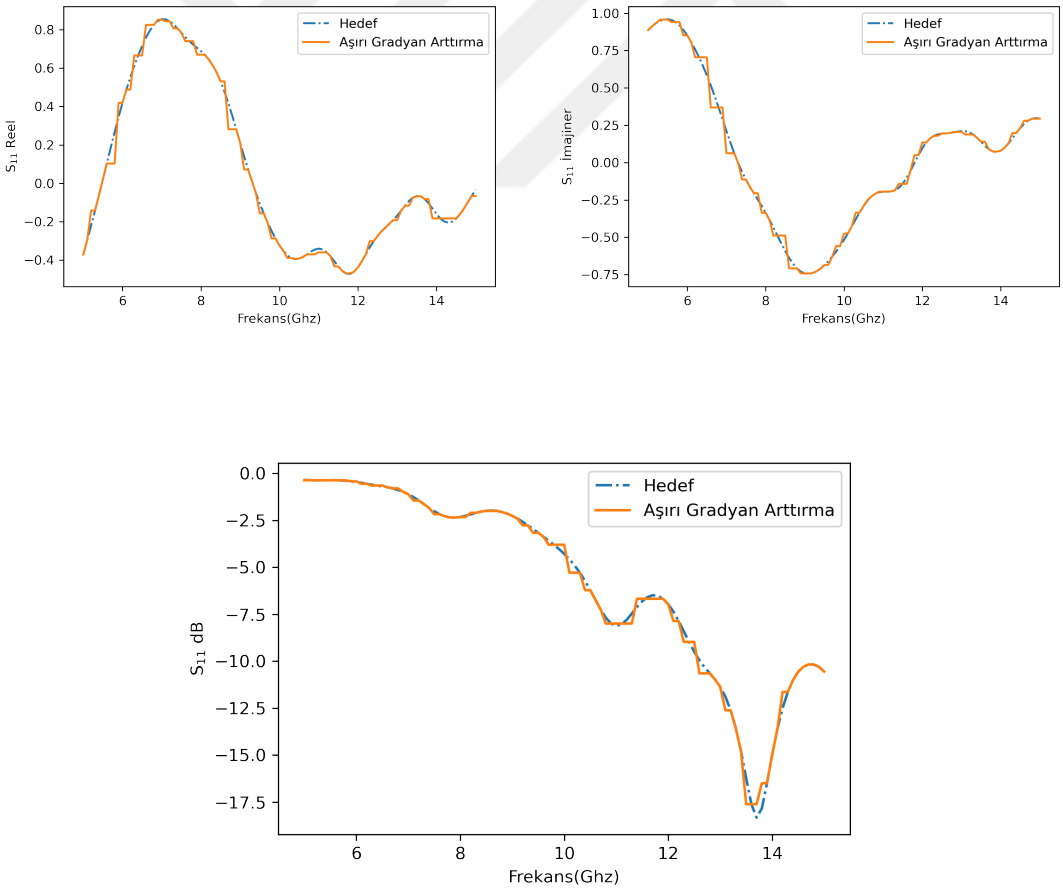
Şekil 4.1 Yarım Küresel Dielektrik Antenin Şeması

Anten tasarımının eğitim ve test süreci için kullanılan veri setleri Tablo 4.1'de sunulmuş ve amaç, farklı eğitim veri örnekleri oranları için Aşırı Gradyan İyileştirme yönteminin performansını test etmek ile beraber önceki çalışma durumlarında, eğitim ve test örnekleri ya nispeten büyüktü ya da çok sayıda değişkenli tasarımlar olduğu için yüksek değişken sayısından dolayı geleneksel ızgara örnekleme yöntemi kullanılarak almıştı.

Tablo 4.1 Vaka çalışmasının veri seti

Parametre	Minimum Değer	Maksimum Değer
Dielektrik Yükseklik DH (mm)	10	50
Dielektrik Sabit Değeri	1.5	3
Çap R (mm)	10	50
f : Frekans (GHz)	5	15

Bu bölümdeki çalışmada ise, Tablo 4.1'de belirtilmiş olan Latin-Hiperküp Örnekleme (LHS) ve Logaritmik Örnekleme (LGS) yöntemleri ile oluşturulmuş 100, 200 ve 300 farklı örnek sayılarına sahip veri kümeleri eğitim için, rastgele seçilmiş 100 test örneğinde oluşmuş veri kümeleri ise Aşırı Gradyan İyileştirme yönteminin performansını test etmek için kullanılacaktır. Ayrıca her bir veri setinde $0,1$ GHz adım boyutu ile $5-15$ GHz arasında frekans aralığı verildiği göz önünde bulundurulmalıdır. Şekil 4.2'de ise en iyi hata oranına sahip LHS200 - RS100 verilerine göre yapılan çalışmanın S_{11} parametrelerinin tahminleri ve değerleri verilmiştir.

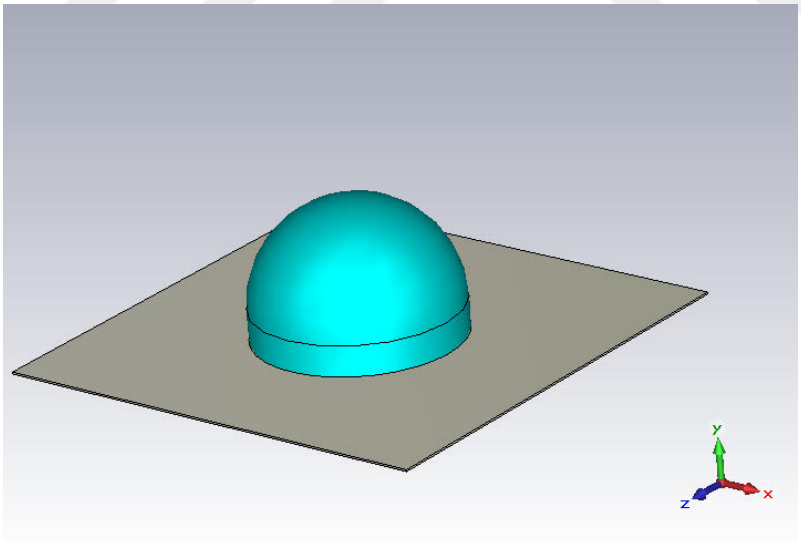


Şekil 4.2 Eğitim ve test veri setlerinden seçilen bir anten modeli (Dielektrik yükseklik 35, dielektrik sabiti 2,7 ve yarıçap 27 mm) için LHS200 kullanılarak eğitilen Aşırı Gradyan İyileştirme'nin performans sonucu

Tablo 4.2 Yarı küresel dielektrik anten için Aşırı Gradyan İyileştirme modelinin S_{11} performansı karşılaştırması

	Ortalama Mutlak Hata ($\times 10^{-3}$)				**Simetrik Ortalama Mutlak Yüzde Hatası ($\times 10^{-3}$)**			
	Eğitim			**RS100**	**Eğitim**			**RS100**
Vaka	**min**	**max**	**ort**	**test**	**min**	**max**	**ort**	**test**
LHS100	11.8241	12.6184	12.2136	34.5155	9.5493	10.4283	9.8756	22.7447
LHS200	11.8729	12.7063	12.2546	34.5588	9.6937	10.5869	10.1958	22.5921
LHS300	11.6586	12.5328	12.1013	35.0463	9.3982	10.4369	9.9793	22.9277
LGS100	15.6843	17.3577	16.5240	57.9151	11.0032	13.1301	11.8324	33.3768
LGS216	14.8995	15.6670	15.2545	42.9524	11.1162	11.9683	11.5080	26.3904
LGS294	14.2316	15.3924	14.6932	40.6370	10.5731	11.5236	11.0643	25.8581

Bu çalışma örneği için, Aşırı Gradyan İyileştirme regresyon modelinin hiperparametreleri şu şekilde alınmıştır: öğrenme oranı: 0.15, maksimum derinlik: 10, yenileme sayısı: 2000, ve genel eğitim süresi yaklaşık 1 dakikadır. Tablo 4.2'da, Aşırı Gradyan İyileştirme algoritmasının performans sonuçları, hem LHS hem de LGS veri kümeleri için, rastgele seçilen 100 örneklenmiş hold-out veri kümesine (RS 100 veri kümesi) dayalı olarak $100, 200, 300$ örnekle sunulmuştur. Aşırı Gradyan İyileştirme aşırı öğrenmeye uğramaksızın sadece 100 tasarım örneği ile seyrek eğitim veri setlerinde bile yüksek regresyon doğruluğu sağlamaktadır. Şekil 4.3'te, çalışılan dielektrik anten örneğinin 3 boyutlu görünümü verilmiştir.



Şekil 4.3 Dielektrik anten örneğinin 3 boyutlu görünümü

Aşırı Gradyan İyileştirme modelinin performansının daha fazla araştırılması için bir anten örneği Şekil 4.1 verilmiş ve antenin geometrik tasarım değişkenleri DH= 35 (mm), R= 27 (mm) ve dielektrik sabiti=2.7 olarak veri setlerinin hiçbir yerinde mevcut olmayan bir anten 3 boyutlu şekli, Şekil 4.3'teki anten

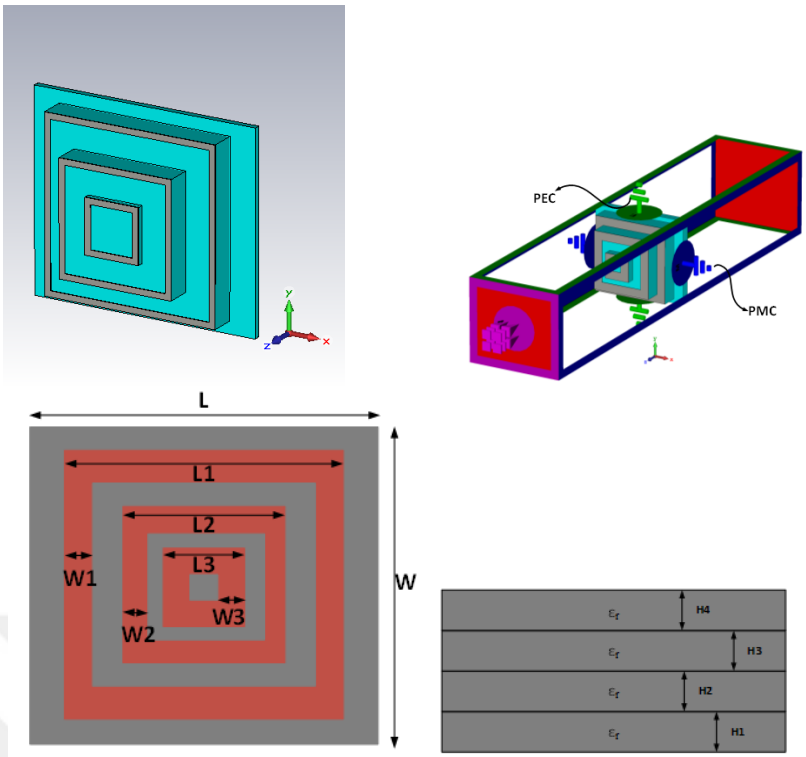
tasarlanmıştır. Tasarlanan antenin, Şekil 4.2 incelendiği gibi, en iyi hata oranına sahip LHS200 - RS100 verilerine göre yapılan çalışmanın S_{11} parametrelerinin Aşırı Gradyan İyileştirme modelleri ile tahminleri ve gerçek değerleri verilmiştir. Böylece, Aşırı Gradyan İyileştirme algoritması'nın, mikrodalga cihazlarının vekil tabanlı modellemesi için seyrek veri setine sahip senaryolarda bile regresyon modeline sahip olmak için etkili ve verimli bir araç olduğu anlaşılmıştır.

4.2 Toplululuk Öğrenmesi Kullanarak Frekans Seçici Yüzey Modelleme

Frekans Seçici Yüzeyler (FSS), geometrik tasarım değişkenlerine göre bu tasarımların EM dalgalarının özelliklerini değiştirebildiği Meta malzemelerin [102] alt sınıflarından biridir. FSS'nin bazı uygulamaları (i) Filtennas Tasarımı, (ii) anten kademelerinin iyileştirilmesi, (iii) yansıtıcı dizi anten tasarımları, (iv) yutucular olarak adlandırılmakla birlikte, bu çalışmada, Topluluk Öğrenme yöntemlerinin performansını test etmek için bir FSS yapısının modellenmesi planlanmıştır ve bir birim eleman tasarımı (Şekil 4.4) 3B EM simülasyon ortamında modellenmiştir. Bir önceki çalışmadaki örneklem yöntemlerinden olan Latin Hiper Küp örnekleme yöntemi kullanılarak Tablo 4.3'te tanımlanan değişken üzerinden 1000 örnek oluşturulmuştur. Bu durumda topluluk algoritmalarının amacı doğrultusunda, girdi (Geometrik tasarım değişkenleri Tablo 4.3) ve çıktılar (FSS öğesinin saçılma parametre yanıtı) arasında model oluşturulmuştur. Bir sonraki alt bölümde, seçilen çalışma durumu için topluluk yöntemlerinin performans sonuçları sunulmaktadır.

Tablo 4.3 FSS birimi elemanının değişken aralığı

Parametre	**Alt Sınır (mm)**	**Üst Sınır (mm)**
L_1	7	9
L_2	4	6
L_3	1	4
ε_r	1.3	2.7
Parametre	**Sabit Tasarım Parametreleri (mm)**	
L	11.34	
W	5	
H_1	1	
$H_2 = H_3 = H_4$	2	
$W_1 = W_2 = W_3$	1	



Şekil 4.4 (sol) FSS birimi elemanının 3B görünümü, (sol orta) sınır koşulu ayarlarıyla birim öğeleri, (sağ ikisi) birim elemanın şeması

4.2.1 Doğrulama Vaka Çalışmaları ve Kıyaslama

Bir önceki bölümde oluşturulan veri seti, regresyon modellerinin oluşturulması için kullanılmıştır. Böylece seçilen FSS birim elemanı için topluluk öğrenme yöntemlerinin performans sonuçları sunulmaktadır. Veri setindeki örnekler rastgele karıştırılmış, veri setinin 80%'i eğitim ve doğrulama işlemi için kullanılmış, kalan 20%'si ise algoritmaların aşırı öğrenme değerlendirilmesi için test veri seti olarak alınmıştır. Tablo 4.4'te her modelin optimal hiper parametreleri sunulmuş olup, bu parametreler, veri setinin 80%'i kullanılarak K-kat çapraz doğrulama yöntemi ile elde edilir. Bununla birlikte, regresyon modellerinde algoritmalar, doğrulama veri kümelerinin kendi aralarındaki ilişkilerini ezberlediği ve doğrulama verileri dışındaki veri örnekleri için de benzer performansa sahip daha genel bir model oluşturamadığı durumlarda aşırı uydurmaya düşme eğilimindedir. Böyle bir durumu önlemek için, test veri seti doğrulaması olarak adlandırılan ek bir test süreci gereklidir. Burada veri kümesinin bir bölümü (burada 20%) modelleme sürecinin dışına alınır ve yalnızca optimal hiper parametre belirleme süreci tamamlandıktan sonra modellere sunulur.

LGBM'nin $2^{\text{maks derinlik}} >$ yaprak sayısı kuralı nedeniyle, sayı yaprakları parametresine yalnızca LGBM simülasyonları verilir. Teorik olarak bunun nedeni, sabit sayıda yaprak için yaprak şeklinde bir ağacın tipik olarak derinlik bilgisine sahip bir ağaçtan çok daha derin olmasıdır.

Tablo 4.4 Modellerin en iyi hiperparametre listesi

Parametreler	Adaboost	GBM	Aşırı Gradyan İyileştirme	Hafif Gradyan İyileştirme
Öğrenme Oranı	0.07311	0.08573	0.02243	0.0961
Maksimum Derinlik	Bu algoritmada böyle bir parameter yok	9	14	25
Yenileme Sayısı	509	1121	1040	1927
Yaprak Sayısı (*)	Bu algoritmalarda böyle bir parameter yok			25

Tablo 4.5'te, hem K-katlama doğrulaması hem de test veri setleri için modellerin performans sonuçları sunulmaktadır. Görüldüğü gibi, ADABOOST yöntemi hariç diğer yöntemler, Ortalama Mutlak Hata Metriği anlamında yüksek doğrulukta sonuçlar elde etmeyi başarmış olmakta ve GBM, XGBM ve LGBM yöntemleri arasında benzer performans sonuçlarına sahip olmalarına rağmen eğitim sürelerinin farklı olduğuna dikkat edilmelidir. Hızlı eğitim süresine sahip bir modele ihtiyaç duyulursa, modelin doğruluğunda hafif bir düşüşle LGBM düşünülebilir, ancak eğitim süresi ihmal edilebilirse, XGBM yöntemi bu tür problemler için en uygun çözümdür. Bu nedenle, bu çalışmada ileri doğrulama çalışmaları için XGBM algoritması, önerilen veriye dayalı vekil model olarak değerlendirilecektir.

Tablo 4.5 K-katlama ve test doğrulama setleri için her modelin performans sonuçları

Model	K-katlı Doğrulama($\times 10^{-3}$)	Test($\times 10^{-3}$)	Tahmini süresi (dk)
ADABOOST	100.1	199.4	38.8
GBM	2.25	3.05	86.8
XGBM	1.9	2.54	17.3
LGBM	4.3	5.81	2.1

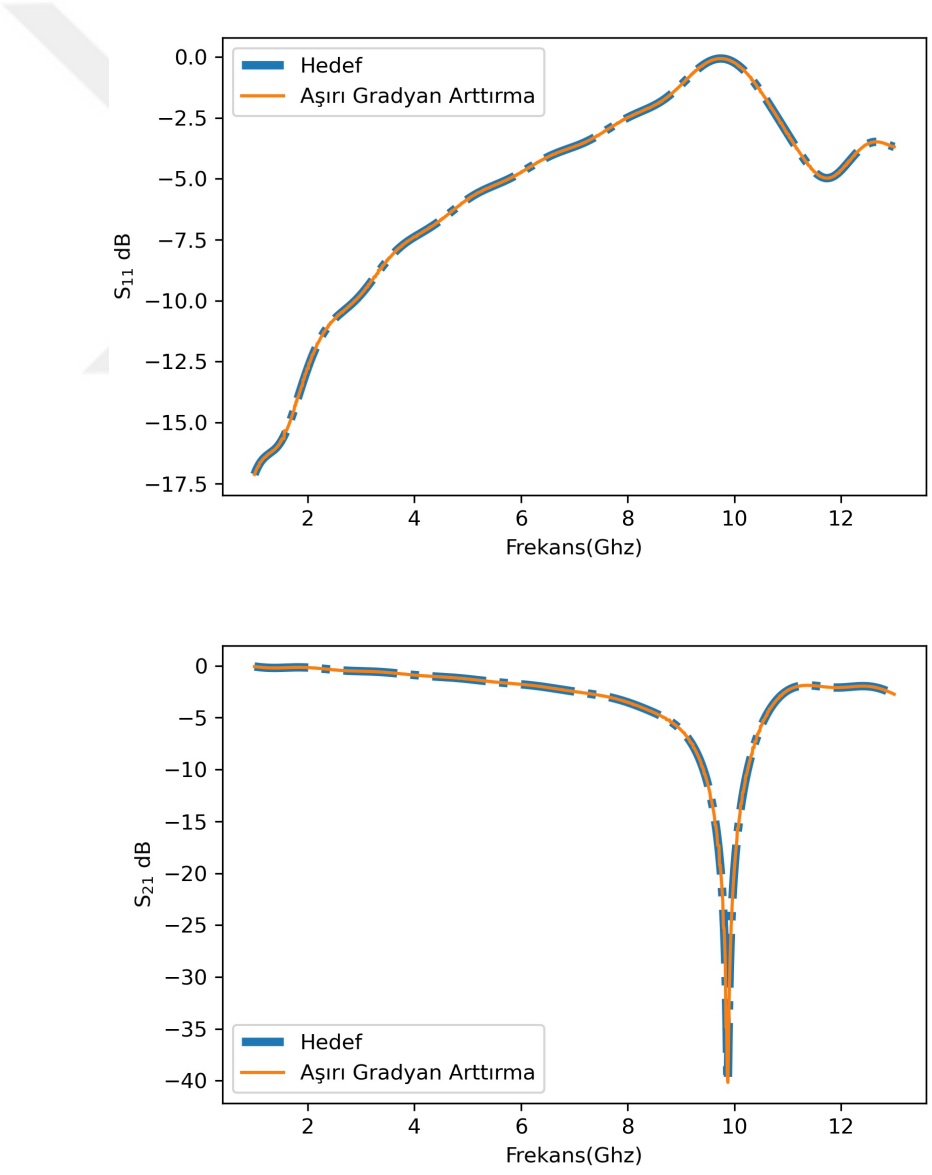
Ayrıca, önerilen tekniğin gerekçelendirilmesi için, üretilen veriye dayalı modelden tahmin edilen değerler, deneysel sonuçlarla karşılaştırılır.

10 GHz çalışma frekansındaki sinyalleri filtrelemek için bir filtre olarak X bandında çalışan bir FSS tasarımı oluşturmak için veri güdümlü vekil model destekli bir optimizasyon süreci dikkate alınmıştır [103].

Daha sonra, FSS'nin optimal olarak seçilen geometrik tasarım değerleri, Şekil 4.5 görüldüğü üzere 3*B* baskı teknolojisi kullanılarak bir modelin prototipini oluşturmak için kullanılır.Şekil 4.6'de, FSS birim elemanının ölçülen özellikleri, XGBM'nin tahmin edilen sonuçları ile karşılaştırılır. Sonuçlardan da anlaşılacağı gibi önerilen yöntem FSS elemanlarının modellenmesi için verimli, doğru ve uygulanabilir bir tekniktir.



Şekil 4.5 Tasarım parametreleri ile 3B yazıcı (PLA malzemesi) kullanan fabrikasyon FSS üniteleri $[L1 = 2, L2 = 6, L3 = 8, \varepsilon_r = 2.5]$.



Şekil 4.6 FSS tasarım ölçülen ve tahmin edilen saçılma karakteristiği

5
İYİLEŞTİRME TABANLI OTOMATİK-HARMANLAMA TEKNİĞİ KULLANARAK MİKRODALGA TRANZİSTÖRÜ MODELLENMESİ

İyileştirme Tabanlı Otomatik-Harmanlama (İTOH) tekniğinin mikrodalga devre elemanlarının modelleme performansı incelenecektir. Bu kapsamda öncelikle Bölüm 5.1'de daha önceden ele alınan ve Aşırı Gradyan İyileştirme yöntemi ile modellenmesi gerçekleşen problemler yeniden bu yöntem ile incelemiş olup, önerilen İTOH tekniğinin literatürdeki bu seçili problemlerdeki başarısı incelenecektir. Daha sonra Bölüm 5.2'de, önceden ele alınan problemlerden farklı olarak, aktif mikrodalga devrelerin en kilit elemanlarından biri olan mikrodalga tranzistörlerinin modellenmesi ele alınacaktır.

5.1 İTOH Tekniğinin Literatürdeki Problemler İle Doğrulanması

Önerilen İTOH tekniği, öncelikle Bölüm 3.1'de verilen üniform olmayan yansıtıcı dizi anten probleminin çözümü için kullanılmıştır.Literatürden daha iyi sonuçlar elde edildikten sonra aynı teknik, benzer seçili diğer problemler olan ve Bölüm 3.2, 4.1 ve 4.2 'de sırası ile sunulan Kapasitif Besleme Anten, yarım küresel dielektrik anten ve frekans seçici yüzey modellemesi problemlerinde de kullanılmıştır.

İTOH yapısına ait ızgara arama (Grid search) algoritması sonucunda elde edilen optimal Hiper-parametreler, üniform olmayan yansıtıcı dizi anten problemi için Tablo5.1 ,Kapasitif Besleme Anten problemi için Tablo5.2, yarım küresel dielektrik anten problemi için Tablo5.4 ve frekans seçici yüzey modellemesi problemi için Tablo5.6'de verilmiştir. Yapılan çalışmada, eğitim verisinin %80 eğitim %20 ise ızgara arama algoritmasının yönlendirilmesi için doğrulama verisi olarak kullanılmıştır. Test verileri kullanılarak elde edilen performans sonucu ise sırasıyla Tablo5.1, Tablo5.3, Tablo5.5 ve Tablo5.7'de sunulmuştur.

Tablo 5.1 Literatürdeki üniform olmayan bir yansıtıcı dizi öğesinin yansıma fazı ile ilgili çalışma üzerine İyileştirme Tabanlı Otomatik-Harmanlama ve Aşırı Gradyan İyileştirme parametreleri ve karşılaştırılması

Yöntem	Hiper-parametreler	Ortalama Mutlak Hata
Aşırı Gradyan Tabanlı İyileştirme[100]	**Ögrenme Oranı:** 0.4 **Maksimum Derinlik:** 4 **Yenileme Sayısı:**2000	3.77
İyileştirme tabanlı Otomatik-Harmanlama	**XGBM parametreleri** **Ögrenme Oranı:** 0.906 **Maksimum Derinlik:** 3 **Yenileme Sayısı**:13988 **LGBM parametreleri** **Ögrenme Oranı:** 0.608 **Maksimum Derinlik:** 3 **Yenileme Sayısı:**18408 **Yaprak Sayısı:**1885	**1.77**

Tablo 5.2 Kapasitif besleme anteninin hassas saçılma parametre tahmini ile ilgili çalışma üzerine İyileştirme Tabanlı Otomatik-Harmanlama ve Aşırı Gradyan İyileştirme parametreleri

Algoritmalar	Hiper-parametreler	
Aşırı Gradyan İyileştirme[100]	**Ögrenme Oranı:** 0.2 **Maksimum Derinlik:** 10 **Yenileme Sayısı:**200	
İyileştirme Tabanlı Otomatik Harmanlama	**REEL**	**IMAJİNER**
	XGBM parametreleri **Ögrenme Oranı:** 0.0940876 **Maksimum Derinlik:** 12 **Yenileme Sayısı:** 4814 **LGBM parametreleri** **Ögrenme Oranı:** 0.048264 **Maksimum Derinlik:** 28 **Yenileme Sayısı:** 18685 **Yaprak Sayısı:** 128	**XGBM parametreleri** **Ögrenme Oranı:** 0.001933 **Maksimum Derinlik:** 115 **Yenileme Sayısı:** 11701 **XGBM parametreleri** **Ögrenme Oranı:** 0.078840 **Maksimum Derinlik**: 18 **Yenileme Sayısı:** 12987 **Yaprak Sayısı:** 221

Tablo 5.3 Kapasitif besleme anteninin hassas saçılma parametre tahmini ile ilgili çalışma üzerine İyileştirme Tabanlı Otomatik-Harmanlama ve Aşırı Gradyan İyileştirme karşılaştırılması

Algoritmalar	**0.5x (Real+Imajiner)**($\times 10^{-3}$)
Aşırı Gradyan İyileştirme[100]	10.221
İyileştirme tabanlı Otomatik-Harmanlama	**8.504**

Tablo 5.4 Yarım küre dielektrik anten ile ilgili çalışma modellenmesi üzerine İyileştirme Tabanlı Otomatik-Harmanlama ve Aşırı Gradyan İyileştirme parametreleri

Algoritmalar	**Hiper-parametreler**	
Aşırı Gradyan İyileştirme[100]	**Ögrenme Oranı:** 0.15 **Maksimum Derinlik:** 10 **Yenileme Sayısı:**2000	
İyileştirme tabanlı Otomatik Harmanlama	**REEL**	**IMAJİNER**
	XGBM parametreleri	**XGBM parametreleri**
	Ögrenme Oranı: 0.181217	**Ögrenme Oranı:** 0.119914
	Maksimum Derinlik: 9	**Maksimum Derinlik:** 9
	Yenileme Sayısı: 17519	**Yenileme Sayısı:** 15606
	LGBM parametreleri	**XGBM parametreleri**
	Ögrenme Oranı: 0.000319	**Ögrenme Oranı:** 0.056132
	Maksimum Derinlik: 10	**Maksimum Derinlik**: 29
	Yenileme Sayısı: 17946	**Yenileme Sayısı:** 9266
	Yaprak Sayısı: 1961	**Yaprak Sayısı:** 357

Tablo 5.5 Yarım küresel dielektrik anten modellemesi için en iyi model olan Aşırı Gradyan İyileştirme ile İyileştirme Tabanlı Otomatik-Harmanlama S_{11} SMAPE cinsinden performansı karşılaştırması

	Simetrik Ortalama Mutlak Yüzde Hatası (SMAPE)	
Vaka	**Aşırı Gradyan tabanlı İyileştirme[100]**	**İyileştirme tabanlı Otomatik-Harmanlama**
Eğitim: LHS 200 Holdout: RS100	%22.59	%4.98

Tablo 5.6 Frekans seçici yüzey ile ilgili çalışma modellenmesi üzerine İyileştirme Tabanlı Otomatik-Harmanlama ve Aşırı Gradyan İyileştirme parametreleri

Algoritmalar	**Hiper-parametreler**	
Aşırı Gradyan İyileştirme[104]	**Ögrenme Oranı:** 0.02243 **Maksimum Derinlik:** 14 **Yenileme Sayısı:**1040	
İyileştirme Tabanlı Otomatik Harmanlama	**REEL**	**IMAJİNER**
	XGBM parametreleri	**XGBM parametreleri**
	Ögrenme Oranı:0.193922	**Ögrenme Oranı:**0.002921
	Maksimum Derinlik:5	**Maksimum Derinlik:**135
	Yenileme Sayısı:15698	**Yenileme Sayısı:**9043
	LGBM parametreleri	**XGBM parametreleri**
	Ögrenme Oranı:0.002123	**Ögrenme Oranı:**0.059432
	Maksimum Derinlik:23	**Maksimum Derinlik:**23
	Yenileme Sayısı:16695	**Yenileme Sayısı:**14302
	Yaprak Sayısı:124	**Yaprak Sayısı:**212

Tablo 5.7 Frekans seçici yüzey ile ilgili çalışma modellenmesi üzerine İyileştirme Tabanlı Otomatik-Harmanlama ve Aşırı Gradyan İyileştirme karşılaştırılması

Algoritmalar	**0.5x (Real+Imajiner)($\times 10^{-3}$)**
Aşırı Gradyan İyileştirme[104]	2.54
İyileştirme tabanlı Otomatik-Harmanlama	**1.8**

Performans sonucu ile ilgili tablolardan da görüleceği üzere, önerilen İTOH tekniğinin Aşırı Gradyan İyileştirme'ye kıyasla çok daha yüksek bir doğruluk ile sonuç verdiği gözlenmektedir. Ayrıca performans sonuçlarının literatürdeki diğer algoritmalardan daha iyi olmasının yanı sıra, Aşırı Gradyan İyileştirme algoritmasından bile daha yüksek doğruluklar sunduğu gözlenmemiştir.

5.2 İTOH Tabanlı Mikrodalga Tranzistör Modellenmesi

Günümüz mikrodalga teknolojisinde verimli analiz ve tasarım konusunda, genellikle doğru ve hızlı tranzistör modellerini kullanmakta, buna bağlı olarak da yüksek performanslı devre tasarımları oluşmaktadır. Mikrodalga ve RF uygulamaları için, önceki yıllarda fizik tabanlı denklemlerden oluşan standart tranzistör modelleri, elektriksel özelliklerin standart modeller tarafından iyi bir şekilde yakalanmaması ve yeni fiziksel fenomenler için fizik tabanlı model denklemlerinin geliştirilmesi gibi bazı yönlerden başarısız olmaktadır. Yaygın olarak kullanılan ve verimli sayısal yöntemlerden biri olan Yapay Zeka ve alt kollarından makine öğrenmesinin gelişmesi ile birlikte, RF ve mikrodalga mühendisliğinde hesaplama açısından verimli ve veri odaklı vekil modeller elde etmek için geniş bir uygulama yelpazesinde ortaya çıkarmaktadır [105, 106]. Yapay Zeka yöntemleri, çok sayıda denklem hesaplamasından, daha az zaman tüketimine kadar pek çok yönüyle ilerleme kaydetmiş aynı zamanda da tasarım optimizasyon sürecini hızlandırmakla beraber, tasarım sürecinin genel hesaplama verimliliğini artırmıştır. RF cihaz modellemesi için yaygın olarak kullanılan Yapay Zeka tabanlı teknikler, geçmişte yarı iletken cihazlar için kompakt modeller olarak hizmet etmiş ve RF cihaz uygulamalarında özel bir başarı elde etmiştir [107–109]. Ölçüm kolaylığı, pasif ve aktif analizi için, Y, Z veya T parametreleri gibi diğer parametrelerin formlarına dönüştürülme kolaylığı nedeniyle doğrusal cihazların, devrelerin tasarımı ve analizi için kullanılan bir RF özelliği [110–112] olan Saçılma veya S-parametreleri, düşük sinyal veya düşük gürültülü kuvvetlendiricilerin tasarımı için çok önemli özellikler olan giriş ve çıkış empedansı, izolasyon, kazanç ve kararlılığın hesaplanması için de kullanılabilir [112]. Bununla birlikte, bir tranzistörün S-parametrelerinin seçilen çalışma bandı, DC öngerilim

koşulları, (gerilim ve akım) sıcaklık gibi parametrelerinin bilinmesi, bilgisayar destekli tasarım ortamında doğru, esnek, hızlı ve uygulaması kolay bir modele oluşması konusunda büyük bir avantaj olmaktadır. Bu çalışma ile birlikte önerilen İTOH algoritması kullanılarak bir mikrodalga tranzistörünün DC besleme değerlerine bağlı olarak saçılma parametrelerinin tahmini yapan bir model geliştirilmesi hedeflenmiştir. Bu amaç doğrultusunda, 2 farklı senaryo ele alınmıştır.

Tablo 5.8 Eğitim ve test senaryoları

Senaryolar	**1V**	**2V**	**2.5V**	**3V**	**4V**
Senaryo 1	Eğitim	Test	Eğitim	Test	Eğitim
Senaryo 2	Eğitim	Test	Eğitim	Test	Test
Akım Değerleri (mA)	**4, 5, 6, 8, 10**		**Frekans (GHz)**	**0.3-10**	

İlk senaryoda seçili bir mikrodalga tranzistöre (BFP740-EDS) ait DC besleme verileri kullanılarak İTOH modellinin interpolasyon yeteneği literatürde sıklıkça kullanılan karışık algoritmalar ile kıyaslanmış, sonrasında İTOH algoritmasının interpolasyona ek olarak extrapolasyon yeteneğinin incelenmesi için ikinci bir senaryo ele alınmıştır. İkinci senaryoda 1V ve 2.5 V ait verilerin modele verilerek modelin dış sınırda bulunan 3V ve 4V değerlerindeki saçılma parametrelerini tahmin etmesi hedeflenmiştir.

Tablo 5.9 İTOH ve rakip algoritmalara ait senaryo 1 S_{11} saçılma parametresi performans sonuçları

	Ortalama Mutlak Hata ($\times 10^{-3}$)				**Ortalama Bağıl Hata**			
	SVRM	**MLP**	**GPR**	**İTOH**	**SVRM**	**MLP**	**GPR**	**İTOH**
S_{11}	318.4	24.3	12.6	8.3	0.4700	0.0350	0.0180	0.0120
S_{21}	1314	114.9	131.8	80.8	0.1100	0.0100	0.0110	0.0070
S_{12}	7.80	0.93	1.0	0.9	0.1800	0.0220	0.0240	0.0210
S_{22}	190.3	24.1	39.2	19.8	0.2800	0.0360	0.0580	0.0295

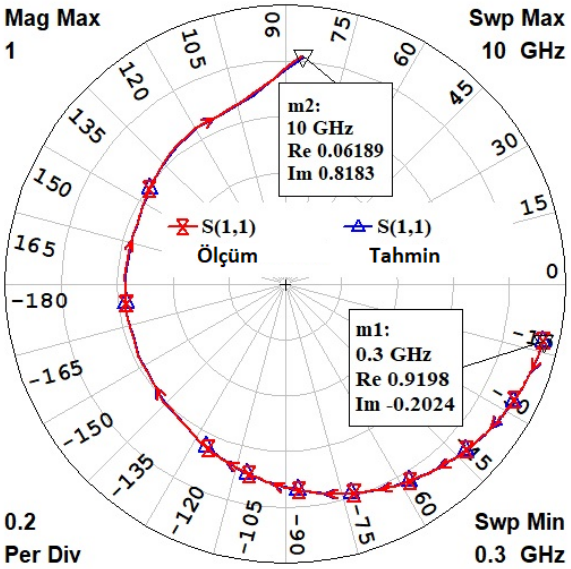
Tablo 5.10 İTOH ve rakip algoritmalara ait senaryo 2 için S_{11} Saçılma Parametresi performans sonuçları

	Ortalama Mutlak Hata ($\times 10^{-3}$)				**Ortalama Bağıl Hata**			
	SVRM	**MLP**	**GPR**	**İTOH**	**SVRM**	**MLP**	**GPR**	**İTOH**
S_{11}	111.1	74.4	57.1	10.89	0.860	0.100	0.080	0.015
S_{21}	180.1	35.1	80.1	9.7	0.850	0.170	0.240	0.008
S_{12}	127.6	1.2	68.2	1.05	0.620	0.027	0.510	0.024
S_{22}	151.7	43	98.6	22.7	0.680	0.064	0.140	0.033

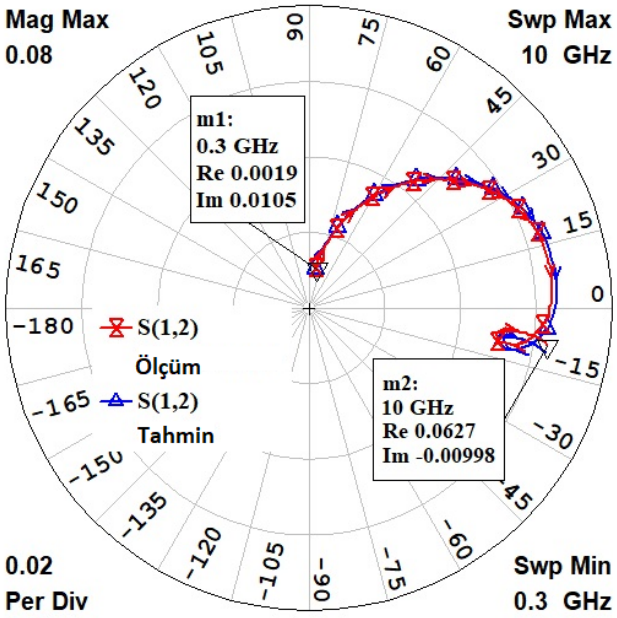
Tablo5.9 ve Tablo5.10'da görüleceği üzere, önerilen İTOH algoritması önceki problemlerde ele alınan pasif mikrodalga elemanlarının modellenmesindeki başarılı

performansına benzer bir performans sergilemiş olup, İTOH algoritmanın aktif devre elemanlarında kullanıma uygun olduğu gözlemlenmiştir.

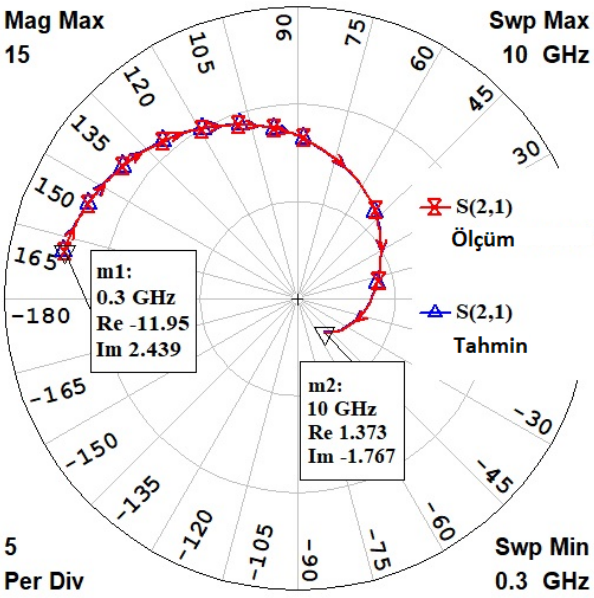
Ayrıca [2 V , 4mA] ve [3 V , 10mA] değerlerine ait saçılma parametrelerinin genlik ve açıları, senaryo 1'de S_{11} için Şekil 5.1, S_{12} için Şekil 5.2, S_{21} için Şekil 5.3, S_{22} için Şekil 5.4, senaryo 2 için ise S_{11} için Şekil 5.5, S_{12} için Şekil 5.6, S_{21} için Şekil 5.7, S_{22} için Şekil 5.8 verilmiştir.



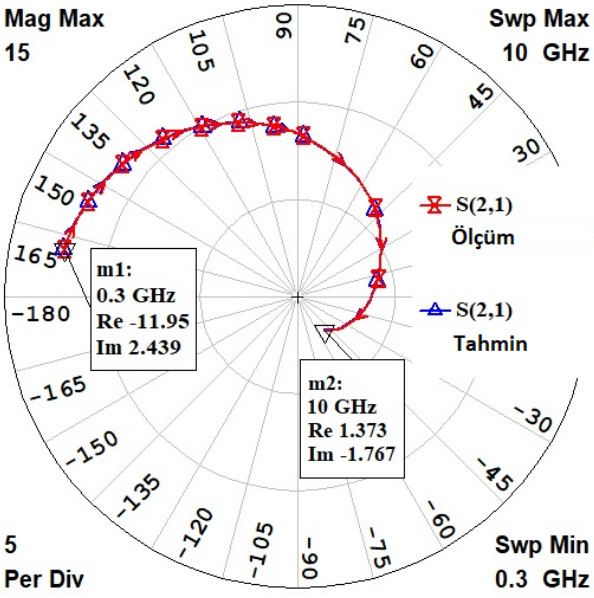
Şekil 5.1 Senaryo 1 (Interpolasyon): 2V , 4mA için Smith diyagramı aracılığıyla S_{11} gerçek değerleri ve İTOH tahmini



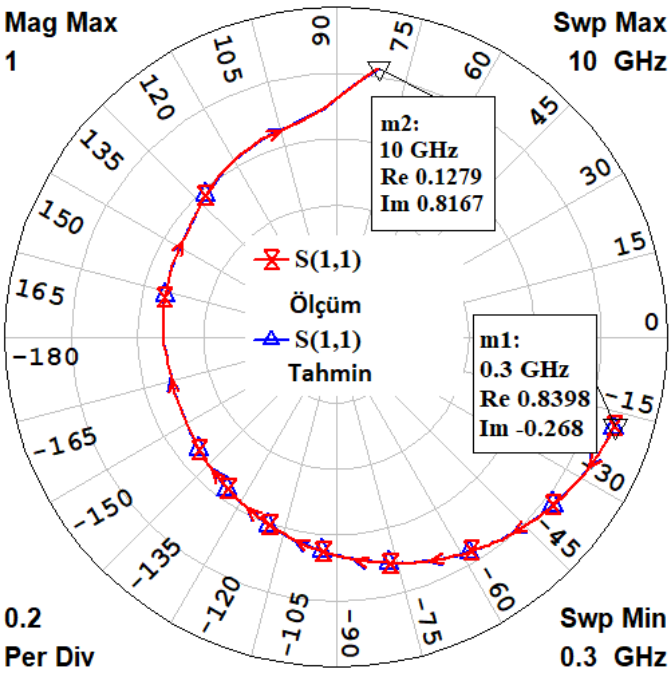
Şekil 5.2 Senaryo 1 (Interpolasyon): 2V , 4mA için Smith diyagramı aracılığıyla S_{12} gerçek değerleri ve İTOH tahmini



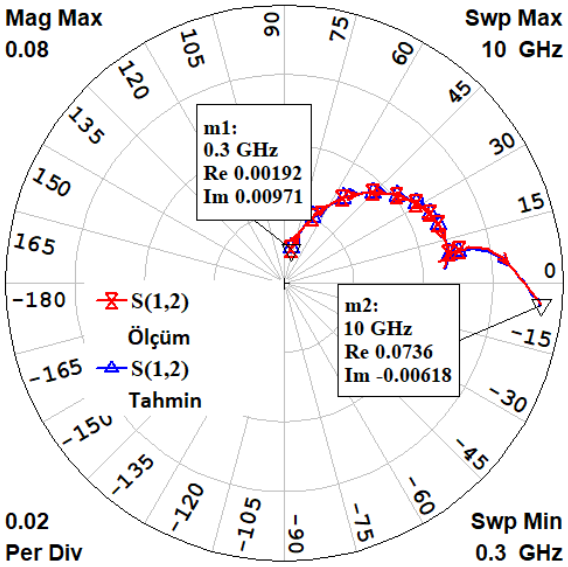
Şekil 5.3 Senaryo 1 (Interpolasyon): 2V , 4mA için Smith diyagramı aracılığıyla S_{21} gerçek değerleri ve İTOH tahmini



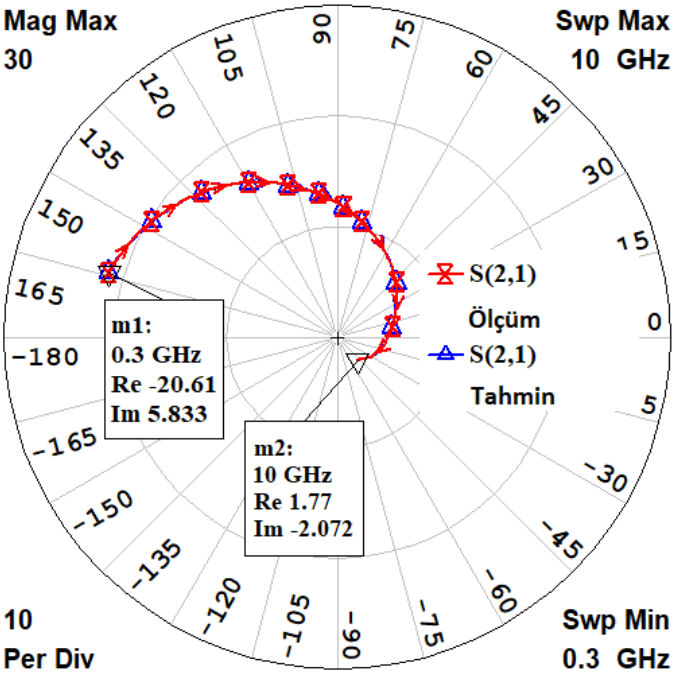
Şekil 5.4 Senaryo 1 (Interpolasyon): 2V , 4mA için Smith diyagramı aracılığıyla S_{22} gerçek değerleri ve İTOH tahmini



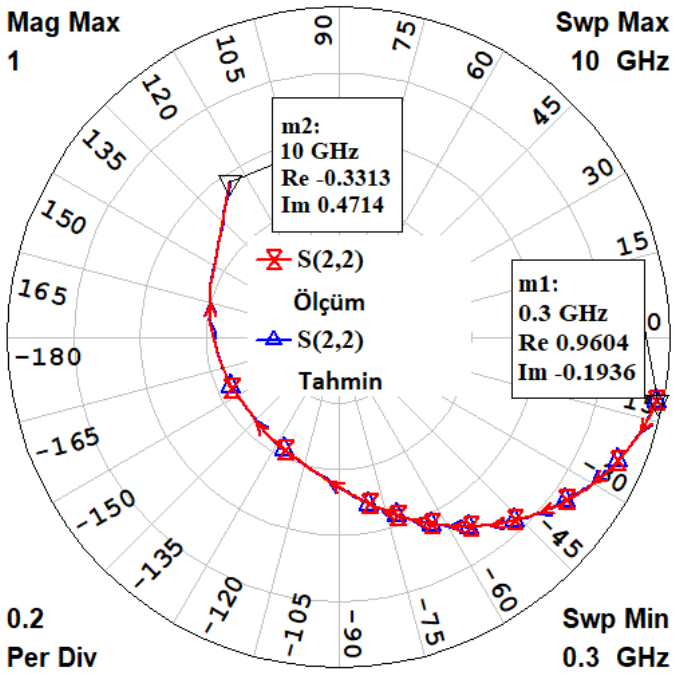
Şekil 5.5 Senaryo 2 (Interpolasyon): 2V , 4mA için Smith diyagramı aracılığıyla S_{11} gerçek değerleri ve İTOH tahmini



Şekil 5.6 Senaryo 2 (Interpolasyon): 2V , 4mA için Smith diyagramı aracılığıyla S_{12} gerçek değerleri ve İTOH tahmini



Şekil 5.7 Senaryo 2 (Interpolasyon): 2V , 4mA için Smith diyagramı aracılığıyla S_{21} gerçek değerleri ve İTOH tahmini



Şekil 5.8 Senaryo 2 (Interpolasyon): 2V , 4mA için Smith diyagramı aracılığıyla S_{22} gerçek değerleri ve İTOH tahmini

Bir diğer tranzistör parametresi olan gürültü parameterleri, 5.8'de verilen senaryolar kullanılarak modellenmiştir.

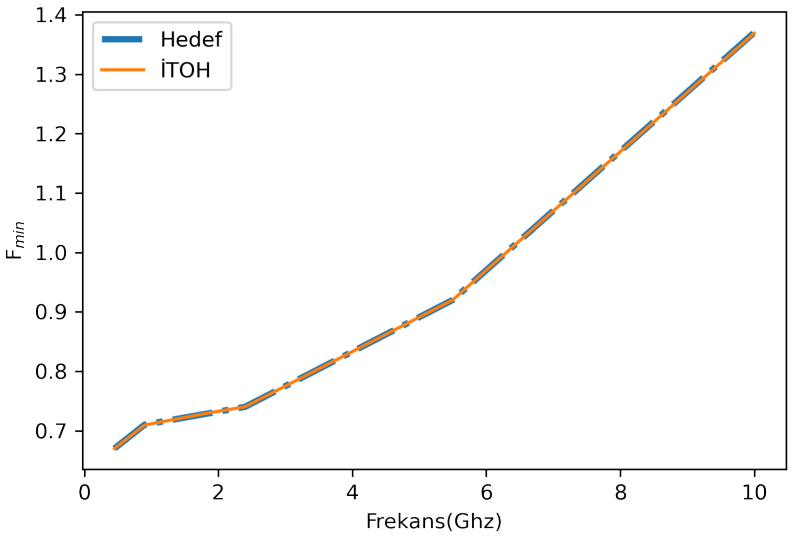
Tablo 5.11 İTOH ve rakip algoritmalara ait senaryo 1 gürültü saçılma parametresi performans sonuçları

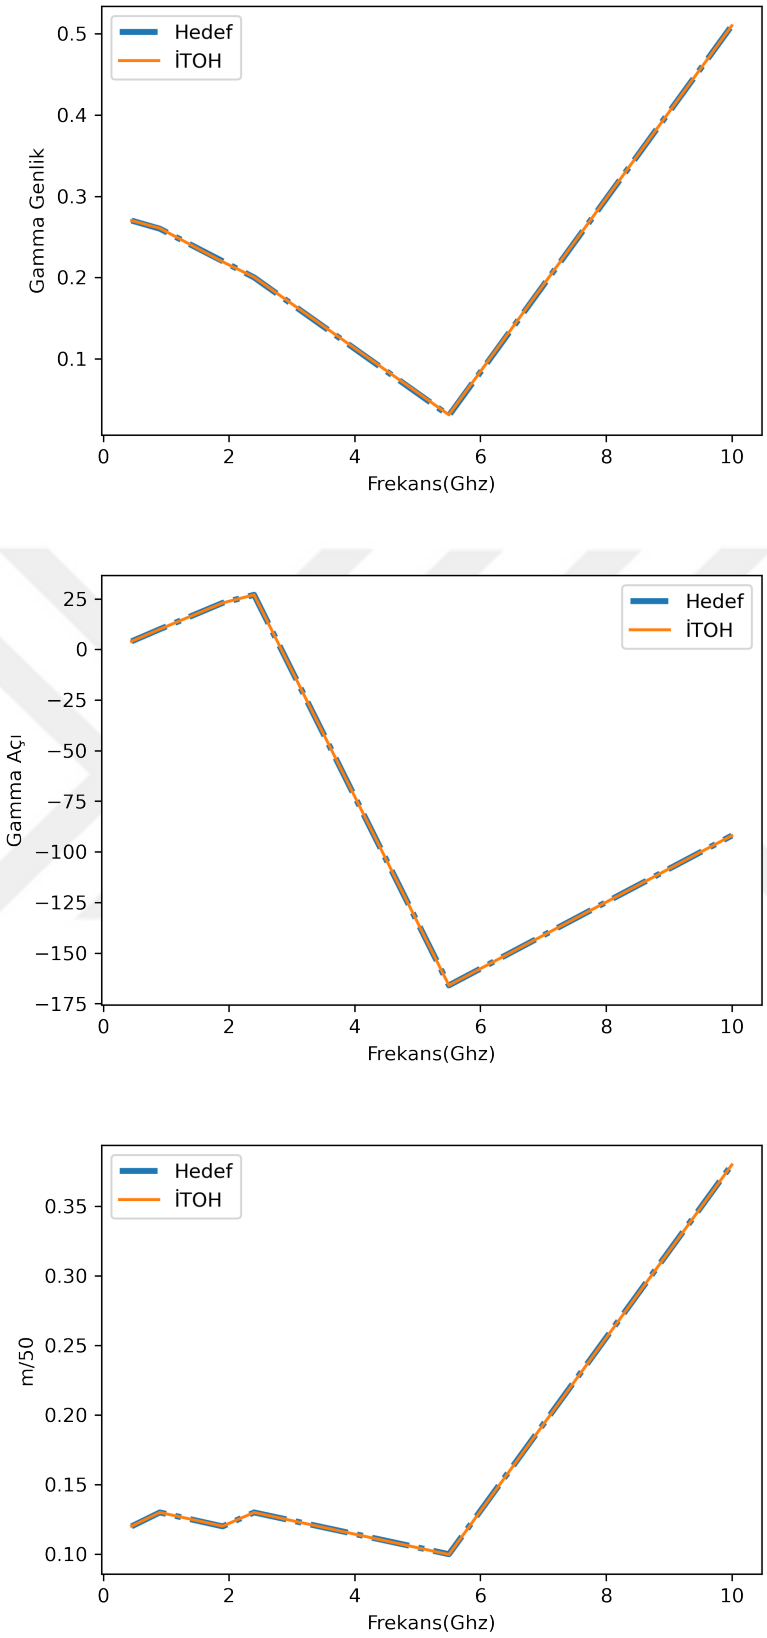
	Ortalama Mutlak Hata ($\times 10^{-3}$)				**Ortalama Bağıl Hata**			
	SVRM	**MLP**	**GPR**	**İTOH**	**SVRM**	**MLP**	**GPR**	**İTOH**
F_{min}	4.97	6.24	0.69	0.30	0.7453	0.5893	0.1077	0.0451
Gamma Genlik	18.74	0.31	0.14	0.08	9.8760	0.1183	0.0573	0.0048
Gamma Açı	35134.10	1991.46	14.68	0.80	90.6370	5.6307	0.0861	0.0058
$m/50$	4.58	2.90	0.05	0.04	3.3603	1.7320	0.0341	0.0168

Tablo 5.12 İTOH ve rakip algoritmalara ait senaryo 2 gürültü saçılma parametresi performans sonuçları

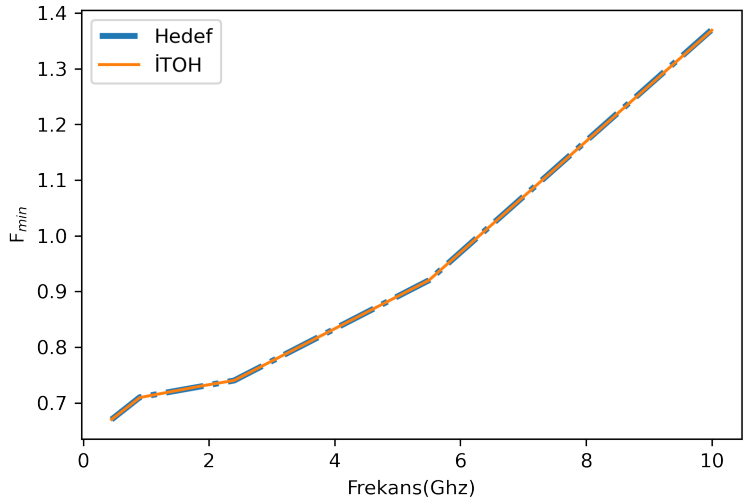
	Ortalama Mutlak Hata ($\times 10^{-3}$)				**Ortalama Bağıl Hata**			
	SVRM	**MLP**	**GPR**	**İTOH**	**SVRM**	**MLP**	**GPR**	**İTOH**
F_{min}	284.82	0.692	7.05	0.30	41.7830	0.0937	0.9081	0.0451
Gamma Genlik	371.79	16.56	2.03	0.32	72.4950	8.8987	1.2661	0.2019
Gamma Açı	136588.10	5173.16	14.02	0.81	140.7300	10.905	0.4516	0.0058
$m/50$	22.96	0.939	0.8	0.39	16.167	0.7074	0.552	0.3244

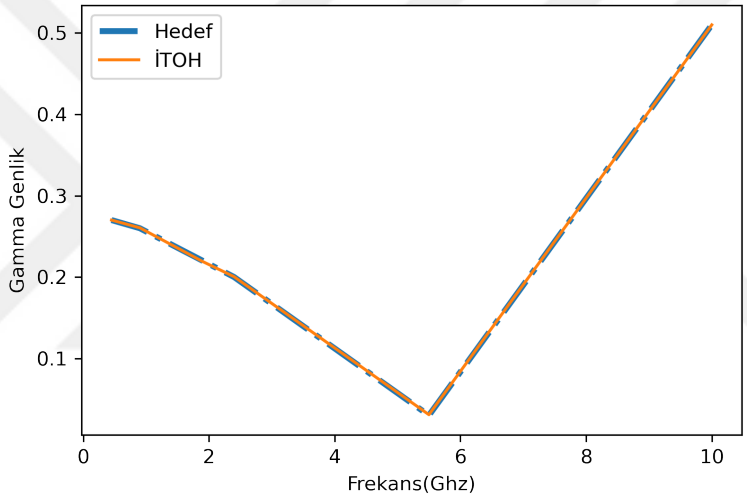
Ayrıca [2 V , 4mA] ve [3 V , 10mA] değerlerine ait gürültü parametrelerinin F_{min},Gamma genlik, Gamma açı ve $m/50$, senaryo 1 için Tablo 5.11 ve Şekil 5.9, senaryo 2 için ise Tablo 5.12 ve Şekil 5.10verilmiştir.

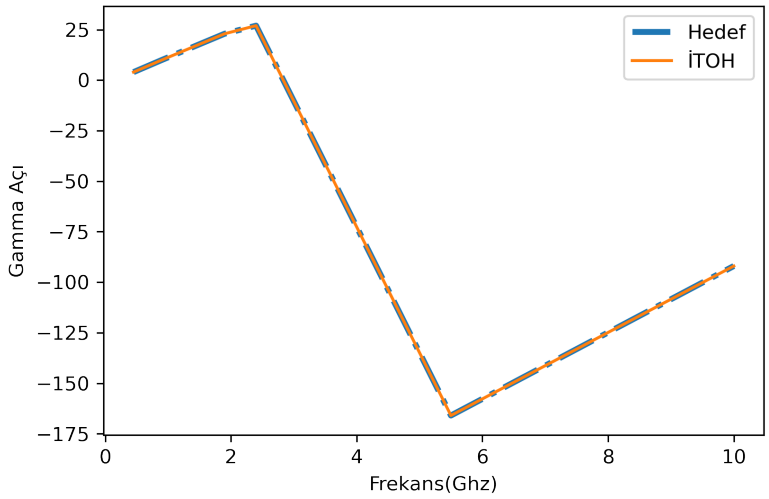


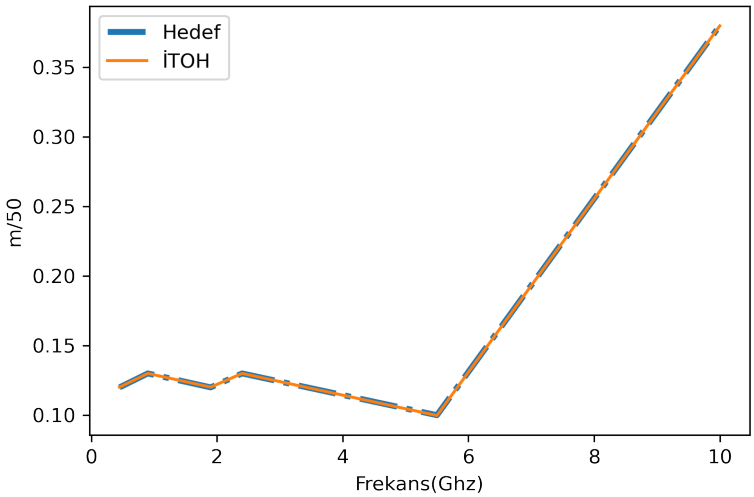


Şekil 5.9 Senaryo 1 (Interpolasyon): 2 V , 4mA için frekans bazında gerçek değerleri ve İTOH tahmini


Hedef
İTOH
F_{min}
Frekans(Ghz)


Hedef
İTOH
Gamma Genlik
Frekans(Ghz)


Hedef
İTOH
Gamma Açı
Frekans(Ghz)



Şekil 5.10 Senaryo 2 (Extrapolasyon): 3V , 10mA için frekans bazında Ggerçek değerleri ve İTOH tahmini

6
SONUÇ VE ÖNERİLER

Bu tez kapsamında, Topluluk Öğrenmesi'nin yöntemlerinden biri olan İyileştirme Yöntemi kullanılarak pasif ve aktif mikrodalga devre elemanlarının davranışlarını, tasarım değişkenlerine (geometrik parametreleri, çalışma frekansı, besleme akımı ve gerilimi vb.) bağlı olarak, yapıların performans kriterleri (Saçılma parametreleri, yansıma açısı) arasındaki doğrusal ve/veya doğrusal olmayan ilişkilerin tahmini, Topluluk Öğrenmesi yöntemi olan İyileştirme metodu ile gerçekleştirilmiştir. Oluşturulan modeller ile, mikrodalga devrelerin tasarım optimizasyon süreçlerinde en çok işlem gücüne ve işlem zamanına ihtiyaç duyulan 3B elektromanyetik simülatör programlarına olan bağımlılığı azaltmanın yanı sıra, mikrodalga tranzistörlerin modellenmesi gibi bazı problemlerde verinin oldukça az ve elde edilmesi maliyetli olan problemlerde de etkin bir modelleme elde edilmesi sağlanmıştır.

Tez kapsamında yapılan çalışmalarda, dört farklı mikrodalga tasarım problemi ele alınmıştır. Yansıtıcı dizi anten yapısına ait yansıma açısının birim hücreye ait geometrik değişkenlere göre değişiminin modellenmesi, mikroşerit yama antenin saçılma parametrelerinin tasarıma ait geometrik değişkenlere göre değişimi, yarı küresel bir dielektrik yüklü anten yapısına ait ışıma ve saçılma parametrelerinin modellenmesi, frekans seçici yüzeye ait saçılma parametrelerinin, Mikrodalga tranzistör elemanın farklı DC besleme koşullarındaki saçılma parametrelerinin modellenmesi olarak sıralanır.

Ele alınan her bir problemde önerilen yöntemin performansı, literatürdeki diğer rakip ve yenilikçi algoritmalar ile kıyaslanmış olup önerilen yöntemin yüksek bir başarıya sahip olduğu gösterilmiştir. Bu sayede mikrodalga devre elemanlarının tasarım optimizasyonu süreçlerinde 3 boyutlu simülatör programlarına olan ihtiyacın ve işlemsel verimlilik açısından yetersiz olan 3B Elektromanyetik güdümlü optimizasyon süreçleri yerine, Topluluk Öğrenmesi'nin yöntemlerinden biri olan İyileştirme yöntemi güdümlü optimizasyon süreçleri ile, yüksek performanslı, çok değişkenli mikrodalga devrelerin tasarım optimizasyon süreçleri için, hızlı güvenilebilir ve tekrarlanabilir

işlemsel açıdan verimli tasarım optimizasyon süreçleri elde edilmiştir.

Bu tez kapsamında mikrodalga devrelerinde İyileştirme yöntemlerinin kullanılabileceği gösterilmiştir. Anten tasarımı, optimizasyon problemleri, mikrodalga devre elemanları modellenmesi gibi konularda yapılması, İyileştirme Yöntemleri'nin mikrodalga alanındaki kullanımını hızla artacaktır.

KAYNAKÇA

[1] J. Bell, *Machine Learning Hands-On for Developers and Technical Professionals*. John Wiley - Sons, Inc, 2014.

[2] J. Ossorio, J. Vague, V. E. Boria, M. Guglielmi, "Exploring the tuning range of channel filters for satellite applications using electromagnetic-based computer aided design tools," *IEEE Transactions on Microwave Theory and Techniques*, vol. 66, no. 2, pp. 717–725, 2017.

[3] P. Chen, B. M. Merrick, T. J. Brazil, "Bayesian optimization for broadband high-efficiency power amplifier designs," *IEEE Transactions on Microwave Theory and Techniques*, vol. 63, no. 12, pp. 4263–4272, 2015.

[4] J. Zhang, F. Feng, W. Na, S. Yan, Q. Zhang, "Parallel space-mapping based yield-driven em optimization incorporating trust region algorithm and polynomial chaos expansion," *IEEE Access*, vol. 7, pp. 143 673–143 683, 2019.

[5] M. U. Memon, A. Salim, H. Jeong, S. Lim, "Metamaterial ınspired radio frequency-based touchpad sensor system," *IEEE Transactions on Instrumentation and Measurement*, vol. 69, no. 4, pp. 1344–1352, 2019.

[6] S. Koziel, A. Pietrenko-Dabrowska, "Reduced-cost electromagnetic-driven optimisation of antenna structures by means of trust-region gradient-search with sparse jacobian updates," *IET Microwaves, Antennas & Propagation*, vol. 13, no. 10, pp. 1646–1652, 2019.

[7] A. Bautista, A.-L. Franc, P. Ferrari, "Accurate parametric electrical model for slow-wave cpw and application to circuits design," *IEEE Transactions on Microwave Theory and Techniques*, vol. 63, no. 12, pp. 4225–4235, 2015.

[8] A. Ciccazzo, G. Di Pillo, V. Latorre, "A svm surrogate model-based method for parametric yield optimization," *IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems*, vol. 35, no. 7, pp. 1224–1228, 2015.

[9] S. Koziel, A. Bekasiewicz, Q. S. Cheng, "Response features for low-cost statistical analysis and tolerance-aware design of antennas," *International Journal of Numerical Modelling: Electronic Networks, Devices and Fields*, vol. 31, no. 3, e2297, 2018.

[10] A. Abd El-Hameed, M. Wahab, A. Elboushi, M. S. Elpeltagy, "Miniaturized triple band-notched quasi-self complementary fractal antenna with improved characteristics for uwb applications," *AEU-International Journal of Electronics and Communications*, vol. 108, pp. 163–171, 2019.

[11] P. Mahouti, "Design optimization of a pattern reconfigurable microstrip antenna using differential evolution and 3d em simulation-based neural network model," *International Journal of RF and Microwave Computer-Aided Engineering*, vol. 29, no. 8, e21796, 2019.

[12] V. K. Devabhaktuni, M. C. Yagoub, Y. Fang, J. Xu, Q.-J. Zhang, "Neural networks for microwave modeling: Model development issues and nonlinear modeling techniques," *International Journal of RF and Microwave Computer-Aided Engineering: Co-sponsored by the Center for Advanced Manufacturing and Packaging of Microwave, Optical, and Digital Electronics (CAMPmode) at the University of Colorado at Boulder*, vol. 11, no. 1, pp. 4–21, 2001.

[13] M. Simsek, A. Aoad, "Efficient reconfigurable microstrip patch antenna modeling exploiting knowledge based artificial neural networks," in *Simulation-Driven Modeling and Optimization*, Springer, 2016, pp. 185–206.

[14] X. Li, J. Gao, G. Boeck, "Printed dipole antenna design using artificial neural network modeling for rfid application," *International Journal of RF and Microwave Computer-Aided Engineering: Co-sponsored by the Center for Advanced Manufacturing and Packaging of Microwave, Optical, and Digital Electronics (CAMPmode) at the University of Colorado at Boulder*, vol. 16, no. 6, pp. 607–611, 2006.

[15] F. Giannini, G. Leuzzi, G. Orengo, M. Albertini, "Small-signal and large-signal modeling of active devices using cad-optimized neural networks," *International Journal of RF and Microwave Computer-Aided Engineering: Co-sponsored by the Center for Advanced Manufacturing and Packaging of Microwave, Optical, and Digital Electronics (CAMPmode) at the University of Colorado at Boulder*, vol. 12, no. 1, pp. 71–78, 2002.

[16] Z. D. Marinković, V. V. Marković, "Temperature-dependent models of low-noise microwave transistors based on neural networks," *International Journal of RF and Microwave Computer-Aided Engineering: Co-sponsored by the Center for Advanced Manufacturing and Packaging of Microwave, Optical, and Digital Electronics (CAMPmode) at the University of Colorado at Boulder*, vol. 15, no. 6, pp. 567–577, 2005.

[17] K. S. R. Krishna, J. L. Narayana, L. P. Reddy, "Ann models for microstrip line synthesis and analysis," *Int. J. Elect. Syst. Sci. Eng*, vol. 1, no. 3, pp. 196–200, 2008.

[18] F. Güneş, S. Nesil, S. Demirel, "Design and analysis of minkowski reflectarray antenna using 3-d cst microwave studio-based neural network model with particle swarm optimization," *International Journal of RF and Microwave Computer-Aided Engineering*, vol. 23, no. 2, pp. 272–284, 2013.

[19] F. Güneş, S. Demirel, S. Nesil, "A novel design approach to x-band minkowski reflectarray antennas using the full-wave em simulation-based complete neural model with a hybrid ga-nm algorithm," *Radioengineering*, vol. 23, no. 1, pp. 144–153, 2014.

[20] F. Güneş, P. Mahouti, S. Demirel, M. A. Belen, A. Uluslu, "Cost-effective grnn-based modeling of microwave transistors with a reduced number of measurements," *International journal of numerical modelling: electronic networks, devices and fields*, vol. 30, no. 3-4, e2089, 2017.

[21] V. Ceperic, N. Bako, A. Baric, "A symbolic regression-based modelling strategy of ac/dc rectifiers for rfid applications," *Expert Systems with Applications*, vol. 41, no. 16, pp. 7061–7067, 2014.

[22] P. Mahouti, F. Güneş, M. A. Belen, S. Demirel, "Symbolic regression for derivation of an accurate analytical formulation using "big data" an application example," *Applied Computational Electromagnetics Society Journal*, vol. 32, no. 5, pp. 372–80, 2017.

[23] P. Mahouti, F. Güneş, M. A. Belen, A. Çalışkan, "A novel design of non-uniform reflectarrays with symbolic regression and its realization using 3-d printer.," *Applied Computational Electromagnetics Society Journal*, vol. 34, no. 2, 2019.

[24] M. Zeng, L. T. Nguyen, B. Yu, O. J. Mengshoel, J. Zhu, P. Wu, J. Zhang, "Convolutional neural networks for human activity recognition using mobile sensors," in *6th International Conference on Mobile Computing, Applications and Services*, IEEE, 2014, pp. 197–205.

[25] Y. Zheng, Q. Liu, E. Chen, Y. Ge, J. L. Zhao, "Time series classification using multi-channels deep convolutional neural networks," in *International Conference on Web-Age Information Management*, Springer, 2014, pp. 298–310.

[26] G. S. Babu, P. Zhao, X.-L. Li, "Deep convolutional neural network based regression approach for estimation of remaining useful life," in *International conference on database systems for advanced applications*, Springer, 2016, pp. 214–228.

[27] D. Held, S. Thrun, S. Savarese, "Learning to track at 100 fps with deep regression networks," in *European Conference on Computer Vision*, Springer, 2016, pp. 749–765.

[28] W. Bao, J. Yue, Y. Rao, "A deep learning framework for financial time series using stacked autoencoders and long-short term memory," *PloS one*, vol. 12, no. 7, 2017.

[29] A. S. Qureshi, A. Khan, A. Zameer, A. Usman, "Wind power prediction using deep neural network based meta regression and transfer learning," *Applied Soft Computing*, vol. 58, pp. 742–755, 2017.

[30] Y. Li, H. Shi, F. Han, Z. Duan, H. Liu, "Smart wind speed forecasting approach using various boosting algorithms, big multi-step forecasting strategy," *Renewable energy*, vol. 135, pp. 540–553, 2019.

[31] Z. Wei, X. Chen, "Deep-learning schemes for full-wave nonlinear inverse scattering problems," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 57, no. 4, pp. 1849–1860, 2018.

[32] J. Wang, X.-S. Yang, B.-Z. Wang, "Efficient gradient-based optimisation of pixel antenna with large-scale connections," *IET Microwaves, Antennas & Propagation*, vol. 12, no. 3, pp. 385–389, 2017.

[33] A. Pietrenko-Dabrowska, S. Koziel, "Computationally-efficient design optimisation of antennas by accelerated gradient search with sensitivity and design change monitoring," *IET Microwaves, Antennas & Propagation*, vol. 14, no. 2, pp. 165–170, 2019.

[34] S. Kozieł, A. Pietrenko-Dąbrowska, "Reduced-cost design closure of antennas by means of gradient search with restricted sensitivity update," *Metrology and Measurement Systems*, pp. 595–605, 2019.

[35] A. Darvish, A. Ebrahimzadeh, "Improved fruit-fly optimization algorithm and its applications in antenna arrays synthesis," *IEEE Transactions on Antennas and Propagation*, vol. 66, no. 4, pp. 1756–1766, 2018.

[36] J. Joung, "Machine learning-based antenna selection in wireless communications," *IEEE Communications Letters*, vol. 20, no. 11, pp. 2241–2244, 2016.

[37] S. Mishra, R. N. Yadav, R. P. Singh, "Directivity estimations for short dipole antenna arrays using radial basis function neural networks," *IEEE Antennas and Wireless Propagation Letters*, vol. 14, pp. 1219–1222, 2015.

[38] J.-Y. Li, Z.-H. Zhan, C. Wang, H. Jin, J. Zhang, "Boosting data-driven evolutionary algorithm with localized data generation," *IEEE Transactions on Evolutionary Computation*, vol. 24, no. 5, pp. 923–937, 2020.

[39] H. Wang, Y. Jin, C. Sun, J. Doherty, "Offline data-driven evolutionary optimization using selective surrogate ensembles," *IEEE Transactions on Evolutionary Computation*, vol. 23, no. 2, pp. 203–216, 2018.

[40] I. A. Baratta, C. B. de Andrade, R. R. de Assis, E. J. Silva, "Infinitesimal dipole model using space mapping optimization for antenna placement," *IEEE Antennas and Wireless Propagation Letters*, vol. 17, no. 1, pp. 17–20, 2017.

[41] A.-K. S. Hassan, A. S. Etman, E. A. Soliman, "Optimization of a novel nano antenna with two radiation modes using kriging surrogate models," *IEEE Photonics Journal*, vol. 10, no. 4, pp. 1–17, 2018.

[42] J. Dong, Q. Li, L. Deng, "Fast multi-objective optimization of multi-parameter antenna structures based on improved moea/d with surrogate-assisted model," *AEU-International Journal of Electronics and Communications*, vol. 72, pp. 192–199, 2017.

[43] S. Mishra, R. N. Yadav, R. P. Singh, "Directivity estimations for short dipole antenna arrays using radial basis function neural networks," *IEEE Antennas and Wireless Propagation Letters*, vol. 14, pp. 1219–1222, 2015.

[44] J. P. Jacobs, "Efficient resonant frequency modeling for dual-band microstrip antennas by gaussian process regression," *IEEE Antennas and Wireless Propagation Letters*, vol. 14, pp. 337–341, 2014.

[45] J. L. Chávez-Hurtado, J. E. Rayas-Sánchez, "Polynomial-based surrogate modeling of rf and microwave circuits in frequency domain exploiting the multinomial theorem," *IEEE Transactions on Microwave Theory and Techniques*, vol. 64, no. 12, pp. 4371–4381, 2016.

[46] J. E. Rayas-Sánchez, "Em-based optimization of microwave circuits using artificial neural networks: The state-of-the-art," *IEEE Transactions on Microwave Theory and Techniques*, vol. 52, no. 1, pp. 420–435, 2004.

[47] F. Feng, C. Zhang, J. Ma, Q.-J. Zhang, "Parametric modeling of em behavior of microwave components using combined neural networks and pole-residue-based transfer functions," *IEEE Transactions on Microwave Theory and Techniques*, vol. 64, no. 1, pp. 60–77, 2015.

[48] H. Kabir, Y. Wang, M. Yu, Q.-J. Zhang, "Neural network inverse modeling and applications to microwave filter design," *IEEE Transactions on Microwave Theory and Techniques*, vol. 56, no. 4, pp. 867–879, 2008.

[49] F. Güneş, P. Mahouti, S. Demirel, M. A. Belen, A. Uluslu, "Cost-effective grnn-based modeling of microwave transistors with a reduced number of measurements," *International journal of numerical modelling: electronic networks, devices and fields*, vol. 30, no. 3-4, e2089, 2017.

[50] D. R. Prado, J. A. López-Fernández, M. Arrebola, G. Goussetis, "Support vector regression to accelerate design and crosspolar optimization of shaped-beam reflectarray antennas for space applications," *IEEE Transactions on Antennas and Propagation*, vol. 67, no. 3, pp. 1659–1668, 2018.

[51] J. P. Jacobs, "Bayesian support vector regression with automatic relevance determination kernel for modeling of antenna input characteristics," *IEEE transactions on antennas and propagation*, vol. 60, no. 4, pp. 2114–2118, 2012.

[52] F. GÜNEŞ, M. A. Belen, P. Mahouti, S. Demirel, "Signal and noise modeling of microwave transistors using characteristic support vector-based sparse regression," *Radioengineering*, vol. 25, no. 3, pp. 490–499, 2016.

[53] J. A. Easum, J. Nagar, D. H. Werner, "Multi-objective surrogate-assisted optimization applied to patch antenna design," in *2017 IEEE International Symposium on Antennas and Propagation & USNC/URSI National Radio Science Meeting*, IEEE, 2017, pp. 339–340.

[54] A. Gehani, P. Agnihotri, D. A. Pujara, "Analysis and synthesis of multiband sierpinski carpet fractal antenna using hybrid neuro-fuzzy model," *Progress In Electromagnetics Research*, vol. 68, pp. 59–65, 2017.

[55] V. F. Rodriguez-Galiano, B. Ghimire, J. Rogan, M. Chica-Olmo, J. P. Rigol-Sanchez, "An assessment of the effectiveness of a random forest classifier for land-cover classification," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 67, pp. 93–104, 2012.

[56] G. Giacinto, F. Roli, "Design of effective neural network ensembles for image classification purposes," *Image and Vision Computing*, vol. 19, no. 9-10, pp. 699–707, 2001.

[57] J. Xia, N. Yokoya, A. Iwasaki, "A novel ensemble classifier of hyperspectral and lidar data using morphological features," in *2017 IEEE international conference on acoustics, speech and signal processing (ICASSP)*, IEEE, 2017, pp. 6185–6189.

[58] P. Du, S. Liu, J. Xia, Y. Zhao, "Information fusion techniques for change detection from multi-temporal remote sensing images," *Information Fusion*, vol. 14, no. 1, pp. 19–27, 2013.

[59] M. Woźniak, M. Graña, E. Corchado, "A survey of multiple classifier systems as hybrid systems," *Information Fusion*, vol. 16, pp. 3–17, 2014.

[60] P. A. R. Kumar, S. Selvakumar, "Distributed denial of service attack detection using an ensemble of neural classifier," *Computer Communications*, vol. 34, no. 11, pp. 1328–1341, 2011.

[61] A. Savio, M. T. Garcıéa-Sebastián, D. Chyzyk, C. Hernández, M. Graña, A. Sistiaga, A. L. De Munain, J. Villanúa, "Neurocognitive disorder detection based on feature vectors extracted from vbm analysis of structural mrı," *Computers in biology and medicine*, vol. 41, no. 8, pp. 600–610, 2011.

[62] B. Ayerdi, A. Savio, M. Graña, "Meta-ensembles of classifiers for alzheimer's disease detection using independent roı features," in *International Work-Conference on the Interplay Between Natural and Artificial Computation*, Springer, 2013, pp. 122–130.

[63] Q. Gu, Y.-S. Ding, T.-L. Zhang, "An ensemble classifier based prediction of g-protein-coupled receptor classes in low homology," *Neurocomputing*, vol. 154, pp. 110–118, 2015.

[64] A. Jain, F. Smarra, R. Mangharam, "Data predictive control using regression trees and ensemble learning," in *2017 IEEE 56th annual conference on decision and control (CDC)*, IEEE, 2017, pp. 4446–4451.

[65] T. Pinto, I. Praça, Z. Vale, J. Silva, "Ensemble learning for electricity consumption forecasting in office buildings," *Neurocomputing*, vol. 423, pp. 747–755, 2021.

[66] X. Lu, W. Zhou, X. Ding, X. Shi, B. Luan, M. Li, "Ensemble learning regression for estimating unconfined compressive strength of cemented paste backfill," vol. 7, IEEE, 2019, pp. 72 125–72 133.

[67] S. Papadopoulos, E. Azar, W.-L. Woon, C. E. Kontokosta, "Evaluation of tree-based ensemble learning algorithms for building energy performance estimation," *Journal of Building Performance Simulation*, vol. 11, no. 3, pp. 322–332, 2018.

[68] R. E. Schapire, "A brief introduction to boosting," in *Ijcai*, vol. 99, 1999, pp. 1401–1406.

[69] B. V. Dasarathy, B. V. Sheela, "A composite classifier system design: Concepts and methodology," *Proceedings of the IEEE*, vol. 67, no. 5, pp. 708–713, 1979.

[70] L. Hansen, "P. salomon,"," *Neural Network Ensembles," vol. IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 12, 1990.

[71] R. E. Schapire, "The strength of weak learnability," *Machine learning*, vol. 5, no. 2, pp. 197–227, 1990.

[72] M. I. Jordan, R. A. Jacobs, "Hierarchical mixtures of experts and the em algorithm," *Neural computation*, vol. 6, no. 2, pp. 181–214, 1994.

[73] D. H. Wolpert, "Stacked generalization," *Neural networks*, vol. 5, no. 2, pp. 241–259, 1992.

[74] G. Rogova, "Combining the results of several neural network classifiers," *Neural networks*, vol. 7, no. 5, pp. 777–781, 1994.

[75] T. K. Ho, J. J. Hull, S. N. Srihari, "Decision combination in multiple classifier systems," *IEEE transactions on pattern analysis and machine intelligence*, vol. 16, no. 1, pp. 66–75, 1994.

[76] L. Lam, C. Y. Suen, "Optimal combinations of pattern classifiers," *Pattern Recognition Letters*, vol. 16, no. 9, pp. 945–954, 1995.

[77] K. Woods, W. P. Kegelmeyer, K. Bowyer, "Combination of multiple classifiers using local accuracy estimates," *IEEE transactions on pattern analysis and machine intelligence*, vol. 19, no. 4, pp. 405–410, 1997.

[78] S.-B. Cho, J. H. Kim, "Combining multiple neural networks by fuzzy integral for robust classification," *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 25, no. 2, pp. 380–384, 1995.

[79] L. I. Kuncheva, J. C. Bezdek, R. P. Duin, "Decision templates for multiple classifier fusion: An experimental comparison," *Pattern recognition*, vol. 34, no. 2, pp. 299–314, 2001.

[80] B. Kégl, "The return of adaboost. mh: Multi-class hamming trees," *arXiv preprint arXiv:1312.6086*, 2013.

[81] Y. Freund, R. Schapire, N. Abe, "A short introduction to boosting," *Journal-Japanese Society For Artificial Intelligence*, vol. 14, no. 771-780, p. 1612, 1999.

[82] T. Hastie, R. Tibshirani, J. Friedman, "The elements of statistical learnin," *Cited on*, p. 33, 2009.

[83] L. Breiman, "Arcing the edge," Technical Report 486, Statistics Department, University of California at ..., Tech. Rep., 1997.

[84] J. H. Friedman, "Stochastic gradient boosting," *Computational statistics & data analysis*, vol. 38, no. 4, pp. 367–378, 2002.

[85] ——, "Greedy function approximation: A gradient boosting machine," *Annals of statistics*, pp. 1189–1232, 2001.

[86] L. Mason, J. Baxter, P. Bartlett, M. Frean, "Boosting algorithms as gradient descent in function space," in *Proc. NIPS*, vol. 12, 1999, pp. 512–518.

[87] S. M. Piryonesi, T. E. El-Diraby, "Data analytics in asset management: Cost-effective prediction of the pavement condition index," *Journal of Infrastructure Systems*, vol. 26, no. 1, p. 04 019 036, 2020.

[88] T. Hastie, R. Tibshirani, J. Friedman, "Boosting and additive trees," in *The elements of statistical learning*, Springer, 2009, pp. 337–387.

[89] T. Chen, C. Guestrin, "Xgboost: A scalable tree boosting system," in *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, 2016, pp. 785–794.

[90] G. Ke, Q. Meng, T. Finley, T. Wang, W. Chen, W. Ma, Q. Ye, T.-Y. Liu, "Lightgbm: A highly efficient gradient boosting decision tree," *Advances in neural information processing systems*, vol. 30, pp. 3146–3154, 2017.

[91] N. Gürsakal, *Makine Öğrenmesi ve Derin Öğrenme*. Dora Basım-Yayın Dağıtım Ltd. Şti, 2017.

[92] Y. Koren, "The bellkor solution to the netflix grand prize," *Netflix prize documentation*, vol. 81, no. 2009, pp. 1–10, 2009.

[93] M. A. Ehsan Bhuiyan, E. I. Nikolopoulos, E. N. Anagnostou, "Machine learning–based blending of satellite and reanalysis precipitation datasets: A multiregional tropical complex terrain evaluation," *Journal of Hydrometeorology*, vol. 20, no. 11, pp. 2147–2161, 2019.

[94] C. Feng, J. Zhang, "Hourly-similarity based solar forecasting using multi-model machine learning blending," in *2018 IEEE Power & Energy Society General Meeting (PESGM)*, IEEE, 2018, pp. 1–5.

[95] P. Mahouti, "Application of artificial intelligence algorithms on modeling of reflection phase characteristics of a nonuniform reflectarray element," *International Journal of Numerical Modelling: Electronic Networks, Devices and Fields*, vol. 33, no. 2, e2689, 2020.

[96] N. Calik, M. A. Belen, P. Mahouti, "Deep learning base modified mlp model for precise scattering parameter prediction of capacitive feed antenna," *International Journal of Numerical Modelling: Electronic Networks, Devices and Fields*, vol. 33, no. 2, e2682, 2020.

[97] D. Pozar, T. Metzler, "Analysis of a reflectarray antenna using microstrip patches of variable size," *Electronics Letters*, vol. 29, no. 8, pp. 657–658, 1993.

[98] M. Salucci, L. Tenuti, G. Oliveri, A. Massa, "Efficient prediction of the em response of reflectarray antenna elements by an advanced statistical learning method," *IEEE Transactions on Antennas and Propagation*, vol. 66, no. 8, pp. 3995–4007, 2018.

[99] A. Belen, F. Güneş, M. A. Belen, P. Mahouti, "3d printed wideband flat gain multilayer nonuniform reflectarray antenna for x-band applications," *International Journal of Numerical Modelling: Electronic Networks, Devices and Fields*, vol. 33, no. 6, e2753, 2020.

[100] H. Kalayci, U. E. Ayten, P. Mahouti, "Ensemble-based surrogate modeling of microwave antennas using xgboost algorithm," *International Journal of Numerical Modelling: Electronic Networks, Devices and Fields*, e2950,

[101] A. Belen, F. Güneş, P. Mahouti, M. Palandöken, "A novel design of high performance multilayered cylindrical dielectric lens antenna using 3d printing technology," *International Journal of RF and Microwave Computer-Aided Engineering*, vol. 30, no. 1, e21988, 2020.

[102] N. Calik, M. A. Belen, P. Mahouti, S. Koziel, "Accurate modeling of frequency selective surfaces using fully-connected regression model with automated architecture determination and parameter selection based on bayesian optimization," *IEEE Access*, vol. 9, pp. 38 396–38 410, 2021.

[103] N. Calik, M. A. Belen, P. Mahouti, "Deep learning base modified mlp model for precise scattering parameter prediction of capacitive feed antenna," *International Journal of Numerical Modelling: Electronic Networks, Devices and Fields*, vol. 33, no. 2, e2682, 2020.

[104] H. Kalaycı, P. Mahouti, M. A. Belen, U. E. Ayten, "Boosting - based modelling of frequency selective surfaces," in *Research & Reviews In Engineering*, 2021, pp. 105–130.

[105] J. Wang, Y.-H. Kim, J. Ryu, C. Jeong, W. Choi, D. Kim, "Artificial neural network-based compact modeling methodology for advanced transistors," *IEEE Transactions on Electron Devices*, vol. 68, no. 3, pp. 1318–1325, 2021.

[106] Z. Marinković, G. Crupi, A. Caddemi, V. Marković, D. M.-P. Schreurs, "A review on the artificial neural network applications for small-signal modeling of microwave fets," *International Journal of Numerical Modelling: Electronic Networks, Devices and Fields*, vol. 33, no. 3, e2668, 2020.

[107] Q.-J. Zhang, K. C. Gupta, V. K. Devabhaktuni, "Artificial neural networks for rf and microwave design-from theory to practice," *IEEE transactions on microwave theory and techniques*, vol. 51, no. 4, pp. 1339–1350, 2003.

[108] G. L. Creech, B. J. Paul, C. D. Lesniak, T. J. Jenkins, M. C. Calcatera, "Artificial neural networks for fast and accurate em-cad of microwave circuits," *IEEE Transactions on Microwave Theory and Techniques*, vol. 45, no. 5, pp. 794–802, 1997.

[109] J. E. Rayas-Sánchez, "Em-based optimization of microwave circuits using artificial neural networks: The state-of-the-art," *IEEE Transactions on Microwave Theory and Techniques*, vol. 52, no. 1, pp. 420–435, 2004.

[110] D. M. Pozar, *Microwave engineering*. John wiley & sons, 2011.

[111] D. A. Frickey, "Conversions between s, z, y, h, abcd, and t parameters which are valid for complex source and load impedances," *IEEE Transactions on microwave theory and techniques*, vol. 42, no. 2, pp. 205–211, 1994.

[112] A. Jarndal, "Neural network electrothermal modeling approach for microwave active devices," *International Journal of RF and Microwave Computer-Aided Engineering*, vol. 29, no. 9, e21764, 2019.

A
GBM REGRESYON AĞAÇ ALGORİTMASI

Model Giriş: Dataset $D : D = (x_1, y_1), (x_2, y_2), .., (x_N, y_N)$ y_i Reel Sayı
Model Çıkış: Final regressor: $f_m(x)$
Kayıp Fonksiyonu: Kare Hatası
Adımlar:**Başlangıç**:$f_0(x)$=argmin$_\gamma(\sum_{i=1}^{N} Loss(y_, \gamma))$
Her m için (1,2, 3..., M): negatif gradient hesaplanır:

$$\widetilde{y}_i^m = -\frac{\partial Loss\,(y_i, f_{m-1}(x))}{\partial f_{m-1}(x)} = \frac{\partial\,[y_i - f_{m-1}(x)]^2}{\partial f_{m-1}(x)} = 2 * (y_i - f_{m-1}(x_i)) \tag{A.1}$$

CART karar ağacının alanı J farklı parçaya böldüğünü varsayarsak $R_{j,m}$ kare kaybını en aza indirerek yeni bir CART ağacına göre eğitilir:

$$f_0(x) = argmin_{b(x)}(\sum_{i=1}^{N}\left[\widetilde{y}_i^m - b\,(x)\right]^2 \rightarrow \left\{R_{j,m}\right\} \tag{A.2}$$

$$f_0(x) = argmin_{\{R_{j,m}\}}(\sum_{i=1}^{N}\left[\widetilde{y}_i^m - b\left(x_i, \left\{R_{j,m}\right\}\right)\right]^2 \tag{A.3}$$

İyileştirilmiş sonuçlar için, tüm ağaç için en uygun parametreyi bulmak üzere doğrusal bir arama yapmak yerine, ağacın içindeki her bölge için en uygun parametreyi benzersiz bir şekilde bulmak için seçilebilir:

$$\gamma = argmin_{\eta_j}(\sum_{i=1}^{N} Loss\left(y_i - f_{m-1}(x) + \gamma_j * I(x \epsilon \left\{R_{j,m}\right\}\right) \tag{A.4}$$

$$\gamma_{j,m} = argmin_{\eta_j}(\sum_{i=1}^{N}\left[y_i - f_{m-1}(x) + \gamma_j * I(x \epsilon \left\{R_{j,m}\right\})\right]^2 \tag{A.5}$$

Fonksiyon güncellenir $f_m\,(x)$:

$$f_m(x) = f_{m-1}(x) + \sum_{j=1}^{N}\left[\gamma_j * I(x_i \epsilon \left\{R_{j,m}\right\})\right] \tag{A.6}$$

Final modeli $f_M(x)$**:**

$$f_M(x) = f_0(x) + \sum_{m=1}^{M}\sum_{j=1}^{J} \gamma_j * I(x_i \epsilon \left\{R_{j,m}\right\}) \tag{A.7}$$

B
XGBM REGRESYON AĞAÇ ALGORİTMASI

Model Giriş: Dataset $D : D = (x_1, y_1), (x_2, y_2), .., (x_N, y_N)$ y_i Reel Sayı
Model Çıkışı: Final regressor: $f_m(x)$
Adımlar:**Başlangıç**:$f_0(x)$=argmin$_\gamma(\sum_{i=1}^{N} Loss(y_, \gamma))$
Her $k = 1$ in m: negatif gradient hesaplanır:

a. gradient hesaplama: $g_i = \frac{\partial Loss(y_i, f_{m-1}(x))}{\partial f_{m-1}(x)} i = 1, 2, 3, 4, .., N$ (B.1)

b. İkinci Türev hesaplama $h_i = \frac{\partial^2 Loss(y_i, f_{m-1}(x))}{\partial^2 f_{m-1}(x)}$ $i = 1, 2, 3, 4, .., N$ (B.2)

c. Regülasyon parametresi ile kayıp fonksiyonu azaltımı ve yeni tahmin

Ağaç eğitimi - Yeni ağaç: $G_m(x) = \sum_{j=1}^{J} b_j * I(x_i \epsilon R_j) i = 1, 2, 3, 4, .., N$ (B.3)

En iyi yapının bulunması:

$$\{R_{j,m}\}_{j=1}^{J} = argmin_{\{R_{j,m}\}_{j=1}^{J}} (\sum_{j=1}^{J} (G_j * b_j \ + \frac{1}{2}(H_j + \lambda) * b_j^2)) + \gamma * J \quad \text{(B.4)}$$

$$G_j = \sum_{x_i \in R_j} g_i, H_j = \sum_{x_i \in R_j} h_i \rightarrow b_j = -\frac{G_j}{H_j + \lambda} \quad \text{(B.5)}$$

Minimal final Loss: $Loss(y_i, f_m(x)) = \sum_{j=1}^{J} (-\frac{1}{2} * \frac{G_j}{H_j + \lambda}) + \gamma * J$ (B.6)

$f_m(x)$ **fonksiyonu güncelleme:** $f_m(x) = f_{m-1}(x) + G_m(x)$ (B.7)

Çıkış: final modeli $f_m(x)$**:**$f_m(x) = f_0(x) + \sum_{m=1}^{M} G_m(x)$ (B.8)

C
BÖLÜNME İÇİN TAM AÇGÖZLÜ ALGORİTMA (EXACT GREEDY ALGORITM FOR SPLIT FINDING

Giriş: I, geçerli düğümlerin örnek kümesi
d, Özellik boyutu
Skor $\leftarrow$0,
G$\leftarrow\sum_{i\in I} g_i$,
H$\leftarrow\sum_{i\in I} h_i$
Her $k = 1$ in m **do**
$G_L\leftarrow$0, $H_L\leftarrow$0
Her j in Sıralanmış(I,X_{jk}'e göre)
$G_L\leftarrow G_L+g_j$, $H_L\leftarrow H_L+g_j$
$G_R\leftarrow G-G_L$, $H_R\leftarrow H-H_L$

$$Skor \leftarrow max(Skor, \left[\frac{G_L^2}{H_L+\lambda}+\frac{G_R^2}{H_R+\lambda}-\frac{G^2}{H+\lambda}\right]) \tag{C.1}$$

Çıkış: Maksimum Puanla Böl

D
BÖLÜNMÜŞ BULMA İÇİN YAKLAŞIK ALGORİTMA (APPROXIMATE ALGORITM FOR SPLIT FINDING

Giriş: D_k={$(x_{1k,h_{1k}})$,$(x_{2k,h_{2k}})$,..,$(x_{1n,h_{1n}})$} $\{S_{k1}, S_{k2}, ..., .S_{kl}\}$ Bölünmüş nokta adayı
Her $k = 1$ in m'de
Propose S_k={$S_{k1}, S_{k2}, ..., .S_{kl}$}
k Özelliğindeki yüzdelikler, Teklif ağaç başına (genel) veya bölüm başına (yerel) yapılabilir
global: Ağacı oluşturmadan önce öbekleri tanımlama
lokal: Her bölmeden önce öbekleri tanımlama

Her $k = 1$ m'de

$$G_{kv} \leftarrow= \sum_{J \in \left\{ j | S_{k,v} \geq x_{jk} > S_{k,v-1} \right\}} g_j \tag{D.1}$$

$$H_{kv} \leftarrow= \sum_{J \in \left\{ j | S_{k,v} \geq x_{jk} > S_{k,v-1} \right\}} h_j \tag{D.2}$$

son
Çıkış: Yalnızca önerilen bölmeler arasında maksimum skoru bulmak için aynı adımı izle

E
SEYREKLİĞE DUYARLI BÖLÜNMÜŞ BULMA (SPARSITY-AWARE SPLIT FINDING)

Input: I, geçerli düğümlerin örnek kümesi I_k= {i ∈ I| $x_{ik} \neq$ kayıp}
d, Özellik boyutu
Ayrıca yaklaşık ayarlar için geçerlidir, yalnızca öbeklere eksik olmayan girişlerin istatistiklerini toplar
Score ←0
G← $\sum_{i \in I} g_i$, $H \leftarrow \sum_{i \in I} h_i$
Her $k = 1$ in m:
Eksik değeri numaralandır sağa git
$G_L \leftarrow 0, H_L \leftarrow 0$
Her j in Sırala (I,X_{jk}'e göre)

$$G_L \leftarrow G_L + g_j, H_L \leftarrow H_L + g_j \qquad G_R \leftarrow G - G_L, H_R \leftarrow H - H_L \tag{E.1}$$

$$score \leftarrow max(Skor, [\frac{G_L^2}{H_L + \lambda} + \frac{G_R^2}{H_R + \lambda} - \frac{G^2}{H + \lambda}]) \tag{E.2}$$

end
Eksik değeri numaralandır sola git
$G_R \leftarrow 0, H_R \leftarrow 0$
Her j in Sırala (I,X_{jk}'e göre)

$$G_R \leftarrow G_R + g_j, H_R \leftarrow H_R + g_j \qquad G_L \leftarrow G - G_R, H_L \leftarrow H - H_R \tag{E.3}$$

$$score \leftarrow max(Skor, [\frac{G_L^2}{H_L + \lambda} + \frac{G_R^2}{H_R + \lambda} - \frac{G^2}{H + \lambda}]) \tag{E.4}$$

son
son Output: Maksimum Puan ile bölünmüş yönler

F
HİSTOGRAM ALGORİTMASI

Giriş: I, Eğitim verileri d, Maksimum derinlik m, Özellik boyutu
nodeSet ←{0}▷ mevcut seviyedeki ağaç düğümleri
rowSet ←{{0,1,2,..}}▷ tree nodes in current level
Her $i = 1$ m'de
  Her nodeSet'deki Node'da
  usedRows ← rowSet[node]
    Her $k = 1$ m'deki
      H← yeni Histogram ()
      ▷ $Build$ Histogram
    Her usedRows'daki j'de
      bin ← $I.f[k][j].bin$
      $H[bin].y \leftarrow H[bin].y + I.y[j]$
      $H[bin].n \leftarrow H[bin].n + 1$
    H histogramındaki en iyi ayrımı bulun.
    ....
    ....
    RowSet ve nodeSet'i en iyi ayırma noktasına göre güncelle

G
GRADYAN TABANLI TEK TARAFLI ÖRNEKLEME (GOSS)

Giriş: I, Eğitim verileri, d, iterasyon, a, Büyük gradyan verilerinin örnekleme oranı, b, Küçük gradyan verilerinin örnekleme oranı, $loss$, Kayıp fonksiyonu, L, Zayıf öğrenici
modeller ← {}
fact ← $\frac{1-a}{b}$
topN ← a × $len(I)$
randN ← b × $len(I)$
Her $i = 1$ d'de
    preds ← $models.predict(I)$
    g ← loss(I,preds), w ← {1,1,...}
    sorted ← $GetSortedIncides$(abs(g))
    topSet ← $sorte$d [1:topN]
    randSet ← $RandomPick(sorted$[topN:len(I])
    rand(N)
    usedSet ← $topSet + randSet$
    w[randSet] x = $fact$ ▷ Küçük gradyan verilerine ağırlık atayın
    newModel ← L(I[usedSet], - g[usedSet], w[usedSet])
    models.append(newModel)
son

H
AÇGÖZLÜ (GREEDY) PAKETLEME

Input:*F*, Özellikler, *K*, maksimum çakışma sayısı, *G*, grafik oluşturma,
searchOrder ← G.sortByDegree()
bundles ← {},
bundlesConflict ← {}
Her *i* in searchOrder'da
    needNew ← True
    Her $j = 1$ in len(bundles)'da
    cnt ← ConflictCnt(bundles[j],F[i])
    if cnt + bundlesConflict[i] ≤ K **do**
        bundles[j]. add(F[i]),
        needNew ← False
        break
    Eğer needNew then **do**
        F[i]'yi paketlere yeni bir paket olarak ekleyin
Output: bundles

I
ÖZEL ÖZELLİKLERİ (EXCLUSIVE FEATURES) BİRLEŞTİRME

Giriş: $numData$, veri sayısı F, bir paket özel özellik
$binRanges \leftarrow 0$,
$totalBin \leftarrow 0$

Her f in F'de
    totalBin + = f. numBin
    binRanges.append(totalBin)
newBin ← new Bin(numData)
Her $i = 1$ in numData'da
    newBin [i] ← 0
    for $j = 1$ in len(F) **do**
    Eğer F[j].bin[i] $\neq 0$ **then**
        newBin[i] ← F[j].bin[i]
        +binRanges[j]
Çıkış: newBin,binRanges

TEZDEN ÜRETİLMİŞ YAYINLAR

Makale

1. Ensemble-Based Surrogate Modelling of Microwave Antennas using XGBoost, International Journal of Numerical Modelling: Electronic Networks, Devices and Fields, DOI: 10.1002/(ISSN)1099-1204

2. Boosting-Based Modelling of Frequency Surfaces, Research - Reviews in Engineering-September, 2021(volume 2) Gecekitaplığı Kitabevi,
ISBN: 978-625-8002-45-4