

**T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**GENİŞ ÇALIŞMA BÖLGELİ
BİR MİKRODALGA TRANSİSTÖRÜNÜN
DESTEK VEKTÖR REGRESYON MAKİNESİ İLE
MODELLENMESİ**

ŞERİFE YÜREKLİ

**YÜKSEK LİSANS TEZİ
ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ
ANABİLİM DALI
HABERLEŞME PROGRAMI**

**DANIŞMAN
PROF. DR.FİLİZ GÜNEŞ**

İSTANBUL, 2017

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

GENİŞ ÇALIŞMA BÖLGELİ BİR MİKRODALGA
TRANSİSTÖRÜNÜN DESTEK VEKTÖR REGRESYON MAKİNESİ
İLE MODELLENMESİ

Şerife YÜREKLİ tarafından hazırlanan tez çalışması 19.12.2017 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektronik ve Haberleşme Mühendisliği Anabilim Dalı'nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Tez Danışmanı

Prof. Dr. Filiz GÜNEŞ
Yıldız Teknik Üniversitesi

Jüri Üyeleri

Prof. Dr. Filiz GÜNEŞ
Yıldız Teknik Üniversitesi

Prof. Dr. Fikret GÜRGEN
Boğaziçi Üniversitesi

Doç. Dr. Hamid TORPİ
Yıldız Teknik Üniversitesi

ÖNSÖZ

Bu tezde Destek Vektör Makineleri'nin mikrodalga teori ve tekniğine uygulanarak mikrodalga transistörünün kara kutu modellemesi gerçekleştirilmiştir.

Bu alanda çalışma fırsatı veren ve tez çalışması süresince hoşgörüsünü ve anlayışını hiç esirgemeyen değerli hocam Prof. Dr. Filiz GÜNEŞ' e teşekkürü bir borç bilirim. Çalışmalarımızı sürekli destekleyen, sıcak ve samimi yaklaşımıyla çalışmamızın keyifli bir seyirde tamamlanmasını sağlayan sevgili hocam Öğretim Görevlisi Dr. Peyman MAHOUTİ'ye a en içten dileklerimle teşekkür ederim. Sadece bu dönemde değil, her zaman destek olan sevgili hayat arkadaşım Özgür YÜREKLİ' ye en kalbi teşekkürlerimi sunarım. Ayrıca, maddi, manevi desteklerini hiçbir zaman eksik etmeyen canım aileme, moral kaynağım biricik kızım Asya Meryem'e sonsuz teşekkürler ederim.

Tez çalışma döneminde akademik izin olanağı saylayan bayrak taşıyıcı hava yolumuz olan THY A.O.' ya teşekkür ederim.

Faydalı olması dileğiyle,

Kasım, 2017

Şerife YÜREKLİ

İÇİNDEKİLER

Sayfa

SİMGE LİSTESİ	vi
KISALTMA LİSTESİ	vii
ŞEKİL LİSTESİ.....	viii
ÇİZELGE LİSTESİ	x
ÖZET	xii
ABSTRACT	xiii
BÖLÜM 1	
GİRİŞ	1
1.1 Literatür Özeti.....	1
1.2 Tezin Amacı.....	2
1.3 Hipotez.....	3
BÖLÜM 2	
DESTEK VEKTÖR MAKİNELERİ	4
2.1 Doğrusal Öğrenen Makineler.....	4
2.1.1 Doğrusal Sınıflandırma	4
2.1.2 Doğrusal Regresyon	6
2.1.3 Doğrusal Makinelerin Çift Gösterimi.....	7
2.2 Kernel'e Bağlı Özellik Uzayları	7
2.2.1 Özellik Uzayında Öğrenme	8
2.2.2 Özellik Uzayına Eşleme	9
2.3 Destek Vektör Makineleri.....	11
2.3.1 Destek Vektör Sınıflandırması	11
2.3.1.1 Doğrusal Destek Vektör Makineleri	12
2.3.1.2 Doğrusal Olmayan Destek Vektör Makineleri.....	13
2.4 Destek Vektör Regresyon Makineleri.....	14
2.5 Birincil Optimizasyon Problem Formülasyonu	15
2.6 Lagrange Fonksiyonu ve Çift Gösterimi	17

BÖLÜM 3

BİR MİKRODALGA TRANSİSTÖRÜNÜN DESTEK VEKTÖR MAKİNELERİ İLE KARAKUTU MODELLEMESİ	20
3.1 Bir Mikrodalga Transistörün DVRM Modeli	21
3.1.1 Bir Mikrodalga Transistörün Kara-Kutu Gösterimi	21
3.1.2 Eğitim ve Test Verisi	21
3.2 Uygulama Örneği: BFP-181' in İşaret Modeli	22
3.2.1 Modelin Eğitim ve Test Verisi	22
3.2.2 Transistör Modelinin Hata Analizi	23
3.2.3 BPF-181'in İşaret Parametrelerinin DVRM Modeli	23
3.2.3.1 Senaryo 1	23
3.2.3.2 Senaryo 2	31
3.2.3.3 Senaryo 3	37
3.2.3.4 Senaryo 4	47
3.2.3.5 Senaryo 5	52
3.2.3.6 Senaryo 6	58
3.2.3.7 Senaryo 7	61
3.2.3.8 Senaryo 8	66
3.3 Ekstrapolasyon İçin Optimum DVRM Modeli	70
3.3.1 Düşük Gerilim Bölgesinde Ekstrapolasyon	72
3.3.2 Orta Gerilim Bölgesinde Ekstrapolasyon	77
3.3.3 Yüksek Gerilim Bölgesinde Ekstrapolasyon	85
BÖLÜM 4	
SONUÇ VE ÖNERİLER	94
KAYNAKLAR	96
ÖZGEÇMİŞ	99

SİMGE LİSTESİ

b	Bias
C	Düzenleme parametresi
F	Öznitelik uzayı
$f(x)$	Hedef fonksiyon
K	Kernel fonksiyonu
l	Örnek Sayısı
L	Genel kayıp fonksiyonu
n	Giriş uzayının boyutu
N	Öznitelik uzayının boyutu
S	Eğitim verisi
S_{11}	Giriş portu yansıtma katsayısı
S_{12}	Geri gerilim kazancı
S_{21}	İleri gerilim kazancı
S_{22}	Çıkış portu yansıtma katsayısı
w	Ağırlık vektörü
X	Giriş uzayı
x_i	Örnek noktası i ' inci verinin hedef değeri
Y	Çıkış domeni
φ	Eşleme vektörü
$\hat{\alpha}_i$	i ' inci verinin Lagrange katsayısı
$\mathcal{E}$	Duyarsız kayıp fonksiyonunu
ξ_i	Esnek değişken
σ	Gauss yayılma parametresi
γ	Gama Parametresi

KISALTMA LİSTESİ

CAD	Computer-Aided Design
DV	Destek Vektörü
DVM	Destek Vektör Makineleri
DVR	Destek Vektör Regresyonu
DVSM	Destek Vektör Sınıflandırma Makineleri
DVRM	Destek Vektör Regresyon Makineleri
GHz	Gigahertz
KKT	Karush-Kuhn-Tucker
LÖM	Lineer Öğrenen Makineler
SVM	Support Vector Machines
SVRM	Support Vector Regression Mechines
YSA	Yapay Sinir Ağları

ŞEKİL LİSTESİ

Sayfa

Şekil 2. 1 İki boyutlu eğitim seti için ayırıcı hiperdüzlem (w,b) [15]	5
Şekil 2. 2 Bir boyutlu lineer regresyon [15]	6
Şekil 2. 3 Özellik Uzayında sınıflandırma İşlemi [15]	9
Şekil 2. 4 Maksimal marjın hiperdüzlem ve destek vektörleri [18].....	12
Şekil 2. 5 Kernel fonksiyonu ile verinin daha yüksek bir boyuta dönüşümü	13
Şekil 2. 6 1-boyutlu lineer regresyon problemi için $\mathcal{E}$ -duyarsız tüp [15]	15
Şekil 2. 7 Nonlinear regresyon problemi için $\mathcal{E}$ -duyarsız tüp [15].....	15
Şekil 3. 1 Bir mikrodalga transistörün işaret-gürültü DVRM modeli [27].....	21
Şekil 3. 2 Senaryo 1’de (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının test datası uzayında değişimi	27
Şekil 3. 3 Senaryo 1’de $V_{DS}=0.75V$, $I_{DS}=2.7mA$ kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının frekans ile değişimi	29
Şekil 3. 4 Senaryo 2’de (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının test datası uzayında değişimi	35
Şekil 3. 5 Senaryo 3’te (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının test datası uzayında değişimi	40
Şekil 3. 6 Senaryo 3’te $V_{DS}=0.5V$, $I_{DS}=2mA$ kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının frekans ile değişimi	43
Şekil 3. 7 Senaryo 3’te $V_{DS}=1V$, $I_{DS}=2.7mA$ kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının frekans ile değişimi	45
Şekil 3. 8 Senaryo 4’te (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının test datası uzayında değişimi	50
Şekil 3. 9 Senaryo 5’te (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının test datası uzayında değişimi	54
Şekil 3. 10 Senaryo 5’te $V_{DS}=2.5V$, $I_{DS}=1mA$ kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının frekans ile değişimi	56
Şekil 3. 11 Senaryo 6’da (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının test datası uzayında değişimi	59
Şekil 3. 12 Senaryo 7 için (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazı (e) S12 büyüklüğü (f) S12 fazı (g) S22 büyüklüğü (h) S22 fazının test datası uzayında değişimi	62
Şekil 3. 13 Senaryo 8 için (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazı (e) S12 büyüklüğü (f) S12 fazı (g) S22 büyüklüğü (h) S22 fazının test datası uzayında değişimi	67
Şekil 3. 14 Düşük, orta ve yüksek gerilim bölgelerine ayrılan bir mikrodalga transistörün saçılma parametreleri DVRM modeli	71

Şekil 3. 15 Düşük gerilim bölgesinde $V_{DS}=0.5V$, $I_{DS}=0.1mA$ 3mA ve 6mA kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının frekans ile değişimi.....	73
Şekil 3. 16 Düşük gerilim bölgesinde $V_{DS}=1.7V$, $I_{DS}=0.1mA$ 3mA ve 6mA kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının frekans ile değişimi.....	75
Şekil 3. 17 Orta gerilim bölgesinde $V_{DS}=2.5V$, $I_{DS}=0.1mA$, 3mA ve 6mA kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazı (e) S12 büyüklüğü (f) S12 fazı (g) S22 büyüklüğü (h) S22 fazının frekans ile değişimi.....	77
Şekil 3. 18 Orta gerilim bölgesinde $V_{DS}=4V$, $I_{DS}=0.1mA$, 3mA ve 6mA kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazı (e) S12 büyüklüğü (f) S12 fazı (g) S22 büyüklüğü (h) S22 fazının frekans ile değişimi.....	81
Şekil 3. 19 Yüksek gerilim bölgesinde $V_{DS}=5V$, $I_{DS}=0.1mA$, 3mA ve 6mA kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazı (e) S12 büyüklüğü (f) S12 fazı (g) S22 büyüklüğü (h) S22 fazının frekans ile değişimi	86
Şekil 3. 20 Yüksek gerilim bölgesinde $V_{DS}=8V$, $I_{DS}=0.1mA$, 3mA ve 6mA kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazı (e) S12 büyüklüğü (f) S12 fazı (g) S22 büyüklüğü (h) S22 fazının frekans ile değişimi.....	90

ÇİZELGE LİSTESİ

	Sayfa
Çizelge 2. 1 DVM için kullanılan Kernel fonksiyonları.....	14
Çizelge 3. 1 Senaryo 1’de S11’in büyüklüğü için DVM parametreleri ve hata oranları	23
Çizelge 3. 2 Senaryo 1’de S11’in açısı için DVM parametreleri ve hata oranları	24
Çizelge 3. 3 Senaryo 1’de S21’in büyüklüğü için DVM parametreleri ve hata oranları	25
Çizelge 3. 4 Senaryo 1’de S21’in açısı için DVM parametreleri ve hata oranları	26
Çizelge 3. 5 Senaryo 1’de $V_{DS}=0.75V$, $I_{DS}=2.7mA$ kutuplama koşulunda frekansa bağlı olarak hedef ve tahmini değerlerin karşılaştırması	29
Çizelge 3. 6 Senaryo 2’de S11’in büyüklüğü için DVM parametreleri ve hata oranları	31
Çizelge 3. 7 Senaryo 2’de S11’in açısı için DVM parametreleri ve hata oranları	32
Çizelge 3. 8 Senaryo 2’de S21’in büyüklüğü için DVM parametreleri ve hata oranları	33
Çizelge 3. 9 Senaryo 2’de S21’in açısı için DVM parametreleri ve hata oranları	34
Çizelge 3. 10 Senaryo 2’de S21’in açısı için DVM parametreleri ve hata oranları	37
Çizelge 3. 11 Senaryo 3’te S11’in büyüklüğü için DVM parametreleri ve hata oranları	37
Çizelge 3. 12 Senaryo 3’te S11’in açısı için DVM parametreleri ve hata oranları	38
Çizelge 3. 13 Senaryo 3’te S21’in büyüklüğü için DVM parametreleri ve hata oranları	39
Çizelge 3. 14 Senaryo 3’te S21’in açısı için DVM parametreleri ve hata oranları	39
Çizelge 3. 15 Senaryo 3’te $V_{DS}=0.5V$, $I_{DS}=2mA$ kutuplama koşulunda frekansa bağlı olarak hedef ve ekstrapolasyon tahmini değerlerin karşılaştırması	42
Çizelge 3. 16 Senaryo 3’te $V_{DS}=1V$, $I_{DS}=2.7mA$ kutuplama koşulunda frekansa bağlı olarak hedef ve İnterpolasyontahmini değerlerin karşılaştırması	45
Çizelge 3. 17 Senaryo 4’te S11’in büyüklüğü için DVM parametreleri ve hata oranları	47
Çizelge 3. 18 Senaryo 4’te S11’in açısı için DVM parametreleri ve hata oranları	48
Çizelge 3. 19 Senaryo 4’te S21’in büyüklüğü için DVM parametreleri ve hata oranları	49
Çizelge 3. 20 Senaryo 4’te S21’in açısı için DVM parametreleri ve hata oranları	50
Çizelge 3. 21 Frekans bölgesi bilgisinin giriş kümesinde kullanılmasının regresyona etkisi (extrapolasyon senaryosu 3-4)	52
Çizelge 3. 22 Senaryo 5’da bölge bilgilerine göre S parametreleri için DVRM parametreleri ve hata oranları	53
Çizelge 3. 23 Senaryo 5’te $V_{DS}=2.5V$, $I_{DS}=1mA$ kutuplama koşulunda frekansa bağlı olarak hedef ve tahmini değerlerin karşılaştırması	56
Çizelge 3. 24 Senaryo 5’te S parametreleri için DVM parametreleri ve hata oranları...	58
Çizelge 3. 25 Senaryo 6’da $V_{DS}=1.7V$, $I_{DS}=2.7mA$ kutuplama koşulunda frekansa bağlı olarak hedef ve ekstrapolasyon tahmini değerlerin karşılaştırması	61

Çizelge 3. 26 Senaryo 7’de yansıma katsayıları için DVM parametreleri ve hata oranları	62
Çizelge 3. 27 Senaryo 8’de yansıma katsayıları için DVM parametreleri ve hata oranları	66
Çizelge 3. 28 Düşük, orta ve yüksek gerilim bölgelerine ayrılmış bir transistörün yansıma katsayıları için DVM parametreleri ve hata oranları	71
Çizelge 3. 29 Düşük gerilim bölgesinde eğitim ve test kümesi bilgileri	72
Çizelge 3. 30 Düşük gerilim bölgesinde eğitim ve test kümesi bilgileri	77
Çizelge 3. 31 Düşük gerilim bölgesinde eğitim ve test kümesi bilgileri	85



**GENİŞ ÇALIŞMA BÖLGELİ BİR MİKRODALGA
TRANSİSTÖRÜNÜN DESTEK VEKTÖR REGRESYON MAKİNESİ
İLE MODELLENMESİ**

Şerife YÜREKLİ

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Tez Danışmanı: Prof. Dr. Filiz GÜNEŞ

Makine öğrenme uygulamaları son yıllarda yoğun olarak çalışılmakta olan bir araştırma konusudur. Yapılan çalışmalar istatistiksel öğrenme teorisine dayanan Destek Vektör Makineleri (DVM) gibi güçlü sınıflandırma algoritmalarının geliştirilmesini ve oldukça farklı alanlarda başarı ile kullanımını mümkün kılmıştır ve Destek Vektör Makineleri'nin birçok uygulamada klasik sınıflandırma algoritmalarına göre daha gürbüz bir algoritma olduğu gösterilmiştir.

Bu tez çalışmasının amacı DVM' nin mikrodalga teori ve tekniğine uygulamak ve bu amaç doğrultusunda geniş çalışma bölgesi bir mikrodalga transistörünün analizini DVRM ile gerçekleştirmektir. Mikrodalga transistörünün analizinde DVM' nin regresyon yapabilme yeteneğinden ve seyreklik özelliğinden yararlanılmıştır. Modelin regresyonu için, makinemiz eğitim ve test işlemlerine tabi tutularak yüksek doğruluk oranlarına sahip modeller elde edilmiştir.

Anahtar Kelimeler: Destek Vektör Makineleri, Destek Vektör Regresyon Makineleri, Makine Öğrenmesi

ABSTRACT

SUPPORT VECTOR REGRESSION MODEL OF A WIDE RANGE MICROWAVE TRANSISTOR

Şerife YÜREKLİ

Department of Electronics and Communications Engineering

MSc. Thesis

Adviser: Prof. Dr. Filiz GÜNEŞ

Applications in learning machine is a searching subject which has been widely worked on. The studies have enabled improving the powerful classification algorithms such as Support Vector Machines (SVM) which are based on statistical learning theory, and the succesful usage of SVM in really different areas. It is has been showed that Support Vector Machines are more robust algorithm than the classic classification algorithm in many applicaitons.

The aim of this thesis study is to apply the SVM into the microwave theory and technique. Therefore in this thesis, a wide range microwave transistor is analysed with SVRM. In the analysis of a microwave transistor is utilized the capability of SVM's making regression and sparseness feature. For the model's regression, our machine has been trained and tested to achieve high accuracy.

Keywords: Support vector machines, support vector regression meachines

**YILDIZ TECHNICAL UNIVERSITY
GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES**

1.1 Literatür Özeti

Bilgi teknolojilerindeki gelişmeler sayesinde çok büyük miktardaki veriler kaydedilebilmektedir ve bu verilerin analizine ihtiyaç duyulmaktadır. Büyük veri analizinin yapılabilmesi için makine öğrenmesi (machine learning) metotları geliştirilmiştir. Makine öğrenmesi metotları, geçmişteki verileri kullanarak veriye en uygun modeli bulmaya çalışır. Daha sonraki veriler, geçmişteki tecrübelerinden yararlanılarak, bu modele göre analiz edilir. Farklı uygulamalar için; sınıflandırma, kümeleme, regresyon, özellik çıkarımı ve ilişki belirleme gibi metotlar kullanılmaktadır [1]. Destek vektör makineleri (DVM), yapay sinir ağları (YSA), karar ağaçları makine öğrenme algoritmalarından birkaçıdır.

Doğrusal olmayan öğrenen makineler ayrık veri biçimindeki giriş-çıkış ilişkilerini sürekli giriş domeninde tanımlanmış fonksiyonlara dönüştürebilmektedir. Bu özelliğe, literatürde öğrenen makinelerin genellemesi ya da verilen ayrık veriye fonksiyon yaklaşılması adı verilmektedir. Böylece, doğrusal olmayan öğrenen makineler, eğitilme süreci tamamlandıktan sonra, yüksek derecede doğrusal olmayan karakteristikleri, yaygın bir çalışma domeninde geçerli olmak üzere öğrenmektedir ve hızla cevap verebilmektedir. Dolayısı ile interaktif olarak kullanılabilen modeller haline dönüşmektedir. Aynı zamanda, yüksek boyutlu giriş uzayında da problemsiz modelleme olanağı sundukları için, tasarım araç-kutularında ve simülasyonlarda kullanımı artmaktadır [2].

Son yirmi yılda DVM, sınıflandırma ve regresyon problemlerine başarıyla uygulanmaktadır. DVM, genelleme ve optimizasyon teorilerini birbirine bağlayan sağlam matematiksel temellere dayandırılmış, hızlı bir öğrenen makinedir. DVM, esas

olarak yüksek derecede doğrusal olmayan fonksiyonlar ile regresyon yapabilme potansiyelinde makinelerdir, çünkü bu doğrusal olmayan fonksiyonlar uygun bir öznitelik uzayında teşkil edilip, doğrusal bir fonksiyon olarak işlem görmektedirler. DVM öğrenme teorisi, sonsuz sayıda örnekleme yerine, küçük sayıda örnekleme prensibine dayandırılmıştır ve bu neden ile hesaplama maliyeti oldukça düşüktür. Optimizasyon işleminde dışbükey amaç fonksiyonunun kullanılması nedeni ile evrensel minimum garanti edilir. İlave olarak, DVM optimizasyon işleminde, sadece ampirik risk değil, yaklaşım fonksiyonunun katsayıları da (yapısal risk) minimize edilir. Bu durum, öğrenen bir makine için, tam risk minimizasyonu oluşturmaktadır [3]. Bütün bu ana çalışma prensipleri ile DVM, sınıflandırma ve regresyon problemlerinde, diğer metotlara göre kesin üstünlükler getirmektedir. Yaklaşım fonksiyonunun, eğitim verisinin küçük bir alt kümesi kullanılarak ifade edilmesi özelliğine “seyreklik” adı verilir ve hesaplamada büyük üstünlükler getireceği açıktır. DVM teorisi, Vapnik ve arkadaşları tarafından, Bell laboratuvarlarında geliştirilmiş olup, önce histogram-tabanlı görüntü sınıflandırma için kullanılmıştır [4]. Gerçek dünyadaki uygulama alanlarının başında mühendislik dalları ve ekonomi gelmektedir ve sınıflandırma, regresyon ve kestirim problemlerine çözüm metodu olarak kullanılmaktadır. DVM’nin reel dünyadaki tipik uygulamalarına şu örnekler verilebilir: Pazarlama tepki modellemesinde; potansiyel müşteri tayininde sınıflandırıcı, müşteri harcama potansiyelinin tayininde regresör olarak DVM kullanılmaktadır [5]. Başarılı bir sınıflandırıcı olarak kredi kartı fraud tespitinde, müşteri kaybı analizinde ve müşteri sadakati analizinde de kullanılmaktadır. Ayrıca çeşitli tiplerdeki anten tasarımlarında (mikroşerit, anten dizisi, yarık,...) [6],[7],[8],[9] mekatronik hareket sistemlerinde ileri-besleme kontrol öğrenmede [10] elektronik mühendisliğinde lineer-faz FIR filtre tasarımında [11], işaret işleme uygulamalarında [12],[13],[14] kullanılmaktadır.

1.2 Tezin Amacı

Bu tez çalışmasının amacı DVM’ nin mikrodalga teori ve tekniğine uygulamak ve bu amaç doğrultusunda bir mikrodalga transistörünün analizini DVRM ile gerçekleştirmektir.

1.3 Hipotez

Tezin ikinci bölümünde DVM teorisi ve DVM regresyonunun matematiksel temelleri yer almaktadır. Bu tezde yer alan DVM uygulamalarında, ikinci bölümde yer alan matematiksel ifadeler kullanılarak hazırlanmış bir DVM araç-kutusu kullanılmıştır.

Üçüncü bölümde uygulama örneği olarak seçilen bir mikrodaga transistörünün, giriş kümesi $\{I, V, f\}$ 'e bağlı olarak yansıma katsayıları çıkışta elde edilebilmektedir. Üretici firmanın katalog verilerinden yararlanılarak giriş ve çıkış kümesi oluşturulmuştur. Giriş ve çıkış kümesinin değer aralığı değiştirilerek eğitim ve test kümesi oluşturulmuştur. DVRM' nin eğitimi ve testi gerçekleştirildikten sonra elde edilen değerler ile hedef kümesi karşılaştırılmıştır. Yüksek doğruluk oranı elde etmek için parametrelere uygun değerler verilip, DVRM' nin öğrenme performansı gözlemlenmiştir. Yüksek doğruluğa sahip regresyon modelleri elde edilmiştir. DVM' nin genelleme yeteneğinden yararlanılarak eğitim kümesinde yer almayan girişler için de çıkışlar elde edilebilmektedir

En son bölümde ise tez çalışmasının sonuçlarına yer verilmiştir.

BÖLÜM 2

DESTEK VEKTÖR MAKİNELERİ

Bu bölümde DVM teorisi ve DVM regresyonunun matematiksel temelleri yer almaktadır.

2.1 Doğrusal Öğrenen Makineler

Eğitici öğrenme, öğrenme makinesine girişlerin ve ilgili çıkışların yer aldığı eğitim kümesi verilmesi ile gerçekleşir. Genellikle örnekler öznitelik vektörleri halindedir ve böylece giriş uzayı R^n in bir altkümesidir. Özellik vektörüne bağlı olarak problemin çözümü için pek çok hipotez seçilebilir. Bunların arasından doğrusal fonksiyonlar, anlaması ve uygulaması en kolay olanlarıdır. Geleneksel istatistiksel ve klasik sinir ağları literatürü, doğrusal fonksiyonları kullanarak örnekleri sınıflara ayırmak ve interpolasyon için birçok metot geliştirmiştir. Bu teknikler verimli iteratif prosedürler ve genelleştirme tekniklerinin teorik analizini içerir ve böylece daha karmaşık sistemlerin yapısı için bir çalışma çerçevesi sağlar [15].

2.1.1 Doğrusal Sınıflandırma


İkili sınıflandırma, genellikle $f: X \subseteq R^n \rightarrow R$ gerçekteğerli bir fonksiyon kullanarak şu şekilde gerçekleştirir: Eğer $f(\mathbf{x}) \geq 0$ ise, giriş $\mathbf{x} = (x_1, \dots, x_n)$ ' pozitif sınıf olarak, aksi takdirde negatif sınıf olarak belirlenir. $f(\mathbf{x})$, $\mathbf{x} \in X$ 'in bir lineer fonksiyonu ise, Eşitlik 2.1'deki gibi yazılabilir.

$$f(\mathbf{x}) = \langle \mathbf{w}, \mathbf{x} \rangle + b \quad (2.1)$$

$$= \sum_{i=1}^n w_i x_i + b$$

$(\mathbf{w}, b) \in \mathbb{R}^n \times \mathbb{R}$; fonksiyonu kontrol eden parametrelerdir. Karar kuralı $\text{sgn}(f(\mathbf{x}))$ tarafından belirlenir ve $\text{sgn}(0) = 1$ olduğunu kabul edilecektir. Öğrenme metodolojisi bu parametreler veriden öğrenilerek gerçekleştirilir.

Bu çeşit hipotezin geometrik yorumlaması şudur: Giriş uzayı X , $\langle \mathbf{w}, \mathbf{x} \rangle + b$ denklemiyle tanımlanan hiperdüzlem tarafından iki parçaya ayrılır. Bir hiperdüzlem; uzayı, iki farklı sınıfın girişlerine karşılık gelecek şekilde iki yarı uzaya ayıran $n-1$ boyutlu bir ilgin altuzaydır. Örneğin Şekil 2.1’ de koyu çizgi ile hiperdüzlem gösterilmiştir. Hiperdüzlemin üstü pozitif bolge, altı negatif bölge olarak tanımlanır. $\mathbf{w}$ vektörü, kendine paralel olan b değerlerinin hiperdüzleme göre hareket ederek değişen değerleriyle hiperdüzleme dik bir yön tanımlar.



Şekil 2. 1 İki boyutlu eğitim seti için ayırıcı hiperdüzlem ($\mathbf{w}, b$) [15]

İstatistikçiler ve sinir ağları araştırmacıları, lineer diskriminant ve perseptron olarak adlandırılan bu basit tür sınıflandırıcıyı sıklıkla kullandılar. $\mathbf{w}$ ve b nicelikleri ağırlık vektörünü ve biası gösterecektir. Bu terimler sinir ağları literatüründen ödünç alınmıştır. Bazen $-b$, θ ile yer değiştirilir ve bu nicelik eşik olarak bilinir.

Giriş, çıkış eğitim seti gibi bazı notasyonlar aşağıdaki gibi tanımlanmıştır:


X giriş uzayını, Y çıkış domenini göstermek için kullanılacaktır. Genellikle $X \subseteq \mathbb{R}^n$, ikili sınıflandırma için $Y = \{-1, 1\}$, m -sınıflı sınıflandırma için $Y = \{1, 2, \dots, m\}$ ve regresyon için $Y = \mathbb{R}$ şeklinde gösterilir. Bir eğitim seti eğitim örneklerinin bir toplamıdır ve aynı zamanda eğitim verisi olarak da adlandırılır. Eğitim verisi genellikle Eşitlik 2.2’ deki gibi gösterilir:

$$S = ((x_1, y_1), \dots, (x_l, y_l)) \subseteq (X \times Y)^l \quad (2.2)$$

l örnek sayısını, x_i örnekleri ve y_i örneklere karşılık gelen etiketleri gösterir. Eğer bütün örneklerin etiketleri denk ise eğitim seti S apaçıktır (trivial). Eğer bir x_i vektörünün transpozisini alınırsa x_i' şeklinde gösterilmektedir [15].

2.1.2 Doğrusal Regresyon

Doğrusal regresyon problemi doğrusal bir fonksiyon bulmayı amaçlar. Bulunan $f(x) = \langle w, x \rangle + b$ şeklindeki doğrusal fonksiyon $Y \subseteq \mathbb{R}^n$ den etiketlenen verilen bir S eğitim noktalarını en iyi şekilde aradeğerlendirir (interpolate). Geometrik olarak bu durum verilen noktalara oturan bir hiperdüzleme karşılık gelir. Şekil 2.2' de bir boyutlu lineer regresyon fonksiyonu görülmektedir. Şekilde “ ξ ” olarak gösterilen uzaklık özel eğitim verileri için hatadır.



Şekil 2. 2 Bir boyutlu lineer regresyon [15]

Bu problem üzerinde 18. yy.'dan beri çalışılmaktadır. Eğitim noktalarından uzaklığın kareleri toplamını minimize eden eğriyi seçmek için; Gauss ve Legendre, birbirlerinden bağımsız olarak, lineer regresyonu bilinen en iyi çözüm olarak önermişlerdir. Bu teknik en küçük kareler yöntemi olarak bilinir ve lineer hedeflerin Gauss gürültüsüyle bozulması durumunda optimum bir tekniktir.

Sayısal kararlılık ve genelleştirme fikirleri, sınıflandırma durumunda maksimal marjın hiperdüzlemine paralel olan bu tekniğin bir çeşidine giriş yaptırmıştır. Bu teknikte, karesel kayıp ve w vektörü kombinasyonunu minimum yapan bir fonksiyon seçilir. Hoerl ve Kennard tarafından önerilen bu çözüm ridge regresyonu olarak bilinir. Bu

algoritmalar matrisin tersine ihtiyaç duyarlar, bununla birlikte basit iteratif prosedür hala vardır. (Adaline algoritması Widrow ve Hoff tarafından 1960’larda geliştirilmiştir.) Sınıflar ile örtüşen hedef değerlerin dikkatli seçimiyle bu regresyon teknikleri aynı zamanda sınıflandırma problemleri için de kullanılabilir [15].

2.1.3 Doğrusal Makinelerin Çift Gösterimi

Lineer makinelerin birçoğu için çift tanımlama söz konusudur. Dualite, destek vektör makinelerinin gelişiminde kritik kavramlardan biri olacaktır.

Dual gösterimin önemli bir özelliği verinin girişler boyunca gram matris şeklinde görülmesi ve hiçbir zaman verinin tek öznitelikleri şeklinde görülmemesidir. Benzer bir şekilde karar fonksiyonunun çift gösteriminde, sadece eğitim ve test verilerinin iç çarpımına ihtiyaç duyulur [15].

2.2 Kernel’e Bağlı Özellik Uzayları

Doğrusal öğrenen makinelerin sınırlı hesaplama gücü, Papert ve Minsky tarafından 1960’larda vurgulandı. Genellikle, karmaşık gerçek dünya uygulamaları doğrusal fonksiyonlara nazaran daha anlamlı hipotez uzaylarına ihtiyaç duymaktadır. Bu problemi görmenin diğer bir yolu da şudur ki: sıklıkla hedef tasarım, verilen özniteliklerin basit bir kombinasyonu ile ifade edilemez; genellikle faydalanılacak verinin daha fazla özelliğine ihtiyaç duyulur. Bu probleme çözüm olarak eşikli doğrusal fonksiyonların çoklu katmanları (multiple layers of thresholded linear functions) sunulmuştur ve bu yaklaşım çok-katmanlı sinir ağlarının ve öğrenen algoritmaların gelişimine yol açmıştır.

Kernel gösterimleri, veriyi yüksek boyutlu özellik uzayına taşıyarak doğrusal öğrenen makinelerin hesaplama gücünü arttırmak için alternatif bir çözüm sunmuştur. Doğrusal öğrenen makinelerin çift gösterimde kullanılmaları, bu adımı kesin olarak gerçekleştirmeyi mümkün kılmıştır. Daha önce bahsedildiği gibi eğitim verileri hiçbir zaman izole edilmiş görülmez, her zaman örnek çiftlerinin arasında iç çarpımlar halindedir. Doğrusal öğrenen makinelerini çift gösterimde kullanmak şöyle bir avantaj sağlar: Bu gösterimde ayarlanabilir parametrelerin sayısı, kullanılan özniteliklerin sayısına bağlı değildir. İç çarpımları, uygun görülen bir kernel fonksiyonuyla yer değiştirerek, ayarlanabilir parametrelerin sayısını arttırmadan yüksek boyutlu özellik

uzayına doğrusal olmayan eşleme gerçekleştirilir. Kernel fonksiyonu özellik vektörleri ve bunlara karşılık gelen iki girişin iç çarpımını hesaplayarak bunu sağlar.

Sinir ağları uygulamaları için mimari seçme problemi, DVM’ de uygun kernel fonksiyonu seçme problemiyle yer değiştirir.

Kernellerin kullanımı, hesaplamada ve genelleştirmede boyut sorununun (the curse of dimensionality) üstesinden gelir [15].

2.2.1 Özellik Uzayında Öğrenme

Hedef fonksiyonun gösterimine bağlı olarak öğrenilmesindeki karmaşıklık ve öğrenme görevinin zorluğu duruma göre değişebilir. İdeal olarak, öğrenme problemine uyan bir gösterim seçilmelidir. Böylece makine öğrenmesindeki önileme stratejisi, verinin gösteriminde değişiklik yapılmasını gerektirir.


$$x = (x_1, \dots, x_n) \rightarrow \phi(x) = (\phi_1(x), \dots, \phi_N(x))$$

(2.3)

Bu adım, giriş uzayı X ’i yeni bir uzaya, $F = \{\phi(x) | x \in X\}$ eşleme ile eşdeğerdir.

Veriyi başka bir uzaya eşleme gerçeği, öğrenmeyi çok basitleştiriyor ve makine öğrenmesinde bu teknik uzun zamandır bilinmektedir. Verinin en iyi gösterimini seçmek için çok sayıda teknik mevcuttur. Veriyi tanımlamak için verilen nicelikler genellikle özellik (feature) olarak adlandırılır. Bazen orijinal nicelikler öznitelik (attributes) , en uygun gösterimi seçme görevi özellik seçimi (feature selection) olarak bilinir. X giriş uzayını gösterirken; $F = \{\phi(x) | x \in X\}$, özellik uzayı (feature space) olarak adlandırılır.

Şekil 2.3’ de, iki boyutlu giriş uzayından iki boyutlu özellik uzayına özellik eşleme örneği görülmektedir. Veri bazı durumlarda giriş uzayında lineer olarak ayrılamazken, özellik uzayında ayrılabilir. Bu durumda kerneller kullanılarak veri çok boyutlu özellik uzayına dönüştürülebilir ve lineer bir makineyi özellik uzayında eğitmeyi mümkün kılar.



Şekil 2. 3 Özellik Uzayında sınıflandırma İşlemi [15]

Özellik seçimi için farklı yaklaşımlar mevcuttur. Bu yaklaşımlardan biri özelliklerin en küçük kümesini tanımlar. Bu en küçük küme hala orijinal özniteliklerdeki gereken bilgiye sahiptir ve bu yöntem boyut azaltma olarak bilinir [15].

$$x = (x_1, \dots, x_n) \rightarrow \phi(x) = (\phi_1(x), \dots, \phi_d(x)), \quad d < n, \quad (\text{boyut azaltma}) \quad (2.4)$$

2.2.2 Özellik Uzayına Eşleme

Doğrusal olmayan bağıntıları doğrusal bir makine ile öğrenebilmek için öncelikle doğrusal olmayan öznitelik kümesi seçilmeli ve veri yeni gösterimi ile tekrar yazılmalıdır. Bu, doğrusal olmayan sabit bir eşleme kullanarak, veriyi doğrusal makinelerin kullanılabileceği öznitelik uzayına eşleme ile eşdeğerdir. Bundan dolayı göz önüne alınacak hipotez kümesi Eşitlik 2.5'teki gibi bir fonksiyon olacaktır:

$$f(x) = \sum_{i=1}^N w_i \cdot \phi_i(x) + b \quad (2.5)$$

Burada

$$x = (x_1, \dots, x_n) \rightarrow \phi(x)^t = (\phi_1(x), \dots, \phi_N(x)) \quad (2.6)$$

Bu adım giriş uzayı X 'i yeni bir uzaya, $F = \{\phi(x) | x \in X\}$ eşleme ile eşdeğerdir. Böylece $f(x)$ x -giriş uzayında doğrusal olmayan bir fonksiyon, F -öznitelik uzayında ise doğrusal bir fonksiyondur. Öznitelik uzayının boyutu N ile giriş uzayının boyutu n

eşit olmayabilir. F -öznitelik uzayının seçimi orijinal verinin içerdiği tüm gerekli bilgiyi yeni uzaydaki gösterimine aktarabilecek şekilde yapılmalıdır. Böylece doğrusal olmayan bir makine iki adımda yapılabilir: Öncelikle, sabit doğrusal olmayan bir eşleme vektörü ϕ , veriyi öznitelik uzayı F' e dönüştürür. Sonra öznitelik uzayında oluşturulan öğrenen makine regresyon için kullanılır.

Doğrusal öğrenme makinelerinin önemli bir özelliği çift gösterime sahip olmalarıdır. Hipotez eğitim verisinin lineer bileşimi olarak ifade edilebilir, böylece karar kuralı sadece test ve eğitim verilerinin iç çarpımı olarak Eşitlik 2.7' deki gibi elde edilebilir:

$$f(\mathbf{x}) = \sum_{i=1}^{\ell} \alpha_i y_i \langle \phi(\mathbf{x}_i), \phi(\mathbf{x}) \rangle + b \quad (i = 1, 2, \dots, \ell) \quad (2.7)$$

Burada y_i i' inci verinin hedef değeri, α_i ise i' inci verinin Lagrange katsayısıdır. Bir sonraki bölümde ağırlık vektörü $\mathbf{w}$ 'nın belirlenmesi dışbükey optimizasyon problemi ile ifade edilecek ve çift gösterim özelliği ile öznitelik uzayında veri oturtma için kullanılacaktır.

Özellik uzayında, $\langle \phi(x), \phi(z) \rangle$ iç çarpımı direk olarak orijinal giriş noktalarının bir fonksiyonu olarak hesaplama yöntemine sahipsek, doğrusal olmayan öğrenme makinesini iki adımda kurulur. Böyle bir direk hesaplama metodu kernel fonksiyonu olarak adlandırılır.

Bir kernel fonksiyonu, $K, x, z \in X$,

$$K(x, z) = \langle \phi(x), \phi(z) \rangle \quad (2.8)$$

olup burada ϕ , X 'den (iç çarpım) özellik uzayı, F' e dönüşümdür.

Kernellerin kullanımı veriyi özellik uzayına dönüştürmeyi ve doğrusal bir makineyi özellik uzayında eğitmeyi mümkün kılar. Böylece özellik uzayının hesaplanmasında oluşacak potansiyel problemlerden kaçınır. Özellik uzayındaki eğitim adımlarında "Gram matris" kullanılır. Bu matris "Kernel matrisi" olarak da bilinir ve K ile ifade edilir [2].

2.3 Destek Vektör Makineleri

Destek Vektör Makineleri (DVM) yöntemi, sınıflandırma ve doğrusal olmayan fonksiyon yaklaşımı problemlerinin çözümü için 1992'de Vapnik ve ekibi tarafından önerilen eğitici bir öğrenme algoritmasıdır. DVM, çok boyutlu özellik uzayında lineer fonksiyonların hipotez uzayını kullanan, optimizasyon teorisi ile elde edilen öğrenme algoritması ile eğitilen öğrenen sistemlerdir. Bu sistemlerin en önemli özelliklerinden biri genelleme teorisi ile elde edilen biasları uygularken hipotezin “esnek (sparse)” dual gösterimlerini üretmesi sonucunda çok verimli algoritmanın oluşmasıdır. Bu KKT durumlarından kaynaklanır ve DVM’ in pratik uygulamasında ve analizinde büyük öneme sahiptir. DV yaklaşımının bir başka önemli özelliği optimizasyon probleminin konveks olması ve bu sebepten lokal minimumu olmamasıdır. Bu sebepler ve azaltılmış sıfır olmayan parametreler, bu sistem ile yapay sinir ağları gibi diğer pattern tanıma sistemleri arasındaki büyük farkı gösterir. DVM disiplinli ve çok kuvvetli bir metot olarak son yıllarda birçok uygulamada performansı ile diğer öğrenen sistemleri geride bırakmıştır [2].

Son yıllarda daha yaygın olarak kullanılmaya başlanan Destek Vektör Makineleri, yazı tanıma, nesne tanıma, ses tanıma, yüz tanıma gibi örüntü tanıma uygulamalarında kullanılmıştır [16]. DVM, istatistiksel öğrenme teorisinde iyi şekilde kurgulanmış bir teoriye sahiptir, sınıflandırma ile regresyon problemlerine yaklaşım için uygundur ve gerçek hayattaki birçok probleme başarılı bir şekilde uygulanmıştır [17]. Son zamanlarda, Destek Vektör Makineleri’ni de içeren ikili makine öğrenme algoritmaları kablosuz iletişim problemlerine, yayılı spektrum alıcı tasarımlarına ve kanal denkleştiricilerine uygulanmıştır.


2.3.1 Destek Vektör Sınıflandırması

Destek vektör sınıflandırmasının amacı çok boyutlu özellik uzayında “hızlı” hesaplanan, “iyi” öğrenen sistemi oluşturmaktır. Bu amaçla genelleme teorisi ve optimizasyon teorisinden yararlanılır. DVM’ de genelleme teorisi, kapasitenin kontrolü ile hiperdüzlem marjın ölçülerini kontrol ederek aşırı uyum (overfitting) problemini ortadan kaldırmayı amaçlar. Optimizasyon teorisi ise bu ölçüleri optimize eden hiperdüzlemi oluşturacak matematiksel teknikleri sağlar [2].

2.3.1.1 Doğrusal Destek Vektör Makineleri

Destek vektör makineleri temelde doğrusal olarak ayırt edilebilen iki sınıf problemlerin çözümünden yola çıkarak doğrusal olarak ayırt edilemeyen veya çoklu sınıf problemlerin çözümü için genelleştirilebilir. Öğrenme kümesindeki verileri: $x_i \in R^d$, $i = 1, \dots, n$, $y_i \in \{-1, +1\}$ olmak üzere $\{x_i, y_i\}$ ile etiketleyelim.

Şekil 2.6’ da ortadaki kalın çizgi ayırıcı hiperdüzlem, w : normal vektörü, daire içine alınmış veriler destek vektörlerini belirtir.



Şekil 2. 4 Maksimal marjın hiperdüzlem ve destek vektörleri [18]

Pozitif örnekleri negatif örneklerden ayıran bir hiperdüzlemimiz olduğunu varsayarsak, iki sınıf probleminde doğrusal sınıflandırıcı hiperdüzlemin normal vektörü w ve ofset değeri b ile tanımlanır. Karar sınırı $w^t x + b = 0$ doğrusudur. Bu hiperdüzlemin ayırdığı yarı uzaylardan her biri bir sınıf belirtir. Bu durumda aşağıdaki koşulların gerçekleşmesi gerekir:

$$w^t x_i + b \geq 1, y_i = 1 \quad (2.9)$$

$$w^t x_i + b \leq -1, y_i = -1$$


Sınıf etiketi genelleştirilmiş olarak $y_i = \text{sgn}(w^t x_i + b)$ eşitliği ile belirtilebilir.

Doğrusal sınıflandırıcının sınırı hiperdüzlem ile öğrenme verileri arasındaki en kısa uzaklık olarak tanımlanır. Ayırt etme yüzeyine en yakın veriler destek vektörleri olarak adlandırılır ve karar sınırı sadece destek vektörleri ile belirlenir. Az sayıda veri noktası

sınıflandırmada etkindir. Destek vektör algoritması en büyük margine sahip ayırıcı hiperdüzlem ile sınıflandırma yaparak öğrenme hatasını en aza indirmeye çalışır [18].

2.3.1.2 Doğrusal Olmayan Destek Vektör Makineleri

Doğrusal olarak ayırt edilemeyen sınıflarda ise çekirdek fonksiyonları devreye girer ve n boyutlu bir veri kümesi $m > n$ olmak üzere m boyutlu yeni bir veri kümesine dönüştürülerek, yüksek boyutta doğrusal sınıflandırma işlemi gerçekleştirilir.



Şekil 2. 5 Kernel fonksiyonu ile verinin daha yüksek bir boyuta dönüşümü

Çekirdek fonksiyonları DVM algoritmasında önemli rol oynar. Çeşitli çekirdek fonksiyonları tanımlanmıştır. DVM modelleri Tablo 2.1’de sunulduğu üzere, lineer, polinom, radyal tabanlı fonksiyon ve sigmoid kernel olmak üzere dört temel grup altında toplanabilir [18].

Lineer kernel, radyal tabanlı kernelin özel bir hali gibi düşünülebilir. Ayrıca, Keerthi ve Lin, belirli parametreler için sigmoid kernelin radyal tabanlı kernel gibi bir davranış gösterdiğini ifade etmişlerdir. Literatürde uzaktan algılama uygulamaları için radyal tabanlı kernelin en iyi sonuçları verdiği ifade edilmektedir [19]. Doğru çekirdek fonksiyonun seçimi sınıflandırma işleminin başarısında oldukça etkilidir. DVM temelde ikili sınıflandırıcı olduğundan çoklu sınıf problemleri basit olarak veri kümesinin


değişik şekillerde ikiye bölünmesi, her bir ikili veri kümesi için DVM algoritmasının çalıştırılması ve sonuçların birleştirilmesi ile çözümlenir.

Çizelge 2. 1 DVM için kullanılan Kernel fonksiyonları


KERNEL FONKSİYONU	FORMÜL	AÇIKLAMA
Lineer Kernel	$K(x, y) = x \cdot y$	.
Polinom Kernel	$K(x, y) = ((x \cdot y) + 1)^d$	d , polinom derecesi
Raydal Tabanlı Kernel	$K(x, y) = e^{-\gamma \ x - x_i\ ^2}$	γ , Gauss Kernelinin boyutu
Sigmoid Kernel	$K(x, y) = \tanh(b(x \cdot y) + r)$	b, r Kernel parametreleri

2.4 Destek Vektör Regresyon Makineleri

Destek vektör metodu maksimal marjin algoritmasındaki tüm temel özellikleri muhafaza ederek regresyon problemine uygulanabilir: doğrusal olmayan bir fonksiyon kernele bağlı özellik uzayında lineer öğrenme makineleri ile öğrenilir. Sistemin kapasitesi uzayın boyutlarına bağlı olmayan bir parametre ile kontrol edilir. Sınıflandırma probleminde olduğu gibi öğrenme algoritması konveks fonksiyonu minimize eder ve çözümü seyrektiler. Kullanılan yaklaşım “genelleme sınırlarını optimize eden bulmak” olarak özetlenebilir ve hedef değerine belli mesafe uzaklık içerisinde olan hatayı yoksayan kayıp fonksiyonu (loss function) tanımlamaya dayanır. Bu tip fonksiyona “ $\mathcal{E}$ -duyarsız kayıp fonksiyonu (ϵ -insensitive loss function)” denir. $\mathcal{E}$ -duyarsız kayıp fonksiyonu kullanmak global minimumun varolması ve güvenilir genelleme sınırının optimizasyonu avantajlarını sağlar. $\mathcal{E}$ -duyarsız kayıp fonksiyonunun bir başka avantajı ise ikincil değişkenlerin seyrekliğini sağlar. Çözümün eğitim verilerinin alt kümesi ile elde edilmesi hesaplamada büyük avantaj sağlamaktadır. Şekil 5 ve 6’ da ξ , eğitim verisinin hata miktarını gösteren değişken olup, $\mathcal{E}$ -duyarsız tüp içinde sıfıra eşittir [2].



Şekil 2. 6 1-boyutlu lineer regresyon problemi için $\mathcal{E}$ -duyarsız tüp [15]



Şekil 2. 7 Nonlineer regresyon problemi için $\mathcal{E}$ -duyarsız tüp [15]

2.5 Birincil Optimizasyon Problem Formülasyonu

Amacımız Eşitlik 2.5'te yer alan $\mathbf{w}'$ yi ve b' yi ℓ adet eğitim verisi, $[(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_\ell, y_\ell)]$ ile doğrusal öğrenen makine teorisini kullanarak belirlemektir. $\mathbf{w}^*$ ve b' nin en uygun değerleri kayıp fonksiyonunun ve amaç fonksiyonunun tanımına bağlıdır. Dışbükey optimizasyon problemi olarak birincil amaç fonksiyonu Eşitlik 2.10'daki gibi ifade edilebilir.

$$\frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^{\ell} L^{\mathcal{E}}(\mathbf{x}_i, y_i, f) \quad (2.10)$$

Burada L genel kayıp fonksiyonu, C ise düzenleme sabitidir. Eşitlik 2.10' da verilen amaç fonksiyonu dışbükeydir. Bu sebeple yerel minimumu yoktur ve evrensel

minimumu bulmayı garanti eder. Bu DVM' nin diğer örüntü tanıma sistemlerine üstünlüklerinden biridir.

En yaygın kullanılan kayıp fonksiyonlarından biri Vapnik tarafından geliştirilen $\mathcal{E}$ - duyarsız kayıp fonksiyonudur [12]:

$$L^{\mathcal{E}}(\mathbf{x}, y, f) = \begin{cases} 0 & \text{if } |y_i - f(\mathbf{x}_i, \mathbf{w}^*)| < \mathcal{E} \\ |y_i - f(\mathbf{x}_i, \mathbf{w}^*)| - \mathcal{E} & \text{aksi takdirde} \end{cases} \quad (2.11)$$

Bu ifade bir $\mathcal{E}$ tüp tanımlar. Bu ifadeye göre tahmin edilen değer tüpün içinde olduğunda kayıp sıfır, dışında olduğunda ise tahmin edilen değer ile tüpün $\mathcal{E}$ yarıçapı arasındaki farka eşittir. Vapnik' in $\mathcal{E}$ -duyarsız kayıp fonksiyonunu kullanarak Eşitlik 2.12 minimize edilir.

$$\frac{1}{2}(\mathbf{w}^t \mathbf{w}) + C \sum_{i=1}^{\ell} (\xi_i + \hat{\xi}_i) \quad (2.12)$$

Bu ifadede örnek noktası tüpün içinde ise ξ_i veya $\hat{\xi}_i$ sıfıra eşittir. Gözlemlenen nokta eğer tüpün üzerinde ise, ξ_i , gözlemlenen nokta ile $\mathcal{E}$ arasındaki pozitif farka eşittir. Bu durumda ilgili Lagrange çarpanı α_i sıfırdan farklı olacaktır. Benzer olarak $\hat{\xi}_i$, gözlemlenen nokta eğer tüpün altında ise sıfırdan farklı olacaktır ve bu durumda Lagrange çarpanı $\hat{\alpha}_i$ sıfırdan farklı olacaktır.

Gözlemlenen nokta tüpün her iki tarafında birden olamayacağına göre α_i ve $\hat{\alpha}_i$ ' den biri sıfırdan farklı olacaktır. Eğer gözlemlenen nokta tüpün içinde ise α_i ve $\hat{\alpha}_i$ ' nin ikisi birden sıfıra eşit olacaktır. Düzenleme parametresi C büyük ise hataya daha fazla vurgu yapılacaktır. Buna karşın C küçük ise daha iyi genelleme kabiliyeti için ağırlıkların normu üzerine vurgu yapılacaktır. Buna karşı düşen kısıtlamalar Eşitlik 2.13' de verilmiştir [2]:

$$(\langle \mathbf{w} \cdot \mathbf{x}_i \rangle + b) - y_i \leq \mathcal{E} + \xi_i \quad (2.13.a)$$

$$y_i - (\langle \mathbf{w} \cdot \mathbf{x}_i \rangle + b) \leq \mathcal{E} + \hat{\xi}_i$$

(2.13.b)

$$\xi_i, \hat{\xi}_i \geq 0, \quad i = 1, 2, \dots, \ell \quad (2.13.c)$$

2.6 Lagrange Fonksiyonu ve Çift Gösterimi

Eşitlik 2.12’ de verilen amaç fonksiyonu ile Eşitlik 2.13’ de yer alan kısıtlamaları bağlayarak Eşitlik 2.14’ te yer alan Lagrange fonksiyonu elde edilir:

$$L = \frac{1}{2}(\mathbf{w}^t \mathbf{w}) + C \left(\sum_{i=1}^{\ell} \hat{\xi}_i + \sum_{i=1}^{\ell} \xi_i \right) - \sum_{i=1}^{\ell} \hat{\alpha}_i [y_i - (\mathbf{w}^t \cdot \mathbf{x}_i) - b + \varepsilon + \hat{\xi}_i] - \sum_{i=1}^{\ell} \alpha_i [(\mathbf{w}^t \cdot \mathbf{x}_i) + b - y_i + \varepsilon + \xi_i] - \sum_{i=1}^{\ell} (\hat{\gamma}_i \hat{\xi}_i + \gamma_i \xi_i) \quad (2.14)$$

Burada $\hat{\gamma}_i^{(\wedge)}$ ve $\alpha_i^{(\wedge)}$ Lagrange çarpanlarıdır. Eyer noktası durumlarından L ’ nin birincil değişkenlere ($\mathbf{w}$, b , ξ_i ve $\hat{\xi}_i$) göre türevinin sıfıra eşit olacağı sonucu çıkartılabilir [20]:

$$\frac{\partial L}{\partial b} = \sum_{i=1}^{\ell} (\hat{\alpha}_i - \alpha_i) = 0 \quad (2.15)$$

$$\frac{\partial L}{\partial \mathbf{w}} = \mathbf{w} - \sum_{i=1}^{\ell} (\hat{\alpha}_i - \alpha_i) \mathbf{x}_i^t = 0 \quad (2.16)$$

$$\frac{\partial L}{\partial \hat{\xi}_i^{(\wedge)}} = C - \alpha_i^{(\wedge)} - \hat{\gamma}_i^{(\wedge)} = 0 \quad (2.17)$$

Eşitlik 2.15, 2.16 ve 2.17’ yı Eşitlik 2.14’ e yerleştirerek çift amaç fonksiyonunun eşdeğer maksimizasyonu şu şekilde elde edilir:

$$W(\alpha, \hat{\alpha}) = -\varepsilon \sum_{i=1}^{\ell} (\hat{\alpha}_i + \alpha_i) + \sum_{i=1}^{\ell} y_i (\hat{\alpha}_i - \alpha_i) - \frac{1}{2} \sum_{i,j=1}^{\ell} (\hat{\alpha}_i - \alpha_i)(\hat{\alpha}_j - \alpha_j) \langle \mathbf{x}_i, \mathbf{x}_j \rangle \quad (2.18)$$

Bu ifadenin kısıtlamaları şu şekildedir:

$$0 \leq \alpha_i \leq C, \quad 0 \leq \hat{\alpha}_i \leq C, \quad i = 1, \dots, \ell \quad (2.19.a)$$

$$\sum_{i=1}^{\ell} \hat{\alpha}_i = \sum_{i=1}^{\ell} \alpha_i \quad (2.19.b)$$

İlgili Karush–Kuhn–Tucker tamamlayıcı durumları Eşitlik 2.20’ da verilmiştir.

$$\alpha_i (\langle \mathbf{w} \cdot \mathbf{x}_i \rangle + b - y_i - \varepsilon - \xi_i) = 0, \quad (2.20.a)$$

$$\hat{\alpha}_i (y_i - \langle \mathbf{w} \cdot \mathbf{x}_i \rangle - b - \varepsilon - \hat{\xi}_i) = 0, \quad (2.20.b)$$

$$\xi_i \cdot \hat{\xi}_i = 0, \quad (2.20.c)$$

$$\alpha_i \cdot \hat{\alpha}_i = 0, \quad (2.20.d)$$

$$(\alpha_i - C) \cdot \xi_i = 0 \quad (2.20.e)$$

$$(\hat{\alpha}_i - C) \cdot \hat{\xi}_i = 0, \quad i = 1, 2, \dots, \ell \quad (2.20.f)$$

Bu aşamada ℓ adet Lagrange çarpan çifti $(\alpha_i, \hat{\alpha}_i)$ bulunmalıdır. Burada α_i ve $\hat{\alpha}_i$ çarpımının sıfır olduğu, yani en azından bu iki terimden birinin sıfır olduğu görülmektedir. Sıfır olmayan α_i ve $\hat{\alpha}_i$ ’ ye ait $\mathbf{x}_i$ ’ ye “destek vektörü” denir. En fazla ℓ adet destek vektörü olabilir.

$(\hat{\alpha}_i - \alpha_i)$ yerine α_i koyarak ve $\hat{\alpha}_i \cdot \alpha_i = 0$ olduğunu göz önünde bulundurarak Eşitlik 2.18’ da x -giriş uzayında yer alan amaç fonksiyonu F -öznitelik uzayında şu şekilde yazılabilir:

$$W(\alpha, \hat{\alpha}) = -\varepsilon \sum_{i=1}^{\ell} |\alpha_i| + \sum_{i=1}^{\ell} y_i \alpha_i - \frac{1}{2} \sum_{i,j=1}^{\ell} \alpha_i \alpha_j \langle \varphi(\mathbf{x}_i) \cdot \varphi(\mathbf{x}_j) \rangle \quad (2.21)$$

Bu şekilde öznitelik uzayındaki çift optimizasyon problemi elde edilir. Bu ifadenin maksimizasyonu $(\alpha, \hat{\alpha})$ ’ye ve Eşitlik 2.20’ deki durumlara bağlı olarak yapılmalıdır. Bu maksimizasyon $(\alpha, \hat{\alpha})$ katsayılarının belirlenmesi ile sonuçlanır. Bu katsayıları Eşitlik 2.16’ ya yerleştirerek ağırlık vektörü $\mathbf{w}$ eğitim verilerinin doğrusal bileşimi olarak elde edilebilir:

$$\mathbf{w} = \sum_i^{\ell} (\alpha_i - \hat{\alpha}_i) \mathbf{x}_i^t \quad (2.22)$$

Verilen verinin destek vektör açılımı şu şekilde elde edilir:

$$f(\mathbf{x}) = \sum_{i=1}^{DV} \alpha_i y_i \langle \varphi(\mathbf{x}_i) \cdot \varphi(\mathbf{x}) \rangle + b \quad (2.23)$$

Öznelik uzayındaki iç çarpım $\langle \varphi(\mathbf{x}_i) \cdot \varphi(\mathbf{x}) \rangle$ genellikle kernel fonksiyonu K olarak adlandırılır ve her $\mathbf{x}, \mathbf{z} \in X$ için şu şekilde ifade edilebilir:

$$K(\mathbf{x}, \mathbf{z}) = \langle \varphi(\mathbf{x}) \cdot \varphi(\mathbf{z}) \rangle \quad (2.24)$$

Burada φ , X den öznelik uzayı F 'e yapılan bir eşlemelemedir. b 'nin değeri çift problemin çözümü ile bulunamaz. Bu sebepten b^* (2.20.a) ve (2.20.b)' de yer alan birincil kısıtlamaları kullanarak bulunmalıdır.

DV açılımı için son olarak şunlar söylenebilir: Eşitlik (2.20.a) ve (2.20.b)' den sadece $|f(\mathbf{x}_i) - y_i| \geq \varepsilon$ ise Lagrange çarpanlarının sıfırdan farklı olabileceği, farklı bir deyişle, ε -tütün içindeki tüm örnekler için, yani $|f(\mathbf{x}_i) - y_i| < \varepsilon$ olduğunda α ve $\hat{\alpha}$ sıfır olacaktır. Bu şekilde Karush-Kuhn-Tucker durumları sağlanmış olur. Bu şekilde azaltılmış sayıda eğitim verisi $\mathbf{x}_i$ ile $\mathbf{w}$ 'nun seyrek açılımı elde edilebilir. Sıfır olmayan Lagrange katsayıları ile gelen örneklere destek vektörü denir. Çözümün eğitim verisinin bir alt kümesi ile ifade edilebilmesinin hesaplamada büyük avantajları vardır. Azaltılmış sayıda sıfır olmayan parametre ve garantili evrensel minimum DVM ile, YSA gibi diğer örüntü tanıma algoritmaları arasındaki en büyük farklılıklardır [2].

BİR MİKRODALGA TRANSİSTÖRÜNÜN DESTEK VEKTÖR MAKİNELERİ İLE KARAKUTU MODELLEMESİ

İyi bir devre tasarımında doğrusal olmayan mikrodalga cihazların modellenmesi halen karmaşık fakat kaçınılmaz bir adımdır. Düşük frekanslarda oldukça basit sayılabilecek pasif elemanların karakterizasyonu bile mikrodalga frekanslarında zor olabilir. Çok sayıda parametrenin karmaşık bağıntılarıyla ifade edilen doğrusal olmayan modellerle karakterize edilebilen yarıiletken cihazlarda parametre seçimi çok önemlidir. Eğer parametreler doğru olarak seçilmezse simülasyon sonuçlarını çarpıtabilir. Cihazın doğrusal olmamasından dolayı bu model parametreleri genellikle deneysel ölçümlerle elde edilemez. Örnek olarak bir mikrodalga transistörü ele alalım. Bilindiği gibi küçük-ışaret ve gürültü davranışını modellemek için iki ayrı yaklaşım mevcuttur. Bunlardan ilki ışıaret ve gürültü performansının genellikle birbirinden ayrıldığı ve cihazın operasyon alanının alt bölgesinde karakterize edildiği toplu elemanlı eşdeğer elektriksel devre yaklaşımıdır. İkinci yaklaşım ise ışıaret ve gürültü davranışlarını tüm operasyon alanında beraber ele alabilen kara-kutu yaklaşımıdır.

Toplu elemanlı eşdeğer elektriksel devre yaklaşımı, ölçüm yapılan kara-kutu karakterizasyon parametrelerinden (mikrodalga frekanslarında S-parametreleridir) devre elemanlarının belirlenmesinde optimizasyon-tabanlı çıkartım tekniklerini kullanır. Bu hesaplama teknikleri çözümün tek olmaması olumsuzluğuna sahiptir. Bazı çalışmalarda bu probleme çözüm üretilmiştir fakat başlangıç değer problemine bağlı belirsizlikler devam etmektedir [2].

Bilgisayar bilimlerindeki gelişmeler ayırık veriyi sürekli veri alanına genelleyebilen öğrenen makineleri mümkün kılmıştır. Sürekli veri alanındaki genelleme özelliği öğrenen makinelerin cihaz modellemede tablo-tabanlı metotlara üstünlüğüdür. YSA


tipik bir öğrenen makinedir ve doğrusal olmayan cihazların kara-kutu modellemesinde kullanılmaktadır. Yapay transistörler, mikrodalga transistörlerinin tipik kara-kutu modeli olup işaret ve gürültü parametrelerini N- ölçüm örneği ile cihazın tüm işlem alanında yüksek doğrulukla tespit edebilir [21], [22],[23], [24]. Bu kara-kutu modelleri mikrodalga cihazların ve devrelerin tasarımına başarı ile uygulanmıştır [25],[26]. Bunun yanı sıra, son yirmi yılda destek vektör makineleri yapay sinir ağlarına rakip öğrenen makineler olarak ortaya çıkmıştır [2].

Bu bölümde BFP-181 transistörünün DVRM modeli tanıtılacaktır. Sıradaki alt bölümde mikrodalga transistörün küçük-ışaret davranışı modelleme esaslarına yer verilmiştir

3.1 Bir Mikrodalga Transistörün DVRM Modeli

3.1.1 Bir Mikrodalga Transistörün Kara-Kutu Gösterimi

Bir mikrodalga transistörün V_{DS} , I_{DS} kutuplama koşullarında ve f işlem frekansında küçük işaret (S-) ve gürültü (N-) davranışının kara-kutu gösterimi [21] de verilmiştir. Burada DVM cihaz işlem durumları f , V_{DS} , I_{DS} ile S parametrelerinin büyüklüğünü ve fazını ilişkilendirmek amacıyla kullanılmıştır. Burada f , V_{DS} , I_{DS} giriş uzayı olup, küçük işaret tanımlayan sekiz fonksiyon, DVM regresyonu yapılacak fonksiyonlardır. Şekil 3.1’de problemin kara-kutu gösterimi verilmiştir.



Şekil 3. 1 Bir mikrodalga transistörün işaret-gürültü DVRM modeli [27]

3.1.2 Eğitim ve Test Verisi

DVRM modelinin eğitim ve test verisi seçilen transistörün üretici verilerinden elde edilmiştir. Bir aktif mikrodalga cihazın kutuplama noktası, V_{DS} , I_{DS} ’ de işaret ve

gürültü performansı genellikle ω -alanında saçılma ve gürültü parametreleri ile verilebilir [21]. Ölçüm performans verileri tüm işlem bandında şu şekilde bir tablo formuna dönüştürülebilir:

$$\begin{bmatrix} f_1 & S^{(1)} \\ f_2 & S^{(2)} \\ \cdot & \cdot \\ \cdot & \cdot \\ f_N & S^{(N)} \end{bmatrix} \quad (3.1)$$

Burada $S^{(1)} ; \dots ; S^{(N)}$ sırasıyla $f_1, \dots, f_N$ işlem frekansındaki saçılma vektörleri olup şu şekilde şu şekilde verilebilir:

$$[S^{(N)}]^t = [|S_{11}|^{(N)} \varphi_{11}^{(N)} |S_{12}|^{(N)} \varphi_{12}^{(N)} |S_{21}|^{(N)} \varphi_{21}^{(N)} |S_{22}|^{(N)} \varphi_{22}^{(N)}] \quad (3.2)$$

(3.1)-(3.2) eşitlikleri ile tanımlanan ifadeler cihazın DVRM modelinin eğitiminde kullanılmaktadır. Böylece belli bir f_k frekansında ve kutuplama koşullarında performans vektörleri $S^{(k)}$ yı elde etmek mümkün olmaktadır. $S^{(k)}$ 'nin ölçülmediği durumlarda dahi modelin cevap verebilmesi genelleme yeteneğine bağlıdır. Sonuç olarak oluşturulan DVM modeli sürekli bir model olup transistörün işaret parametreleri ile işlem durumları V_{DS} , I_{DS} ve işlem frekansı arasındaki doğrusal olmayan bağlılığı ilişkilendirme yeteneğine sahiptir [2].

3.2 Uygulama Örneği: BFP-181' in İşaret Modeli

3.2.1 Modelin Eğitim ve Test Verisi

Uygulama örneği olarak, BFP-181 modellenen eleman olarak seçilmiş ve transistörün 1 Ghz- 20 Ghz frekans aralığı, $V_{DS} = 0.5V, 0.75, 1V, 1.5V, 1.7, 2V, 2.5V, 3V, 3.5V, 4V, 5V, 6V, 8V$ kutuplama gerilimi ve $I_{DS} = 0.1 \text{ mA} - 6 \text{ mA}$ akım aralığı için S parametreleri üretici verilerinden elde edilmiştir. Giriş ve çıkış kümesinin değer aralığı değiştirilerek eğitim ve test kümesi oluşturulmuştur. Eğitim ve test aşamasında Intel i7- 5500U CPU, 2.40 Ghz İşlemci, 8 GB RAM'e sahip bir bilgisayar kullanılmıştır.

3.2.2 Transistör Modelinin Hata Analizi

Hedef verisi ile olan uyumluluğu hesaplamak ve DVRM modelinin performansını ölçmek amacı ile aşağıda yer alan hata terimleri kullanılmıştır [27].

$$\text{Hata Oranı 1: } E_{S_{ij}} = \frac{1}{n} \sum_{k=1}^n |S_{ij(\text{ölçülen})}^k - S_{ij(\text{tahmin edilen})}^k| \quad (3.3)$$

$$\text{Hata Oranı 2: } E_{S_{ij}} = \frac{1}{n} \sum_{k=1}^n \frac{|S_{ij(\text{ölçülen})}^k - S_{ij(\text{tahmin edilen})}^k|}{|S_{ij(\text{ölçülen})}^k|} \quad (3.4)$$

Burada S_{ij} işaret parametreleri, n ise her bir kutuplama koşulundaki ayırık frekans sayısının toplamıdır.

3.2.3 BPF-181'in İşaret Parametrelerinin DVRM Modeli

3.2.3.1 Senaryo 1

Bu senaryoda transistörün 1 GHz – 20 GHz frekans aralığı, $V_{DS} = 0.5V, 1V, 1.7$ kutuplama gerilimi ve $I_{DS} = 0.1 \text{ mA} - 6 \text{ mA}$ akım aralığı için S parametreleri üretici verilerinden elde edilerek oluşturulan eğitim kümesi kullanılmıştır. Modelin testi için ise $V = 0.75V, 1.5V$ için mevcut S verisi kullanılarak interpolasyon senaryosu kurulmuştur. Eğitim için 2700, test için ise 1800 adet S verisi kullanılmıştır.

Çizelge 3. 1 Senaryo 1'de S11'in büyüklüğü için DVM parametreleri ve hata oranları

s (0, 1, 2, 3, 4)	t (0, 1, 2, 3)	c (default=1)	p (default=0.1)	Hata Oranı 1	Hata Oranı 2
0	0	100	0.001	0.6047	1
0	1	100	0.001	0.6047	1
0	2	100	0.001	0.6047	1
0	3	100	0.001	0.6047	1
1	0	100	0.001	0.6047	1
1	1	100	0.001	0.6047	1
1	2	100	0.001	0.6047	1
1	3	100	0.001	0.6047	1
2	0	100	0.001	0.9654	1.7158
2	1	100	0.001	0.9667	1.7191
2	2	100	0.001	0.7740	1.2825
2	3	100	0.001	0.9752	1.7158

Çizelge 3. 1 Senaryo 1’de S11’in büyüklüğü için DVM parametreleri ve hata oranları
(devamı)

3	0	100	0.001	0.0562	0.0875
3	1	100	0.001	8.0203	12.1548
3	2	100	0.001	0.0038	0.0069
3	3	100	0.001	999.1922	1.5259E+0.3
4	0	10	0.001	0.0754	0.1121
4	1	10	0.001	2.9175	4.6103
4	2	10	0.001	0.0038	0.0068
4	3	10	0.001	975.2793	1.5081E+0.3
3	2	1	0.001	0.0044	0.0078
3	2	10	0.001	0.0040	0.0072
3	2	100	0.001	0.0038	0.0069
3	2	1000	0.001	0.0046	0.0079
3	2	10000	0.001	0.0055	0.0093
4	2	1	0.001	0.0044	0.0077
4	2	10	0.001	0.0040	0.0072
4	2	100	0.001	0.0038	0.0068
4	2	1000	0.001	0.0054	0.0090
4	2	10000	0.001	0.0104	0.0165

Çizelge 3. 2 Senaryo 1’de S11’in açısı için DVM parametreleri ve hata oranları

s (0, 1, 2, 3, 4)	t (0, 1, 2, 3)	c (default=1)	p (default=0.1)	Hata Oranı 1	Hata Oranı 2
0	0	100	0.001	14.8471	0.1037
0	1	100	0.001	3.8243	0.0312
0	2	100	0.001	28.6339	0.2816
0	3	100	0.001	14.5139	0.1006
1	0	100	0.001	-	-
1	1	100	0.001	-	-
1	2	100	0.001	-	-
1	3	100	0.001	-	-
2	0	100	0.001	108.6742	0.9952
2	1	100	0.001	108.6953	0.9957
2	2	100	0.001	108.6631	0.9967
2	3	100	0.001	108..6987	0.9957
3	0	100	0.001	68.4775	0.7905
3	1	100	0.001	65.015	0.6988
3	2	100	0.001	23.2101	0.1615
3	3	100	0.001	1.0240E+ 0.3	24.7251
4	0	100	0.001	70.6841	0.6123

Çizelge 3. 2 Senaryo 1’de S11’in açısı için DVM parametreleri ve hata oranları
(devamı)


4	1	100	0.001	78.0394	0.8329
4	2	100	0.001	23.6791	0.1692
4	3	100	0.001	955.5225	21.0177
0	1	1	0.001	4.7034	0.0522
0	1	10	0.001	3.9506	0.0359
0	1	100	0.001	3.8243	0.0312
0	1	1000	0.001	4.0838	0.0333
0	1	10000	0.001	3.3301	0.0296

Çizelge 3. 3 Senaryo 1’de S21’in büyüklüğü için DVM parametreleri ve hata oranları


s (0, 1, 2, 3, 4)	t (0, 1, 2, 3)	c (default=1)	p (default=0.1)	Hata Oranı 1	Hata Oranı 2
0	0	100	0.001	0.8708	0.4972
0	1	100	0.001	0.6335	0.4387
0	2	100	0.001	0.5586	0.4497
0	3	100	0.001	2.1069	0.8070
1	0	100	0.001	-	-
1	1	100	0.001	-	-
1	2	100	0.001	-	-
1	3	100	0.001	-	-
2	0	100	0.001	2.4666	1.0624
2	1	100	0.001	2.4704	1.0695
2	2	100	0.001	1.9476	0.8746
2	3	100	0.001	2.4619	1.0911
3	0	100	0.001	0.8482	0.3080
3	1	100	0.001	6.3434	8.0610
3	2	1	0.001	0.2176	0.0380
3	2	10	0.001	0.1262	0.0292
3	2	100	0.001	0.0859	0.0252
3	2	1000	0.001	0.0654	0.0239
3	2	10000	0.001	0.0662	0.0265
3	3	100	0.001	999.4993	451.2686
4	0	100	0.001	0.8754	0.3962
4	1	100	0.001	2.9970	3.5109
4	2	1	0.001	0.2171	0.0385
4	2	10	0.001	0.1263	0.0294
4	2	100	0.001	0.0858	0.0255
4	2	1000	0.001	0.0855	0.0524
4	2	10000	0.001	0.1257	0.1137
4	3	100	0.001	975.2574	548.8492

Çizelge 3. 4 Senaryo 1’de S21’in açısı için DVM parametreleri ve hata oranları

s (0, 1, 2, 3, 4)	t (0, 1, 2, 3)	c (default=1)	p (default=0.1)	Hata Oranı 1	Hata Oranı 2
0	0	100	0.001	2.9162	nan
0	1	100	0.001	1.4456	nan
0	2	1	0.001	9.8677	nan
0	2	10	0.001	3.5212	nan
0	2	100	0.001	1.4384	nan
0	2	1000	0.001	1.1886	nan
0	2	10000	0.001	1.1871	nan
0	3	100	0.001	47.2977	nan
1	0	100	0.001	-	-
1	1	100	0.001	-	-
1	2	100	0.001	-	-
1	3	100	0.001	-	-
2	0	100	0.001	45.2262	inf
2	1	100	0.001	45.2294	inf
2	2	100	0.001	44.5819	inf
2	3	100	0.001	45.1372	inf
3	0	100	0.001	8.6991	inf
3	1	100	0.001	22.9384	inf
3	2	1	0.001	6.2950	inf
3	2	10	0.001	1.8742	inf
3	2	100	0.001	1.2152	inf
3	2	1000	0.001	1.0540	inf
3	2	10000	0.001	0.9829	inf
3	3	100	0.001	986.5843	inf
4	0	100	0.001	8.6901	inf
4	1	100	0.001	37.3339	inf
4	2	1	0.001	6.6170	inf
4	2	10	0.001	1.8776	inf
4	2	100	0.001	1.2172	inf
4	2	1000	0.001	1.0443	inf
4	2	10000	0.001	1.1903	inf
4	3	100	0.001	986.5843	inf




(a)




(b)

Şekil 3. 2 Senaryo 1’de (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının test datası uzayında değişimi



(c)




(d)

Şekil 3. 2 Senaryo 1’de (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının test datası uzayında değişimi (devamı)


Çizelge 3. 5 Senaryo 1’de $V_{DS}=0.75V$, $I_{DS}=2.7mA$ kutuplama koşulunda frekansa bağlı olarak hedef ve tahmini değerlerin karşılaştırması

f	S11M Hedef	S11m Tahmin	S11P Hedef	S11P Tahmin	S21M Hedef	S21M Tahmin	S21P Hedef	S21P Tahmin
1	0.4756	0.4761	168.1	167	1.496	1.4743	46.8	45.9473
1.2	0.4686	0.4701	161.7	162	1.584	1.5606	45.8	44.9618
1.5	0.4658	0.4667	154.2	154	1.685	1.6539	44.4	43.6706
2	0.4666	0.4687	145.3	145	1.788	1.7509	42.6	41.8704
2.5	0.4729	0.4753	139.2	139	1.843	1.7988	41.2	40.3585
3	0.4792	0.4837	134.8	133	1.867	1.8112	39.9	38.9858
4	0.4959	0.5015	128.6	127	1.847	1.7701	37.6	36.4062
5	0.5117	0.5185	124.6	123	1.755	1.6813	35.3	34.0238
6	0.5316	0.5377	121.5	120	1.624	1.5680	33.0	31.6378
8	0.5700	0.5741	117.6	116	1.361	1.3262	28.6	27.1033
10	0.6031	0.6068	115.4	115	1.156	1.1262	24.6	23.1642
12	0.6284	0.6323	114.0	115	1.008	0.9821	21.0	19.4633
15	0.6619	0.6633	112.7	113	0.849	0.8264	16.0	14.9643
17	0.6776	0.6806	112.1	114	0.772	0.7466	13.3	12.5118
20	0.6984	0.7014	111.5	110	0.677	0.6537	9.5	8.94690




(a)

Şekil 3. 3 Senaryo 1’de $V_{DS}=0.75V$, $I_{DS}=2.7mA$ kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının frekans ile değişimi




(b)



(c)

Şekil 3. 3 Senaryo 1’de $V_{DS}=0.75V$, $I_{DS}=2.7mA$ kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının frekans ile değişimi (devamı)



(d)

Şekil 3. 3 Senaryo 1’de $V_{DS}=0.75V$, $I_{DS}=2.7mA$ kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının frekans ile değişimi (devamı)

3.2.3.2 Senaryo 2

Bu senaryoda, senaryo 1’deki akım, volt ve frekans değerleri kullanılmıştır. Frekans ; düşük, orta ve yüksek frekans bölgelerine ayrılarak giriş uzayının boyutu artırılmıştır. koşulmuştur. Eğitim için 2700, test için 1800 adet S verisi kullanılmıştır.

Çizelge 3. 6 Senaryo 2’de S11’in büyüklüğü için DVM parametreleri ve hata oranları

s (0, 1, 2, 3, 4)	t (0, 1, 2, 3)	c (default=1)	p (default=0.1)	Hata Oranı 1	Hata Oranı 2
0	0	100	0.001	0.6047	1
0	1	100	0.001	0.6047	1
0	2	100	0.001	0.6047	1
0	3	100	0.001	0.6047	1
1	0	100	0.001	0.6047	1
1	1	100	0.001	0.6047	1
1	2	100	0.001	0.6047	1
1	3	100	0.001	0.6047	1
2	0	100	0.001	0.9675	1.7180
2	1	100	0.001	0.9671	1.7180
2	2	100	0.001	0.7999	1.3180
2	3	100	0.001	0.9726	1.7147
3	0	100	0.001	0.0575	0.0892
3	1	100	0.001	3.0049	4.2555
3	2	100	0.001	0.0037	0.0066

Çizelge 3. 6 Senaryo 2’de S11’in büyüklüğü için DVM parametreleri ve hata oranları
(devamı)

3	3	100	0.001	1.2344E+0.3	1.9269E+03
4	0	10	0.001	0.0714	0.1058
4	1	10	0.001	3.9056	6.1476
4	2	10	0.001	0.0038	0.0067
4	3	10	0.001	1.1929E+0.3	1.8818E+0.3
3	2	1	0.001	0.0043	0.0076
3	2	10	0.001	0.0039	0.0069
3	2	100	0.001	0.0037	0.0066
3	2	1000	0.001	0.0038	0.0068
3	2	10000	0.001	0.0052	0.0087
4	2	1	0.001	0.0043	0.0076
4	2	10	0.001	0.0039	0.0069
4	2	100	0.001	0.0038	0.0067
4	2	1000	0.001	0.0075	0.0117
4	2	10000	0.001	0.0131	0.0204

Çizelge 3. 7 Senaryo 2’de S11’in açısı için DVM parametreleri ve hata oranları

s (0, 1, 2, 3, 4)	t (0, 1, 2, 3)	c (default=1)	p (default=0.1)	Hata Oranı 1	Hata Oranı 2
0	0	100	0.001	9.6254	0.0687
0	1	100	0.001	3.9244	0.0332
0	2	100	0.001	6.0708	0.0478
0	3	100	0.001	69.5901	0.6890
1	0	100	0.001	-	-
1	1	100	0.001	-	-
1	2	100	0.001	-	-
1	3	100	0.001	-	-
2	0	100	0.001	108.6787	0.9953
2	1	100	0.001	108.6942	0.9955
2	2	100	0.001	108.6587	0.9965
2	3	100	0.001	108.6842	0.9955
3	0	100	0.001	68.4083	0.7947
3	1	100	0.001	78.5728	0.7600
3	2	100	0.001	25.3944	0.1774
3	3	100	0.001	1.2550e+03	27.7247
4	0	100	0.001	70.4211	0.6109
4	1	100	0.001	63.9488	0.6544
4	2	100	0.001	26.0590	0.1893
4	3	100	0.001	1.1764e+03	23.3106
0	1	1	0.001	5.6166	0.0669

Çizelge 3. 7 Senaryo 2’de S11’in açısı için DVM parametreleri ve hata oranları
devamı


0	1	10	0.001	4.9321	0.0439
0	1	100	0.001	3.9244	0.0332
0	1	1000	0.001	3.9409	0.0333
0	1	10000	0.001	3.9426	0.0332

Çizelge 3. 8 Senaryo 2’de S21’in büyüklüğü için DVM parametreleri ve hata oranları


s (0, 1, 2, 3, 4)	t (0, 1, 2, 3)	c (default=1)	p (default=0.1)	Hata Oranı 1	Hata Oranı 2
0	0	100	0.001	0.7470	0.4871
0	1	100	0.001	0.5564	0.4481
0	2	100	0.001	0.5660	0.4493
0	3	100	0.001	2.1927	0.8807
1	0	100	0.001	-	-
1	1	100	0.001	-	-
1	2	100	0.001	-	-
1	3	100	0.001	-	-
2	0	100	0.001	2.4678	1.0665
2	1	100	0.001	2.4680	1.0712
2	2	100	0.001	1.9783	0.8953
2	3	100	0.001	2.4621	1.0832
3	0	100	0.001	0.8412	0.3068
3	1	100	0.001	6.6524	11.2985
3	2	1	0.001	0.2297	0.0384
3	2	10	0.001	0.1352	0.0294
3	2	100	0.001	0.0910	0.0245
3	2	1000	0.001	0.0712	0.0226
3	2	10000	0.001	0.0639	0.0245
3	3	100	0.001	1.234e+03	580.6700
4	0	100	0.001	0.8630	0.4097
4	1	100	0.001	2.1758	1.8818
4	2	1	0.001	0.2286	0.0388
4	2	10	0.001	0.1352	0.0295
4	2	100	0.001	0.0909	0.0250
4	2	1000	0.001	0.0902	0.0482
4	2	10000	0.001	0.1044	0.0734
4	3	100	0.001	1.1929e+03	702.8137

Çizelge 3. 9 Senaryo 2’de S21’in açısı için DVM parametreleri ve hata oranları

s (0, 1, 2, 3, 4)	t (0, 1, 2, 3)	c (default=1)	p (default=0.1)	Hata Oranı 1	Hata Oranı 2
0	0	100	0.001	2.9162	nan
0	1	100	0.001	1.4456	nan
0	2	1	0.001	9.8677	nan
0	2	10	0.001	3.5212	nan
0	2	100	0.001	1.4384	nan
0	2	1000	0.001	1.1886	nan
0	2	10000	0.001	1.1871	nan
0	3	100	0.001	47.2977	nan
1	0	100	0.001	-	-
1	1	100	0.001	-	-
1	2	100	0.001	-	-
1	3	100	0.001	-	-
2	0	100	0.001	45.2262	inf
2	1	100	0.001	45.2294	inf
2	2	100	0.001	44.5819	inf
2	3	100	0.001	45.1372	inf
3	0	100	0.001	8.6991	inf
3	1	100	0.001	22.9384	inf
3	2	1	0.001	6.2950	inf
3	2	10	0.001	1.8742	inf
3	2	100	0.001	1.2152	inf
3	2	1000	0.001	1.0540	inf
3	2	10000	0.001	0.9829	inf
3	3	100	0.001	986.5843	inf
4	0	100	0.001	8.6901	inf
4	1	100	0.001	37.3339	inf
4	2	1	0.001	6.6170	inf
4	2	10	0.001	1.8776	inf
4	2	100	0.001	1.2172	inf
4	2	1000	0.001	1.0443	inf
4	2	10000	0.001	1.1903	inf
4	3	100	0.001	986.5843	inf




(a)




(b)

Şekil 3. 4 Senaryo 2’de (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının test datası uzayında değişimi



(c)



(d)

Şekil 3. 4 Senaryo 2’de (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının test datası uzayında değişimi (devamı)

Senaryo 1 ve 2 karşılaştırması aşağıdaki tabloda yapılmıştır. Frekans bölgesi bilgisinin eğitim kümesinde kullanılmasının DVM’nin regresyon yapabilme yeteneğinde etkisi olmadığı görülmüştür.

Çizelge 3. 10 Senaryo 2’de S21’in açısı için DVM parametreleri ve hata oranları

					SENARYO 1		SENARYO 2	
	s	t	c	p	Hata 1	Hata 2	Hata 1	Hata 2
S11M	3	2	100	0.001	0.0038	0.0069	0.0037	0.0066
S11P	0	1	100	0.001	3.8243	0.0312	3.9244	0.0332
S21M	3	2	1000	0.001	0.0654	0.0239	0.0712	0.0226
S21P	3	2	1000	0.001	1.0540	inf	1.0470	inf

3.2.3.3 Senaryo 3

Bu senaryoda transistörün 1 GHz – 20 GHz frekans aralığı, $V_{ds} = 0.75V$, 1.5V kutuplama gerilimi ve $I_{ds} = 0.1\text{ mA} - 6\text{ mA}$ akım aralığı için S parametreleri üretici verilerinden elde edilerek oluşturulan eğitim kümesi kullanılmıştır. Modelin testi için ise $V = 0.5V$, 1V, 1.7 için mevcut S verisi kullanılarak interpolasyon ve ekstrapolasyon senaryosu koşulmuştur. Eğitim için 1800, test için 2700 adet S verisi kullanılmıştır.

Çizelge 3. 11 Senaryo 3’te S11’in büyüklüğü için DVM parametreleri ve hata oranları

s (0, 1, 2, 3, 4)	t (0, 1, 2, 3)	c (default=1)	p (default=0.1)	Hata Oranı 1	Hata Oranı 2
0	0	100	0.001	0.6093	1
0	1	100	0.001	0.6093	1
0	2	100	0.001	0.6093	1
0	3	100	0.001	0.6093	1
1	0	100	0.001	0.6093	1
1	1	100	0.001	0.6093	1
1	2	100	0.001	0.6093	1
1	3	100	0.001	0.6093	1
2	0	100	0.001	0.9680	1.7107
2	1	100	0.001	0.9662	1.7085
2	2	100	0.001	1.2720	2.1337
2	3	100	0.001	0.9796	1.7137
3	0	100	0.001	0.0607	0.0950
3	1	100	0.001	5.6441	8.4083
3	2	100	0.001	0.0071	0.0132
3	3	100	0.001	666.1268	1.0193e+03
4	0	10	0.001	0.0698	0.1055
4	1	10	0.001	0.1931	0.3290
4	2	10	0.001	0.0071	0.0130
4	3	10	0.001	666.1268	989.3753

Çizelge 3. 11 Senaryo 3'te S11'in büyüklüğü için DVM parametreleri ve hata oranları (devamı)

3	2	1	0.001	0.0070	0.0126
3	2	10	0.001	0.0069	0.0127
3	2	100	0.001	0.0071	0.0130
3	2	1000	0.001	0.0069	0.0297
3	2	10000	0.001	0.0106	0.0357
4	2	1	0.001	0.0070	0.0126
4	2	10	0.001	0.0069	0.0127
4	2	100	0.001	0.0071	0.0130
4	2	1000	0.001	0.0197	0.0297
4	2	10000	0.001	0.0234	0.0357

Çizelge 3. 12 Senaryo 3'te S11'in açısı için DVM parametreleri ve hata oranları

s (0, 1, 2, 3, 4)	t (0, 1, 2, 3)	c (default=1)	p (default=0.1)	Hata Oranı 1	Hata Oranı 2
0	0	100	0.001	13.6938	0.0983
0	1	100	0.001	6.6934	0.0517
0	2	100	0.001	7.8851	0.0595
0	3	100	0.001	69.9654	0.6872
1	0	100	0.001	-	-
1	1	100	0.001	-	-
1	2	100	0.001	-	-
1	3	100	0.001	-	-
2	0	100	0.001	108.6595	0.9954
2	1	100	0.001	108.6780	0.9956
2	2	100	0.001	109.1654	1.0014
2	3	100	0.001	108.6862	0.9958
3	0	100	0.001	67.5726	0.7636
3	1	100	0.001	70.8265	0.7506
3	2	100	0.001	25.6157	0.1793
3	3	100	0.001	642.2233	15.5928
4	0	100	0.001	70.9884	0.6163
4	1	100	0.001	119.1615	1.3273
4	2	100	0.001	25.7305	0.1826
4	3	100	0.001	618.6524	13.3489
0	1	1	0.001	8.8863	0.0857
0	1	10	0.001	7.1892	0.0582
0	1	100	0.001	6.6934	0.0517
0	1	1000	0.001	6.7766	0.0505
0	1	10000	0.001	6.7872	0.0510

Çizelge 3. 13 Senaryo 3'te S21'in büyüklüğü için DVM parametreleri ve hata oranları


s (0, 1, 2, 3, 4)	t (0, 1, 2, 3)	c (default=1)	p (default=0.1)	Hata Oranı 1	Hata Oranı 2
0	0	100	0.001	0.8319	0.4908
0	1	100	0.001	0.6154	0.4405
0	2	100	0.001	0.5480	0.4460
0	3	100	0.001	1.9325	0.7629
1	0	100	0.001	-	-
1	1	100	0.001	-	-
1	2	100	0.001	-	-
1	3	100	0.001	-	-
2	0	100	0.001	2.4169	1.1302
2	1	100	0.001	2.4152	1.1340
2	2	100	0.001	2.6868	1.5194
2	3	100	0.001	2.4132	1.1604
3	0	100	0.001	0.8313	0.3591
3	1	100	0.001	7.6697	12.2192
3	2	1	0.001	0.3212	0.1559
3	2	10	0.001	0.2902	0.2165
3	2	100	0.001	0.3801	0.3510
3	2	1000	0.001	0.6049	0.5857
3	2	10000	0.001	0.9581	0.9296
3	3	100	0.001	66.4259	311.5803
4	0	100	0.001	0.8531	0.4284
4	1	100	0.001	3.1663	3.1984
4	2	1	0.001	0.3224	0.1579
4	2	10	0.001	0.2925	0.2191
4	2	100	0.001	0.3789	0.3499
4	2	1000	0.001	0.5917	0.5724
4	2	10000	0.001	1.2241	1.4713
4	3	100	0.001	666.4259	311.5803

Çizelge 3. 14 Senaryo 3'te S21'in açısı için DVM parametreleri ve hata oranları

s (0, 1, 2, 3, 4)	t (0, 1, 2, 3)	c (default=1)	p (default=0.1)	Hata Oranı 1	Hata Oranı 2
0	0	100	0.001	3.1014	0.2687
0	1	1	0.001	3.3070	0.2387
0	1	10	0.001	2.6084	0.2322
0	1	100	0.001	2.4914	0.2349
0	1	1000	0.001	2.4432	0.2329
0	1	10000	0.001	2.4390	0.2301
0	2	100	0.001	2.8002	0.2767
0	3	100	0.001	46.3955	1.0203
1	0	100	0.001	-	-


Çizelge 3. 14 Senaryo 3'te S21'in açısı için DVM parametreleri ve hata oranları (devamı)

1	1	100	0.001	-	-
1	2	100	0.001	-	-
1	3	100	0.001	-	-
2	0	100	0.001	44.3799	1.0418
2	1	100	0.001	44.3807	1.0429
2	2	100	0.001	44.2148	1.0308
2	3	100	0.001	44.2913	1.0375
3	0	100	0.001	9.2406	0.6295
3	1	100	0.001	24.3375	2.2899
3	2	100	0.001	3.3402	0.5131
3	3	100	0.001	679.2118	29.9321
4	0	100	0.001	9.5860	0.7444
4	1	100	0.001	28.2693	2.6094
4	2	100	0.001	3.3388	0.5136
4	3	100	0.001	651.5530	39.3106




(a)

Şekil 3. 5 Senaryo 3'te (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının test datası uzayında değişimi




(b)



(c)

Şekil 3. 5 Senaryo 3'te (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının test datası uzayında değişimi (devamı)




(d)


Şekil 3. 5 Senaryo 3'te (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının test datası uzayında değişimi (devamı)

Çizelge 3. 15 Senaryo 3'te $V_{DS}=0.5V$, $I_{DS}=2mA$ kutuplama koşulunda frekansa bağlı olarak hedef ve ekstrapolasyon tahmini değerlerin karşılaştırması

f	S11M Hedef	S11M Tahmin	S11P Hedef	S11P Tahmin	S21M Hedef	S21M Tahmin	S21P Hedef	S21P Hedef
1	0.4887	0.5138	-153.7	-147	1.772	1.9113	66.8	70
1.2	0.4692	0.4943	-161.7	-156	1.893	2.0270	65.0	68
1.5	0.4559	0.4750	-171.7	-165	2.016	2.1694	62.7	66
2	0.4428	0.4617	175.2	-178	2.141	2.3085	59.6	63
2.5	0.4430	0.4590	166.5	172	2.176	2.3656	57.2	61
3	0.4505	0.4608	159.6	165	2.155	2.3905	54.7	58
4	0.4695	0.4733	149.4	155	2.003	2.3386	50.6	54
5	0.4931	0.4919	142.9	146	1.791	2.1665	47.0	50
6	0.5184	0.5114	138.8	142	1.602	1.9632	43.8	47
8	0.5594	0.5520	134.0	138	1.319	1.5826	38.5	44
10	0.5915	0.5857	131.5	134	1.126	1.3064	33.9	40
12	0.6181	0.6110	130.3	131	0.989	1.1563	30.0	34
15	0.6472	0.6435	129.0	128	0.844	1.0118	25.6	29
17	0.6627	0.6585	128.1	128	0.766	0.9530	22.9	25
20	0.6846	0.6789	127.3	128	0.673	0.8689	19.3	25




(a)




(b)

Şekil 3. 6 Senaryo 3'te $V_{DS}=0.5V$, $I_{DS}=2mA$ kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının frekans ile değişimi



(c)




(d)

Şekil 3. 6 Senaryo 3'te $V_{DS}=0.5V$, $I_{DS}=2mA$ kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının frekans ile değişimi (devamı)


Çizelge 3. 16 Senaryo 3'te $V_{DS}=1V$, $I_{DS}=2.7mA$ kutuplama koşulunda frekansa bağlı olarak hedef ve İnterpolasyontahmini değerlerin karşılaştırması

f	S11M Hedef	S11M Tahmin	S11P Hedef	S11P Tahmin	S21M Hedef	S21M Tahmin	S21P Hedef	S21P Tahmin
1	0.4739	0.4613	170.8	168	1.544	1.4881	48.8	46
1.2	0.4647	0.4531	164.3	161	1.641	1.5784	47.7	46
1.5	0.4585	0.4471	156.8	157	1.749	1.6933	46.3	45
2	0.4561	0.4469	147.7	147	1.868	1.8177	44.6	43
2.5	0.4587	0.4510	141.4	140	1.941	1.8878	43.1	42
3	0.4661	0.4562	136.9	135	1.982	1.9324	42.0	41
4	0.4786	0.4717	130.8	128	2.006	1.9434	40.0	38
5	0.4911	0.4865	126.7	125	1.970	1.8837	38.3	37
6	0.5046	0.5048	123.7	121	1.889	1.7776	36.5	35
8	0.5398	0.5390	119.5	117	1.652	1.5420	33.0	31
10	0.5725	0.5720	116.8	116	1.420	1.3312	29.7	28
12	0.5993	0.5988	115.3	115	1.239	1.1584	26.6	24
15	0.6338	0.6339	113.7	112	1.042	0.9646	22.0	21
17	0.6526	0.6530	113.0	112	0.949	0.868992	19.5	17
20	0.6768	0.6752	112.3	110	0.832	0.749191	15.7	14




(a)

Şekil 3. 7 Senaryo 3'te $V_{DS}=1V$, $I_{DS}=2.7mA$ kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının frekans ile değişimi




(b)



(c)

Şekil 3. 7 Senaryo 3'te $V_{DS}=1V$, $I_{DS}=2.7mA$ kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının frekans ile değişimi



(d)

Şekil 3. 7 Senaryo 3'te $V_{DS}=1V$, $I_{DS}=2.7mA$ kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının frekans ile değişimi

3.2.3.4 Senaryo 4

Bu senaryoda, Senaryo 3'teki akım, volt ve frekans değerleri kullanılmıştır. Frekans ; düşük, orta ve yüksek frekans bölgelerine ayrılarak giriş uzayının boyutu artırılmıştır. Eğitim için 1800, test için 2700 adet S verisi kullanılmıştır.

Çizelge 3. 17 Senaryo 4'te S11'in büyüklüğü için DVM parametreleri ve hata oranları

s (0, 1, 2, 3, 4)	t (0, 1, 2, 3)	c (default=1)	p (default=0.1)	Hata Oranı 1	Hata Oranı 2
0	0	100	0.001	0.6093	1
0	1	100	0.001	0.6093	1
0	2	100	0.001	0.6093	1
0	3	100	0.001	0.6093	1
1	0	100	0.001	0.6093	1
1	1	100	0.001	0.6093	1
1	2	100	0.001	0.6093	1
1	3	100	0.001	0.6093	1
2	0	100	0.001	0.9680	1.7107
2	1	100	0.001	0.9662	1.7085
2	2	100	0.001	1.2720	2.1337
2	3	100	0.001	0.9796	1.7137
3	0	100	0.001	0.0607	0.0950
3	1	100	0.001	5.6441	8.4083

Çizelge 3. 17 Senaryo 4'te S11'in büyüklüğü için DVM parametreleri ve hata oranları (devamı)

3	2	100	0.001	0.0071	0.0132
3	3	100	0.001	666.1268	1.0193e+03
4	0	10	0.001	0.0698	0.1055
4	1	10	0.001	0.1931	0.3290
4	2	10	0.001	0.0071	0.0130
4	3	10	0.001	666.1268	989.3753
3	2	1	0.001	0.0070	0.0126
3	2	10	0.001	0.0069	0.0127
3	2	100	0.001	0.0071	0.0130
3	2	1000	0.001	0.0069	0.0297
3	2	10000	0.001	0.0106	0.0357
4	2	1	0.001	0.0070	0.0126
4	2	10	0.001	0.0069	0.0127
4	2	100	0.001	0.0071	0.0130
4	2	1000	0.001	0.0197	0.0297
4	2	10000	0.001	0.0234	0.0357

Çizelge 3. 18 Senaryo 4'te S11'in açısı için DVM parametreleri ve hata oranları

s (0, 1, 2, 3, 4)	t (0, 1, 2, 3)	c (default=1)	p (default=0.1)	Hata Oranı 1	Hata Oranı 2
0	0	100	0.001	11.0149	0.0779
0	1	100	0.001	7.3523	0.0551
0	2	100	0.001	8.1446	0.0621
0	3	100	0.001	69.8521	0.6851
1	0	100	0.001	-	-
1	1	100	0.001	-	-
1	2	100	0.001	-	-
1	3	100	0.001	-	-
2	0	100	0.001	108.6603	0.9954
2	1	100	0.001	108.6773	0.9956
2	2	100	0.001	109.1521	1.0012
2	3	100	0.001	108.6788	0.9958
3	0	100	0.001	67.4703	0.7735
3	1	100	0.001	60.3882	0.6029
3	2	100	0.001	27.3499	0.1915
3	3	100	0.001	798.9640	17.6922
4	0	100	0.001	70.7027	0.6142
4	1	100	0.001	68.2460	0.7189
4	2	100	0.001	27.7426	0.2003

Çizelge 3. 18 Senaryo 4'te S11'in açısı için DVM parametreleri ve hata oranları (devamı)


4	3	100	0.001	765.7118	14.9277
0	1	1	0.001	9.6055	0.0948
0	1	10	0.001	8.0696	0.0665
0	1	100	0.001	7.3523	0.0551
0	1	1000	0.001	7.3092	0.0534
0	1	10000	0.001	7.3092	0.0534

Çizelge 3. 19 Senaryo 4'te S21'in büyüklüğü için DVM parametreleri ve hata oranları

s (0, 1, 2, 3, 4)	t (0, 1, 2, 3)	c (default=1)	p (default=0.1)	Hata Oranı 1	Hata Oranı 2
0	0	100	0.001	0.6948	0.4788
0	1	100	0.001	0.5475	0.4477
0	2	100	0.001	0.5425	0.4451
0	3	100	0.001	0.0951	0.8793
1	0	100	0.001	-	-
1	1	100	0.001	-	-
1	2	100	0.001	-	-
1	3	100	0.001	-	-
2	0	100	0.001	2.4156	1.1316
2	1	100	0.001	2.4134	0.1359
2	2	100	0.001	2.6499	1.4998
2	3	100	0.001	2.4164	1.1565
3	0	100	0.001	0.8267	0.3635
3	1	100	0.001	4.2034	5.9030
3	2	1	0.001	0.3205	0.1422
3	2	10	0.001	0.2824	0.1940
3	2	100	0.001	0.3483	0.3008
3	2	1000	0.001	0.5955	0.5596
3	2	10000	0.001	0.9099	0.8641
3	3	100	0.001	823.3129	400.6316
4	0	100	0.001	0.8467	0.4511
4	1	100	0.001	3.7121	5.1208
4	2	1	0.001	0.3214	0.1432
4	2	10	0.001	0.2832	0.1950
4	2	100	0.001	0.3564	0.3088
4	2	1000	0.001	0.6121	0.5757
4	2	10000	0.001	1.2647	1.6021
4	3	100	0.001	785.8816	489.9370


Çizelge 3. 20 Senaryo 4'te S21'in açısı için DVM parametreleri ve hata oranları

s (0, 1, 2, 3, 4)	t (0, 1, 2, 3)	c (default=1)	p (default=0.1)	Hata Oranı 1	Hata Oranı 2
0	0	100	0.001	2.7464	0.2663
0	1	1	0.001	3.4455	0.2263
0	1	10	0.001	2.5993	0.2241
0	1	100	0.001	2.4021	0.2228
0	1	1000	0.001	2.4056	0.2232
0	1	10000	0.001	2.4157	0.2202
0	2	100	0.001	2.8550	0.2757
0	3	100	0.001	47.7618	1.0369
1	0	100	0.001	-	-
1	1	100	0.001	-	-
1	2	100	0.001	-	-
1	3	100	0.001	-	-
2	0	100	0.001	44.3718	1.0418
2	1	100	0.001	44.3666	1.0417
2	2	100	0.001	44.1624	1.0289
2	3	100	0.001	44.3050	1.0377
3	0	100	0.001	9.2088	0.6553
3	1	100	0.001	20.6500	2.0045
3	2	100	0.001	3.0628	0.4622
3	3	100	0.001	836.8616	39.3676
4	0	100	0.001	9.5467	0.6553
4	1	100	0.001	29.2026	2.8006
4	2	100	0.001	3.0527	0.4612
4	3	100	0.001	797.7063	52.5631




(a)

Şekil 3. 8 Senaryo 4'te (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının test datası uzayında değişimi




(b)



(c)

Şekil 3. 8 Senaryo 4'te (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının test datası uzayında değişimi (devamı)



(d)

Şekil 3. 8 Senaryo 4'te (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının test datası uzayında değişimi (devamı)

Senaryo 3 ve 4 karşılaştırması aşağıdaki tabloda yapılmıştır. Frekans bölgesi bilgisinin eğitim kümesinde kullanılmasının DVM'nin regresyon yapabilme yeteneğinde etkisi olmadığı görülmüştür.

Çizelge 3. 21 Frekans bölgesi bilgisinin giriş kümesinde kullanılmasının regresyona etkisi (extrapolasyon senaryosu 3-4)

					SENARYO 3		SENARYO 4	
	s	t	c	p	Hata 1	Hata 2	Hata 1	Hata 2
S11M	3	2	100	0.001	0.0071	0.0130	0.0068	0.0126
S11P	0	1	100	0.001	6.6934	0.0517	7.3523	0.0551
S21M	3	2	1000	0.001	0.2902	0.2165	0.2824	0.1940
S21P	3	2	1000	0.001	2.4914	0.2349	2.4021	0.2228


3.2.3.5 Senaryo 5

Bu senaryoda transistörün 1 GHz – 20 GHz frekans aralığı, $V_{DS} = 2V, 8V$ kutuplama gerilimi ve $I_{DS} = 0.1 \text{ mA} - 6 \text{ mA}$ akım aralığı için S parametreleri üretici verilerinden oluşturulan eğitim kümesi kullanılmıştır. Modelin testi için ise $V = 2.5V, 3V, 3.5V, 4V, 5V, 6V$ için mevcut S verisi kullanılarak interpolasyon senaryosu koşulmuştur. Eğitim için 1320, test için 3960 adet S verisi kullanılmıştır. Bu senaryo için sadece akım bölgesi, sadece frekans bölgesi ve son olarak da bölge bilgisi olmadan senaryolar koşulmuştur ancak akıma ve frekansa göre bölge eklemenin DVRM'nin öğrenme


performansında etkili olmadığı görülmüştür. Bu kadar geniş gerilim aralığında (2V-8V) hata oranları yüksek çıkmıştır.

Çizelge 3. 22 Senaryo 5’da bölge bilgilerine göre S parametreleri için DVRM parametreleri ve hata oranları

S11M						
	s	t	C	p	Hata Oranı1	Hata Oranı 2
Çift bölge	3	0	100	0.001	0.0815	0.0622
Akım bölgesi	3	0	1	0.001	0.0636	0.1086
Frekans bölgesi	3	0	1	0.001	0.0639	0.1096
Bölge yok	3	0	1	0.001	0.0639	0.1098
S11P						
	s	t	C	p	Hata Oranı1	Hata Oranı 2
Çift bölge	0	0	100	0.001	9.8493	0.0751
Akım bölgesi	0	0	100	0.001	11.2282	0.0841
Frekans bölgesi	0	0	100	0.001	10.4531	0.0796
Bölge yok	0	0	100	0.001	12.1618	0.0902
S21M						
	s	t	C	p	Hata Oranı1	Hata Oranı 2
Çift bölge	0	1	10	0.001	0.0293	0.0524
Akım bölgesi	0	1	10	0.001	10.5994	0.0735
Frekans bölgesi	0	1	10	0.001	0.5089	0.2422
Bölge yok	0	1	10	0.001	4.7462	NaN
S21M						
	s	t	C	p	Hata Oranı1	Hata Oranı 2
Çift bölge	0	0	100	0.001	2.3207	-
Akım bölgesi	0	0	100	0.001	2.5700	-
Frekans bölgesi	0	0	100	0.001	2.3746	-
Bölge yok	0	0	100	0.001	2.4061	-




(a)




(b)

Şekil 3. 9 Senaryo 5’te (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının test datası uzayında değişimi



(c)




(d)

Şekil 3. 9 Senaryo 5’te (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının test datası uzayında değişimi (devamı)


Çizelge 3. 23 Senaryo 5'te $V_{DS}=2.5V$, $I_{DS}=1mA$ kutuplama koşulunda frekansa bağlı olarak hedef ve tahmini değerlerin karşılaştırması

f	S11M Hedef	S11M Tahmin	S11P Hedef	S11P Tahmin	S21M Hedef	S21M Tahmin	S21P Hedef	S21P Tahmin
1.2	0.7155	0.3862	-76.3	-77	3.215	3.5975	117.4	116
1.5	0.6655	0.3881	-83.3	-84	3.688	3.5848	113.7	116
2.5	0.5512	0.3943	-102.0	-84	4.754	3.5428	104.8	113
4	0.4578	0.3901	-122.0	-115	5.544	3.8807	97.0	96
6	0.4024	0.4026	-140.6	-134	5.961	3.7966	91.1	91
8	0.3871	0.4150	-153.9	-142	6.017	3.7124	87.4	90
10	0.3882	0.4275	-164.2	-159	5.874	3.6283	84.6	93
12	0.4010	0.4264	-172.4	-176	5.552	3.9452	82.2	80
15	0.4247	0.4451	178.9	177	4.936	3.8189	79.3	79
17	0.4427	0.4576	174.5	172	4.526	3.7348	77.6	76
20	0.4751	0.4763	169.5	172	3.946	3.6085	75.4	73




(a)

Şekil 3. 10 Senaryo 5'te $V_{DS}=2.5V$, $I_{DS}=1mA$ kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının frekans ile değişimi




(b)



(c)

Şekil 3. 10 Senaryo 5'te $V_{DS}=2.5V$, $I_{DS}=1mA$ kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının frekans ile değişimi (devamı)



(d)


Şekil 3. 10 Senaryo 5’te $V_{DS}=2.5V$, $I_{DS}=1mA$ kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının frekans ile değişimi (devamı)

3.2.3.6 Senaryo 6


Bu senaryoda transistörün 1 GHz – 20 GHz frekans aralığı, $V_{ds}=1V$ kutuplama gerilimi ve $I_{ds}=0.1mA - 6mA$ akım aralığı için S parametreleri üretici verilerinden oluşturulan eğitim kümesi kullanılmıştır. Modelin testi için ise $V=0.5V, 0.75V, 1.5V, 1.7$ için mevcut S verisi kullanılarak extrapolasyon senaryosu koşulmuştur. Eğitim için 900, test için 3600 adet S verisi kullanılmıştır.

Çizelge 3. 24 Senaryo 5’te S parametreleri için DVM parametreleri ve hata oranları

	s	t	C	p	Hata Oranı1	Hata Oranı 2
S11M	4	2	1	0.001	0.0293	0.0524
S11P	0	2	1000	0.001	10.5994	0.0735
S21M	4	2	10	0.001	0.5089	0.2422
S21P	0	2	1000	0.001	4.7462	NaN




(a)




(b)

Şekil 3. 11 Senaryo 6’da (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının test datası uzayında değişimi



(c)



(d)

Şekil 3. 11 Senaryo 6'da (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının test datası uzayında değişimi (devamı)

Çizelge 3. 25 Senaryo 6’da $V_{DS}=1.7V$, $I_{DS}=2.7mA$ kutuplama koşulunda frekansa bağlı olarak hedef ve ekstrapolasyon tahmini değerlerin karşılaştırması

f	S11M Hedef	S11M Tahmin	S11P Hedef	S11P Tahmin	S21M Hedef	S21M Tahmin	S21P Hedef	S21P Tahmin
1	0.4659	0.5063	175.1	170	1.613	1.6945	51.7	48
1.2	0.4535	0.4994	168.3	164	1.720	1.7639	50.4	47
1.5	0.4453	0.4937	160.4	156	1.844	1.8600	49.0	46
2	0.4399	0.4924	151.2	147	1.983	1.9721	47.1	44
2.5	0.4408	0.4954	144.8	141	2.075	2.0326	45.7	43
3	0.4429	0.4997	140.0	136	2.138	2.0720	44.7	42
4	0.4495	0.5098	133.7	130	2.206	2.0977	43.1	40
5	0.4600	0.5209	129.4	126	2.229	2.0561	41.8	38
6	0.4687	0.5333	126.5	123	2.222	1.9858	40.7	36
8	0.4900	0.5620	122.6	119	2.133	1.7775	38.6	33
10	0.5139	0.5904	119.8	116	1.962	1.5832	36.5	29
12	0.5400	0.6129	117.7	115	1.766	1.4308	34.4	26
15	0.5741	0.6419	115.6	113	1.497	1.2684	31.3	22
17	0.5954	0.6587	114.6	113	1.360	1.1877	29.3	19
20	0.6232	0.6796	113.7	112	1.189	1.0874	26.3	15


3.2.3.7 Senaryo 7

2V-8V geniş gerilim aralığında sonuçlar iyi çıkmadığı için, voltaj; düşük, orta ve yüksek gerilim bölgelerine ayrılmıştır. Bu senaryoda orta gerilim bölgesinde çalışılmıştır.

Transistörün 1 GHz – 20 GHz frekans aralığı, $V_{DS}=3V$ kutuplama gerilimi ve $I_{DS} = 0.1 mA - 6 mA$ akım aralığı için S parametreleri üretici verilerinden oluşturulan eğitim kümesi kullanılmıştır. Modelin testi için ise $V = 2.5V, 3.5V, 4V$ için mevcut S verisi kullanılarak ekstrapolasyon senaryosu kurulmuştur. Eğitim için 660, test için 1960 adet S verisi kullanılmıştır


Çizelge 3. 26 Senaryo 7’de yansıma katsayıları için DVM parametreleri ve hata oranları

	s	t	C	p	Hata Oranı1	Hata Oranı 2
S11M	3	2	1	0.001	0.0261	0.0544
S11P	0	2	1000	0.001	4.0122	0.284
S21M	3	2	1	0.001	0.6948	0.1823
S21P	0	2	1000	0.001	1.1548	inf
S12M	3	2	10	0.001	0.0071	0.0812
S12P	0	2	1000	0.001	0.5563	0.0221
S22M	4	2	1	0.001	0.0268	0.0107
S22P	0	2	1000	0.001	0.06590	0.2636




(a)

Şekil 3. 12 Senaryo 7 için (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazı (e) S12 büyüklüğü (f) S12 fazı (g) S22 büyüklüğü (h) S22 fazının test datası uzayında değişimi




(b)




(c)

Şekil 3. 12 Senaryo 7 için (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazı (e) S12 büyüklüğü (f) S12 fazı (g) S22 büyüklüğü (h) S22 fazının test datası uzayında değişimi (devamı)




(d)




(e)

Şekil 3. 12 Senaryo 7 için (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazı (e) S12 büyüklüğü (f) S12 fazı (g) S22 büyüklüğü (h) S22 fazının test datası uzayında değişimi (devamı)




(f)



(g)

Şekil 3. 12 Senaryo 7 için (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazı (e) S12 büyüklüğü (f) S12 fazı (g) S22 büyüklüğü (h) S22 fazının test datası uzayında değişimi (devamı)



(h)


Şekil 3. 12 Senaryo 7 için (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazı (e) S12 büyüklüğü (f) S12 fazı (g) S22 büyüklüğü (h) S22 fazının test datası uzayında değişimi (devamı)

3.2.3.8 Senaryo 8


Bu senaryoda orta gerilim bölgesinde çalışılmıştır. Transistörün 1 GHz – 20 GHz frekans aralığı, $V_{DS}=6V$ kutuplama gerilimi ve $I_{DS} = 0.1 \text{ mA} - 6 \text{ mA}$ akım aralığı için S parametreleri üretici verilerinden oluşturulan eğitim kümesi kullanılmıştır. Modelin testi için ise $V=5V, 8V$ için mevcut S verisi kullanılarak ekstrapolasyon senaryosu koşulmuştur. Eğitim için 660, test için 1320 adet S verisi kullanılmıştır

Çizelge 3. 27 Senaryo 8’de yansıma katsayıları için DVM parametreleri ve hata oranları

	s	t	C	p	Hata Oranı 1	Hata Oranı 2
S11M	3	2	1	0.001	0.0810	0.1873
S11P	0	0	10000	0.001	7.8995	0.0558
S21M	0	0	10000	0.001	0.6914	0.2174
S21P	0	0	1000	0.001	1.1522	0.1181
S12M	4	0	1	0.001	0.0095	0.1294
S12P	0	0	1000	0.001	2.2073	0.0822
S22M	3	0	1	0.001	0.0656	0.01313
S22P	0	0	1000	0.001	0.8996	0.1799




(a)




(b)

Şekil 3. 13 Senaryo 8 için (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazı (e) S12 büyüklüğü (f) S12 fazı (g) S22 büyüklüğü (h) S22 fazının test datası uzayında değişimi




(c)




(d)

Şekil 3. 13 Senaryo 8 için (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazı (e) S12 büyüklüğü (f) S12 fazı (g) S22 büyüklüğü (h) S22 fazının test datası uzayında değişimi (devamı)




(e)




(f)

Şekil 3. 13 Senaryo 8 için (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazı (e) S12 büyüklüğü (f) S12 fazı (g) S22 büyüklüğü (h) S22 fazının test datası uzayında değişimi (devamı)



(g)




(h)

Şekil 3. 13 Senaryo 8 için (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazı (e) S12 büyüklüğü (f) S12 fazı (g) S22 büyüklüğü (h) S22 fazının test datası uzayında değişimi (devamı)

3.3 Extrapolasyon İçin Optimum DVRM Modeli

Yukarıdaki bölümlerden anlaşılacağı üzere, DVRM'nin geniş frekans bandında ve orta akım bölgesinde extrapolasyon yapmaya muktedir olduğu görülmüştür. Ancak 05V-

8V kutuplama gerilimi çalışma bölgesinde extrapolasyon yapılırken, gerilimi bölgelere bölme ihtiyacı doğmuştur.



Şekil 3. 14 Düşük, orta ve yüksek gerilim bölgelerine ayrılan bir mikrodalga transistörün saçılma parametreleri DVRM modeli

Çizelge 3. 28 Düşük, orta ve yüksek gerilim bölgelerine ayrılmış bir transistörün yansıma katsayıları için DVM parametreleri ve hata oranları

Düşük Gerilim Bölgesi ($0.5V \leq V_{DS} < 2.5V$)						
	s	t	C	p	Hata Oranı1	Hata Oranı 2
S11M	4	2	1	0.001	0.0293	0.0524
S11P	0	2	1000	0.001	10.5994	0.0735
S21M	4	2	10	0.001	0.5089	0.2422
S21P	0	2	1000	0.001	4.7462	NaN
Orta Gerilim Bölgesi ($2.5V \leq V_{DS} < 5V$)						
	s	t	C	p	Hata Oranı1	Hata Oranı 2
S11M	3	2	1	0.001	0.0261	0.0544
S11P	0	2	1000	0.001	4.0122	0.284
S21M	3	2	1	0.001	0.6948	0.1823
S21P	0	2	1000	0.001	1.1548	inf
S12M	3	2	10	0.001	0.0071	0.0812
S12P	0	2	1000	0.001	0.5563	0.0221
S22M	4	2	1	0.001	0.0268	0.0107
S22P	0	2	1000	0.001	0.06590	0.2636


Çizelge 3. 28 Düşük, orta ve yüksek gerilim bölgelerine ayrılmış bir transistörün yansıma katsayıları için DVM parametreleri ve hata oranları (devamı)

Yüksek Gerilim Bölgesi ($5V \leq V_{DS} \leq 8V$)						
	s	t	C	p	Hata Oranı1	Hata Oranı 2
S11M	3	2	1	0.001	0.0810	0.1873
S11P	0	0	10000	0.001	7.8995	0.0558
S21M	0	0	10000	0.001	0.6914	0.2174
S21P	0	0	1000	0.001	1.1522	0.1181
S12M	4	0	1	0.001	0.0095	0.1294
S12P	0	0	1000	0.001	2.2073	0.0822
S22M	3	0	1	0.001	0.0656	0.01313
S22P	0	0	1000	0.001	0.8996	0.1799


3.3.1 Düşük Gerilim Bölgesinde Ekstrapolasyon

Çizelge 3. 29 Düşük gerilim bölgesinde eğitim ve test kümesi bilgileri

Düşük Gerilim Bölgesi ($0.5V \leq V_{DS} < 2.5V$)	
Eğitim Kümesi	Test Test Kümes
$f = 1-20$ GHz	$f = 1-20$ GHz
$I_{DS} = 0.1$ mA – 6 mA	$I_{DS} = 0.1$ mA – 6 mA
$V_{DS} = 1V$	$V_{DS} = 0.5V, 0.75V, 1.5V, 1.7$
900 adet S verisi	3600 adet S verisi




(a)




(b)

Şekil 3. 15 Düşük gerilim bölgesinde $V_{DS}=0.5V$, $I_{DS}=0.1mA$ 3mA ve 6mA kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının frekans ile değişimi




(c)




(d)

Şekil 3. 15 Düşük gerilim bölgesinde $V_{DS}=0.5V$, $I_{DS}=0.1mA$ 3mA ve 6mA kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının frekans ile değişimi (devamı)




(a)




(b)

Şekil 3. 16 Düşük gerilim bölgesinde $V_{DS}=1.7V$, $I_{DS}=0.1mA$ 3mA ve 6mA kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının frekans ile değişimi



(c)




(d)

Şekil 3. 16 Düşük gerilim bölgesinde $V_{DS}=1.7V$, $I_{DS}=0.1mA$ 3mA ve 6mA kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazının frekans ile değişimi (devamı)

3.3.2 Orta Gerilim Bölgesinde Ekstrapolasyon


Çizelge 3. 30 Düşük gerilim bölgesinde eğitim ve test kümesi bilgileri

Orta Gerilim Bölgesi ($2.5V \leq V_{DS} < 5V$)	
Eğitim Kümesi	Test Test Kümes
$f = 1-20$ GHz	$f = 1-20$ GHz
$I_{DS} = 0.1$ mA – 6 mA	$I_{DS} = 0.1$ mA – 6 mA
$V_{DS} = 3V$	$V_{DS} = 2.5V, 3.5V, 4V$
660 adet S verisi	1980 adet S verisi




(a)

Şekil 3. 17 Orta gerilim bölgesinde $V_{DS}=2.5V$, $I_{DS}=0.1mA$, $3mA$ ve $6mA$ kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazı (e) S12 büyüklüğü (f) S12 fazı (g) S22 büyüklüğü (h) S22 fazının frekans ile değişimi




(b)




(c)

Şekil 3. 17 Orta gerilim bölgesinde $V_{DS}=2.5V$, $I_{DS}=0.1mA$, $3mA$ ve $6mA$ kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazı (e) S12 büyüklüğü (f) S12 fazı (g) S22 büyüklüğü (h) S22 fazının frekans ile değişimi (devamı)




(d)




(e)

Şekil 3. 17 Orta gerilim bölgesinde $V_{DS}=2.5V$, $I_{DS}=0.1mA$, $3mA$ ve $6mA$ kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazı (e) S12 büyüklüğü (f) S12 fazı (g) S22 büyüklüğü (h) S22 fazının frekans ile değişimi (devamı)




(f)




(g)

Şekil 3. 17 Orta gerilim bölgesinde $V_{DS}=2.5V$, $I_{DS}=0.1mA$, $3mA$ ve $6mA$ kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazı (e) S12 büyüklüğü (f) S12 fazı (g) S22 büyüklüğü (h) S22 fazının frekans ile değişimi (devamı)




(h)

Şekil 3. 17 Orta gerilim bölgesinde $V_{DS}=2.5V$, $I_{DS}=0.1mA$, $3mA$ ve $6mA$ kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazı (e) S12 büyüklüğü (f) S12 fazı (g) S22 büyüklüğü (h) S22 fazının frekans ile değişimi (devamı)




(a)

Şekil 3. 18 Orta gerilim bölgesinde $V_{DS}=4V$, $I_{DS}=0.1mA$, $3mA$ ve $6mA$ kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazı (e) S12 büyüklüğü (f) S12 fazı (g) S22 büyüklüğü (h) S22 fazının frekans ile değişimi




(b)




(c)

Şekil 3. 18 Orta gerilim bölgesinde $V_{DS}=4V$, $I_{DS}=0.1mA$, $3mA$ ve $6mA$ kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazı (e) S12 büyüklüğü (f) S12 fazı (g) S22 büyüklüğü (h) S22 fazının frekans ile değişimi (devamı)




(d)




(e)

Şekil 3. 18 Orta gerilim bölgesinde $V_{DS}=4V$, $I_{DS}=0.1mA$, $3mA$ ve $6mA$ kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazı (e) S12 büyüklüğü (f) S12 fazı (g) S22 büyüklüğü (h) S22 fazının frekans ile değişimi (devamı)




(f)



(g)

Şekil 3. 18 Orta gerilim bölgesinde $V_{DS}=4V$, $I_{DS}=0.1mA$, $3mA$ ve $6mA$ kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazı (e) S12 büyüklüğü (f) S12 fazı (g) S22 büyüklüğü (h) S22 fazının frekans ile değişimi (devamı)




(h)

Şekil 3. 18 Orta gerilim bölgesinde $V_{DS}=4V$, $I_{DS}=0.1mA$, $3mA$ ve $6mA$ kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazı (e) S12 büyüklüğü (f) S12 fazı (g) S22 büyüklüğü (h) S22 fazının frekans ile değişimi (devamı)


3.3.3 Yüksek Gerilim Bölgesinde Ekstrapolasyon

Çizelge 3. 31 Düşük gerilim bölgesinde eğitim ve test kümesi bilgileri

Yüksek Gerilim Bölgesi ($5V \leq V_{DS} \leq 8V$)	
Eğitim Kümesi	Test Test Kümes
$f= 1-20$ GHz	$f= 1-20$ GHz
$I_{DS} = 0.1$ mA – 6 mA	$I_{DS} = 0.1$ mA – 6 mA
$V_{DS} = 6V$	$V_{DS} = 5V, 8V$
660 adet S verisi	1320 adet S verisi




(a)




(b)

Şekil 3. 19 Yüksek gerilim bölgesinde $V_{DS} = 5V$, $I_{DS} = 0.1mA$, $3mA$ ve $6mA$ kutuplama koşulunda (a) S_{11} büyüklüğü (b) S_{11} fazı (c) S_{21} büyüklüğü (d) S_{21} fazı (e) S_{12} büyüklüğü (f) S_{12} fazı (g) S_{22} büyüklüğü (h) S_{22} fazının frekans ile değişimi




(c)




(d)

Şekil 3. 19 Yüksek gerilim bölgesinde $V_{DS}=5V$, $I_{DS}=0.1mA$, $3mA$ ve $6mA$ kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazı (e) S12 büyüklüğü (f) S12 fazı (g) S22 büyüklüğü (h) S22 fazının frekans ile değişimi (devamı)




(e)




(f)

Şekil 3. 19 Yüksek gerilim bölgesinde $V_{DS}=5V$, $I_{DS}=0.1mA$, $3mA$ ve $6mA$ kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazı (e) S12 büyüklüğü (f) S12 fazı (g) S22 büyüklüğü (h) S22 fazının frekans ile değişimi (devamı)




(g)




(h)

Şekil 3. 19 Yüksek gerilim bölgesinde $V_{DS}=5V$, $I_{DS}=0.1mA$, $3mA$ ve $6mA$ kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazı (e) S12 büyüklüğü (f) S12 fazı (g) S22 büyüklüğü (h) S22 fazının frekans ile değişimi (devamı)




(a)




(b)

Şekil 3. 20 Yüksek gerilim bölgesinde $V_{DS}=8V$, $I_{DS}=0.1mA$, $3mA$ ve $6mA$ kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazı (e) S12 büyüklüğü (f) S12 fazı (g) S22 büyüklüğü (h) S22 fazının frekans ile değişimi




(c)




(d)

Şekil 3. 20 Yüksek gerilim bölgesinde $V_{DS}=8V$, $I_{DS}=0.1mA$, $3mA$ ve $6mA$ kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazı (e) S12 büyüklüğü (f) S12 fazı (g) S22 büyüklüğü (h) S22 fazının frekans ile değişimi (devamı)




(e)




(f)

Şekil 3. 20 Yüksek gerilim bölgesinde $V_{DS}=8V$, $I_{DS}=0.1mA$, $3mA$ ve $6mA$ kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazı (e) S12 büyüklüğü (f) S12 fazı (g) S22 büyüklüğü (h) S22 fazının frekans ile değişimi (devamı)



(g)



(h)

Şekil 3. 20 Yüksek gerilim bölgesinde $V_{DS} = 8\text{V}$, $I_{DS} = 0.1\text{mA}$, 3mA ve 6mA kutuplama koşulunda (a) S11 büyüklüğü (b) S11 fazı (c) S21 büyüklüğü (d) S21 fazı (e) S12 büyüklüğü (f) S12 fazı (g) S22 büyüklüğü (h) S22 fazının frekans ile değişimi (devamı)

SONUÇ VE ÖNERİLER

Elektronik endüstrisindeki üretilebilir tasarım gereksinimi ve kısa pazarlama süresi talebi, bilgisayar destekli tasarım metotlarını gerekli kılmaktadır. Yüksek frekanslarda bilgisayar-destekli tasarım için modelleme halen büyük zorluk olarak görülmektedir [28],[29].

Günümüzde modellemeden anlaşılan, gerek eleman gerekse sistem seviyesinde, çalışma domenini mümkün en geniş kapsamlı şekilde içeren az sayıda yüksek doğruluklu veri ile mümkün en yüksek doğruluğa sahip modeller oluşturabilmektir.

Bu tez çalışmasında Destek Vektör Makineleri' ni mikrodalga teori ve tekniğine uygulamak amaçlanmıştır ve bu amaç doğrultusunda mikrodalga transistörünün DVRM ile analizi gerçekleştirilmiştir. Bu tezde yer alan DVM uygulamalarında, ikinci bölümde yer alan matematiksel ifadeler kullanılarak hazırlanmış bir DVM araç-kutusu kullanılmıştır.

Bu çalışmada yer alan DVM analiz modellerinin eğitim ve test verilerinin oluşturulmasında üretici firmanın katalog değerlerinden yararlanılmıştır. Eğitici öğrenme, öğrenme makinesine girişlerin ve ilgili çıkışların yer aldığı eğitim kümesi verilmesi ile gerçekleştirilmiştir. DVM' in eğitimi gerçekleştirildikten sonra test aşamasında hedef değerler ile tahmin edilen değerler karşılaştırılmıştır. Modelin hata analizi gerçekleştirilip, yüksek doğruluk oranı elde etmek için parametrelere uygun değerler verilmiştir ve DVM' in öğrenme performansı gözlemlenmiştir.

DVM analiz modeliyle bir mikrodalga transistörünün işaret parametreleri başarılı bir şekilde elde edilmiştir. Grafiklerden ve doğruluk oranlarından anlaşılaacağı üzere yüksek doğruluğa sahip modeller elde edilmiştir. Eğitim kümeleri yüzlerce veriden oluşmasına

rağmen DVM' in seyreklik özelliğinden yararlanılarak daha az sayıda destek vektörü ile analiz yapılmıştır. Çözümün eğitim verilerinin alt kümesi ile elde edilmesi hesaplamada büyük avantaj sağlamaktadır. DVM' nin genelleme yeteneğinden yararlanılarak eğitim kümesinde yer almayan girişler için de çıkışlar elde edilmiştir.

Giriş kümesinde akım ve frekans bölgesi bilgisinin eklemenin DVRM'de etkili olmadığı görülmüştür. Transistörün kutuplama gerilimi çok geniş range olduğundan ve S parametreleri gerilim ile değiştiğinden, gerilimi bölgelere bölme ihtiyacı doğmuştur. Düşük orta ve yüksek gerilim bölgelerine ayrılarak optimum giriş kümesi elde edilmiştir. Böylece ekstrapolasyon sonuçlarında başarı oranının arttığı gözlemlenmiştir.

Daha dar gerilim bölgelerinde, geniş gerilim aralığına nispeten daha başarılı olduğu görülmüştür.

İnterpolasyon senaryolarında daha yüksek doğruluk oranları elde edilmiştir. Ekstrapolasyon senaryolarında giriş kümesinde gerilim aralığı daraldıkça başarı oranı artmıştır.

İşaret parametrelerinin açıları için çalışılırken, DVM mimari parametrelerinin seçiminde destek vektör sınıflandırıcısı kullanıldığında hızlı ve regresyon kadar yüksek doğruluk oranlarına sahip modeller elde edilmiştir.

Sonuç olarak optimum data kullanılarak, yüksek doğruluğa sahip modeller oluşturulmuştur ve bir mikrodalga transistörünün analizi gerçekleştirilerek işaret parametreleri giriş değişkenlerinin fonksiyonu olarak çıkışta elde edilebilmektedir.

KAYNAKLAR

- [1] Amasyalı, M.F., (2006). Makine Öğrenmesine Giriş, <https://www.ce.yildiz.edu.tr/personal/mfatih/file/476/Yapay+Zeka>, 21 Ekim 2017
- [2] Türker Tokan, N., (2009). Destek Vektör Makineleri'nin Mikrodalga Teori ve Tekniğindeki Uygulamaları, Doktora Tezi, YTÜ Fen Bilimleri Enstitüsü
- [3] Vapnik, V., (1995). The Nature of Statistical Learning Theory, Springer-Verlag, New York.
- [4] Chapelle, O., Haffner, P. ve Vapnik, V., (1999). "Support vector machines for histogram-based image classification", IEEE Transactions on Neural Networks, 10(5):1055-1064.
- [5] Kim, D., Lee, H. ve Cho, S., (2008). "Response modeling with support vector regression", Expert Systems with Applications, 34:1102–1108.
- [6] Ayestarán, R.G. ve Las-Heras, F., (2005). "Support Vector Regression for the Design of Array Antennas", IEEE Antennas and Wireless Propagation Letters, 4: 414-416.
- [7] Ayestarán, R.G., Campillo, M. F. ve Las-Heras, F., (2007). "Multiple Support Vector Regression for Antenna Array Characterization and Synthesis", IEEE Transactions on Antennas and Propagation, 55(9): 2495- 2501.
- [8] Ayestarán, R.G., Las-Heras, F. ve Herrán, L.F., (2006). "High-Accuracy Neural-Network-Based Array Synthesis Including Element Coupling", IEEE Antennas and Wireless Propagation Letters, 5: 45-48.
- [9] Ramón, M., Xu, N. ve Christodoulou, C.G., (2005). "Beamforming Using Support Vector Machines", IEEE Antennas and Wireless Propagation Letters, 4: 439-442
- [10] Kruif, J. ve Vries, T., (2001). "On using a Support Vector Machine in Learning Feed-Forward Control", 2001 IEEE/ASME International Conference on Advanced Intelligent Mechatronics Proceedings, 8-12 July 2001, Como, Italy.
- [11] Santamaria, I., (2003). "Design of linear-phase FIR filters using support vector regression approach", Electronics Letters, 39(19).

- [12] Ganapathiraju, A., Hamaker, J.E. ve Picone, J., (2004). "Applications of Support Vector Machines to Speech Recognition", IEEE Trans. on Signal Processing, 52(8): 2348-2356.
- [13] Rojo-Álvarez, J.L., Martínez-Ramón, M., Figueiras-Vidal, A.R., García-Armada, A. ve Artés-Rodríguez, A., (2003). "A Robust Support Vector Algorithm for Nonparametric Spectral Analysis", IEEE Signal Processing Letters, 10(11):320-323.
- [14] Rojo-Álvarez, J.L., Camps-Valls, G., Martínez-Ramón, M., Soria-Olivas, E., Navia-Vázquez, A. ve Figueiras-Vidal, A.R., (2005). "Support vector machines framework for linear signal processing", Signal Processing, 85(12):2316-2326.
- [15] Cristianini, N. ve Shawe-Taylor, J., (2000). An Introduction to Support Vector Machines (and Other Kernel-Based Learning Methods), Cambridge University Press.
- [16] Burges, J.C., "A Tutorial on Support Vector Machines for Pattern Recognition", Data Mining and Knowledge Discovery 2, 121-167.
- [17] Osuna, E.E., Freund R. ve Girosi F., (1997). "Support Vector Machines: Training and Applications", Technical Report A.I Memo No. 1602, C.B.C.L. Paper No. 144, March 1997, MIT Artificial Intelligence Laboratory.
- [18] Özkaya, A., Kaya, M. E. ve Gürgen, F. (2005). "Destek Vektör Makinelerini Kullanarak Aritmi Sınıflandırması" BİYOMUT, National Symposium on Biomedical Engineering, İstanbul
- [19] Keerthi, S. Ve Lin C. J., (2003). "Asymptotic Behaviors of Support Vector Machines with Gaussian Kernel", Neural Computation, 15, 1667–1689.
- [20] Drucker, H., Burges, C., Kaufman, L., Smola, A. ve Vapnik, V.N., (1996). "Support Vector Regression Machines", In Advances in Neural Information Processing Systems, 9:155.
- [21] Güneş, F., Gürgen, F. ve Torpi, H., (1996). "Signal-Noise Neural Network Model for Active Microwave Devices", IEE Proc.- Circuits, Devices Syst., 143(1):1-8.
- [22] Güneş, F., Torpi, H. ve Gürgen, F., (1998). "Multidimensional Signal-Noise Neural Network Model", IEE Proc.- Circuits, Devices Syst., 145(2):111-117.
- [23] Giannini, F., Leuzzi, G., Orenco, G. ve Albertini, M., (2002). "Small-Signal and Large-Signal Modeling of Active Devices using CAD-Optimized Neural Networks", Int. J. RF Microwave Computer-Aided Eng., 12(1):71-78.
- [24] Marinković, Z.D. ve Marković, V.V., (2005). "Temperature-Dependent Models of Low-Noise Microwave Transistors Based on Neural Networks", Int. J. RF Microwave Computer-Aided Eng., 15(6):567-577.
- [25] Güneş, F. ve Tepe, C., (2002). "Gain-Bandwidth Limitations of Microwave Transistor", Int. J. RF Microwave Computer-Aided Eng., 12(6):483-495.
- [26] Cengiz, Y., Göksu, H. ve Güneş, F., (2006). "Design of a Broadband Microwave Amplifier Using Neural Performance Data Sheets and Very Fast Simulated Reannealing", Lecture Notes in Computer Science, 3973:815-820.

- [27] Güneş, F., N. T. Tokan. ve Gürgen, F., (2007). “Signal-noise support vector model of a microwave transistor,” Int. J. RF and Microwave CAE, 17:404–415,
- [28] Zhang, Q.J. ve Gupta, K.C., (2000). “Neural Networks for RF and Microwave Design”, Artech House Publishers
- [29] Steer, M.B., Bandler, J.W. ve Snowden, C.M., (2002). “Computer-Aided Design of RF and Microwave Circuits and Systems”, IEEE Trans. Microwave Theory Tech., 50:996–1005.



ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Şerife YÜREKLİ
Doğum Tarihi ve Yeri : 16.08.1988 / Kastamonu
Yabancı Dili : İngilizce
E-posta : serifeakgoz@gmail.com

ÖĞRENİM DURUMU

Derece	Alan	Okul/Üniversite	Mezuniyet Yılı
Lisans	Elektronik ve Haberleşme Müh	YTÜ	2009
Lise	Fen Bilimleri	Pertevniyal Lisesi	2005

İŞ TECRÜBESİ

Yıl	Firma/Kurum	Görevi
2011	THY A.0.	İş Analisti /Proje Yönetici
2010	Sentim Bilişim	Yazılım Uzmanı