

YILDIZ TEKNİK ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

**DESTEK VEKTÖR MAKİNELERİNİN MİKRODALGA
TEORİ VE TEKNİĞİNDEKİ UYGULAMALARI**

Elektronik ve Haberleşme Yük. Müh. Nurhan TÜRKER TOKAN

FBE Elektronik ve Haberleşme Mühendisliği Anabilim Dalı Haberleşme Programında

Hazırlanan

DOKTORA TEZİ

Tez danışmanı : Prof. Dr. Filiz GÜNEŞ (YTÜ)

Jüri üyeleri : Prof. Dr. Fikret GÜRGEN (BÜ)

: Prof. Dr. Sedef KENT (İTÜ)

: Doç. Dr. Ahmet Serdar TÜRK (YTÜ)

: Yrd. Doç. Dr. Hamit TORPİ (YTÜ)

İSTANBUL, 2009

İÇİNDEKİLER

	Sayfa
SİMGE LİSTESİ	v
KISALTIMA LİSTESİ	vii
ŞEKİL LİSTESİ	viii
ÇİZELGE LİSTESİ	x
ÖNSÖZ.....	xi
ÖZET	xii
ABSTRACT	xiii
1. GİRİŞ.....	14
2. DESTEK VEKTÖR REGRESYON MAKİNELERİ.....	19
2.1 Öznitelik Uzayında Doğrusal Öğrenen Makineler	19
2.2 Birincil Optimizasyon Problem Formülasyonu	20
2.3 Lagrange Fonksiyonu ve Çift Gösterimi	21
3. BİR MİKRODALGA TRANSİSTÖRÜN İŞARET-GÜRÜLTÜ DESTEK VEKTÖR MODELİ.....	25
3.1 Bir Mikrodalga Transistörün DVM Modeli	26
3.1.1 Bir Mikrodalga Transistörün Kara-Kutu Gösterimi	26
3.1.2 Eğitim ve Test Verisi	27
3.2 Uygulama Örneği: ATF-551M4' in İşaret-Gürültü Modeli	28
3.2.1 Modelin Eğitim ve Test Verisi	28
3.2.2 Transistör Modelinin Hata Analizi	28
3.2.3 ATF-551M4'ün İşaret-Gürültü Parametrelerinin DVRM Modeli.....	29
3.2.4 ATF-551M4'ün İşaret-Gürültü Parametrelerinin YSA Modeli.....	29
3.2.5 DVRM ve YSA Model Sonuçları.....	30
3.3 Sonuçlar	35
4. MİKROŞERİT İLETİM HATLARININ DESTEK VEKTÖR TASARIMI.....	36
4.1 Problemin Tanımı	37
4.1.1 Eğitim ve Test Verilerinin Oluşturulması	38
4.1.2 Analiz.....	39
4.1.3 Sentez.....	40
4.2 Destek Vektör Regresyonu	40

4.3	Sayısal Sonuçlar.....	42
4.3.1	Mikroşerit Hatların DVR Analizi	42
4.3.1.1	Mikroşerit İletim Hattı DVR Analiz Modeli ile Gerçeklenen Örnekler:.....	46
4.3.2	Mikroşerit Hatların Ters Modelleme ile Sentezi	47
4.3.2.1	Mikroşerit İletim Hattı DVR Sentez Modeli ile Gerçeklenen Örnekler:.....	48
4.4	Sonuç	50
5.	MİKROŞERİT ANTENLERİN ÖLÇÜM SONUÇLARINA DAYANDIRILMIŞ DESTEK VEKTÖR KARAKTERİZASYONU.....	51
5.1	Mikroşerit Antenin Tasarım Problemi.....	52
5.1.1	Dikdörtgen Mikroşerit Antenler	52
5.1.2	Rezonans Frekansı, Band Genişliği ve Giriş Empedansı Kara-Kutu Modelleri ...	52
5.1.3	Rezonans Frekansı, Band Genişliği ve Giriş Empedansı DVR ve YSA Sonuçları	54
5.2	Sonuç	55
6.	RF/MİKRODALGA DÜZLEMSEL İLETİM HATLARININ BİLGİ-TABANLI DESTEK VEKTÖR SENTEZİ	56
6.1	RF/Mikrodalga Düzlemsel İletim Hatlarının Analiz ve Sentez Tanımı	57
6.1.1	RF/Mikrodalga Düzlemsel İletim Hatlarının Bilgi-Tabanlı Destek Vektör Sentezi	59
6.2	Uygulamalar	59
6.2.1	Kara-Kutu Modellerinin Hata Analizi	59
6.2.2	Sağlam Analiz Formülasyonuna Dayandırılmış Sentez	59
6.2.3	Kaba ve Hassas Modellere Dayandırılmış Sentez	64
6.3	Sonuç	69
7.	MİKRODALGA TEKNOLOJİSİNDE UZMAN REGRESYON SİSTEMLERİNİN UZLAŞMASI	70
7.1	Regresyon Uzlaşması.....	71
7.2	k -NN ve LS Algoritmaları	72
7.2.1	k -NN Algoritması	72
7.2.1.1	Mesafe Ölçütü.....	73
7.2.1.2	k -NN Tahmini	73
7.2.1.3	Ağırlıklı Mesafe.....	74
7.2.2	LS Algoritması.....	76
7.3	Uygulama Örneği.....	78
7.4	Sonuç	83
8.	SONUÇLAR.....	84
	KAYNAKLAR.....	86
	EKLER	90
	Ek 1 ATF-551M4 Mikrodalga Transistörünün Üretici Verileri	91
	ÖZGEÇMİŞ.....	101

SİMGE LİSTESİ

b	Bias
C	Düzenleştirme parametresi
D	Geometri vektörü
E	Karesel hata
e_i	Toplam karesel hata
F	Öznitelik uzayı
F_{\min}	Gürültü kalitesi
f_r	Rezonans Frekansı
\mathcal{G}	Geometri vektörü
H	Dielektrik taban maddesinin kalınlığı
H_e	Efektif kalınlık
H_1	Ekranlama kalınlığı
$K(k)$	Birinci tip tam eliptik integral
L	Şerit uzunluğu
L	Genel kayıp fonksiyonu
n	Toplam test verisi sayısı
N	Öznitelik uzayının boyutu
P	Bir örnek noktası
p_i	N - Boyutlu örnek verisi
q	Dolgu faktörü
R_{in}	Giriş empedansı
R_n	Gürültü direnci
S_{11}	Giriş portu yansıtma katsayısı
S_{12}	Geri gerilim kazancı
S_{21}	İleri gerilim kazancı
S_{22}	Çıkış portu yansıtma katsayısı
T	Şerit kalınlığı
$\tan \delta$	Kayıp tanjantı
w	Ağırlık vektörü
W	Şerit genişliği
W_e	Efektif şerit kalınlığı

$W(x, p_i)$	Ağırlık ölçütü
\mathbf{x}	Giriş uzayı
x	Sorgu noktası
y_i	i ' inci verinin hedef değeri
Z_0	Karakteristik empedans
ϕ	Eşleme vektörü
α_i	i ' inci verinin Lagrange katsayısı
\mathcal{E}	Duyarsız kayıp fonksiyonunu
ξ_i	Esnek değişken
σ	Gauss yayılma parametresi
\mathcal{E}_{eff}	Efektif dielektrik sabiti
\mathcal{E}	Dielektrik vektörü
\mathcal{E}_r	Dielektrik sabiti.
\mathcal{E}_{eff}	Efektif dielektrik sabiti
λ	Uyarlamalı adım boyutu
τ	Uyarlama parametresi
Γ_{opt}	Çıkış yansıtma katsayısı

KISALTMA LİSTESİ

ARM	Ampirik Risk Minimizasyonu
BG	Bant Geniřlięi
CPU	Central Processing Unit
KA	ok Katmanlı Algılayıcı
DV	Destek Vektörü
DVM	Destek Vektör Makineleri
DVR	Destek Vektör Regresyonu
DVRM	Destek Vektör Regresyon Makineleri
EDDK	Eřdüzlemlı Dalga Kılavuzu
EM	Elektromagnetik
GHz	Gigahertz
KKT	Karush-Kuhn-Tucker
<i>k</i> -NN	<i>k</i> - En Yakın Komřu
LS	En Kçük Kareler
MB	Megabyte
MMIC	Monolithic Microwave Integrated Circuit
<i>N</i> -	Grlt Parametresi
RAM	Random Access Memory
RF	Radyo Frekansları
<i>S</i> -	İřaret Parametresi
YRM	Yapısal Risk Minimizasyonu
YSA	Yapay Sinir Aęları

ŞEKİL LİSTESİ

Şekil 3.1 Bir mikrodalga transistörün işaret-gürültü DVRM modeli.....	27
Şekil 3.2 $V_{DS}=2.7V$, $I_{DS}=10mA$ kutuplama koşulunda (a) S_{11} ve S_{22} ; (b) S_{12} ve S_{21} parametrelerinin frekans ile değişimi.....	30
Şekil 3.3 $V_{DS}=2.7V$, $I_{DS}=10mA$ kutuplama koşulunda (a) F_{min} ; (b) R_n ; (c) Γ_{opt} 'un büyüklüğünün ve açısının frekans ile değişimi.....	31
Şekil 3.4 $V_{DS}=2.7V$, $I_{DS}=15mA$ kutuplama koşulunda (a) S_{11} ve S_{22} ; (b) S_{12} ve S_{21} parametrelerinin frekans ile değişimi.....	31
Şekil 3.5 $V_{DS}=2.7V$, $I_{DS}=15m$ kutuplama koşulunda (a) F_{min} ; (b) R_n ; (c) Γ_{opt} 'un büyüklüğünün ve açısının frekans ile değişimi.....	32
Şekil 3.6 $V_{DS}=2.7V$, $I_{DS}=20mA$ kutuplama koşulunda (a) S_{11} ve S_{22} ; (b) S_{12} ve S_{21} parametrelerinin frekans ile değişimi.....	33
Şekil 3.7 $V_{DS}=2.7V$, $I_{DS}=20mA$ kutuplama koşulunda (a) F_{min} ; (b) R_n ; (c) Γ_{opt} 'un büyüklüğünün ve açısının frekans ile değişimi.....	34
Şekil 4.1 (a) Mikroşerit iletim hattı (\mathcal{M}); (b) İletim hattı eşdeğeri (\mathcal{T}).....	37
Şekil 4.2 Mikroşerit iletim hatlarının (a) Analiz ($\mathcal{A} : \mathcal{M}(\mathcal{R}^5) \rightarrow \mathcal{T}(\mathcal{R}^2)$); (b) Sentez ($\mathcal{S} : \mathcal{T}(\mathcal{R}^2) \rightarrow \mathcal{M}(\mathcal{R}^5)$) kara-kutu modeli.....	38
Şekil 4.3 Mikroşerit hat (a) karakteristik empedansı; (b) efektif dielektrik sabiti için ϵ parametresi ile DV sayısı ve doğruluğunun değişimi.....	44
Şekil 4.4 Mikroşerit hat (a) karakteristik empedansı; (b) efektif dielektrik sabiti için ϵ parametresi ile DV sayısı ve hesaplama süresinin değişimi.....	45
Şekil 4.5 (a) Karakteristik empedansın; (b) Efektif dielektrik sabitinin şerit genişliği ile değişimi.....	47
Şekil 4.6 DVR modellemesinde çeşitli adaptasyon parametreleri için hatanın döngü sayısı ile değişimi.....	48
Şekil 4.7 Şerit genişliğinin karakteristik empedans ile değişimi.....	49
Şekil 4.8 Farklı kalınlıklarda (a) izotropik; (b) anizotropik dielektrik maddeye sahip mikroşerit hatların şerit genişliğinin karakteristik empedans ile değişimi.....	50
Şekil 5.1 Dikdörtgen mikroşerit anten.....	52
Şekil 5.2 Giriş empedansı ve bant genişliği hesaplamasında kullanılan kara-kutu modeli.....	53
Şekil 5.3 Rezonans frekansı hesaplamasında kullanılan kara-kutu modeli.....	53

Şekil 6.1 En yaygın kullanılan RF/Mikrodalga düzlemsel iletim hatlarının genel geometrik yapısı.....	58
Şekil 6.2 (a) Analiz; (b) Sentez kara-kutu modeli.....	58
Şekil 6.3 DVRM sentez modelinde (a) Doğruluk ve destek vektörü sayısının; (b) Eğitim süresi ve destek vektörü sayısının ϵ parametresi ile değişimi.....	61
Şekil 6.4 Sağlam analitik formülleri kullanan bilgi-tabanlı DVRM yaklaşımı.....	62
Şekil 6.5 (a) $H/S=5$, $H_1/S=5$; (b) $H/S=7$, $H_1/S=10$ için W/S 'in karakteristik empedans ile değişimi.....	64
Şekil 6.6 Kaba ve hassas veri üretici kullanan bilgi-tabanlı DVRM yaklaşımı.....	65
Şekil 6.7 EM Simülatör ve hassas DVRM (a) eğitim verisi; (b) test verisi ile test sonuçları. .	67
Şekil 6.8 Hassas sentez verisi ile eğitilmiş DVRM sonuçlarının (a) $H = 0.5$ mm; (b) $H = 2$ mm; (c) $H = 5$ mm için EM Simülatör sonuçları ile karşılaştırılması.	68
Şekil 7.1 Regresyon uzlaşması blok diyagramı.....	72
Şekil 7.2 k -NN regresyonunun iletken sırtlı üstü ekranlanmış EDDK'nın sentezine uygulanması.	75
Şekil 7.3 LS regresyonunun iletken sırtlı üstü ekranlanmış EDDK' nun sentezine uygulanması.	77
Şekil 7.4 Alumina ($\epsilon_r = 9.8$) dielektrik maddesi ve $H/S=5$, $H_1/S=5$ için W/S 'in Z_0 ile değişimi.....	79
Şekil 7.5 Silikon ($\epsilon_r = 11.8$) dielektrik maddesi ve $H/S=7$, $H_1/S=10$ için W/S 'in Z_0 ile değişimi.....	79
Şekil 7.6 Galyum arsenit ($\epsilon_r = 12.9$) dielektrik maddesi ve $H/S=5$, $H_1/S=5$ için W/S 'in Z_0 ile değişimi.....	80
Şekil 7.7 Yaygın kullanılan dielektrik maddelerin $H/S=5$, $H_1/S=5$ için “Ortalama” uzlaşım metodu sonuçları ile hedef değerlerinin karşılaştırılması.	81
Şekil 7.8 Yaygın kullanılan dielektrik maddelerin $H/S=5$, $H_1/S=5$ için “Minimum” uzlaşım metodu sonuçları ile hedef değerlerinin karşılaştırılması.	82
Şekil 7.9 Yaygın kullanılan dielektrik maddelerin $H/S=5$, $H_1/S=5$ için “Maksimum” uzlaşım metodu sonuçları ile hedef değerlerinin karşılaştırılması.	82
Şekil 7.10 Yaygın kullanılan dielektrik maddelerin $H/S=5$, $H_1/S=5$ için “Ortanca” uzlaşım metodu sonuçları ile hedef değerlerinin karşılaştırılması.	83

ÇİZELGE LİSTESİ

Çizelge 3.1 İşaret-gürültü fonksiyonlarının eğitiminde kullanılan destek vektör sayısı.	29
Çizelge 3.2 ATF551M4'ün hata analizi.	34
Çizelge 3.3 ATF551M4'ün işaret-gürültü DVRM ve YSA modellerinin zaman analizi.....	35
Çizelge 4.1 DVR'nin Z_o ve ϵ_{eff} için performans parametreleri.....	43
Çizelge 4.2 YSA ve DVR modellerinin doğruluğu.	45
Çizelge 4.3 YSA ve DVR modellerinin zaman analizi.	46
Çizelge 4.4 Sabit ve uyarlanabilir adım boyutunun performanslarının karşılaştırılması.	48
Çizelge 5.1 R_{in} , BG ve f_r fonksiyonlarının test doğruluk oranları.....	54
Çizelge 5.2 f_r fonksiyonunun regresyon zaman analizi.	54
Çizelge 5.3 Dikdörtgen mikroşerit antenin giriş empedansı DVR sonucunun hedef değerleri, YSA sonucu ve diğer teorik yöntemlerle karşılaştırılması.	54
Çizelge 5.4 Dikdörtgen mikroşerit antenin bant genişliği DVR sonucunun hedef değerleri, YSA sonucu ve diğer teorik yöntemlerle karşılaştırılması.	55
Çizelge 5.5 Dikdörtgen mikroşerit antenin rezonans frekansı DVR sonucunun hedef değerleri, YSA sonucu ve diğer teorik yöntemlerle karşılaştırılması.	55
Çizelge 6.1 İletken sırtlı üstü ekranlanmış EDDK sentez DVRM modeli için tipik değerler..	62
Çizelge 6.2 Sentez YSA modellerinin sonuçları.	63
Çizelge 6.3 DVRM değişkenlerinin değer aralıkları.	65
Çizelge 6.4 Kaba sentez veri kümesi ile eğitilen DVRM modeli için ϵ parametresine bağlı olarak DV sayısı ve doğruluk değişimi.....	65
Çizelge 6.5 Hassas sentez DV'leri ile eğitilen DVRM modelin eğitim ve testteki doğruluğu.	66
Çizelge 7.1 LS polinom katsayıları.	78
Çizelge 7.2 Regresyon modellerinin test doğrulukları.	81
Çizelge 7.3 Uzlaşım metotlarının doğrulukları.	81

ÖNSÖZ

Bu tez çalışmasında, son on yılda Yapay Sinir Ağları (YSA)' na rakip olarak literatüre tanıtılan Destek Vektör Makineleri (DVM)'nin mikrodalga teori ve tekniğindeki uygulamalarına öncülük etmek amaçlanmıştır. Bu amaçla DVM temel mikrodalga problemlerine uyarlanmış ve destek vektör regresyon makinelerinin performansı Yapay Sinir Ağları ile karşılaştırılarak üstünlükleri belirtilmiştir.

Tezim süresince tecrübesini benimle paylaşmaya hazır bir danışman, moral aşılayan destekleyen bir psikolog, beni çırak gibi yetiştiren bir usta ve akademik kişiliğiyle benim için model olan değerli hocam Prof. Dr. Filiz GÜNEŞ'e en samimi teşekkürlerimi sunarım. Tezin konusunun ortaya çıkmasında ve hazırlanmasında, orijinal fikirleri ve konuya hâkim bakış tarzı ile yönlendirmede bulunan sayın hocam Prof. Dr. Fikret GÜRGEN' e teşekkürü bir borç bilirim. Ayrıca, manevi desteğini hiçbir zaman benden esirgemeyen hayat arkadaşım Arş. Gör. Fikret TOKAN'a, anne ve babalarım, sevgili kardeşim Nurdan TÜRKER'e, canım arkadaşım Arş. Gör. Sultan ALDIRMAZ'a ve moral kaynağım, biricik oğlum Emre' me sonsuz teşekkürler ederim.

Tez konumuyla ilgili projemizi destekleyen Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK)'na teşekkür ederim.

Çalışmamın bu konu üzerinde çalışacak araştırmacılara faydalı olması dileğiyle.

Nisan 2009

Nurhan Türker Tokan

DESTEK VEKTÖR MAKİNELERİNİN MİKRODALGA TEORİ VE TEKNİĞİNDEKİ UYGULAMALARI

Elektronik endüstrisindeki üretilebilir tasarım gereksinimi ve kısa pazarlama süresi talebi, artan devre karmaşıklığı ve frekans ile birleşince tasarım aşamasında güçlü bilgisayar destekli tasarım metodolojilerini gerekli kılmaktadır. Son on yılda Destek Vektör Makineleri (DVM) diğer klasik optimizasyon tekniklerine rakip hızlı ve yüksek doğruluğa sahip öğrenen makineler olarak sınıflandırma ve regresyon problemlerine başarıyla uygulanmaktadır. Bu tez çalışmasında, DVM' nin mikrodalga teori ve tekniğindeki uygulamalarına öncülük etmek amaçlanmıştır. Bu amaçla DVM çeşitli aktif/pasif mikrodalga cihazların analiz ve sentez modeline uyarlanmış ve Destek Vektör Regresyon Makineleri (DVRM)'nin üstünlükleri Yapay Sinir Ağları (YSA) ile karşılaştırılarak belirtilmiştir. Bu tezdeki DVRM uygulamaları kısaca şu şekilde özetlenebilir: (i) Bir mikrodalga transistörün küçük-ışaret ve gürültü davranışlarının modellenmesi yapılmıştır. (ii) Mikroşerit iletim hatlarının analiz ve sentezi, analiz DVRM/YSA kara-kutusunun iki yönlü kullanılması ile gerçekleştirilmiştir. (iii) Cihaz ölçüm verilerinin DVRM formülasyonuna tipik bir örnek olarak, mikroşerit antenlerin ölçüm verisinin destek vektör karakterizasyonu gerçekleştirilmiştir. (iv) Kaba modeller kadar hızlı, hassas modeller kadar doğru çalışan, "Bilgi-Tabanlı" destek vektör makineleri tasarlanmış ve RF/Mikrodalga düzlemsel iletim hatlarının sentezine uygulanmıştır. (v) "Uzman Regresyon Sistemlerinin Uzlaşması" tasarlanmış ve hızlı ve verimli bir sistem olarak mikrodalga teknolojisine uygulanmıştır.

Anahtar Kelimeler: Destek vektör makineleri, destek vektör regresyonu, mikrodalga transistör, mikroşerit iletim hattı, mikroşerit anten, regresyon uzlaşması.

THE APPLICATIONS OF SUPPORT VECTOR MACHINES IN MICROWAVE THEORY AND TECHNIQUE

The drive in the electronics industry for manufacturability driven design and time to market, coupled with ever-increasing circuit complexities and operating frequencies, demands powerful computer-aided design (CAD) methodologies. Within the last decade, Support Vector Machines (SVM) have emerged as fast and highly accurate nonlinear learning machines that can be interactively used in a wide range of classification and regression problems, resulting in its improved generalization performance over other classical optimization techniques. The motivation of this thesis is to be one of the pioneering works in SVM applications into the microwave theory and technique. Therefore in this thesis, SVM is adopted to the modeling, analysis and synthesis of the various active/passive microwave devices and the superiorities of Support Vector Regression Machines (SVRM) are determined comparable with the similar properties of Artificial Neural Networks (ANN). If briefly mentioned, the SVRM applications in this thesis can be ordered as follows: (i) Modeling of the small-signal and noise behaviors of a microwave transistor; (ii) The analysis and synthesis of the microstrip lines using the analysis SVRM/ANN black-box bidirectionally. (iii) As a typical example for SVRM formulation of the device measurement data, the support vector characterization of the measurement data of the microstrip antennas is realized. (iv) The “Knowledge-based” SVM which is as fast as coarse models and as accurate as fine models is designed and is applied into the synthesis of RF/Microwave planar transmission lines. (v) “The Consensual of Expert Regressor Systems” is designed and applied into microwave as a fast and efficient system.

Keywords: Support vector machines, support vector regression, microwave transistor, microstrip transmission line, microstrip antenna, consensual of regression.

1. GİRİŞ

Ampirik veri modelleme problemi birçok mühendislik uygulamasında büyük öneme sahiptir. Ampirik veri modellemesinde sistemin modelini inşaa etmekte “elemanterden bütüne ulaşma” işlemi kullanılır. Bu yolla henüz gözlemlenmemiş sistem cevaplarını elde etmek amaçlanmaktadır. Sonuç olarak, gözlemlerin kalitesi ve sayısı, ampirik veri-tabanlı modelin performansını tayin eden faktörlerin başında gelir. Gözleme ile örnekleme sonucunda sonlu sayıda veri elde edilir ve bu örnekleme işlemi genel olarak homojen yapıda değildir ve yüksek boyuta sahip problemler için giriş uzayında düşük yoğunluklu bir veri dağılımı oluşturur.

Elektronik endüstrisindeki üretilebilir tasarım gereksinimi ve kısa pazarlama süresi talebi, bilgisayar destekli tasarım metodolojilerini gerekli kılmaktadır (Zhang ve Gupta, 2000; Steer vd., 2002). Yüksek frekanslarda bilgisayar-destekli tasarım için modelleme halen büyük zorluk olarak görülmektedir. 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 oluşturabilmektedir. Bilgisayar bilimlerindeki gelişmeler günümüzde ayrık veri biçimindeki giriş-çıkış ilişkilerini sürekli giriş domeninde tanımlanmış fonksiyonlara dönüştürebilen doğrusal olmayan öğrenen makineleri mümkün kılmıştır. Bu özelliğe, literatürde öğrenen makinelerin genellemesi ya da verilen ayrık veriye fonksiyon yaklaşıklaması 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 gittikçe artan sıklıkla yer almaktadırlar. Bu özellikler, doğrusal olmayan öğrenen makineleri, alternatifleri olan polinom uydurma ve tablo tabanlı yöntemlere göre üstün kılar.

Günümüzde, Yapay Sinir Ağları (YSA), hızlı ve esnek bir öğrenen makine olarak mikrodalga modelleme uygulamalarında yaygın kullanılmaktadır (Zhang ve Gupta, 2000). Yapay sinir ağı modelleri ölçülen ve/veya simülasyon sonucunda elde edilen veri ile ağı eğitilmesi sonucunda oluşturulur. Böylece elde edilen YSA modelleri, hızlı ve doğru bir model olarak mikrodalga tasarım ve optimizasyon problemlerinde tasarımcı tarafından interaktif olarak kullanılmaktadır (Zhang ve Gupta, 2000). Ancak, doğruluğu yüksek bir YSA modellemesi için, yüksek doğruluğa sahip veri teminindeki hesaplama maliyeti ve insan zamanının efektif

kullanılması problemleri, hala efektif çözümler beklemektedir. Şimdiye kadar karmaşık yapıya sahip bilgi-tabanlı YSA sistemleri önerilmiştir (Wang ve Zhang, 1997; Watson vd., 1999; Jargon vd., 2002; Bakr vd., 2000; Devabhaktuni vd., 2001; Bandler vd., 2002; Devabhaktuni vd., 2003), Buna karşın, aşağıdaki paragraflarda bahsedileceği gibi, “Bilgi-Tabanlı Destek Vektör Makineleri” önerimiz, bu probleme çok sade ve basit çözümler getirmektedir.

Son on yılda DVM, YSA’ya rakip öğrenen makineler olarak 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 (Vapnik, 1995). 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 (Chapelle vd., 1999). Sonrasında reel dünyada çok çeşitli uygulama alanları bulmuştur. 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 (Kim vd., 2008). Ayrıca çeşitli tiplerdeki anten tasarımlarında (mikroşerit, anten dizisi, yarık,...) (Ayestarán ve Las-Heras, 2005; Ayestarán vd., 2007; Ayestarán vd., 2006; Ramón vd., 2005), mekatronik hareket sistemlerinde ileri-besleme kontrol öğrenmede (Kruif ve Vries, 2001), elektronik mühendisliğinde lineer-faz FIR filtre tasarımında (Santamaria, 2003), işaret işleme uygulamalarında (Ganapathiraju vd., 2004; Rojo-Álvarez vd., 2003; Rojo-Álvarez vd., 2005) kullanılmaktadır. Tezin ikinci bölümünde, DVM regresyonunun matematiksel temelleri yer

almaktadır. DVM teorisi ayrıntıları ile (Cristianini ve Shawe-Taylor, 2000)'de mevcuttur. Bu tezde yer alan DVM uygulamalarında, ikinci bölümde yer alan matematiksel ifadeler kullanılarak hazırlanmış bir DVM araç-kutusu kullanılmıştır (Chang ve Lin, 2001).

Bu tez çalışması, literatürde DVM'nin mikrodalga teori ve tekniğine uygulanmasına ve rakibi YSA ile karşılaştırıp, yerleşmesine öncülük eden çalışmalardan biridir. Bu amaçla mikrodalga aktif/pasif elemanların modellenmesinde, analiz, sentezlerinde kullanılmış ve uluslararası atıf yayını olarak hazırlanmış ve kabul edilmiştir. İlk olarak daha önce YSA modeli oluşturulan bir mikrodalga transistörün (Güneş vd.,1996) DVM modeli oluşturulmuştur. Üçüncü bölümde yer alan bu çalışmada, bir mikrodalga transistörün küçük-ışaret ve gürültü davranışlarının DVM ile modellenmesi yapılmıştır. İki ayrı transistör seçilmiş ve YSA ve DVM ile modellemeleri yapılarak ışıaret ve gürültü parametreleri kestirim sonuçları ile modellerin performans ve doğrulukları karşılaştırılmıştır (Türker ve Güneş, 2006; Güneş vd., 2007). Elde edilen grafik ve tablolardan DVM' nin hem performans hem de doğruluk açısından YSA'ya kıyasla üstünlüklere sahip olduğu görülmektedir.

DVM'nin mikrodalga teorisindeki ikinci uygulaması mikroşerit iletim hatlarının destek vektör tasarımıdır (Güneş vd., 2008; Türker Tokan ve Güneş, 2008a; 2008b). Bu çalışmada Destek Vektör Regresyonu (DVR) mikroşerit iletim hatlarının analiz ve sentezine uyarlanmıştır. Tasarım aşamasında, destek vektör sayısı, doğruluk ve hesaplama süresi detaylı olarak incelenmiş ve DVR performansı YSA eşdeğerinininki ile karşılaştırılmıştır. Ayrıca sentez, analiz kara-kutu modelinin ters eğitilmesi ile sağlanmıştır. Ters eğitimde adaptif adım boyutu kullanılarak çok daha hızlı yakınsama elde edilmiştir. Mikroşerit iletim hatlarının tasarımı en yaygın olarak kullanılan izotropik ve anizotropik dielektrik maddeler kullanılarak yapılmış ve bu örneklerde Destek Vektör Regresyon Makineleri (DVRM)' nin regresyon problemlerinde yüksek fonksiyon yaklaşırma kabiliyeti ve hızlı yakınsama oranı sebebiyle üstünlükleri gösterilmiştir. Bu çalışmaya dördüncü bölümde yer verilmiştir.

Beşinci bölümde mikroşerit antenlerin ölçüm sonuçlarına dayandırılmış destek vektör karakterizasyonu yapılmıştır (Türker Tokan ve Güneş, 2008c; 2008d). Anten mühendisliğinde, mikroşerit antenlerin rezonans frekansı, band genişliği ve giriş empedansının hesaplanmasında iki farklı analiz yaklaşımı mevcuttur. İlk yaklaşım antenin iletim hattı modeli ya da kovuk modeli oluşturulup, basit analitik formüller ile çalışma parametrelerinin hesaplanmasıdır ve fiziksel bir görüş verir. Alternatif yaklaşım, anteni bir elektromagnetik sınır problemi olarak ele alıp ya spektral domende ya da uzay domeninde Green fonksiyonlarını kullanarak moment metodu ile çözmeyi içerir. Bu yaklaşım sağlam bir

elektromagnetik bilgiye sahip olmayı gerektirir. Bu çözüm uzun sürer ve kolaylıkla bilgisayar destekli tasarıma aktarılamaz. Literatürde bu iki yaklaşımla da elde edilen teorik değerlerin dikkörtgen mikroşerit antenin ölçüm sonuçları ile pek uyumlu olmadığı görülmüştür (Sağıroğlu vd., 1999; Güney vd., 2000). Bu sebeplerden dolayı bu çalışmada, ölçmeye dayandırılan bir modelleme yaklaşımı kullanılmıştır. Böylece en ağır teoride bile hesaba katılmayan faktörlerin hesaba katılması mümkün olabilecektir. Bu çalışmada, dikkörtgen mikroşerit anten rezonans frekansı, bant genişliği, ve giriş empedansı, “N” ölçme verisi kullanılarak DVM ile formüle edilmiştir. DVM formülasyon sonuçlarının, literatürde yer almış teorik sonuçlara göre çok yüksek doğruluğa sahip olduğu gözlemlenmiştir. Ayrıca, DVM performansı YSA’nınki ile de karşılaştırılarak üstünlükleri belirtilmiştir.

Elektromagnetik devre tasarımında kullanılan detaylı teorik modeller (3-Boyutlu Elektromagnetik (EM) modeller) yüksek doğruluğa sahip olmasına karşın işlemciye duyarlı ve yavaştır. Yaklaşık modeller (örn. ampirik modeller) ise hızlı fakat sınırlı doğruluğa sahiptir. Doğrulukları belirli frekans aralığında ya da işlem alanındadır. YSA ve DVM gibi doğrusal olmayan öğrenen makineler yaklaşık modeller kadar hızlı, detaylı EM modeller gibi yüksek doğruluğa sahiptir. Bu sebeple mikrodalga elemanlarının bilgisayar destekli tasarımının öğrenen makinelerle yapılması verimli bir alternatif çözümdür. Eğitim verisinin oluşturulması kullanılan bilgisayarın işlemcisine bağlı olarak uzun zaman alabilen ve modelin gelişmesini yavaşlatan bir işlemdir. Günümüzde model gelişim zamanını azaltılmış sayıda eğitim verisi kullanarak azaltmak için çalışmalar yapılmaktadır. Bu, modeli oluşturmadaki insan etkileşimini de azaltacaktır. Bu amaçla geliştirilen yöntemlere altıncı bölümde yer verilmiştir. Altıncı bölümde yer alan çalışmada, literatürde ilk olarak bilgi-tabanlı destek vektör makinesi tasarlanmış ve bu metot RF/Mikrodalga düzlemsel iletim hatlarının sentezinde kullanılmıştır. Bu amaçla iki ayrı yaklaşım, iki ayrı örnekle gösterilmiştir. İlk yaklaşımda sentez verisi, sağlam matematiksel formülasyonlardan elde edilen analiz eğitim verisinin problem tanımına uygun olarak yeniden düzenlenmesi ile elde edilmiştir. İkinci yaklaşımda ise sentez için kullanılan DVM modellerinin oluşturulmasında iki tip veri üretici kullanılmıştır: Kaba ve hassas veri üretici. Kaba veri üreticiler yaklaşık çözüm yaptığı için hızlıdır fakat doğrulukları kısıtlıdır (Örn. Analitik formülasyonlar). Hassas veri üreticiler ise yüksek doğruluğa sahip fakat yavaştır (EM simülatörler). İkinci yaklaşımda yer alan teknikte öncelikle kaba veri üreticiden elde edilen sentez veri kümesi ile DVM eğitilir. DVM modelinden elde edilen destek vektörler hassas veri üreticiye girdi olarak verilerek azaltılmış sayıda veriye ve yüksek doğruluğa sahip yeni bir veri kümesi oluşturulur. Yeni veri kümesiyle eğitilen DVM, hem yüksek doğruluğa sahip hem de çok hızlıdır. Bu çalışmada gerçekleştirilen

tasarım ile DVM, EM simülatör olarak kullanılabilir.

DVM ile gerçekleştirilen bir başka çalışma “Mikrodalga Teknolojisinde Uzman Regresyon Sistemlerinin Uzlaşması” isimli çalışmadır. Bu çalışmada, verilen bir bağımsız değişken vektörü için en yüksek doğrulukla cevap veren regresyon modelinin çıkışının sistem çıkışı olarak kabul edildiği hızlı ve verimli bir sistem tasarlamak amaçlanmıştır. Bu amaçla dört ayrı regresyon algoritması (DVRM, YSA, k -NN, LS) seçilen bir regresyon problemine uyarlanmış ve dört ayrı regresyon modelinin çıkışları arasında hedef değerine bağlı olarak uzlaşma yapılarak bir çıkış elde edilmiştir. Bu çalışmada kullanılan uzlaşım metotları şunlardır: 1) Ortalama almak; 2) Minimumu almak; 3) Maksimumu almak; 4) Ortancayı almak. Regresyon modellerinin kullanacağı veri kümesi önışlemci olarak seçilen DVM’den geçirilerek DV’lerden oluşan yeni bir veri kümesi elde edilmiştir. Azaltılmış sayıda veri ile işlem yapmak regresyon modellerini hızlandırarak daha verimli bir hale getirecektir. Bu çalışma detaylı olarak yedinci bölümde yer almaktadır.

Sonuçlar bölümünde ise genel olarak tezin literatüre katkılarına yer verilmiştir. Ayrıca DVM’nin mikrodalga teori ve tekniğindeki uygulamalarına örnek olarak yapılan beş ayrı regresyon uygulamasında gerçekleştirilen yenilikler özetlenmiştir.

2. DESTEK VEKTÖR REGRESYON MAKİNELERİ

DVM, doğrusal öğrenme makinelerini, genelleme teorisinin sağladığı kavrayışları göz önünde bulundurarak ve optimizasyon teorisini uygulayarak, kernele bağlı öznitelik uzayında verimli bir şekilde eğitmek için geliştirilen bir sistemdir. Bu sistemlerin en önemli özelliklerinden biri genelleme teorisi ile elde edilen eğilimleri uygularken, hipotezin seyrek gösterimlerini üretmesi sonucunda çok verimli algoritmanın oluşmasıdır. Bu Karush-Kuhn-Tucker (KKT) durumlarından kaynaklanır (Kuhn ve Tucker, 1951) ve DVM' nin pratik uygulamasında ve analizinde büyük öneme sahiptir. DV yaklaşımının bir başka önemli özelliği optimizasyon probleminin konveks olması ve bu sebepten lokal minimumu olmamasıdır. Garantili evrensel minimum ve azaltılmış sayıda sıfır olmayan parametreler, bu sistem ile yapay sinir ağları gibi diğer örüntü tanıma sistemleri arasındaki en büyük farklılıklardır. Vapnik ve ekibi tarafından geliştirilen bu öğrenme stratejisi, disiplinli ve çok kuvvetli bir metot olarak son yıllarda birçok uygulamada performansı ile diğer öğrenen sistemleri geride bırakmıştır.

2.1 Öznitelik Uzayında Doğrusal Öğrenen Makineler

Doğrusal olmayan bağıntıları doğrusal bir makine ile öğrenebilmek için öncelikle doğrusal olmayan öznitelik kümesi seçilmeli ve veri yeni gösterimi ile tekrardan yazılmalıdır. Bu, doğrusal olmayan sabit bir eşleme kullanarak, veriyi doğrusal makinelerin kullanılacağı öznitelik uzayına eşleme ile eşdeğerdir. Bundan dolayı göz önüne alınacak hipotez kümesi şu tip bir fonksiyon olacaktır:

$$f(\mathbf{x}) = \sum_{i=1}^N \mathbf{w}_i \cdot \phi_i(\mathbf{x}) + b \quad (2.1.a)$$

Burada

$$\mathbf{x} = (x_1, \dots, x_n) \rightarrow \boldsymbol{\phi}(\mathbf{x})^t = (\phi_1(x), \dots, \phi_N(x)) \quad (2.1.b)$$

Bu adım giriş uzayı X 'i yeni bir uzaya, $F = \{\boldsymbol{\phi}(\mathbf{x}) | \mathbf{x} \in X\}$ eşleme ile eşdeğerdir. Böylece $f(\mathbf{x})$ 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. Buradan yola çıkarak (2.1.a) denkleminde yer alan \mathbf{w} ve b büyüklükleri ağırlık vektörü ve bias olarak adlandırılacaktır. Burada \mathbf{w}

$$\mathbf{w}' = [w_1, \dots, w_N] \quad (2.1.c)$$

olup yapay sinir ağı literatüründen alınmış bir terimdir. Bazen b yerine eşik olarak bilinen θ kullanılabilir.

Doğrusal öğrenen makinelerin önemli bir özelliği çift gösterim ile ifade edilebilmeleridir. Bu hipotezin eğitim verisinin doğrusal bileşimi ile ifade edilebileceği anlamına gelir. Böylece karar kuralı eğitim ve test verilerinin iç çarpanını kullanarak şu şekilde elde edilebilir:

$$f(\mathbf{x}) = \sum_{i=1}^{\ell} \alpha_i y_i \langle \boldsymbol{\varphi}(\mathbf{x}_i), \boldsymbol{\varphi}(\mathbf{x}) \rangle + b \quad (2.1.d)$$

Burada y_i i ' inci verinin hedef değeri, α_i ise i ' inci verinin Lagrange katsayısıdır ($i = 1, 2, \dots, \ell$). 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.

2.2 Birincil Optimizasyon Problem Formülasyonu

Amacımız (2.1.a)' da yer alan \mathbf{w}' yı 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 şu şekilde ifade edilebilir.

$$\frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^{\ell} L^\varepsilon(\mathbf{x}_i, y_i, f) \quad (2.2)$$

Burada L genel kayıp fonksiyonu, C ise düzenleme sabitidir. (2.2)' de 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 (Vapnik, 1995):

$$L^\varepsilon(\mathbf{x}, y, f) = \begin{cases} 0 & \text{if } |y_i - f(\mathbf{x}_i, \mathbf{w}^*)| < \varepsilon \\ |y_i - f(\mathbf{x}_i, \mathbf{w}^*)| - \varepsilon & \text{aksi takdirde} \end{cases} \quad (2.3)$$

Bu ifade bir ε tüp tanımlar. Bu ifadeye göre tahmin edilen değer tüpün içinde olduğunda kayıp sıfır, dışında olduğunda ise tahmin edilen değer ile tüpün ε yarıçapı arasındaki farka eşittir. Vapnik' in ε -duyarsız kayıp fonksiyonunu kullanarak (2.4) minimize edilir.

$$\frac{1}{2}(\mathbf{w}^t \mathbf{w}) + C \sum_{i=1}^{\ell} (\xi_i + \hat{\xi}_i) \quad (2.4)$$

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 ε 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 (2.5)' de verilmiştir:

$$(\langle \mathbf{w} \cdot \mathbf{x}_i \rangle + b) - y_i \leq \varepsilon + \xi_i \quad (2.5.a)$$

$$y_i - (\langle \mathbf{w} \cdot \mathbf{x}_i \rangle + b) \leq \varepsilon + \hat{\xi}_i \quad (2.5.b)$$

$$\xi_i, \hat{\xi}_i \geq 0, \quad i = 1, 2, \dots, \ell \quad (2.5.c)$$

2.3 Lagrange Fonksiyonu ve Çift Gösterimi

(2.4)' de verilen amaç fonksiyonu ile (2.5)' de yer alan kısıtlamaları bağlayarak (2.6)' da yer alan Lagrange fonksiyonu elde edilir:

$$L = \frac{1}{2}(\mathbf{w}^t \mathbf{w}) + C \left(\sum_{i=1}^{\ell} \hat{\xi}_i + \sum_{i=1}^{\ell} \xi_i \right) - \sum_{i=1}^{\ell} \hat{\alpha}_i [y_i - (\mathbf{w}^t \cdot \mathbf{x}_i) - b + \varepsilon + \hat{\xi}_i] - \sum_{i=1}^{\ell} \alpha_i [(\mathbf{w}^t \cdot \mathbf{x}_i) + b - y_i + \varepsilon + \xi_i] - \sum_{i=1}^{\ell} (\hat{\gamma}_i \hat{\xi}_i + \gamma_i \xi_i) \quad (2.6)$$

Burada $\hat{\gamma}_i^{(\wedge)}$ ve $\alpha_i^{(\wedge)}$ Lagrange çarpanlarıdır. Eyer noktası durumlarından L ' nin birincil

değişkenlere (\mathbf{w}_i , b , ξ_i ve $\hat{\xi}_i$) göre türevinin sıfıra eşit olacağı sonucu çıkartılabilir (Drucker vd., 1996):

$$\frac{\partial \mathbf{L}}{\partial b} = \sum_{i=1}^{\ell} (\hat{\alpha}_i - \alpha_i) = 0 \quad (2.7)$$

$$\frac{\partial \mathbf{L}}{\partial \mathbf{w}} = \mathbf{w} - \sum_{i=1}^{\ell} (\hat{\alpha}_i - \alpha_i) \mathbf{x}_i^t = 0 \quad (2.8)$$

$$\frac{\partial \mathbf{L}}{\partial \xi_i^{(\Lambda)}} = C - \alpha_i - \gamma_i = 0 \quad (2.9)$$

(2.7), (2.8) ve (2.9)' u (2.6)' ya yerleştirerek çift amaç fonksiyonunun eşdeğer maksimizasyonu şu şekilde elde edilir:

$$\mathbf{W}(\alpha, \hat{\alpha}) = -\varepsilon \sum_{i=1}^{\ell} (\hat{\alpha}_i + \alpha_i) + \sum_{i=1}^{\ell} y_i (\hat{\alpha}_i - \alpha_i) - \frac{1}{2} \sum_{i,j=1}^{\ell} (\hat{\alpha}_i - \alpha_i) (\hat{\alpha}_j - \alpha_j) \langle \mathbf{x}_i \mathbf{x}_j \rangle \quad (2.10)$$

Bu ifadenin kısıtlamaları şu şekildedir:

$$0 \leq \alpha_i \leq C, 0 \leq \hat{\alpha}_i \leq C, i = 1, \dots, \ell \quad (2.11.a)$$

$$\sum_{i=1}^{\ell} \hat{\alpha}_i = \sum_{i=1}^{\ell} \alpha_i \quad (2.11.b)$$

İlgili Karush–Kuhn–Tucker tamamlayıcı durumları (2.12)' de verilmiştir.

$$\alpha_i (\langle \mathbf{w} \cdot \mathbf{x}_i \rangle + b - y_i - \varepsilon - \xi_i) = 0, \quad (2.12.a)$$

$$\hat{\alpha}_i (y_i - \langle \mathbf{w} \cdot \mathbf{x}_i \rangle - b - \varepsilon - \hat{\xi}_i) = 0, \quad (2.12.b)$$

$$\xi_i \cdot \hat{\xi}_i = 0, \quad (2.12.c)$$

$$\alpha_i \cdot \hat{\alpha}_i = 0, \quad (2.12.d)$$

$$(\alpha_i - C) \cdot \xi_i = 0 \quad (2.12.e)$$

$$(\hat{\alpha}_i - C) \cdot \hat{\xi}_i = 0, \quad i = 1, 2, \dots, \ell \quad (2.12.f)$$

Bu aşamada ℓ adet Lagrange çarpın 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 (2.10)'da x -giriş uzayında yer alan amaç fonksiyonu F -öznitelik uzayında şu şekilde yazılabilir:

$$\mathbf{W}(\alpha, \hat{\alpha}) = -\varepsilon \sum_{i=1}^{\ell} |\alpha_i| + \sum_{i=1}^{\ell} y_i \alpha_i - \frac{1}{2} \sum_{i,j=1}^{\ell} \alpha_i \alpha_j \langle \varphi(\mathbf{x}_i), \varphi(\mathbf{x}_j) \rangle \quad (2.13)$$

Bu şekilde öznitelik uzayındaki çift optimizasyon problemi elde edilir. Bu ifadenin maksimizasyonu $(\alpha, \hat{\alpha})$ 'ye ve (2.12)'deki durumlara bağlı olarak yapılmalıdır. Bu maksimizasyon $(\alpha, \hat{\alpha})$ katsayılarının belirlenmesi ile sonuçlanır. Bu katsayıları (2.8)'e yerleştirerek ağırlık vektörü \mathbf{w} eğitim verilerinin doğrusal bileşimi olarak elde edilebilir:

$$\mathbf{w} = \sum_i^{\ell} (\alpha_i - \hat{\alpha}_i) \mathbf{x}_i^t \quad (2.14)$$

Verilen verinin destek vektör açılımı şu şekilde elde edilir:

$$f(\mathbf{x}) = \sum_{i=1}^{DV} \alpha_i y_i \langle \varphi(\mathbf{x}_i), \varphi(\mathbf{x}) \rangle + b \quad (2.15)$$

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

$$K(x, z) = \langle \varphi(x), \varphi(z) \rangle \quad (2.16)$$

Burada φ, X 'den öznitelik uzayı F 'e yapılan bir eşlemedir.

b 'nin değeri çift problemin çözümü ile bulunamaz. Bu sebepten b^* (2.12.a) ve (2.12.b)'de yer alan birincil kısıtlamaları kullanarak bulunmalıdır.

DV açılımı için son olarak şunlar söylenebilir: (2.12.a) ve (2.12.b)'den sadece $|f(\mathbf{x}_i) - y_i| \geq \varepsilon$ ise Lagrange çarpanlarının sıfırdan farklı olabileceği, farklı bir deyişle, ε -tüpün 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} 'nin 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. DVM teorisi hakkında detaylı bilgi ve literatür (Cristianini ve Shawe-Taylor, 2000)' de mevcuttur.

3. BİR MİKRODALGA TRANSİSTÖRÜN İŞARET-GÜRÜLTÜ DESTEK VEKTÖR MODELİ

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- işaret ve gürültü davranışını modellemek için iki ayrı yaklaşım mevcuttur. Bunlardan ilki işaret ve gürültü performansının genellikle birbirinden ayrıldığı ve cihazın operasyon alanının alt bölgesinde karakterize edildiği toplu elemanlı eşdeğer elektriksel devre yaklaşımıdır. İkinci yaklaşım ise işaret 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.

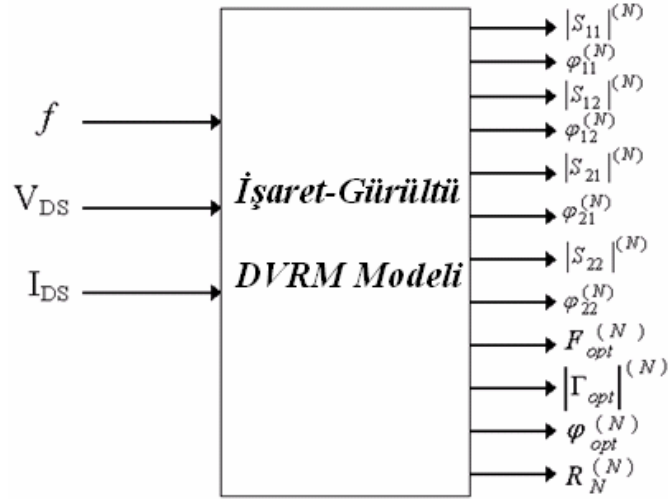
Bilgisayar bilimlerindeki gelişmeler ayrık veriyi sürekli veri alanına genelleyeabilen öğrenen makineleri mümkün kılmıştır. Sürekli veri alanındaki genelleme özelliği öğrenen makinelerin cihaz modellemede tablo-tabanlı metotlara üstünlüğüdür. YSA tipik bir öğrenen makinedir ve doğrusal olmayan cihazların kara-kutu modellemesinde kullanılmaktadır. Yapay transistörler (Güneş vd., 1996, 1998; Giannini vd., 2002; Marinkoviç ve Markoviç, 2005) mikrodalga transistörlerin tipik kara-kutu modeli olup işaret ve gürültü parametrelerini N-ölçüm örneği ile cihazın tüm işlem alanında yüksek doğrulukla tespit edebilir. Bu kara-kutu modelleri mikrodalga cihazların ve devrelerin tasarımına başarı ile uygulanmıştır (Güneş ve Tepe, 2002; Cengiz vd., 2006). Yapay sinir ağları cihazın doğrusal olmayan özelliklerinin karakterizasyonunda da kullanılmıştır. Buna örnek olarak transistörün üçüncü derece bozulum karakterizasyonu (Giannini vd., 2006) verilebilir. Bunun yanı sıra, son on yılda destek vektör makineleri yapay sinir ağlarına rakip öğrenen makineler olarak ortaya çıkmıştır. DVM genelleme ve optimizasyon teorilerini birbirine bağlayan ağır matematiksel ifadelerle sahiptir

ve hesaplamadaki hızı bu ifadelerle ispatlanabilmektedir. DVM'nde doğrusal olmayan bir fonksiyon, doğrusal bir öğrenen makine ile öznelik uzayında öğrenilebilir ve sistemin kapasitesi uzayın boyutuna bağlı olmayan bir parametre ile kontrol edilmektedir. Öğrenme algoritması optimizasyon prosedüründe evrensel minimumu garanti eden bir dışbükey fonksiyonu minimize eder. Çözüm eğitim verisinin küçük bir alt kümesi ile ifade edilebilir. Buna “seyreklik” denir ve hesaplamada büyük avantajlar getirdiği aşikârdır. Azaltılmış sayıda sıfır olmayan parametreler ve garantili evrensel minimum bu sistem ve diğer öğrenen sistemler arasındaki en büyük farklılıklardır. Mikrodalga teorisinde öğrenen makinelere olan ihtiyaç DVM metodunun mikrodalga dünyasına tanıtılmasını sağlamıştır. Bu çalışmada daha önce YSA modeli oluşturulan bir mikrodalga transistörün (Güneş vd., 1996, 1998) DVM modeli oluşturulmuş ve performansı YSA modeli ile karşılaştırılmıştır. Bu amaçla iki ayrı mikrodalga transistör ele alınmıştır: N23200A ve ATF-551M4. N23200A transistörünün DVRM modeli ile (Türker ve Güneş, 2006) başlanan bu çalışma ATF-551M4 transistörünün DVRM modeli ile geliştirilmiş ve detaylandırılmıştır (Güneş vd., 2007). Bu bölümde ATF-551M4 transistörünün DVRM modeli tanıtılacaktır. Sıradaki alt bölümde mikrodalga transistörün küçük-ışaret ve gürültü davranışı modelleme esaslarına yer verilmiştir. Genel olarak tanımlanan bu esasların her tip mikrodalga transistörüne uydurulması mümkündür.

3.1 Bir Mikrodalga Transistörün DVM Modeli

3.1.1 Bir Mikrodalga Transistörün Kara-Kutu Gösterimi

Bir mikrodalga transistörün V_{DS} , I_{DS} kutuplama koşullarında ve f işlem frekansında küçük ışıret (S -) ve gürültü (N -) davranışının kara-kutu gösterimi (Güneş vd.,1996)'da verilmiştir. Burada DVM cihaz işlem durumları f , V_{DS} , I_{DS} ile S ve N parametrelerinin büyüklüğünü ve fazını ilişkilendirmek amacıyla kullanılmıştır. Burada f , V_{DS} , I_{DS} giriş uzayı olup, küçük ışıret ve gürültü davranışını tanımlayan on iki fonksiyon, DVM regresyonu yapılacak fonksiyonlardır. Şekil 3.1'de problemin kara-kutu gösterimi verilmiştir.



Şekil 3.1 Bir mikrodalga transistörün işaret-gürültü DVRM modeli.

3.1.2 Eğitim ve Test Verisi

DVRM modelinin eğitim ve test verisi seçilen transistörün üretici verilerinden elde edilmiştir (Bkz. Ek-1). (Güneş vd.,1996)'da verildiği gibi, bir aktif mikrodalga cihazın kutuplama noktası, V_{DS} , I_{DS} ' de işaret ve gürültü performansı genellikle ω -alanında saçılma ve gürültü parametreleri ile verilebilir. Ölçüm performans verileri tüm işlem bandında şu şekilde bir tablo formuna dönüştürülebilir:

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

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

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

$$\left[N^{(N)} \right]^t = \left[F_{opt}^{(N)} |\Gamma_{opt}|^{(N)} \varphi_{opt}^{(N)} R_N^{(N)} \right] \quad (3.3)$$

(3.1)-(3.3) eşitlikleri ile tanımlanan ifadeler cihazın DVRM ve YSA modelinin eğitiminde kullanılmaktadır. Böylece belli bir f_k frekansında ve kutuplama koşullarında performans vektörleri $S^{(k)}$ ve $N^{(k)}$, y_1 elde etmek mümkün olmaktadır. $S^{(k)}$ ve $N^{(k)}$, nın ölçülmediği durumlarda dahi modelin cevap verebilmesi genelleme yeteneğine bağlıdır. Sonuç olarak

oluşturulan DVM modeli sürekli bir model olup transistörün işaret ve gürültü parametreleri ile işlem durumları V_{DS} , I_{DS} ve işlem frekansı arasındaki doğrusal olmayan bağıllığı ilişkilendirme yeteneğine sahiptir.

3.2 Uygulama Örneği: ATF-551M4' in İşaret-Gürültü Modeli

3.2.1 Modelin Eğitim ve Test Verisi

Uygulama örneği olarak, ATF-551M4 modellenecek aktif mikrodalga elemanı olarak seçilmiş ve transistörün 0.5 GHz - 10 GHz frekans aralığı, $V_{DS} = 2V, 2.7V, 3V$ kutuplama gerilimi ve $I_{DS} = 10mA, 15mA, 20mA$ kutuplama akımı için S - ve N - parametreleri üretici verilerinden elde edilmiştir. S - ve N - verilerinin her ikisi için üretici verilerinde 0.5GHz - 10 GHz aralığında on iki ayrı frekansta ortak değer vardır. $I_{DS} = 10mA, 15mA, 20mA$ ve $V_{DS} = 2V, 3V$ ' da toplam 72 adet S - ve N - verisi DVRM ve YSA modellerinin eğitiminde kullanılmıştır. $I_{DS} = 10mA, 15mA, 20mA$ ve $V_{DS} = 2.7 V$ için mevcut 36 adet S - ve N - verisi ise modellerin testi için kullanılmıştır. Eğitim ve test aşamasında "Pentium 4 CPU, 3 GHz İşlemci, 256 MB RAM"e sahip bir bilgisayar kullanılmıştır.

3.2.2 Transistör Modelinin Hata Analizi

Hedef verisi ile olan uyumluluğu hesaplamak ve DVRM ve YSA modellerinin performansını karşılaştırabilmek amacı ile aşağıda yer alan hata terimlerini kullanmak (Güneş vd.,1996)' da olduğu gibi uygun görülmüştür:

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

$$E_{N_{ij}} = \frac{1}{n} \sum_{k=1}^n \frac{|N_{ij}^k(\text{ölçülen}) - N_{ij}^k(\text{tahmin edilen})|}{|N_{ij}^k(\text{ölçülen})|} \quad (3.5)$$

Burada S_{ij} ve N_i sırası ile işaret ve gürültü parametreleri, n ise her bir kutuplama koşulundaki ayırık frekans sayısının toplamıdır. Toplam ortalama hata, işaret ve gürültü hatalarının ortalamasını alarak şu şekilde bulunabilir:

$$E_T = \frac{1}{4} \sum_{i=1}^4 E_{i(\text{isaret})} + \frac{1}{3} \sum_{i=1}^3 E_{i(\text{gürültü})} \quad (3.6)$$

3.2.3 ATF-551M4'ün İşaret-Gürültü Parametrelerinin DVRM Modeli

Seçilen aktif elemanın DVRM modelinin oluşturulmasında Çizelge 3.1' de verilen sayıda destek vektörü kullanılarak işaret ve gürültü davranışını tanımlayan her bir karakterizasyon fonksiyonunun regresyonu sağlanmıştır. ATF-551M4'ün DVRM modelinde (Şekil. 3.1) yayılma parametresi 0.1 olan radyal tabanlı fonksiyon kerneli kullanılmıştır:

$$K(x, x') = \exp\left(-\frac{\|x - x'\|^2}{2\sigma^2}\right) \quad (3.7)$$

Çizelge 3.1 İşaret-gürültü fonksiyonlarının eğitiminde kullanılan destek vektör sayısı.


(Toplam eğitim verisi: 72)	DV sayısı
S ₁₁ ' in Büyüklüğü	59
S ₁₁ ' in Açısı	64
S ₁₂ ' nin Büyüklüğü	58
S ₁₂ ' nin Açısı	57
S ₂₁ ' in Büyüklüğü	61
S ₂₁ ' in Açısı	53
S ₂₂ ' nin Büyüklüğü	61
S ₂₂ ' nin Açısı	54
F _{min}	62
Γ_{opt} ' un Büyüklüğü	62
Γ_{opt} ' un Açısı	54
R _n	57

3.2.4 ATF-551M4'ün İşaret-Gürültü Parametrelerinin YSA Modeli


Şekil 3.1' de verilen modeli YSA ile oluştururken (Güneş vd.,1996)' dakine benzer bir yapı kullanılmıştır. Oluşturulan çok katmanlı algılayıcı (ÇKA) ağı çıkış katmanında yer alan nöron sayısı ile aynı sayıda nörona sahip bir gizli katmana sahiptir ve ağı eğitilmesinde Levenberg-Marquardt geri yayılım algoritması kullanılmıştır. Giriş katmanında üç nörona, gizli ve çıkış katmanında on iki nörona sahip ÇKA' nın öğrenme oranı 0.1 olup 300 iterasyonda eğitilmiştir. Gizli ve çıkış katmanında sırası ile hiperbolik tanjant sigmoid ve doğrusal aktivasyon fonksiyonları kullanılmıştır.


3.2.5 DVRM ve YSA Model Sonuçları

DVRM ve YSA'nın test sonuçları hedef değerleri ile karşılaştırmalı olarak üç ayrı düzlemde gösterilmiştir. Bunlar: $V_{DS} = 2.7V$ ' da $I_{DS} = 10mA$, $15mA$ ve $20mA$ için (i) S_{11} ve S_{22} ' nin değişimleri Şekil 3.2a, 3.4a, 3.6a' da Smith abağında gösterilmiştir; (ii) S_{12} ve S_{21} ' nin değişimleri Şekil 3.2b, 3.4b, 3.6b' de kutupsal koordinatlarda gösterilmiştir; (iii) Gürültü parametresi, F_{min} , R_n , Γ_{opt} ' un büyüklüğü ve açısının değişimleri Şekil. 3.3 a-b-c, 3.5 a-b-c, 3.7 a-b-c' de kartezyen koordinatlarda gösterilmiştir.




Şekil 3.2 $V_{DS}=2.7V$, $I_{DS}=10mA$ kutuplama koşulunda (a) S_{11} ve S_{22} ; (b) S_{12} ve S_{21} parametrelerinin frekans ile değişimi.





(c)


Şekil 3.3 $V_{DS}=2.7V$, $I_{DS}=10mA$ kutuplama koşulunda (a) F_{min} ; (b) R_n ; (c) Γ_{opt} 'un büyüklüğünün ve açısının frekans ile değişimi.



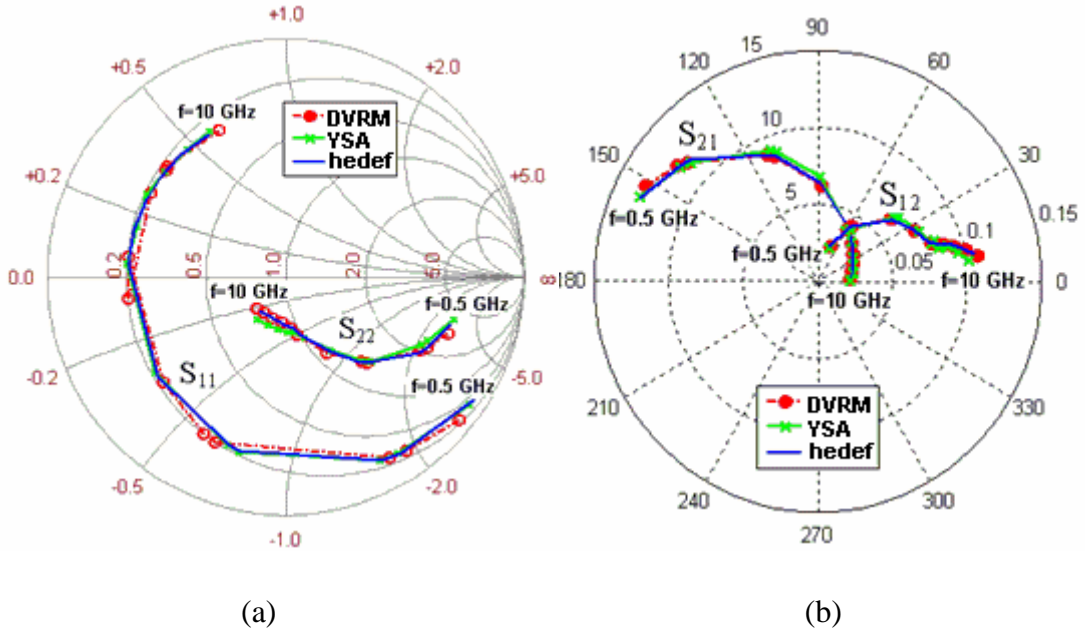
(a)

(b)


Şekil 3.4 $V_{DS}=2.7V$, $I_{DS}=15mA$ kutuplama koşulunda (a) S_{11} ve S_{22} ; (b) S_{12} ve S_{21} parametrelerinin frekans ile değişimi.




Şekil 3.5 $V_{DS}=2.7V$, $I_{DS}=15m$ kutuplama koşulunda (a) F_{\min} ; (b) R_n ; (c) Γ_{opt} 'un büyüklüğünün ve açısının frekans ile değişimi.



Şekil 3.6 $V_{DS}=2.7V$, $I_{DS}=20mA$ kutuplama koşulunda (a) S_{11} ve S_{22} ; (b) S_{12} ve S_{21} parametrelerinin frekans ile değişimi.





(c)

Şekil 3.7 $V_{DS}=2.7V$, $I_{DS}=20mA$ kutuplama koşulunda (a) F_{min} ; (b) R_n ; (c) Γ_{opt} 'un büyüklüğünün ve açısının frekans ile değişimi.

Çizelge 3.2'de DVRM ve YSA modelleri için verilen hata analizi (3.4)-(3.6)' da yer alan tanımlamalara bağlı olarak yapılmıştır. S_{11} ve Γ_{opt} 'un açı karakteristiğinde yer alan ani değişimler sebebiyle en yüksek hata bu modellerde oluşmuştur. Hata analizi tablosundan transistörün DVRM ile modellenmesinin YSA ile modellenmesine göre doğruluk açısından üstünlüğe sahip olduğu görülmektedir.

Çizelge 3.2 ATF551M4'ün hata analizi.

ATF551M4	YSA	DVRM
E_{S11}	0.0337	0.0918
E_{S21}	0.0966	0.0538
E_{S12}	0.0910	0.0726
E_{S22}	0.0988	0.0533
E_{ST}	0.0800	0.0679
E_{N1}	0.0601	0.0552
E_{N2}	0.0638	0.1033
E_{N3}	0.0601	0.0552
E_{NT}	0.0613	0.0713
E_T	0.1413	0.1391

Çizelge 3.3' de ATF551M4' ün DVRM ve YSA modellerinin zaman analizi verilmiştir. Çizelge 3.3 DVRM' nin YSA' na oranla daha hızlı öğrenen bir sistem olduğunu göstermektedir.

Çizelge 3.3 ATF551M4' ün işaret-gürültü DVRM ve YSA modellerinin zaman analizi.

	YSA	DVRM
Eğitim süresi (sn)	37.562	1.29
Test süresi (sn)	0.047	0.015
Toplam süre (sn)	37.609	1.305

3.3 Sonuçlar

Bu çalışmada, doğrusal olmayan fonksiyonların regresyonunda destek vektör makinelerinin yapay sinir ağlarına rakip bir öğrenen makine olduğu bir örnek ile gösterilmiştir. Bir mikrodalga transistörün işaret-gürültü DVRM modeli mikrodalga dünyasına tanıtılmış, işaret-gürültü YSA modelinin yerini alabileceği gösterilmiştir. Seçilen bir transistör ile uygulama örneği yapılarak DVRM'in doğrusal olmayan fonksiyon regresyon kapasitesi eşdeğer YSA modelinkine ile karşılaştırılmıştır. Buradan şu sonuca ulaşılabilir: DVM doğrusal olmayan mikrodalga cihazların küçük-ışaret ve gürültü davranışını modellemede yüksek doğruluk ve verimle kullanılabilir.


4. MİKROŞERİT İLETİM HATLARININ DESTEK VEKTÖR TASARIMI

Bu çalışmada DVM, mikroşerit iletim hatlarının tasarımında regresyon amaçlı kullanılmıştır. Bu tip uygulamalarda DVM, Destek Vektör Regresyonu (DVR) olarak adlandırılabilir. Gözlemlenen ayrık bir $\{(x_i, y_i), x_i \in \mathbf{R}^n, y_i \in \mathbf{R}, i=1,2,\dots,N\}$ verisi verildiğinde, DVM öğrenme metodu temel olarak regresyon için $y \cong f(\mathbf{x})$, sınıflandırma için $y = \text{sgn } f(\mathbf{x})$ ile $f(\mathbf{x}) = b + \sum y_j \mathbf{a}_j K(\mathbf{x}_j, \mathbf{x})$ yaklaşıklama fonksiyonunu oluşturur. Bu amaçla destek vektör $(\{\mathbf{x}_j, j=1,\dots,m\} \subset \{\mathbf{x}_i, i=1,\dots,N\})$ alt kümesi belirlenir, kernel fonksiyonu, K , seçilir ve b ve $\mathbf{a}_j, j=1,\dots,m$ parametreleri belirlenir. Çözüm eğitim verilerinin küçük bir alt kümesi ile ifade edilebilmektedir. Azaltılmış sayıdaki sıfır olmayan parametreler (destek vektörleri) ve evrensel minimumu bulabilme özellikleri DVM ile diğer örüntü tanıma sistemleri arasındaki en büyük farklılıklardır.

Bilindiği gibi mikrodalga iletim hatlarının çözümü için kullanılan tam-dalga metotları, genellikle matematiksel olarak karmaşık, hesaplama yükü yüksek, devre tasarımını yeterince kısa bir sürede yapamayan, bilgi ve zaman gerektiren sayısal hesaplamalar içeren metotlardır ve çözümleri çok pahalı yazılım paketleri gerektirir. Bu sebeplerden dolayı, tam-dalga metotları bilgisayar destekli tasarım modelleri için pek uygun değildir. Pratik uygulamalarda, hat karakteristiklerini %1 yaklaşıklıkla hesaplayabilen basit formülasyonlar gereklidir. Bazı araştırmacılar, yüksek doğrulukla sonuç vermesi için çeşitli nümerik sabitlerle ayarlanmış, yaklaşık analitik çözümlere dayanan formülasyonlar önermişlerdir (Collins, 1992; Bahl ve Bhartia, 1988; Edwards, 1981). Bu çalışmada yer alan kara-kutu modellerinin eğitim ve test verilerinin oluşturulmasında deneysel-analitik formülasyonlardan yararlanılmıştır.

Bu çalışmanın orijinallikleri şu şekilde özetlenebilir: i) RF/Mikrodalga düzlemsel iletim hatlarının tasarımı için yeni bir metot önerilmiş ve bu metot mikroşerit iletim hatlarının analizine uyarlanmıştır. Böylece verilen bir mikroşerit iletim hattı $\{W, H, T, \epsilon_r, \epsilon_y\}$ sistemi için karakteristik empedans $\{Z_0\}$ ve efektif dielektrik sabiti $\{\epsilon_{eff}\}$ giriş değişkenlerinin fonksiyonu olarak çıkışta elde edilebilmektedir. (ii) DVR'ın ϵ -parametresi ile destek vektör sayısı, doğruluk ve hesaplama süresi incelenmiş ve DVR performansı YSA eşdeğerininiki ile karşılaştırılmıştır. (iii) Sentez prosedürü, belirlenen bir karakteristik empedans $\{Z_0\}$ için izotropik veya anizotropik bir taban maddesi $\{H, T, \epsilon_r, \epsilon_y\}$ üzerindeki şerit genişliğinin $\{W\}$ bulunması olarak özetlenebilir. Sentez, analiz DVR/YSA biriminin iki yönlü kullanılması ile yapılmakta ve algoritmada uyarlamalı adım boyutu kullanılarak çok hızlı güncelleme işlemi gerçekleştirilmektedir.

4.1 Problemin Tanımı



Şekil 4.1 (a) Mikroşerit iletim hattı (\mathcal{M}); (b) İletim hattı eşdeğeri (\mathcal{T}).

Şekil 4.1.a'da verilen mikroşerit iletim hattı \mathcal{M} – uzayında $\mathcal{M} = \{\mathcal{G}, \mathcal{E}\} \in \mathcal{R}^5$ olarak tanımlanabilir. Burada \mathcal{G} ve \mathcal{E} sırası ile geometri ve dielektrik vektörleri olup şu şekilde tanımlanabilirler:


$$\mathcal{G}^t = [W, H, T] \quad (4.1)$$


$$\mathcal{E}^t = [\epsilon_r, \epsilon_y] \quad (4.2)$$

Burada W , şerit genişliği, H , dielektrik taban maddesinin kalınlığı, T , şerit kalınlığı ve ϵ_r, ϵ_y , dielektrik sabitlerdir. Benzer olarak Z_0 ve ϵ_{eff} eşdeğer iletim hattının (Şekil 4.1.b) karakteristik empedansı ve efektif dielektrik sabiti olup \mathcal{T} –uzayında şu şekilde ifade edilebilir:

$$\mathcal{T} = \{Z_0, \epsilon_{eff}\} \in \mathcal{R}^2 \quad (4.3)$$

Böylece mikroşerit iletim hatlarının analizi, $\mathcal{A} : \mathcal{M}(\mathcal{R}^5) \rightarrow \mathcal{T}(\mathcal{R}^2)$, sentezi de $\mathcal{S} : \mathcal{T}(\mathcal{R}^2) \rightarrow \mathcal{M}(\mathcal{R}^5)$ ile tanımlanabilmektedir. Analiz ve sentez kara-kutu modelleri Şekil 4.2.a ve b'de yer almaktadır.





Şekil 4.2 Mikroşerit iletim hatlarının (a) Analiz ($\mathcal{A} : \mathcal{M}(\mathcal{R}^5) \rightarrow \mathcal{T}(\mathcal{R}^2)$); (b) Sentez ($\mathcal{S} : \mathcal{T}(\mathcal{R}^2) \rightarrow \mathcal{M}(\mathcal{R}^5)$) kara-kutu modeli.

4.1.1 Eğitim ve Test Verilerinin Oluşturulması

$\mathcal{A} : \mathcal{M} \rightarrow \mathcal{T}$ eşlemlenmesinde yüksek doğrulukla sonuç elde edebilmek için çeşitli nümerik sabitlerle ayarlanmış, yaklaşık analitik çözümlere dayanan formülasyonlar kullanılmıştır (Collins, 1992; Bahl ve Bhartia, 1988; Edwards, 1981):

$$C_a = \frac{2\pi\epsilon_o}{\ln\left(\frac{8H}{W} + \frac{W}{4H}\right)}, \quad W/H \leq 1 \quad (4.4.a)$$

$$C_a = \epsilon_o \left[\frac{W}{H} + 1.393 + 0.667 \ln\left(\frac{W}{H} + 1.444\right) \right], \quad W/H > 1 \quad (4.4.b)$$

Şerit kalınlığı T 'nin etkisi, W yerine efektif şerit kalınlığı W_e 'nin kullanılması ile hesaba katılabilir:

$$W_e = W + 0.398T \left(1 + \ln \frac{4\pi W}{T} \right), \quad W/H \leq \frac{1}{2\pi} \quad (4.5.a)$$

$$= W + 0.398T \left(1 + \ln \frac{2\pi}{T} \right), \quad W/H > \frac{1}{2\pi} \quad (4.5.b)$$

İzotropik taban maddesine sahip bir mikroşerit hattın efektif dielektrik sabiti, ϵ_{eff} şu şekildedir:

$$\epsilon_{eff} = \frac{\epsilon_r + 1}{2} + \frac{\epsilon_r - 1}{2} \left(1 + \frac{12H}{W} \right)^{-\frac{1}{2}} + F(\epsilon_r, H) - 0.217 (\epsilon_r - 1) \frac{T}{\sqrt{WH}} \quad (4.6)$$

Burada $F(\epsilon_r, H)$:

$$F(\varepsilon_r, H) = 0.02(\varepsilon_r - 1) \left(1 - \frac{W}{H}\right)^2, \quad W/H \leq 1 \quad (4.7.a)$$

$$0, \quad W/H > 1 \quad (4.7.b)$$

Karakteristik empedans (4.8)'de olduğu gibi ifade edilebilir:

$$Z_0 = \frac{\sqrt{\varepsilon_{\text{eff}}} \sqrt{\mu_0 \varepsilon_0}}{C} = \sqrt{\frac{\mu_0 \varepsilon_0}{\varepsilon_{\text{eff}}}} \frac{1}{C_a} \quad (4.8)$$

Dielektrik taban maddesi anizotropik olduğunda ise, kalınlık parametresi, H, efektif kalınlık, H_e ile değiştirilir ve dielektrik sabiti ε_r yerine geometrik ortalamaları, ε_g kullanılır:

$$H_e = \sqrt{\frac{\varepsilon_r}{\varepsilon_y}} H \quad (4.9)$$

$$\varepsilon_g = \sqrt{\varepsilon_r \varepsilon_y} \quad (4.10)$$

Dielektrik taban maddesi anizotropik olan mikroşerit iletim hattının efektif dielektrik sabiti, ε_{eff} :

$$\varepsilon_{\text{eff}} = \left[\frac{\varepsilon_g + 1}{2} + \frac{\varepsilon_g - 1}{2} \left(1 + 12 \frac{H_e}{W}\right)^{-\frac{1}{2}} + F(\varepsilon_g, H_e) \right] \frac{C_a(H_e)}{C_a(H)} \quad (4.11)$$

Bu ifadelerde yer alan dielektrik kalınlığı H ve dielektrik sabitleri $\varepsilon_r, \varepsilon_y$ 'ye şu aralıklarda değer verilmiştir: $0.1\text{mm} \leq H \leq 4\text{mm}$; $1 \leq \varepsilon_r, \varepsilon_y \leq 12.9$. Şerit genişliğinin değer aralığı ise $0.1\text{mm} \leq W \leq 4\text{mm}$ 'dir.

4.1.2 Analiz

$\mathcal{A}: \mathcal{M} \rightarrow \mathcal{T}$ eşlemlenmesinde, Z_0 and ε_{eff} 'in destek vektör regresyonu için, iki tip veri (4.4-4.11) formülasyonlarını kullanarak veri üretmek için yazılmış program kullanılarak üretilmiştir. Bunlar: Z_0 için (\mathcal{M}, Z_0) ve ε_{eff} için $(\mathcal{M}, \varepsilon_{\text{eff}})$. \mathcal{M} vektörü daha sonra 0-1 aralığında normalize edilerek DVR giriş verisi m elde edilir: $m = \mathcal{M} / \|\mathcal{M}\|$.

4.1.3 Sentez

$\mathfrak{S} : \mathcal{C} \rightarrow \mathcal{M}$ eşlemlenmesinde, analiz prosedüründe elde edilen ağırlık vektörünün kullanıldığı ters eğitim yapılmıştır. Ağırlık vektörü sabit kalırken W ve ΔW girdileri çıkışı hedefe yaklaştıracak şekilde değişmektedir. W için güncelleme eşitliği şu şekilde yapılmıştır:

$$W_{\text{yeni}} = W_{\text{eski}} + \Delta W \cdot \lambda \quad (4.12)$$

Bu ifadede (4.13)'de verilen uyarlamalı adım boyutu kullanılmıştır:

$$\lambda = e^{(-\frac{\tau}{E})} \quad (4.13)$$

τ uyarlama parametresi, E ise (4.14)'de yer alan karesel hatadır:

$$E = \frac{1}{2} (Z_o - Z_{\text{oref}})^2 \quad (4.14)$$

4.2 Destek Vektör Regresyonu

$\mathcal{C} \{Z_o, \varepsilon_{\text{eff}}\}$ 'nin regresyonu problemi şu şekilde özetlenebilir: Öncelikle Z_o 'ı ele alalım. Eğitim aşamasında L eğitim çifti $\{(m^0, Z_o^0), (m^1, Z_o^1), \dots, (m^{L-1}, Z_o^{L-1})\}$ bölüm 4.1.1'de belirtilen aralık içerisinde üretilir. Amaç, Z_o 'ın çeşitli giriş-çıkış örneklerinden \tilde{Z}_o fonksiyonunu bulmaktır. DVR ile \tilde{Z}_o şu şekilde ifade edilir:

$$\tilde{Z}_o(m) = \langle w, \varphi(m) \rangle + b \quad (4.15)$$

Burada $\langle \cdot, \cdot \rangle$ iç çarpım, φ ise giriş uzayı \mathcal{M} 'den çok boyutlu uzaya dönüşüm yapan doğrusal olmayan bir eşlemedir. Yani $\tilde{Z}_o(m)$, m -giriş uzayında doğrusal olmayan bir fonksiyon ve φ -özellik uzayında doğrusal bir fonksiyondur. w ve b sırası ile ağırlık vektörü ve bias olup birincil dışbükey amaç (Regresyon Risk) fonksiyonunu minimize ederek şu şekilde bulunur (Cristianini ve Shawe-Taylor, 2000):

$$R_{\text{reg}} = \frac{1}{2} \|w\|^2 + C \sum_{i=0}^{L-1} L^e(m, Z_o, \tilde{Z}_o) \quad (4.16)$$

Burada C düzenleme sabiti, $L^e(m, Z_o)$ genel kayıp fonksiyonudur. (4.16) eşitliğinde verilen amaç fonksiyonunun yerel minimumunun olmaması ve evrensel minimumu

garantilemesi DVM' nin YSA gibi diğer örüntü tanıma metotlarına olan üstünlüğüdür. Bu çalışmada Vapnik tarafından geliştirilen ε -duyarsız kayıp fonksiyonu kullanılmıştır (Vapnik, 1995):

$$L^\varepsilon(\mathbf{m}, Z_o, \tilde{Z}_o) = \begin{cases} 0, & \text{eger } |Z_o^i - \tilde{Z}_o(\mathbf{m}^i)| \leq \varepsilon \\ |Z_o^i - \tilde{Z}_o(\mathbf{m}^i)| - \varepsilon, & \text{aksi takdirde} \end{cases} \quad (4.17)$$

Bu fonksiyonda kayıp, eğer tahmin edilen değer tüpün dışında ise tahmin edilen değer ile tüpün ε yarıçapının farkı, içinde ise 0'dır. Vapnik (1995)'e göre, regresyon riskinin minimizasyonunu, vektörün \mathbf{m} giriş verisi cinsinden yazılabildiği çift optimizasyon problemi olarak yeniden düzenlenmesi ile mümkündür:

$$\mathbf{w} = \sum_{i=0}^{L-1} (\alpha_i - \alpha_i') \boldsymbol{\phi}(\mathbf{m}^i) \quad (4.18)$$

Burada α_i ve α_i' bilinmeyen Lagrange çarpanlarıdır. (4.18)'i (4.15)' e yerleştirsek, \tilde{Z}_o şu şekilde yazılabilir:

$$\begin{aligned} \tilde{Z}_o(\mathbf{m}) &= \sum_{i=0}^{L-1} (\alpha_i - \alpha_i') \langle \boldsymbol{\phi}(\mathbf{m}^i), \boldsymbol{\phi}(\mathbf{m}) \rangle + b \\ &= \sum_{i=0}^{L-1} (\alpha_i - \alpha_i') K(\mathbf{m}^i, \mathbf{m}) + b \end{aligned} \quad (4.19)$$

α_i , α_i' çarpanları ve b çift problemde regresyon riskini minimize edecek şekilde seçilmelidir. (4.19)' da, $K(\mathbf{m}^i, \mathbf{m}) = \langle \boldsymbol{\phi}(\mathbf{m}^i), \boldsymbol{\phi}(\mathbf{m}) \rangle$ kernel fonksiyonu \mathcal{M} orijinal uzayda çalışmaktadır. Polinom ve radyal kerneller sıklıkla kullanılan kernel tipleridir (Cristianini ve Shawe-Taylor, 2000). Lagrange çarpım tekniğini uygulayarak çift uzay amaç fonksiyonunun aşağıda yer alan eşdeğer maksimizasyon haline gelmesi sağlanır (Cristianini ve Shawe-Taylor, 2000):

$$\begin{aligned} W(\alpha, \alpha') &= -\varepsilon \sum_{i=0}^{L-1} (\alpha_i' + \alpha_i) + \sum_{i=0}^{L-1} Z_o^i (\alpha_i' - \alpha_i) \\ &\quad - \frac{1}{2} \sum_{i,j=0}^{L-1} (\alpha_i' - \alpha_i) (\alpha_i' + \alpha_i) K(\mathbf{m}^i, \mathbf{m}^j) \end{aligned} \quad (4.20)$$

Bu ifadenin kısıtlamaları şu şekildedir:

$$0 \leq \alpha_i', \alpha_i \leq C \quad (4.21.a)$$

$$\sum_{i=0}^{L-1} (\alpha_i' - \alpha_i) = 0 \quad (4.21.b)$$

α_i, α_i' çift değişkenleri ve b , (4.20)' nin Karush-Kuhn-Tucker durumlarını (Cristianini ve Shawe-Taylor, 2000) kullanarak ve (4.21.a), (4.21.b) kısıtlamalarına bağlı olarak maksimizasyonu ile elde edilir. Karush-Kuhn-Tucker durumlarından, sadece $|\tilde{Z}_o(m^i) - Z_o^i| \geq \varepsilon$ ise Lagrange çarpanlarının sıfırdan farklı olduğu görülmektedir. Diğer bir deyişle ε - tüpün içindeki tüm örneklerde ($\Leftrightarrow |\tilde{Z}_o(m^i) - Z_o^i| < \varepsilon$) α_i, α_i' çarpanları yok olmaktadır. Böylece w ' nun m^i cinsinden seyrek dağılımı elde edilir. Yok olmayan çarpanlarla gelen örnekler destek vektörleridir. Çözümün eğitim verilerinin küçük bir alt kümesi ile ifade edilmesi hesaplamada büyük avantajları beraberinde getirir. Azaltılmış sayıda sıfır olmayan parametre ve garantilenmiş evrensel minimum DVM' nin alternatif metotlara göre üstünlüğüdür. DVM' nin detaylı matematiksel teorisi ve literatürü (Cristianini ve Shawe-Taylor, 2000)'de yer almaktadır.

Düzenleştirme parametresi C, mikroşerit hattın karakteristik empedansının eğitim verilerinin kullanılması ile bulunmasındaki başarısını ifade etmede kullanılan bir parametredir. Z_o ' ın (4.4) - (4.11) formülasyonları ile belirlenmesinde L adet veri çifti eğitim aşamasında izotropik ve anizotropik dielektrik maddeler için şu şekilde üretilmiştir: $\{(m^0, Z_o^0), (m^1, Z_o^1), \dots, (m^{L-1}, Z_o^{L-1})\}$. Eğitim aşamasından sonra, teste eğitim kümesinde yer almayan yeni mikroşerit yapıları için Z_o belirlenebilmektedir. Benzer olarak DVR ε_{eff} ' in regresyonuna da uyarlanabilir. DVR analiz ve ters modelleme ile sentezin sayısal detaylarına bir sonraki bölümde yer verilmiştir.

4.3 Sayısal Sonuçlar

4.3.1 Mikroşerit Hatların DVR Analizi

Bu uygulamada genişlik parametresi (γ) 0.1 olan radyal tabanlı kernel kullanılmıştır:

$$K(m^i, m) = \exp(-\gamma \|m - m^i\|^2) \quad (4.22)$$


Düzenleştirme parametresi, C, ise 1 olarak seçilmiştir. DVR'ın eğitimi için 886 veri çifti dielektrik maddeler $0.1\text{mm} \leq H \leq 4\text{mm}$; $1 \leq \varepsilon_x, \varepsilon_y \leq 12.9$ aralığında, şerit genişliği $0.1\text{mm} \leq W \leq 4\text{mm}$ aralığında olacak şekilde üretilmiştir. Ayrıca test için eğitim kümesinde


yer almayan 120 adet veri çifti üretilmiştir. Çizelge 4.1'den görüldüğü gibi karakteristik empedansın eğitiminde 466 destek vektörü ile %99.26 doğruluk, efektif dielektrik sabitinin eğitiminde ise 479 destek vektörü ile %99.46 doğruluk elde edilebilmektedir. Bu çizelgedeki değerler $\varepsilon = 0.1$ seçilerek elde edilmiştir.

Çizelge 4.1 DVR'nin Z_o ve ε_{eff} için performans parametreleri.


$\varepsilon = 0.1$	Z_o	ε_{eff}
DV sayısı (%)	52.59	54.06
Geçen süre (ortalama sn)	0.5	0.5028
Doğruluk (%)	99.26	99.46


Z_o ve ε_{eff} fonksiyonlarının ε parametresi ile DV sayısı ve doğruluğunun değişimi $0.1 \leq \varepsilon \leq 50$ aralığında incelenmiş ve Şekil 4.3.a ve b' de grafiksel olarak verilmiştir. Benzer olarak (4.17)'de yer alan ε parametresinin DV sayısı ve hesaplama süresi üzerindeki etkisi Şekil 4.4.a ve b' de sırası ile Z_o ve ε_{eff} için verilmiştir.





Şekil 4.3 Mikroşerit hat (a) karakteristik empedansı; (b) efektif dielektrik sabiti için ϵ parametresi ile DV sayısı ve doğruluğun değişimi.





Şekil 4.4 Mikroşerit hat (a) karakteristik empedansı; (b) efektif dielektrik sabiti için ϵ parametresi ile DV sayısı ve hesaplama süresinin değişimi.

Şekil 4.3 ve 4.4' den görüldüğü gibi uygun ϵ parametresi seçimi ile yüksek doğruluk düşük sayıda DV ile kısa sürede elde edilebilmektedir. Bu çalışmada DVR' nin performansı popüler bir öğrenen makine olan YSA ile karşılaştırılmıştır. Bu amaçla iki tip çok katmanlı algılayıcı (ÇKA) yapısı Şekil 4.2.a ve b' de verilen kara-kutu modellerinde kullanılmıştır. ÇKA yapılarından ilki 7 nörona sahip bir gizli katmana, ikincisi ise sırası ile 7 ve 4 nörona sahip iki gizli katmana sahiptir. Her iki ÇKA, hiperbolik tanjant sigmoid ve lineer transfer fonksiyonları ile aktive edilmiş ve Levenberg-Marquardt geri yayılım algoritması ile eğitilmişlerdir. Öğrenme oranı 0.1 olup DVR için üretilen veri kümeleri kullanılmıştır. Doğruluk ve hesaplama verimliliği Çizelge 4.2 ve 4.3'de DVR ile karşılaştırmalı olarak yer almaktadır.

Çizelge 4.2 YSA ve DVR modellerinin doğruluğu.

% Doğruluk	YSA 1*	YSA 2**	DVR
Z_o	97.64	99.13	99.26
ϵ_{eff}	98.12	99.55	99.46

* bir saklı katmana sahip ÇKA

** iki saklı katmana sahip ÇKA

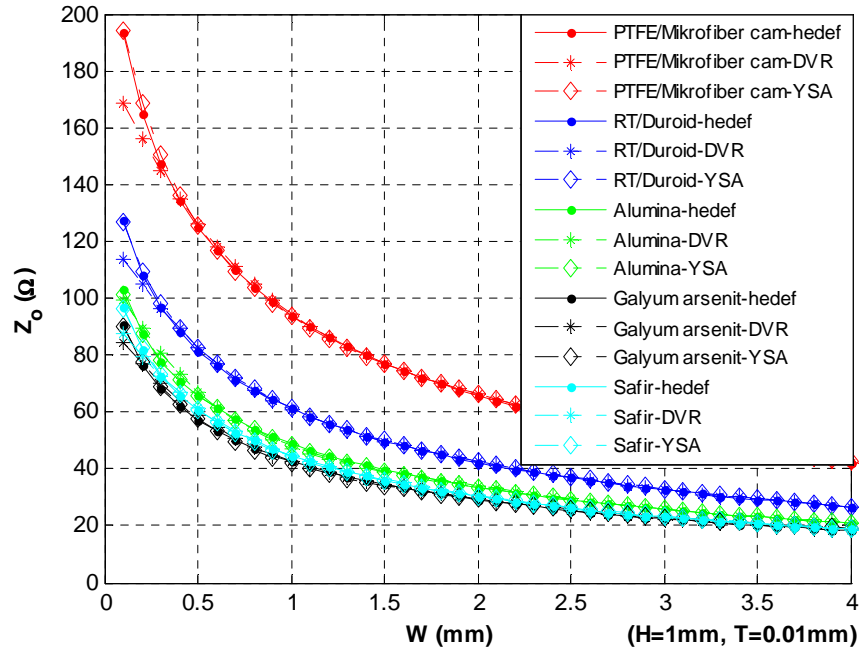
Çizelge 4.3 YSA ve DVR modellerinin zaman analizi.

	YSA 1	YSA 2	DVR
Eğitim süresi (sn)	27.953*	44.156*	1.015
Test süresi (sn)	0.015	0.017	0.013
Toplam süre (sn)	27.968	44.173	1.028


*300 adımda eğitilmiştir.

4.3.1.1 Mikroşerit İletim Hattı DVR Analiz Modeli ile Gerçeklenen Örnekler:

Mikroşerit iletim hattının Z_o ve ϵ_{eff} 'nin analiz örnekleri Şekil 4.5.a and b' de en yaygın kullanılan izotropik ve anizotropik dielektrik maddeler için verilmiştir. Bu maddeler $\epsilon_r = 2.26$ ve $\epsilon_y = 2.2$ ile PTFE/mikrofiber cam, $\epsilon_r = 6.36$ ve $\epsilon_y = 6$ ile RT/Duroid 6006, $\epsilon_r = 9.7$ ile alumina, $\epsilon_r = 9.4$ ve $\epsilon_y = 11.6$ ile safir ve $\epsilon_r = 12.9$ ile galyum arsenittir.



(a)



(b)

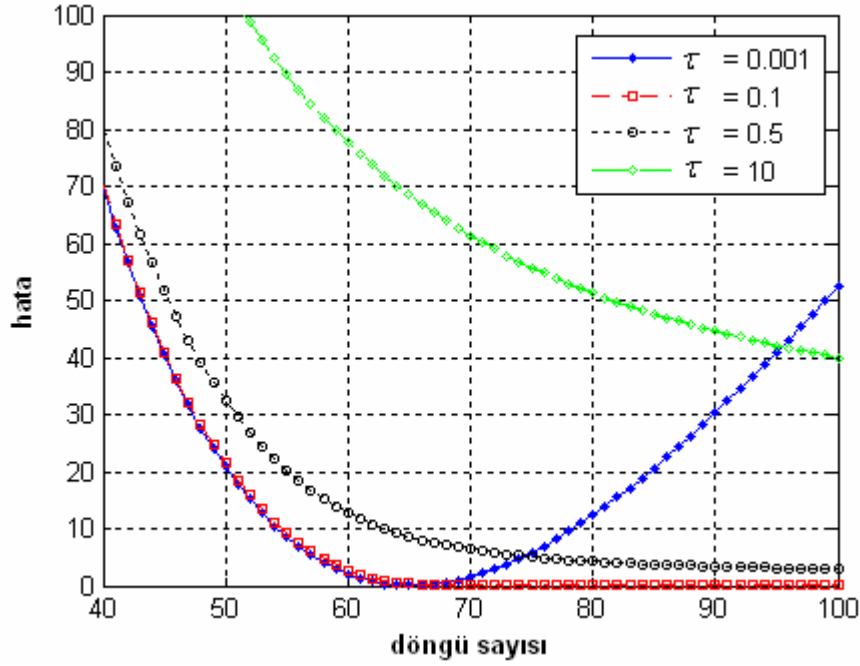
Şekil 4.5 (a) Karakteristik empedansın; (b) Efektif dielektrik sabitinin şerit genişliği ile değişimi.

4.3.2 Mikroşerit Hatların Ters Modelleme ile Sentezi

Pratik uygulamalarda genellikle belirlenen bir dielektrik madde (H , T , ϵ_r , ϵ_y) üzerinde belli bir Z_o için şerit genişliği W 'nin belirlenmesi talep edilmektedir. Bu çalışmada, bu sentez problemi analiz modelinin ters eğitimi ile sağlanmıştır. Bu işlem esnasında analiz parametreleri ve ağırlıkları sabit kalmaktadır. W ve ΔW giriş değişkenleri hedef karakteristik empedansı (Z_{oref}) bulacak şekilde güncellenmektedir. Uyarlanabilir adım boyutu kullanılarak yapılan bu güncelleme işlemi (4.12) – (4.14) eşitlikleri kullanılarak (4.23)' e dönüştürülebilir:

$$W_{\text{new}} = W_{\text{old}} + \Delta W \cdot e^{-\frac{\tau}{2(Z_o - Z_{oref})^2}} \quad (4.23)$$

DVR modellemesinde adaptasyon parametresi τ ' nun etkileri Şekil 4.6' da verilmiştir. Şekil 4.6' dan sistemin τ ' ya bağlı değişimi incelenerek τ , DVR sentez modellemesi için 0.1, YSA sentez modellemesi için 0.3 olarak seçilmiştir. Ayrıca sabit ve uyarlanabilir adım boyutunun performansı DVR ve YSA için Çizelge 4.4' de verilmiştir. Çizelge 4.4'den görülebileceği gibi uyarlanabilir adım boyutu ile işlem 20-70 kat hızlı olarak yapılabilmektedir.



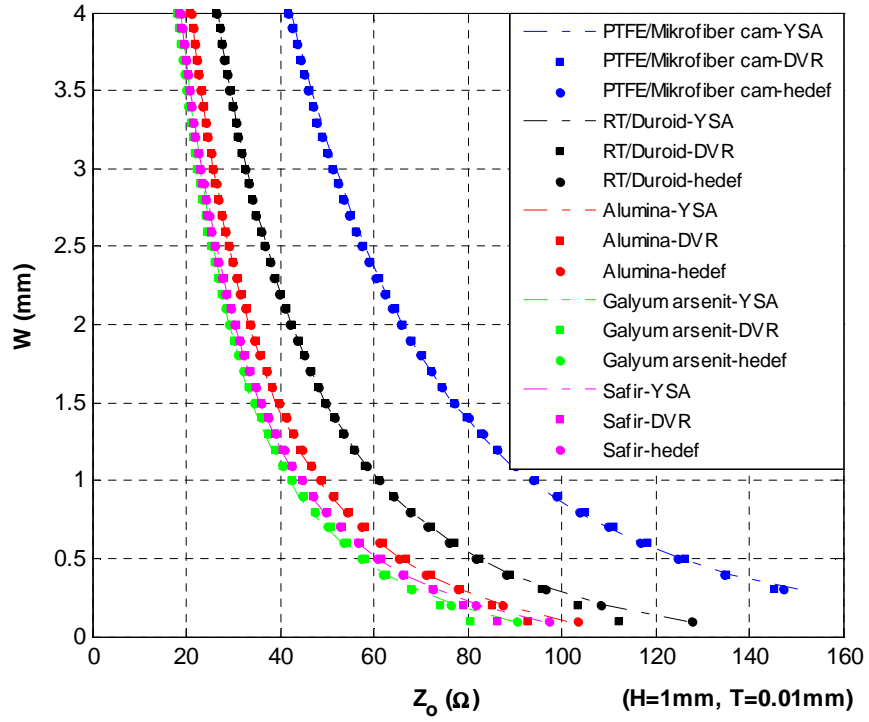
Şekil 4.6 DVR modellemesinde çeşitli adaptasyon parametreleri için hatanın döngü sayısı ile değişimi.

Çizelge 4.4 Sabit ve uyarlanabilir adım boyutunun performanslarının karşılaştırılması.

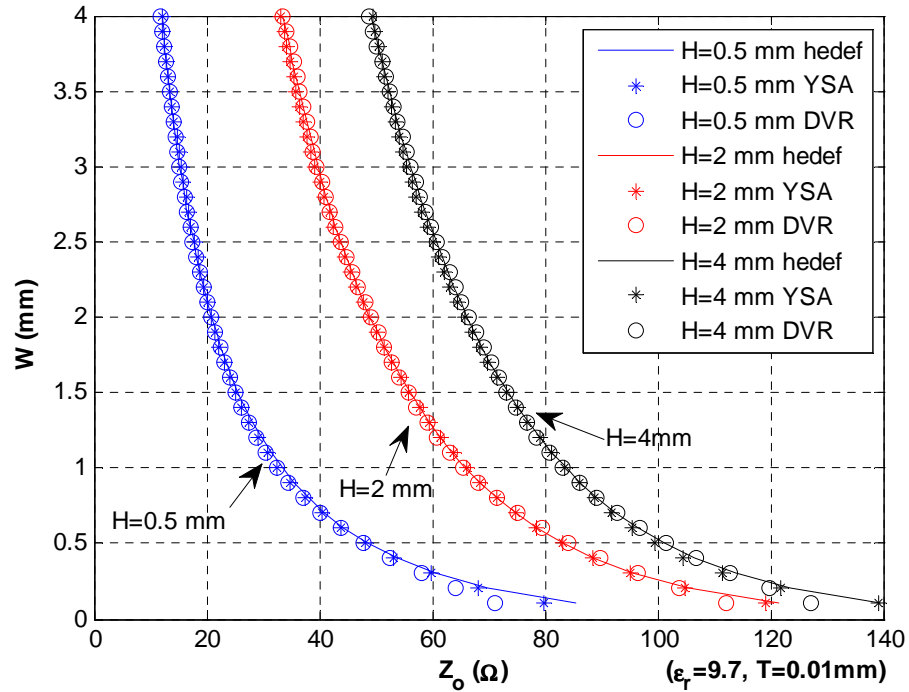
	Sabit adım boyutu			Uyarlanabilir adım boyutu		
	W (mm)	Z _o (Ω)	Hesaplama süresi (sn)	W (mm)	Z _o (Ω)	Hesaplama süresi (sn)
DVR	3.658	42.93	11.234	3.646	43	0.45
YSA	3.625	43.13	36.188	3.612	43.19	0.64

4.3.2.1 Mikroşerit İletim Hattı DVR Sentez Modeli ile Gerçeklenen Örnekler:


Sentez işleminde şerit genişliği W, Şekil 4.7 ve 4.8’ de verildiği gibi 15-170Ω karakteristik empedans değerleri için en yaygın kullanılan izotropik ve anizotropik maddeler için belirlenmiştir. Şekil 4.7’ de dielektrik madde kalınlığı ve şerit kalınlığı sabit tutulmuş (H=1mm, T=0.01mm) ve şerit genişliğinin karakteristik empedans ile değişimi incelenmiştir. Şekil 4.8. a ve b’de ise şerit genişliğinin karakteristik empedans ile değişimi izotropik alumina ve anizotropik RT/Duroid 6006 dielektrik maddeleri için sabit şerit kalınlığında farklı dielektrik madde kalınlıkları için incelenmiştir.



Şekil 4.7 Şerit genişliğinin karakteristik empedans ile değişimi.



(a)



(b)

Şekil 4.8 Farklı kalınlıklarda (a) izotropik; (b) anizotropik dielektrik maddeye sahip mikroşerit hatların şerit genişliğinin karakteristik empedans ile değişimi.

4.4 Sonuç

Bu çalışmanın literatüre katkıları şu şekilde özetlenebilir: (1) DVR'yi mikrodalga teknolojisine mikroşerit iletim hatlarının DV modelini oluşturarak tanıtmak amaçlanmıştır. Bunun için öncelikle problem tanımlanmış ve matematiksel olarak formüle edilmiş; sonrasında ise destek vektör regresyonuna adapte edilerek Vapnik' in ε - parametresi ile doğruluk, hesaplama verimi ve destek vektör sayısı detaylı olarak incelenmiştir. DVR performansı en yakın rakibi YSA ile karşılaştırılmıştır. DVR'nin yüksek yaklaşıklama kapasitesi ve seyreklik özelliğinden dolayı çok daha hızlı yakınsaması sebebiyle regresyon uygulamalarında YSA'nın yerini alabileceği gösterilmiştir. (2) Problemi tanımlayan karakutunun iki yönlü kullanılması ile analiz ve sentezin sadece analiz kara-kutusu kullanılarak yapılabileceği gösterilmiştir. Bu çalışmada bu izotropik ve anizotropik dielektrik maddeye sahip mikroşerit hatlara uyarlanmıştır. Diğer tip mikrodalga sistemlere uyarlamak mümkündür. Ayrıca uyarlanabilir adım boyutu kullanılarak çok daha hızlı yakınsama elde edilmiştir.

5. MİKROŞERİT ANTENLERİN ÖLÇÜM SONUÇLARINA DAYANDIRILMIŞ DESTEK VEKTÖR KARAKTERİZASYONU

Uzay aracı, uçak, füze ve uydu uygulamalarında boyut, ağırlık, fiyat, yerleştirme kolaylığı ve aerodinamik gibi sınırlamalara sahip düşük profilli antenler gerekmektedir. Günümüzde mobil radyo ve kablosuz iletişim gibi benzer gereksinimlere sahip pek çok ticari uygulamalar mevcuttur. Bu gereksinimleri karşılamak amacıyla mikroşerit antenler kullanılabilir (Balanis, 1997). Bu antenler düşük profilli, düzlemsel ve düzlemsel olmayan yüzeylerle uyumlu, modern baskı teknikleri ile üretimi basit ve ucuz, sert yüzeyler üzerine monte edildiğinde mekanik olarak sağlam, MMIC tasarımları ile uyumlu ve uygun şekil ve mod seçildiğinde rezonans frekansı, polarizasyon, patern ve empedans açısından oldukça kullanışlıdır. Buna ek olarak, yama ve yer düzlemi arasına değişken rezonans frekansa sahip adaptif elemanlar yük olarak eklenerek empedans, polarizasyon ve patern ayarlanabilmektedir (Bahl ve Bhartia, 1980).

Mikroşerit antenler dielektrik taban maddesi üzerine monte edilmiş iletken madde (yama) sebebiyle “yama antenler” olarak adlandırılır. Yama kare, dikdörtgen, çember, eliptik, üçgen veya herhangi bir geometrik şekilde oluşturulabilir. Bu çalışmada, en yaygın kullanılan dikdörtgen mikroşerit antenler ele alınmaktadır (Şekil 5.1). Dikdörtgen mikroşerit antenler, genellikle patern maksimumu yama düzlemine dik olacak şekilde tasarlanır. Bu tip antenlerin rezonans frekansı civarındaki dar bant içinde verimli olarak çalıştırılabilmesi nedeni ile, talep edilen rezonans frekansı için yama boyutlarının seçimi önemli bir anten sentez problemidir.


Anten mühendisliğinde, yama antenlerin rezonans frekansı, bant genişliği ve giriş empedansının hesaplanmasında iki farklı analiz yaklaşımı mevcuttur: İlk yaklaşım antenin iletim hattı modeli ya da kovuk modeli oluşturulup, basit analitik formüller ile çalışma parametrelerinin hesaplanmasıdır ve fiziksel bir görüş verir. Alternatif yaklaşım, anteni bir elektromagnetik sınır problemi olarak ele alıp ya spektral domende ya da uzay domeninde Green fonksiyonlarını kullanarak moment metodu ile çözmeyi içerir. Bu yaklaşım sağlam bir elektromagnetik bilgiye sahip olmayı gerektirir. Bu çözüm uzun sürer ve kolaylıkla bilgisayar destekli tasarıma aktarılamaz. Literatürde bu iki yaklaşımla da elde edilen teorik değerlerin dikdörtgen mikroşerit antenin deneysel sonuçları ile pek uyumlu olmadığı görülmüştür (Sağiroğlu vd., 1999; Güney vd., 2000). Bu sebeplerden dolayı, bu çalışmada, ölçmeye dayandırılan bir modelleme yaklaşımı kullanılmıştır. Böylece en ağır teoride bile hesaba katılmayan faktörlerin hesaba alınabilmesi mümkün olabilecektir. “N” ayrık ölçme verisini, çalışma domeninde genelleştirebilmek için, sağlam matematiksel temeller ile geliştirilmiş bir

doğrusal olmayan öğrenen makine olan destek vektör makineleri kullanılmıştır (Vapnik-Chervonenkis teorisi (Vapnik, 1995; Cristianini ve Shawe-Taylor, 2000)). Bu öğrenen makineler bilim ve mühendislik alanında, özellikle işaret işleme konusunda yaygın uygulamalara sahiptir.

Sıradaki bölümde mikroşerit antenin tasarımı ve kara-kutu modellerinin tanımlanmasına yer verilmiştir. Sonuçlar bölümünde ise DVM modellerinin sonuçları, deneysel sonuçlar, YSA sonuçları ve literatürde mevcut teorik yöntemlerin sonuçları tablolar halinde yer almaktadır.

5.1 Mikroşerit Antenin Tasarım Problemi

5.1.1 Dikdörtgen Mikroşerit Antenler




Şekil 5.1 Dikdörtgen mikroşerit anten.

Dikdörtgen mikroşerit antenler, Şekil 5.1’ de verildiği gibi W genişliğine, L uzunluğuna sahip dikdörtgen yamanın yer düzlemi üzerinde yer alan h kalınlığına, ϵ_r dielektrik sabitine sahip dielektrik madde üzerine yerleştirilmesi ile yapılırlar.


5.1.2 Rezonans Frekansı, Band Genişliği ve Giriş Empedansı Kara-Kutu Modelleri

Bant genişliği ve giriş empedansı kara-kutu modellerinin eğitiminde deneysel sonuçlardan elde edilmiş 27 veri çifti kullanılmıştır. Model performansı eğitim kümesinde yer almayan 6 veri çifti ile test edilmiştir. Benzer şekilde rezonans frekansı kara-kutu modeli eğitiminde 37

veri çifti, testinde 9 veri çifti kullanılmıştır. Eğitim ve test aşamalarında giriş değerleri 0-1 aralığında normalize edilmiştir. Şekil 5.2 ve 5.3'de sırası ile giriş empedansı ve bant genişliği ile rezonans frekansı kara-kutu modeli yer almaktadır.



Şekil 5.2 Giriş empedansı ve bant genişliği hesaplamasında kullanılan kara-kutu modeli.



Şekil 5.3 Rezonans frekansı hesaplamasında kullanılan kara-kutu modeli.

DVM uygulamasında radyal tabanlı kernel kullanılmıştır. Genişlik parametresi γ , optimum performans için 0.1 olarak seçilmiştir. Benzer olarak düzenleme parametresi, C, 1 olarak seçilmiştir. R_{in} fonksiyonunun eğitiminde 27 veriden 24'ü, BG fonksiyonunun eğitiminde 27 veriden 22'si ve f_r fonksiyonunun eğitiminde 37 veriden 31'i ($\Leftrightarrow \varepsilon = 0.1$) destek vektörü olarak hesaba katılmıştır. DVR'nin performansı bir diğer öğrenen makine olan YSA ile karşılaştırılmıştır. Bu amaçla Şekil 5.2 ve 5.3'de yer alan kara-kutular için iki ayrı ÇKA kullanılmıştır. R_{in} ve BG YSA modeli, birinci gizli katmanında 5, ikinci gizli katmanında 4, çıkış katmanında ise 2 nörona sahiptir. f_r YSA modeli ise birinci gizli katmanında 4, ikinci gizli katmanında 3, çıkış katmanında ise 1 nörona sahiptir. İki YSA modeli de hiperbolik tanjant ve lineer transfer fonksiyonları ile eğitilmiştir. Levenberg-Marquardt geri yayılım algoritması 0.1 öğrenme oranı ile kullanılmıştır.

5.1.3 Rezonans Frekansı, Band Geniřlięi ve Giriř Empedansı DVR ve YSA Sonuęları

Bu üç fonksiyonun DVR ve YSA regresyon doęruluk oranları izelge 5.1' de yer almaktadır. DVR' nin YSA'ya oranla en byk stnlę eęitim sresinin ok daha kısa olmasıdır. DVR ve YSA kara-kutu modellerinin f_r fonksiyonunun regresyonu iin zaman analizi izelge 5.2' de yer almaktadır. izelge 5.3-5.5' de dikdrtgen mikrořerit antenin f_r , BG ve R_{in} test verilerinin DVR sonucunun hedef deęerleri, YSA sonucu ve dięer teorik yntemlerle karřılařtırılması yer almaktadır.

izelge 5.1 R_{in} , BG ve f_r fonksiyonlarının test doęruluk oranları.

% doęruluk	DVR	YSA
R_{in}	99.8	98.87
BG	97.85	98.81
f_r	98.79	98.33

izelge 5.2 f_r fonksiyonunun regresyon zaman analizi.

(* 300 iterasyonda eęitilmiřtir.)	DVR	YSA*
Eęitim sresi (sn)	0.047	4.06
Test sresi (sn)	0.012	0.045
Toplam sre (sn)	0.059	4.105

izelge 5.3 Dikdrtgen mikrořerit antenin giriř empedansı DVR sonucunun hedef deęerleri, YSA sonucu ve dięer teorik yntemlerle karřılařtırılması.

h / λ_d	W	L	a	$\tan \delta$	$R_{\text{ö}}$	R_{YSA}	R_{DVR}	$R_{\text{(Carver, 1979)}}$	$R_{\text{(Güney, 1994a)}}$	$R_{\text{(Kara, 1996a)}}$
0.0384	18.1	19.6	6.27	0.001	58	57.24	58.09	83.7	63.2	36.2
0.066	13.37	14.12	4.75	0.002	52	51.48	51.89	67.9	57.4	36.9
0.1292	13.75	15.8	5.82	0.002	44	43.31	43.90	47.4	49	51.5
0.1475	10	15.2	3.45	0.002	45	44.49	45.10	310.1	228.3	46.4
0.1814	12.56	27.56	3.2	0.002	46	46.56	46.09	1041.6	508	45
0.2182	10.3	33.8	3.6	0.002	47	46.76	47.09	2488.8	785.9	46.5

Çizelge 5.4 Dikdörtgen mikroşerit antenin bant genişliği DVR sonucunun hedef değerleri, YSA sonucu ve diğer teorik yöntemlerle karşılaştırılması.

h/λ_d	W	L	a	$\tan \delta$	$BG_{\text{ö}}$	BG_{YSA}	BG_{DVR}	$BG_{\text{(Carver ve Mink, 1981)}}$	$BG_{\text{(Güney, 1994b)}}$	$BG_{\text{(Kara, 1996b)}}$
0.0384	18.1	19.6	6.27	0.001	4.9	4.73	4.99	3.96	2.2	6.17
0.066	13.37	14.12	4.75	0.002	7.7	7.66	7.79	7.29	4.2	9.16
0.1292	13.75	15.8	5.82	0.002	15.9	15.83	14.93	18.06	10.5	15.11
0.1475	10	15.2	3.45	0.002	18	17.83	17.68	14.08	11.8	17.47
0.1814	12.56	27.56	3.2	0.002	20	19.85	19.89	10.10	14.54	19.66
0.2182	10.3	33.8	3.6	0.002	21.6	21.16	21.91	7.11	16.95	21.73

Çizelge 5.5 Dikdörtgen mikroşerit antenin rezonans frekansı DVR sonucunun hedef değerleri, YSA sonucu ve diğer teorik yöntemlerle karşılaştırılması.

W	L	h	ϵ_r	$f_{r\text{ö}}$	$f_{r\text{YSA}}$	$f_{r\text{DVR}}$	f_r (Howell, 1975)	f_r (Hammerstad, 1975)	f_r (Carver, 1979)	f_r (Bahl ve Bhartia, 1980)	f_r (James, 1981)
1.81	1.96	0.157	2.33	4805	4782	4829	5014	4635	4749	4824	4520
1.337	1.412	0.2	2.55	6200	6218	6209	6653	5845	6053	6201	5682
1.375	1.580	0.476	2.55	5100	4923	5143	5945	4667	4993	5092	4407
1	1.52	0.476	2.55	5820	5889	5840	6180	4855	5423	5352	4576
1.256	2.756	0.952	2.55	3580	3765	3618	3408	2668	3115	2983	2485
1.03	3.38	1.281	2.55	3200	3169	3178	2779	2183	2623	2474	1992
1.7	1.1	0.3175	2.33	6800	6876	6628	8933	6958	6806	7405	6467
6.858	4.14	0.152	2.5	2200	2301	2266	2292	2208	2204	2241	2158
0.79	1.185	0.017	2.22	8450	8538	8286	8496	8369	8431	8478	8298

5.2 Sonuç

Bu çalışmada esas olarak “N” ölçme verisine dayandırılmış, bir mikrodalga anten karakterize edilmiştir. Ölçme temelli bir metot olduğu için, teoride hesaba alınamayan faktörlerin de hesaba katılması sağlanmıştır. Aynı zamanda, günümüzün en geliştirilmiş doğrusal olmayan öğrenme makinesi olan “Destek Vektör Makineleri (DVM)” nin anten mühendisliğine önemli bir uygulaması da demonstre edilmiştir. DVM, en yakın rakibi YSA ile karşılaştırılarak, üstünlükleri vurgulanmıştır.

6. RF/MİKRODALGA DÜZLEMSEL İLETİM HATLARININ BİLGİ-TABANLI DESTEK VEKTÖR SENTEZİ

Elektronik endüstrisindeki üretilebilir tasarım gereksinimi ve kısa pazarlama süresi talebi, artan devre karmaşıklığı ve frekans ile birleşince tasarım aşamasında güçlü bilgisayar destekli tasarım metodolojilerini gerekli kılmaktadır (Zhang ve Gupta, 2000; Steer vd., 2002). Yüksek-frekanslarda bilgisayar-destekli tasarım için modelleme halen büyük zorluk olarak görülmektedir (Gupta, 1998). Bilgisayar bilimlerindeki gelişmeler günümüzde ayrık veriyi sürekli veriye dönüştürebilen öğrenen makineleri mümkün kılmıştır. Günümüzde yapay sinir ağları ve destek vektör makineleri doğrusal olmayan giriş-çıkış ilişkisine sahip ayrık veriyi genelleyebilen hızlı ve esnek makineler olarak kullanılmaktadır. Her iki tip öğrenen makine yaklaşık modeller kadar hızlı olup detaylı EM modeller kadar doğru cevap verebilir. Bu da bilgisayar destekli tasarımda öğrenen makinelerin kullanımını faydalı bir alternatif haline getirir. Fakat öğrenen makinelerin doğruluğu daha çok eğitim verisinin seçimine bağlıdır. Eğitim verisi ölçüm ya da simülasyon ile elde edilebilir. Yüksek doğruluğa sahip eğitim verisinin üretimi hem işlemci zamanı (detaylı model hesaplamaları) hem de insan zamanı (giriş alanında parametre değişimi) aldığı için külfetlidir ve model tasarımını geciktirir. EM-YSA alanında model gelişim zamanını azaltılmış sayıda yüksek doğruluklu veri kullanarak minimuma indirecek yöntemler üzerine çalışılmaktadır. Bu yöntemler aynı zamanda harcanan insan zamanını da azaltacaktır. Yüksek doğruluğa sahip eğitim verisine olan ihtiyacı azaltan bazı yöntemler geliştirilmiştir. Bunlar şu şekilde özetlenebilir: Bilgi-tabanlı yapay sinir ağları (Wang ve Zhang, 1997), fark metodu (Watson vd., 1999), önsel-bilgi girdili ağlar (Jargon vd., 2002) ve uzay eşlemlmeli sinir ağları (Bakr vd., 2000; Devabhaktuni vd., 2001; Bandler vd., 2002). (Devabhaktuni vd., 2003)' de bilgi-tabanlı otomatik model üretimi tekniği ile çoklu veri üretici ve bilgili sinir ağlarını kullanarak az sayıda yüksek doğruluğa sahip eğitim verisi ile yüksek doğruluk elde edilmiştir.

Bu çalışmada, literatürde ilk olarak, bilgi-tabanlı destek vektör makinesi tasarlanmış ve bu metod tektaş ya da hibrit mikrodalga tümleşik devrelerinde kullanılan RF/Mikrodalga düzlemsel iletim hatlarının sentezinde kullanılmıştır. Bu yaklaşımda analiz işlemini tersine çeviren genel bir sentez metodu tanıtılmıştır. Bu sentez metodunun kaba modeller kadar hızlı, hassas modeller kadar yüksek doğruluklu olması amaçlanmıştır. Bu sebeple DVM metodu seçilmiştir. Bunun sebebi DVM' nin çalışma prensibinin eğitim verisinde seyrekliğe yol açarak azaltılmış sayıda eğitim verisi ile aynı fonksiyonu çok daha kısa sürede gerçekleyebilmesidir. Bu çalışmada tasarlanan bilgi-tabanlı DVR metodu iki ayrı örnekle

tanıtılmıştır. İlk örnekte sentez işlemi için yüksek doğruluğa sahip eğitim ve test verisi iki aşamada elde edilmiştir. Öncelikle yüksek doğruluğa sahip analiz verisi, sağlam matematiksel yaklaşımlar kullanılarak elde edilmiş detaylı analitik analiz ifadelerinden elde edilmiştir. Sentez verisi ise analiz verisinin giriş-çıkış ilişkisinin sentez probleminin tanımına uygun olarak düzenlenmesi ile elde edilmiştir. DVR bu şekilde elde edilen sentez verisine uygulanarak sentez formülasyonu elde edilmiştir. İkinci örnekte kaba ve hassas veri üreticilerin kullanımı ile kaba ve hassas DVRM sentez modelleri tasarlanmıştır. Kaba veri üreticinin yaklaşık sonuçları hızlı vermesinden dolayı tüm giriş uzayını kapsayan bir eğitim veri kümesi oluşturulmuş ve DVRM kaba sentez modelinin eğitiminde kullanılmıştır. Bu modelin eğitiminden elde edilen DVler, hassas veri üreticisine girdi olarak verilerek azaltılmış sayıda yüksek doğruluğa sahip yeni eğitim kümesi elde edilmiştir. Son olarak elde edilen eğitim kümesi ile DVRM hassas sentez modeli eğitilmiş ve yüksek doğruluğa sahip sonuçları çok kısa bir sürede verebilen bilgi-tabanlı DVRM sentez modeli oluşturulmuştur. Her iki örneğin sonuçları da yapay sinir ağlarının sonuçları ile karşılaştırılmıştır. Bu çalışma şu şekilde düzenlenmiştir: Sıradaki bölümde RF/Mikrodalga düzlemsel iletim hatlarının analizi ve sentezi genel olarak tanımlanmıştır. 6.2 bölümünde gerçekleştirilen örnekler tanıtılmış ve sonuçları verilmiştir. Son bölümde ise çalışmanın genel sonuçlarına yer verilmiştir.

6.1 RF/Mikrodalga Düzlemsel İletim Hatlarının Analiz ve Sentez Tanımı

RF/Mikrodalga düzlemsel iletim hatlarının analiz ve sentezinde temelde iki tip parametre kümesi vardır: M - Uzayı ve T - Uzayı. M - Uzayı iletim hattında dalganın yayılımı ile ilgili tüm parametreleri içerir ve şu şekilde karakterize edilebilir:

$$M = [D, \varepsilon, f] \in R^n \quad (6.1.a)$$

Burada D seçilen düzlemsel iletim hattının geometrik yapısını tanımlayan geometri vektörüdür ve şu şekilde ifade edilebilir:


$$D = [W, S, H, H_1] \quad (6.1.b)$$

Burada H, H_1 dielektrik taban maddesinin ve ekranlamanın kalınlıkları, W ve S ise Şekil 6.1' de iletken sırtlı üstü ekranlanmış Eşdüzlemlili Dalga Kılavuzu (EDDK) için verilen hat boyutlarıdır. M - uzayında, ε dielektrik sabiti vektörü ve f işlem frekansıdır. Benzer olarak, T - uzayı, eşdeğer iletim hattının temel parametreleri olan karakteristik empedansı ve efektif dielektrik sabitini içermektedir:

$$T = [Z_o, \varepsilon_{eff}] \in R^2 \quad (6.2)$$


Buradan iletim hattının analiz ve sentezi M - ve T - uzayları arasında şu şekilde verilebilir:

$$A: M(R^n) \Rightarrow T(R^2) ; S: T(R^2) \Rightarrow M(R^n) \quad (6.3)$$




Şekil 6.1 En yaygın kullanılan RF/Mikrodalga düzlemsel iletim hatlarının genel geometrik yapısı.

Uygulamada sentez, genellikle Şekil 6.2’de verildiği gibi belli bir karakteristik empedans Z_o ve dielektrik madde ε için geometrik yapıyı belirlemek olarak tanımlanabilir. Bu çalışmada sentez işlemi iletken sırtlı üstü ekranlanmış eşdüzlemlı dalga kılavuzu (EDDK) ve mikroşerit iletim hatlarına uygulanmıştır. DVR hakkında bilgiye tezin 2. bölümde yer verilmiştir. Bu bölümde DVR’ nin matematiksel temellerine değinilmeyecektir.



(a)



(b)

Şekil 6.2 (a) Analiz; (b) Sentez kara-kutu modeli.

6.1.1 RF/Mikrodalga Düzlemsel İletim Hatlarının Bilgi-Tabanlı Destek Vektör Sentezi

Bu çalışmada düzlemsel iletim hatlarının bilgi-tabanlı DVRM sentez modeli oluşturulmuştur. Bu iletim hatları mikrodalga tümleşik devrelerinde kullanılacağından dolayı bu yaklaşım kuvazi-statik frekans aralığında geçerliliğe sahiptir. Bilgi yükleme iki ayrı yöntem kullanılarak yapılmış, bu yöntemler iki ayrı örnekle tanıtılmıştır. İlk örnekte iletken sırtlı üstü ekranlanmış EDDK'nın bilgi-tabanlı DVM sentez modeli sağlam matematiksel analiz formülasyonuna dayalı olarak oluşturulmuştur. İkinci örnekte, mikroşerit iletim hatlarının sentezinin DV açılımı kaba model verilerini kullanarak yapılmıştır. Kaba DVRM modelinden elde edilen DVler bir elektromagnetik simülatör yardımı ile hassas model ile eşleştirilmiştir.

6.2 Uygulamalar

6.2.1 Kara-Kutu Modellerinin Hata Analizi

Hedef verisi ile tahmin edilen değer arasındaki doğruluğu hesaplayabilmek için ve DVRM ve YSA modellerinin performansını kıyaslayabilmek için aşağıda verilen hata terimleri (Güneş vd., 2007)' de olduğu gibi uygun görülmüştür:

$$\text{Dogruluk}_X = 1 - \frac{\sum_{k=1}^n |X_{k \text{ hedef}} - X_{k \text{ tahmin edilen}}|}{\sum_{k=1}^n X_{k \text{ hedef}}} \quad (6.4)$$

Burada $X_{k \text{ tahmin edilen}}$, k'ncü hedef değeri $X_{k \text{ hedef}}$ için tahmin edilen değer, n ise toplam test verisi sayısıdır.

6.2.2 Sağlam Analiz Formülasyonuna Dayandırılmış Sentez

İletken sırtlı üstü ekranlanmış EDDK'nın sentezinde, geometri fonksiyonu $D(Z_0, \epsilon)$, H/S ve H_1/S 'i serbest değişken olarak kabul ederek $W/S(Z_0, \epsilon)$ formunda üretilmektedir. Analiz formülasyonları üst ekranlama, iletken sırt, yanal yer düzleminin kırılması ve hattan hatta kuplajlama gibi tüm temel çevresel sınırlamaların da hesaba katıldığı konform dönüşüm tekniği kullanılarak elde edilmiştir (Ghione ve Naldi, 1987). Böylece karakteristik empedans hat geometrisinin ve dielektrik maddenin fonksiyonu olarak şu şekilde verilebilir:

$$Z_o = \frac{60\pi}{\sqrt{\epsilon_{eff}}} \frac{I}{\frac{K(k_1)}{K(k_1')} + \frac{K(k_2)}{K(k_2')}}} \quad (6.5.a)$$

Burada $K(k)$ birinci tip tam eliptik integral ve $k_1' = \sqrt{1-k_1^2}$, $k_2' = \sqrt{1-k_2^2}$ 'dir.

$$\frac{K}{K'} = \frac{1}{\pi} \ln\left(2 \frac{1+\sqrt{k}}{1-\sqrt{k}}\right) \quad 0.7 \leq k \leq 1 \quad (6.5.b)$$

$$= \left[\frac{1}{\pi} \ln\left(2 \frac{1+\sqrt{k'}}{1-\sqrt{k'}}\right) \right]^{-1} \quad 0 \leq k \leq 0.7 \quad (6.5.c)$$

$$\text{Burada } k_1 = \frac{\tanh(\pi S/4H)}{\tanh[\pi(S+2W)/4H]} \text{ ve } k_2 = \frac{\tanh(\pi S/4H_1)}{\tanh[\pi(S+2W)/4H_1]}. \quad (6.5.d)$$

Efektif dielektrik sabiti (6.5.e) ile verilebilir:


$$\epsilon_{eff} = 1 + q(\epsilon_r - 1) \quad (6.5.e)$$

Dolgu faktörü, q aşağıda yer almaktadır:


$$q = \frac{\frac{K(k_1)}{K(k_1')}}{\frac{K(k_1)}{K(k_1')} + \frac{K(k_2)}{K(k_2')}}} \quad (6.5.f)$$

$W/S(Z_o, \epsilon)$ 'in DV açılımını elde etmek için sentez verisi üretilmelidir. Bu veri (6.5.a-f) arasında yer alan Z_o analiz formülasyonunun ters çevrilmesi ile elde edilir. Bunun için öncelikle analiz formülasyonlarını kullanarak Z_o 'ı veren bir bilgisayar programı yazılır, daha sonra ise analiz programının çıktıları sentez probleminin giriş-çıkış tanımına göre tekrardan düzenlenir. Bu şekilde $1 < H/S, H_1/S < 10$, $6 < \epsilon_r < 13$, $10 \Omega < Z_o < 220 \Omega$ ve $0.01 < W/S < 1$ aralığında 4872 adet sentez verisi üretilmiştir. DVR teorisinin seyrekliğe sahip olduğu matematiksel açıklaması ile birlikte tezin 2. bölümünde anlatılmıştır. DVRM' nin sahip olduğu seyreklik özelliği sebebiyle 4872 adet verinin sadece bir kısmı eğitimde kullanılmıştır. Destek vektör sayısı ile doğruluk ve hesaplama süresinin değişimleri ϵ -duyarsız kayıp fonksiyonuna bağlı olarak Şekil 6.3' de verilmiştir. Bu değişimlere ait bazı tipik değerler Çizelge 6.1' de mevcuttur. Sağlam analiz formülasyonuna dayandırılmış bilgi-tabanlı DVRM yaklaşımı blok şeması Şekil 6.4' de yer almaktadır. Programlar Matlab Versiyon 7.4' de

yazılmış ve Intel Core 2 Duo 1.83 GHz işlemciye ve 1GB RAM' e sahip bilgisayarda koşturulmuştur. Çizelge 6.1'den görülebildiği gibi az sayıda destek vektörü ile bile geçerli olabilecek doğruluklar elde edilebilmektedir. Buna örnek olarak %82.85 doğruluk toplam verinin % 0.74' ü olan 36 destek vektörü ile elde edilebilmektedir. İletken sırtlı üstü ekranlanmış EDDK'nun sentez DVRM modelinin yapıldığı bu uygulamada ε 0.05 olarak seçilerek % 99.18 doğruluk 4872 adet eğitim verisinin 1257'si kullanılarak elde edilmiştir. DVRM eğitiminde kernel tipi olarak radyal tabanlı fonksiyon seçilmiştir. Denemeler sonucunda düzenleme parametresi, C 1000 olarak seçilmiştir.



(a)



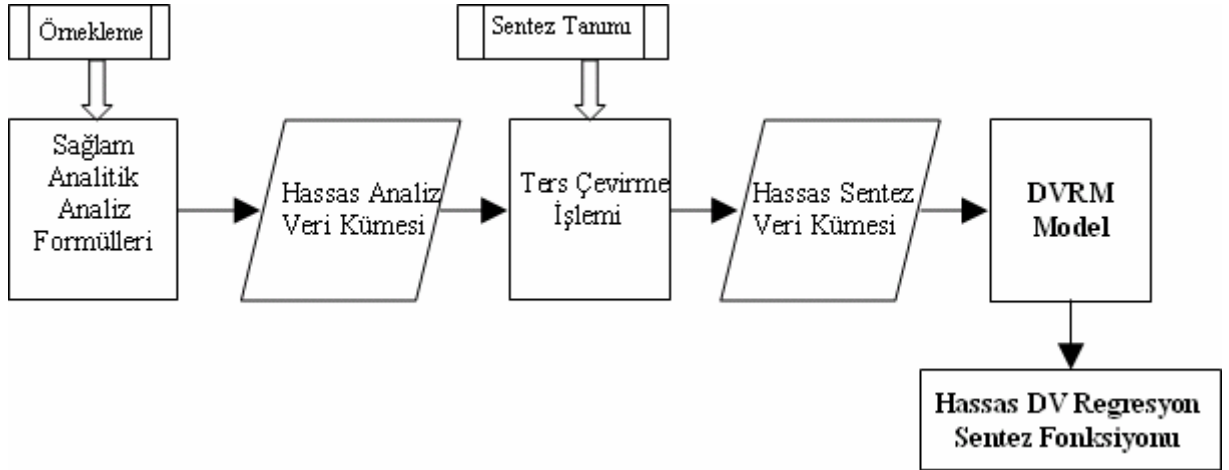
(b)

Şekil 6.3 DVRM sentez modelinde (a) Doğruluk ve destek vektörü sayısının; (b) Eğitim süresi ve destek vektörü sayısının ε parametresi ile değişimi.

Çizelge 6.1 İletken sırtlı üstü ekranlanmış EDDK sentez DVRM modeli için tipik değerler.

ϵ	DV sayısı / Toplam veri sayısı	Doğruluk (%)
0.01	2901/4872	99.33
0.05*	1257/4872	99.18
0.1	652/4872	97.65
0.2	147/4872	91.46
0.3	36/4872	82.85
0.4	8/4872	76.93
0.5	8/4872	76.90

* Yapılan uygulamada ϵ 0.05 olarak seçilmiştir.



Şekil 6.4 Sağlam analitik formülleri kullanan bilgi-tabanlı DVRM yaklaşımı.

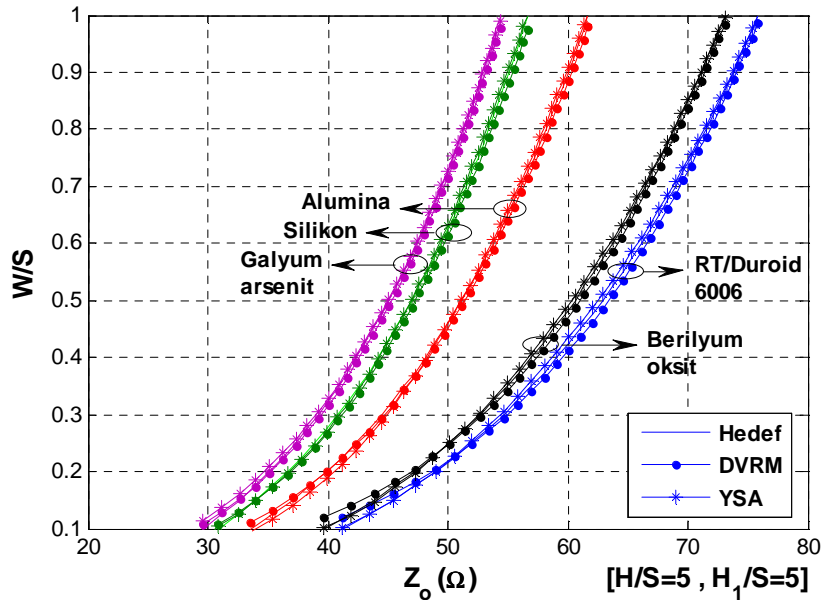
Bu çalışmada 4872 eğitim verisi, DVRM ve YSA öğrenen makineleri ile üç ayrı tip regresyon işlemine uyarlanmıştır. İlk regresyon 4872 eğitim verisinden seçilen 1257 DV ile DVRM kullanılarak yapılmıştır. Bu regresyonda evrensel minimum garantilidir ve seyreklik özelliği hesaplamada büyük üstünlükler sağlamaktadır. İkinci regresyon basit bir YSA mimarisinin eğitiminde 4872 eğitim verisi kullanılarak yapılmıştır. Son regresyon modeli ise ikinci regresyon modelinde kullanılan YSA mimarisinin 1257 adet destek vektörü ile eğitilmesi ile karma bir model olarak oluşturulmuştur. YSA mimarisinde bir gizli katmana sahip Çok Katmanlı Algılayıcı(ÇKA) ağı yeterli görülmüştür. Ağın eğitiminde Levenberg-Marquardt geri yayılım algoritması kullanılmıştır. ÇKA 4 giriş nöronuna, gizli katmanında 4 nörona ve

bir çıkış nöronuna sahiptir. Öğrenme oranı 0.1 olarak seçilmiş, eğitim 300 adımda sonlandırılmıştır. Hiperbolik tanjant sigmoid ve lineer fonksiyonları gizli ve çıkış katmanında aktivasyon fonksiyonu olarak kullanılmıştır. YSA modellerinin ve DVRM modelinin performansları Çizelge 6.2’de yer almaktadır. Çizelge 6.2’den görülebileceği gibi doğruluk ve hesaplama süresi göz önünde bulundurulduğunda en iyi sonuçlar DVRM ile elde edilmiştir. Karma model ikinci sırada yer almaktadır. Buradan YSA modelin eğitiminde sadece DV’lerin kullanılmasının yeterli olduğu sonucu çıkarılabilir. Ayrıca eğitim verisinin azalmasının eğitim süresini de azaltacağı aşikârdır. Bu durumda YSA eğitim süresinin DVRM eğitim süresine yaklaşması dikkat edilmesi gereken bir diğer noktadır.


En yaygın kullanılan dielektrik maddeler için $W/S(Z_o, \epsilon)$ fonksiyonunun karakteristik empedans ile değişimi $H/S=5$, $H_1/S=5$ ve $H/S=7$, $H_1/S=10$ için Şekil 6.5a ve b’ de yer almaktadır. Şekil 6.5’de karma YSA yapısından elde edilen sonuçlara yer verilmiştir.

Çizelge 6.2 Sentez YSA modellerinin sonuçları.

	Doğruluk (%)	Eğitim süresi (sn)
YSA₁ (4872 veri ile eğitilmiştir)	98.47	32.014
YSA₂ (1257 DV ile eğitilmiştir)	98.61	11.264
DVRM (1257 DV ile eğitilmiştir)	99.18	8.143



(a)



(b)

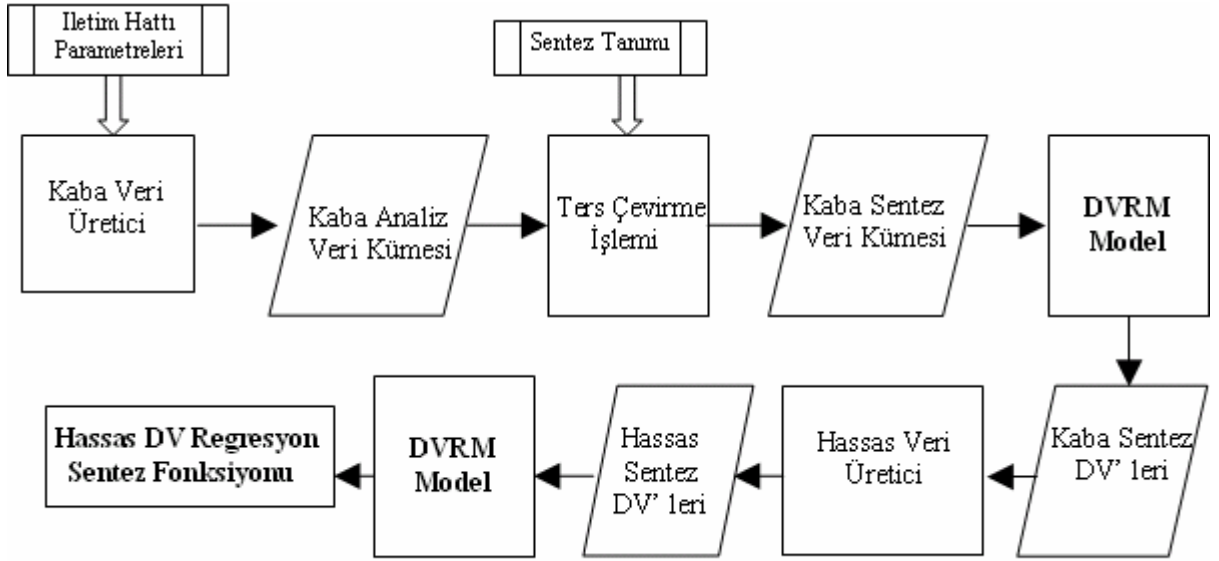
Şekil 6.5 (a) $H/S=5$, $H_1/S=5$; (b) $H/S=7$, $H_1/S=10$ için W/S 'in karakteristik empedans ile değişimi.

6.2.3 Kaba ve Hassas Modellere Dayandırılmış Sentez

Mikroşerit iletim hatlarının kaba ve hassas modellere dayandırılmış bilgi-tabanlı DVRM sentezi blok şeması Şekil 6.6' da verilmiştir. Mikroşerit iletim hattının sentez tanımı Şekil 6.2' de verildiği gibi $W(Z_0, \epsilon, H)$ fonksiyonunun bulunmasıdır. Bu prosedür şu şekilde özetlenebilir: (i) Analiz eğitim ve test verisi kaba veri üretici kullanılarak elde edilir. Kaba veri üretici (Collins, 1992)' de yer alan analitik formülasyonları kullanan bir bilgisayar programıdır. Bu şekilde 1290 eğitim verisi ve 350 test verisi oluşturulur. (ii) Sentez verisi, analiz verisinin giriş ve çıkışlarının sentez probleminin tanımına uygun olarak düzenlenmesi ile elde edilir. Bu şekilde kaba sentez veri kümesi elde edilir. (iii) Kaba sentez veri kümesi DVRM modeli ile eğitilerek kaba sentez DV'leri elde edilir. (iv) Sentez DV'leri hassas veri üretici ile hassas sentez verisi haline getirilir. Bu şekilde bilgi sentez DV'lerine verilmiş olur. Hassas veri üretici olarak EM simülasyon yapan bir program kullanılmıştır. (v) Hassas sentez DV'leri ile eğitilen DVRM modeli kaba modeller kadar hızlı, hassas modeller kadar yüksek doğruluğa sahiptir. Bu şekilde DVRM'in EM simülatör olarak kullanılması sağlanmıştır.

Çizelge 6.3'de DVRM değişkenlerinin değer aralıkları yer almaktadır. Çizelge 6.4'de kaba sentez veri kümesi ile eğitilen DVRM modeli için ϵ parametresine bağlı olarak DV sayısı ve doğruluk değişimi verilmiştir. Yapılan uygulamada $\epsilon=0.25$ olarak seçilmiş ve 151 DV ile

elde edilen %99.1 doğruluk yeterli bulunmuştur.



Şekil 6.6 Kaba ve hassas veri üretici kullanan bilgi-tabanlı DVRM yaklaşımı.

Çizelge 6.3 DVRM değişkenlerinin değer aralıkları.

Değişken	Min.	Maks.
H(mm)	0.1	10
ϵ_r	2	13
$Z_0(\Omega)$	11	200
W(mm)	0.1	10

Çizelge 6.4 Kaba sentez veri kümesi ile eğitilen DVRM modeli için ϵ parametresine bağlı olarak DV sayısı ve doğruluk değişimi.

ϵ	DV sayısı/toplam eğitim verisi	Doğruluk (%)
0.1	361/1290	99.49
0.15	264/1290	99.28
0.2	195/1290	99.29
0.25*	151/1290	99.10
0.3	113/1290	98.94


* Yapılan uygulamada $\epsilon=0.25$ olarak seçilmiştir.

Hassas sentez DV'leri ile eğitilen DVRM modelin eğitiminde kernel tipi olarak radyal tabanlı


fonksiyon seçilmiştir. Denemeler sonucunda düzenleme parametresi, C 1000, ε parametresi 0.01 olarak seçilmiştir. Çizelge 6.5’ de hassas sentez DV’leri (151 DV) ile eğitilen DVRM modelin eğitim ve testteki doğruluğu yer almaktadır. ε parametresi 0.01 olarak seçilerek %98.91 doğruluk 134 DV ile elde edilmiştir. EM Simülâtör ve hassas DVRM’in test sonuçları Şekil 6.7’de verilmiştir. Şekil 6.7.a’ da eğitim verisi (151 adet DV) ile test edilen hassas DVRM modelin sonuçları EM simülâtör sonuçları ile karşılaştırmalı olarak verilmiştir. Benzer olarak Şekil 6.7.b’ de test verisi (350 adet veri) ile test edilen hassas DVRM modelin sonuçları EM simülâtör sonuçları ile karşılaştırmalı olarak verilmiştir. Hassas sentez DV’leri ile eğitilmiş DVRM ile elde edilen $W(Z_o, \varepsilon, H)$ fonksiyonu farklı kalınlıklarındaki PTFE\microfiber cam ($\varepsilon_r=2.26$) ve mika ($\varepsilon_r=6$) mika dielektrik maddeleri için EM simülâtör sonuçları ile karşılaştırmalı olarak Şekil 6.8’de verilmiştir.

Çizelge 6.5 Hassas sentez DV’leri ile eğitilen DVRM modelin eğitim ve testteki doğruluğu.

$\varepsilon = 0.01$	% Doğruluk
Eğitim	99.6859
Test	98.9155




(a)




(b)

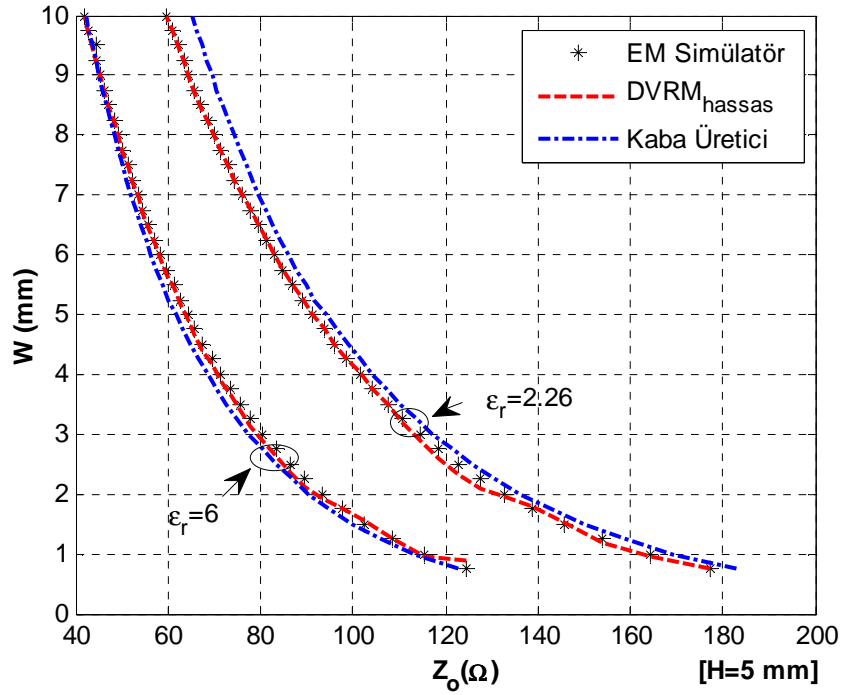
Şekil 6.7 EM Simülâtör ve hassas DVRM (a) eğitim verisi; (b) test verisi ile test sonuçları.



(a)



(b)



(c)

Şekil 6.8 Hassas sentez verisi ile eğitilmiş DVRM sonuçlarının (a) $H = 0.5$ mm; (b) $H = 2$ mm; (c) $H = 5$ mm için EM Simülator sonuçları ile karşılaştırılması.

6.3 Sonuç

Bu çalışmada, literatürde ilk olarak, bilgi-tabanlı destek vektör makinesi tasarlanmış ve bu metot tektaş ya da hibrit mikrodalga tümleşik devrelerinde kullanılan RF/Mikrodalga düzlemsel iletim hatlarının sentezinde kullanılmıştır. Bilgi yükleme iki ayrı yöntem kullanılarak yapılmış ve bu yöntemler iki ayrı örnekle tanıtılmıştır. İlk örnekte iletken sırtlı üstü ekranlanmış EDDK' nın bilgi-tabanlı DVRM sentez modeli sağlam matematiksel analiz formülasyonuna dayalı olarak oluşturulmuştur. Ayrıca bu uygulamada oluşturulan YSA modelinin eğitiminde sentez DV'leri kullanılmış ve başarılı bir eğitim elde edilmiştir. Buradan YSA modelinin eğitiminde sadece DV' lerin kullanılmasının yeterli olduğu sonucu çıkarılabilir. Ayrıca YSA eğitim verisinin azalması eğitim süresini de azaltmıştır.

İkinci örnekte, mikroşerit iletim hatlarının sentezinin DV açılımı kaba model verilerini kullanarak yapılmıştır. Kaba DVRM modelinden elde edilen DVler bir elektromagnetik simülatör yardımı ile hassas model ile eşleştirilmiş ve elde edilen hassas veri kümesi DVRM eğitiminde kullanılmıştır. Bu şekilde kaba modeller kadar hızlı, hassas modeller kadar yüksek doğruluklu bir sentez metodu geliştirilmiştir.

7. MİKRODALGA TEKNOLOJİSİNDE UZMAN REGRESYON SİSTEMLERİNİN UZLAŞMASI

Mikrodalga devrelerinde yer alan karmaşık yapıların modellenmesinde yüksek doğrulukla cevap verebilen, hızlı ve verimli tasarım araçlarına ihtiyaç duyulmaktadır. Tam-dalga çözümleri hesaplamada yüksek doğruluğa sahip olmasına karşın simülasyonları uzun zaman almaktadır. Bu durum özellikle bir elemanın fiziksel yapısının talep edilen cevabı verecek şekilde değiştirilmesi gereken durumlarda geçerlidir. Bilgisayar destekli EM simülasyonlar, benzer durumlar için yapılan önceki simülasyonlardan yaralanamaz. Buna örnek olarak, modellenen cihazın ya da yapının bir geometrik parametresinde yapılan en küçük bir değişimin tüm simülasyonun tekrardan yapılmasını gerektirmesi verilebilir. Bu sınırlamaların üstesinden gelebilmek için mikrodalga eleman ve cihazların modellenmesinde yapay sinir ağları büyük rağbet görmüştür (Zhang vd., 2003). YSA modelleri, bilgisayar destekli EM modellerine oranla hesaplama yükünde oldukça fazla azalma sağlamıştır. Fakat YSA'nın da bazı kısıtlamaları mevcuttur. Bunlara örnek olarak gizli katman sayısını ve gizli katmanlarda yer alan nöron sayısını belirleyecek verimli bir yöntemin olmaması verilebilir. Ayrıca YSA veriye aşırı uyumlu model oluşturarak genellemede güçlük yaratabilir. Günümüzde Vapnik (1995) tarafından geliştirilen DVM, YSA'nın bu sınırlamalarının üstesinden gelebilecek birçok cazip özelliğe sahip olmasından dolayı günümüzde popülerlik kazanmıştır. Bu YSA'nın kullandığı ampirik risk minimizasyonu yerine daha etkili olduğu ispatlanmış yapısal risk minimizasyonu kullanmasından kaynaklanmaktadır. Bu farklı felsefe, DVM'i genellemede YSA'na oranla üstün kılar (Angiulli vd., 2007). İlk olarak DVM sınıflandırma problemlerine çözüm üretmek amacıyla geliştirilmiş, sonrasında ise regresyon problemlerine adapte edilmiştir.

Regresyon problemleri bir bağımsız değişken kümesine bağımlı değişken çıkışını tahmin etmekle ilgilidir. k -NN (k - en yakın komşu) algoritması, regresyon problemlerinde sıklıkla kullanılan bir algoritmadır. k -NN, bellek-tabanlı bir model olup giriş-çıkış ilişkisi bilinen bir örnek kümesi ile tanımlanır. Bu örnek kümesinde bağımsız değişkenlere bağlı olarak bağımlı çıkış değişkeni yer almaktadır. k -NN algoritması, yeni bir bağımsız değişken kümesi verildiğinde, çıkışı k -NN örneklerine bağlı olarak belirlemeyi amaçlar. k -NN bunu bağımsız değişkenlere en yakın k sayıda komşuyu bulup çıkışlarının ortalamasını alarak hesaplar.

Regresyon problemlerinde sıklıkla kullanılan bir diğer algoritma en küçük kareler (LS) algoritmasıdır. LS metodu özetle M' inci dereceden bir modelin $M+1$ sayıda elemana sahip katsayı kümesi a,b,c,\dots için mümkün en iyi değerlerin bulunması olarak özetlenebilir. Bu

şekilde elde edilen M' inci dereceden model bilinmeyen bağımsız değişken vektörü verildiğinde çıkışı verebilmektedir.

Bir regresyon probleminde güvenilir, nitel ve nicel bir modelin seçimi başlıca öneme sahiptir. Bir modele bağlı regresyon bazı durumlarda yetersiz doğruluğa sahip tahmin sonucu verebilir. Buna karşın uzlaşma stratejisinde, birden fazla model ayrı ayrı eğitilerek model tahmin sonuçları, ortalama almak, minimumu almak, maksimumu almak gibi uzlaşım yöntemleri ile birleştirilir. Böylece, bir model ile regresyona oranla daha yüksek doğruluk ve kararlılık elde edilebilir.

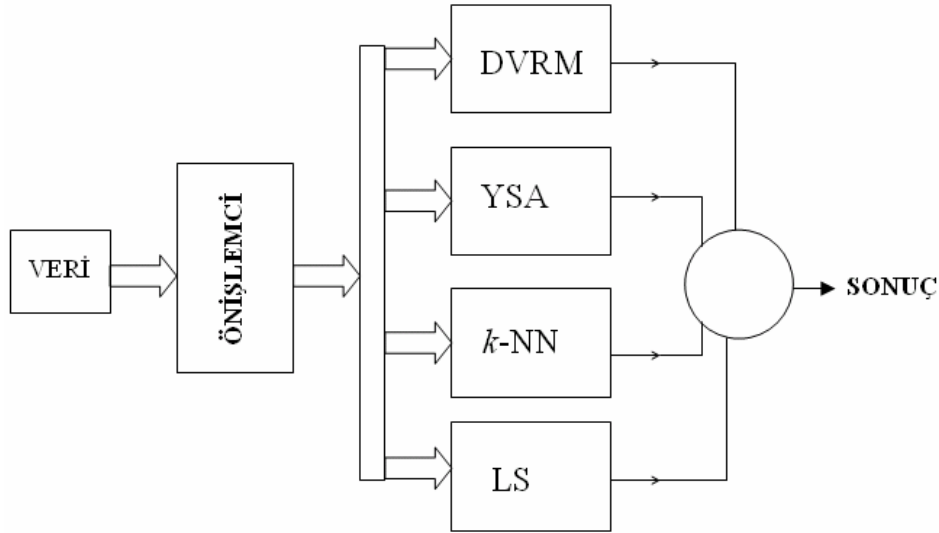
Bu çalışmada uzman regresyon sistemlerinin uzlaşması, mikrodalga teknolojisine uyarlanmıştır. Bu amaçla yukarıda bahsedilen dört ayrı algoritma (DVRM, YSA, k -NN, LS) seçilen bir regresyon problemine uyarlanmış ve dört ayrı regresyon modelinin çıktıları arasında hedef değerine bağlı olarak uzlaşım yapılarak bir çıkış elde edilmiştir. Bu çalışmada kullanılan uzlaşım metotları şunlardır: 1) Ortalama almak; 2) Minimumu almak; 3) Maksimumu almak; 4) Ortancayı almak. Dört ayrı uzlaşım metodu ve regresyon modelleri bir uygulama örneği ile demonstre edilmiştir. Regresyon modellerinin kullandığı örnek veri kümesi, önışlemci olarak seçilen DVM' den geçirilerek elde edilen DV' lerden oluşan bir kümedir. Azaltılmış sayıda örnek verisi ile işlem yapmak regresyon modellerini hızlandırarak daha verimli bir hale getirecektir. 7.1 bölümünde regresyon uzlaşımının detaylarına yer verilmiştir. 7.2' de k -NN ve LS algoritmalarının matematiksel temelleri yer almaktadır. 7.3' de uygulama örneği olarak DVRM, YSA, k -NN ve LS regresyon modelleri ile iletken sırtlı üstü ekranlanmış EDDK' nın uzlaşımli sentezi verilecektir. Son bölümde ise çalışmaya ait genel sonuçlara yer verilmiştir.

7.1 Regresyon Uzlaşması

Regresyon uzlaşması birden fazla regresyon modelinin sonuçlarının birleştirilmesi ile yapılır. Regresyon uzlaşmasındaki temel fikir birden fazla sayıdaki modelin, bağımsız değişkenler ile bağımlı değişkenler arasındaki ilişkiyi bir modele oranla daha efektif olarak belirleyecek olmasıdır. Bu çalışmada kullanılan regresyon uzlaşması blok diyagramı Şekil 7.1' de yer almaktadır. Önışlemci olarak küçük sayıda örnekleme prensibine dayandırılmış DVM kullanılmıştır. Bu şekilde regresyon modellerinin eğitim verisi, azaltılmış sayıda DV ile oluşturulmuştur. Böylece önışlemci çıkışından elde edilen DV kümesi, örnek küme olarak regresyon modellerine verilmiştir. Sonrasında dört ayrı regresyon modeli (DVRM, YSA, k -NN, LS) ile sistem cevabı elde edilebilmektedir. DVRM ve YSA modellerinin eğitimi

önceden yapılmış ve test aşamasında girdilere bağlı cevabı saliseler içinde verebilmeleri sağlanmıştır.

Başarılı bir regresyon uzlaşması için, uzlaşmada yer alan her bir regresyon modelinin yeterli doğruluğa sahip olması gereklidir (Li vd., 2007). Bu amaçla, uzlaşmada yer alacak modellerin seçiminde bir doğruluk kriteri kullanılmalıdır. Regresyon modelinin doğruluğu belirlenen kriterden düşük ise o model regresyon uzlaşmasına dahil edilmez. Kriteri sağlayan regresyon modellerinin çıkışları arasında uzlaşım yapılarak bir sistem çıkışı elde edilir. Bunun için dört ayrı uzlaşım metodu kullanılmıştır. Bunlardan ilki regresyon model çıkışlarının ortalamasını almaktır. İkinci uzlaşım metodu regresyon model çıkışlarından minimum olanı almaktır. Üçüncü olarak kullanılan uzlaşım metodu ise regresyon model çıkışlarından maksimum olanı almaktır. Son uzlaşım metodu ise ortanca (median) olarak bilinen ortada olanı almaktadır. Dört ayrı uzlaşım metodu ve regresyon modelleri iletken sırtlı üstü ekranlanmış EDDK'nın sentezi ile demonstre edilmiştir. Bu uygulama sonuçları ile birlikte 7.3'de yer almaktadır. Sıradaki bölümde k -NN ve LS algoritmalarının matematiksel temelleri yer almaktadır.



Şekil 7.1 Regresyon uzlaşması blok diyagramı.

7.2 k -NN ve LS Algoritmaları

7.2.1 k -NN Algoritması

k -NN, bellek-tabanlı bir model olup giriş-çıkış ilişkisi bilinen bir örnek kümesi ile tanımlanır. Bu örnek kümesinde bağımsız değişkenlere bağlı olarak bağımlı çıkış değişkeni yer

almaktadır. Bağımlı ya da bağımsız değişkenler sürekli ya da kategorik olabilir. Sürekli bağımlı değişkenler için görev regresyondur. Aksi takdirde sınıflandırmadır. k -NN hem sınıflandırma, hem de regresyon için kullanılabilir.

k -NN algoritmasında amaç yeni bir bağımsız değer vektörü verildiğinde (sorgu noktası) k -NN örneklerine bağlı olarak çıkışın hesaplanmasıdır. k -NN bunu sorgu noktasına en yakın mesafedeki k adet örneği bularak yapar. k -en yakın komşu adı buradan gelmektedir. Regresyon problemlerinde k -NN tahmini k adet en yakın komşunun ortalamasının alınması ile, sınıflandırma problemlerinde ise oy çokluğu ile belirlenir.

k -NN modelinde k parametresinin seçimi önemlidir ve tahmin kalitesini oldukça etkilemektedir. Verilen bir problemde k parametresinin küçük seçilmesi tahminde yüksek değışintiye sebep olurken yüksek seçilmesi ise yüksek hataya sebep olabilmektedir. Yani k parametresi yanlış sınıflandırma ihtimalini minimize edecek kadar büyük, k en yakın komşuya yeterince yakın olacak kadar küçük seçilmelidir.

7.2.1.1 Mesafe Ölçütü

Bir sorgu noktası verildiğinde k -NN o noktaya en yakın k adet komşunun çıkışına bağlı olarak tahmin üretir. Bu sebepten k -NN'in tahmin yapabilmesi için sorgu noktası ile örnek noktaları arasındaki mesafeyi tanımlayan bir ölçüte ihtiyaç vardır. En popüler olarak kullanılan mesafe ölçütü öklit uzaklığıdır. Bu çalışmada yer alan k -NN uygulamasında öklit uzaklığı kullanılmıştır. Diğer mesafe ölçütleri karesel öklit, şehir-bloğu ve Chebychev olup (7.1)'de yer almaktadır.

$$D(x, p) = \begin{cases} \sqrt{(x - p)^2} & \text{Öklit} \\ (x - p)^2 & \text{Karesel öklit} \\ \text{Abs}(x - p) & \text{Şehir bloğu} \\ \text{Max}(|x - p|) & \text{Chebychev} \end{cases} \quad (7.1)$$

Burada x ve p sırası ile sorgu noktası ve bir örnek noktasıdır.

7.2.1.2 k -NN Tahmini

k değeri seçildikten sonra k en yakın komşuya bağlı olarak tahmin yapılabilir. Regresyon uygulamalarında k -NN tahmini k en yakın komşunun ortalaması ile bulunabilir.

$$y = \frac{1}{k} \sum_{i=1}^k y_i \quad (7.2)$$

Burada y_i i' inci örneğin çıkış değeri, y ise sorgu noktası için yapılan tahmindir. Buraya kadar k adet en yakın komşunun etkisi sorgu noktasına olan uzaklıkları göz önünde bulundurulmadan eşit olarak alındı. Buna alternatif bir yaklaşım k adet komşunun yakınlık derecesine bağlı olarak değerlendirilmesidir.

7.2.1.3 Ağırlıklı Mesafe

Ağırlıklı mesafe, sorgu noktasına en yakın komşunun etkisinin en fazla, en uzak komşunun etkisinin ise en az olması mantığına dayanır. Bu amaçla W ağırlık ölçütü, k komşunun sorgu noktasına uzaklığına bağlı olarak her bir komşu için şu şekilde tanımlanır:

$$W(x, p_i) = \frac{\exp(-D(x, p_i))}{\sum_{i=1}^K \exp(-D(x, p_i))} \quad (7.3)$$


Burada $D(x, p_i)$, sorgu noktası x ile i' inci örnek p_i arasındaki mesafedir. Bu şekilde tanımlanan ağırlıkların (7.4)' ü sağlayacağı aşikardır.

$$\sum_{i=1}^K W(x_o, x_i) = 1 \quad (7.4)$$

Böylece regresyon problemleri için çıkış şu şekilde verilebilir:

$$y = \sum_{i=1}^K W(x_o, x_i) y_i \quad (7.5)$$

k -NN metodunun iletken sırtlı üstü ekranlanmış EDDK' nun sentezine uygulanması Şekil 7.2'de verilmiştir.



Şekil 7.2 k -NN regresyonunun iletken sırtlı üstü ekranlanmış EDDK'nın sentezine uygulanması.

7.2.2 LS Algoritması

LS metodu basit olarak M ' inci dereceden bir modelin $M+1$ sayıda elemana sahip katsayı kümesi a, b, c, \dots için mümkün en iyi değerlerin bulunması olarak özetlenebilir. Doğrusal olmayan model genel olarak (7.6) ile verilebilir.

$$y = a + bx + cx^2 + dx^3 + \dots \quad (7.6)$$

Veri sayısı (N) bilinmeyen sayısından fazla olmalıdır ($N > M + 1$). Modelin toplam karesel hatası minimize edilerek bilinmeyen katsayılar bulunur. Hata e_i :

$$e_i = y_i - \hat{y}_i = y_i - a - bx_i - cx_i^2 - \dots \quad (7.7)$$

Bu genel model için toplam karesel hata (7.8)' de verilmiştir:

$$E_M = \sum_{i=1}^N e_i^2 = \sum_{i=1}^N (y_i - a - bx_i - cx_i^2 - \dots)^2 \quad (7.8)$$

E_M ' i minimize etmek için eşitlik (7.8)'in $M+1$ bilinmeyene (a, b, c, \dots) bağlı olarak türevi alınır ve sıfıra eşitlenir. b katsayısı için bu prosedür şu şekilde verilebilir:

$$\begin{aligned} \frac{\partial E_M}{\partial b} &= \frac{\partial}{\partial b} \sum_{i=1}^N (y_i - a - bx_i - cx_i^2 - \dots)^2 = 0 \\ &= -2 \sum_{i=1}^N (y_i - a - bx_i - cx_i^2 - \dots) x_i \end{aligned} \quad (7.9)$$

Kısmi türevlerin sonuçları (7.9)'dakine benzer $M+1$ eşitlik oluşturur. Parametreler bu eşitlikler çözülerek elde edilebilir. Karesel bir model için ($M = 2$) terimler düzenlendikten ve bilinmeyenler eşitliğin sağ tarafına alındıktan sonra şu eşitlikler elde edilir:

$$\sum_{i=1}^N y_i = aN + b \sum_{i=1}^N x_i + c \sum_{i=1}^N x_i^2 \quad (7.10)$$

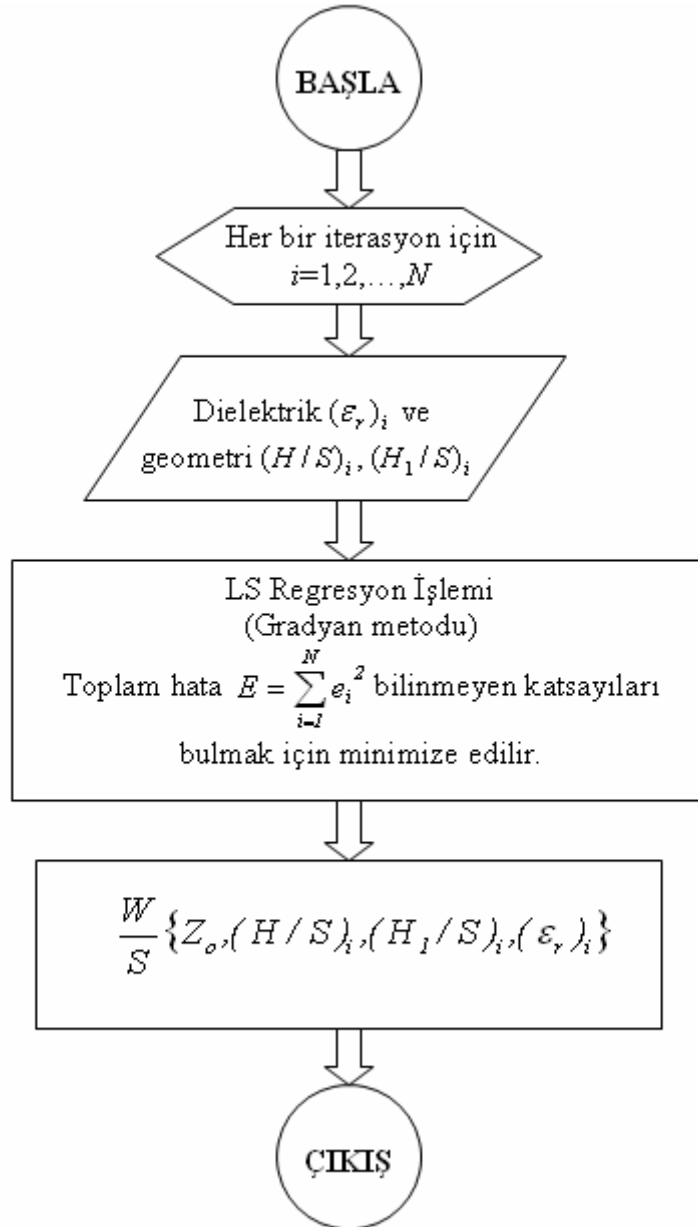
$$\sum_{i=1}^N y_i x_i = a \sum_{i=1}^N x_i + b \sum_{i=1}^N x_i^2 + c \sum_{i=1}^N x_i^3 \quad (7.11)$$

$$\sum_{i=1}^N y_i x_i^2 = a \sum_{i=1}^N x_i^2 + b \sum_{i=1}^N x_i^3 + c \sum_{i=1}^N x_i^4 \quad (7.12)$$

Bu şekilde $M+1$ bilinmeyen (a, b, c, \dots) için $M+1$ adet eşitlik çözümünden (a, b, c, \dots) katsayıları elde edilebilir. Bu eşitlikler (7.13)' de verilen matris formuna dönüştürülebilir (Shiavi, 1999).

$$\begin{bmatrix} N & \sum_{i=1}^N x_i & \sum_{i=1}^N x_i^2 \\ \sum_{i=1}^N x_i & \sum_{i=1}^N x_i^2 & \sum_{i=1}^N x_i^3 \\ \sum_{i=1}^N x_i^2 & \sum_{i=1}^N x_i^3 & \sum_{i=1}^N x_i^4 \end{bmatrix} \begin{bmatrix} a \\ b \\ c \end{bmatrix} = \begin{bmatrix} \sum_{i=1}^N y_i \\ \sum_{i=1}^N y_i x_i \\ \sum_{i=1}^N y_i x_i^2 \end{bmatrix} \quad (7.13)$$

LS algoritmasınıniletken sırtlı üstü ekranlanmış EDDK' nun sentezine uygulanması Şekil 7.2' de verilmiştir. LS ve k -NN algoritmasına dair sonuçlar ise bölüm 7.3' de yer almaktadır.



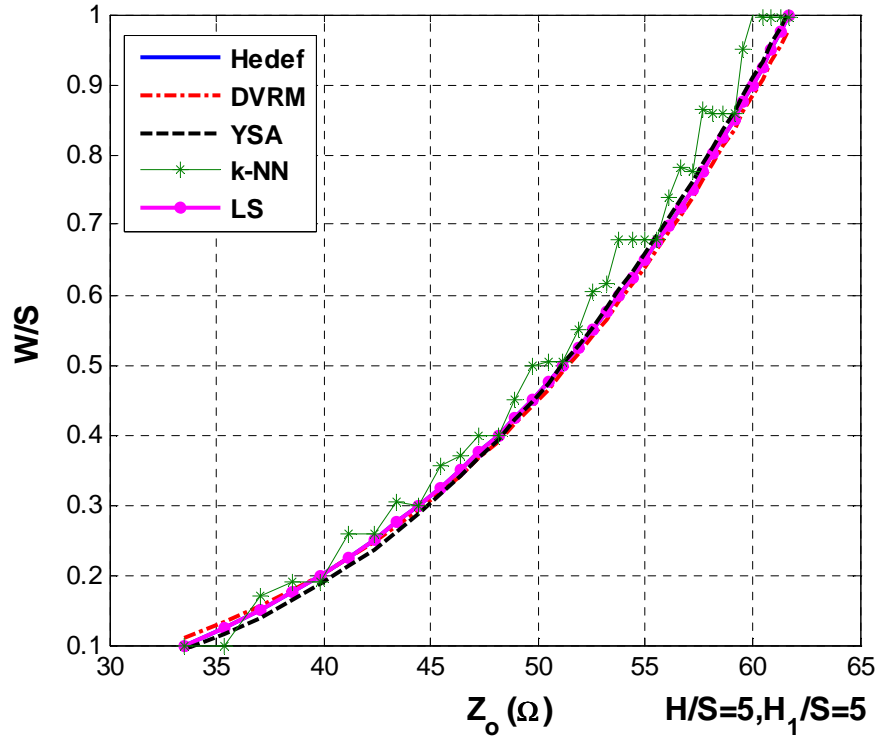
Şekil 7.3 LS regresyonununiletken sırtlı üstü ekranlanmış EDDK' nun sentezine uygulanması.

7.3 Uygulama Örneği


Regresyon uzlaşmasına uygulama örneği olarak mikrodalga devrelerinde kullanılan iletken sırtlı üstü ekranlanmış EDDK' nun sentezi yapılmıştır. Bunun için Bölüm 6.2'deki "Tam Analiz Formülasyonuna Dayandırılmış Sentez" uygulamasında yer alan iletken sırtlı üstü ekranlanmış EDDK veri kümesi kullanılmıştır. Eğitim verisi olarak oluşturulmuş 4872 adet sentez verisi, önışlemci olarak seçilen DVM'e girdi olarak verilmiş ve 1257 adet DV elde edilmiştir. Sentez verisine ve önışlemcide yer alan DVM modeline ait detaylar Bölüm 6.2'de mevcuttur. Elde edilen yeni veri kümesi DVRM, YSA, k -NN, LS regresyon modellerine girdi olarak verilmiştir. DVRM ve YSA modellerinin eğitimi 1257 adet veri ile yapılmıştır. YSA modeli mimarisi Bölüm 6.2'de anlatılmıştır. DVRM regresyon modelinde ε 0.01, C 1000 olarak seçilmiştir. DVRM eğitiminde kernel tipi olarak radyal tabanlı fonksiyon seçilmiştir. LS algoritmasında 3. dereceden polinom uygun görülmüştür. k -NN uygulamasında ağırlıklı mesafe kullanılmış ve k 3 olarak seçilmiştir. Şekil 7.4, 7.5 ve 7.6'da yer alan LS polinomlarının katsayıları Çizelge 7.1'de yer almaktadır. Şekil 7.4-7.6'da farklı dielektrik madde ve kalınlık değerleri için W/S 'in Z_0 ile değişiminin 4 farklı regresyon metodu sonuçları hedef değerleri ile karşılaştırılmalı olarak verilmiştir.

Çizelge 7.1 LS polinom katsayıları.


	a	b	c	d
Şekil 7.4	-0. 607059	0. 43256. 10^{-1}	-0.11193. 10^{-2}	0.13612. 10^{-4}
Şekil 7.5	-0.355670	0.27032. 10^{-1}	-0.78957. 10^{-3}	0.12667. 10^{-4}
Şekil 7.6	-0. 607053	0. 49073. 10^{-1}	-0.14406. 10^{-2}	0.19876. 10^{-4}



Şekil 7.4 Alumina ($\epsilon_r = 9.8$) dielektrik maddesi ve $H/S=5$, $H_1/S=5$ için W/S 'in Z_o ile değişimi.



Şekil 7.5 Silikon ($\epsilon_r = 11.8$) dielektrik maddesi ve $H/S=7$, $H_1/S=10$ için W/S 'in Z_o ile değişimi.



Şekil 7.6 Galyum arsenit ($\epsilon_r = 12.9$) dielektrik maddesi ve $H/S=5$, $H_1/S=5$ için W/S 'in Z_0 ile değişimi.

Regresyon uzlaşması kabul kriteri olarak %95 doğruluk seçilmiştir. Çizelge 7.2'de 375 adet test verisi için DVRM, YSA, k -NN ve LS regresyon modellerinin doğrulukları yer almaktadır. Çizelge 7.2'den görüldüğü gibi k -NN regresyon modeli % 90.24 doğruluğa sahiptir. Kabul kriterini sağlamadığı için regresyon uzlaşmasında yer almayacaktır.


Tablo 7.3'de ortalama, minimum, maksimum ve ortanca uzlaşım metotlarının doğrulukları yer almaktadır. Şekil 7.7'de farklı dielektrik maddeleri için $H/S=5$, $H_1/S=5$ oranlarında "Ortalama" uzlaşım metodu kullanılarak elde edilen sonuçlar ile hedef değerlerinin karşılaştırılması yer almaktadır. Benzer olarak Şekil 7.8'de "Minimum" uzlaşım metodu, Şekil 7.9'da "Maksimum" uzlaşım metodu, Şekil 7.10'da "Ortanca" uzlaşım metodu kullanılarak elde edilen sonuçlar ile hedef değerleri karşılaştırılmıştır.


Çizelge 7.2 Regresyon modellerinin test doğrulukları.

	Doğruluk (%)
DVRM	98.2929
YSA	98.9205
k-NN	90.2497
LS	99.1425


Çizelge 7.3 Uzlaşım metotlarının doğrulukları.

	Doğruluk (%)
Ortalama	98.7853
Minimum	98.4968
Maksimum	96.5205
Ortanca	99.6379


Şekil 7.7 Yaygın kullanılan dielektrik maddelerin $H/S=5$, $H_1/S=5$ için "Ortalama" uzlaşım metodu sonuçları ile hedef değerlerinin karşılaştırılması.



Şekil 7.8 Yaygın kullanılan dielektrik maddelerin $H/S=5$, $H_1/S=5$ için “Minimum” uzlaşım metodu sonuçları ile hedef değerlerinin karşılaştırılması.



Şekil 7.9 Yaygın kullanılan dielektrik maddelerin $H/S=5$, $H_1/S=5$ için “Maksimum” uzlaşım metodu sonuçları ile hedef değerlerinin karşılaştırılması.



Şekil 7.10 Yaygın kullanılan dielektrik maddelerin $H/S=5$, $H_1/S=5$ için “Ortanca” uzlaşım metodu sonuçları ile hedef değerlerinin karşılaştırılması.

7.4 Sonuç

Regresyon uzlaşımı birden fazla regresyon modelinin sonucunun birleştirilmesi ile yapılır. Regresyon uzlaşımındaki temel fikir birden fazla sayıdaki modelin, bağımsız değişkenler ile bağımlı değişkenler arasındaki ilişkiyi bir modele oranla daha efektif olarak belirleyecek olmasıdır. Bu çalışmada, regresyon modellerinin kullandığı örnek veri kümesi, önişlemci olarak seçilen DVM’ den geçirilerek elde edilen azaltılmış sayıda DV’ lerden oluşan bir kümedir. Azaltılmış sayıda örnek verisi ile işlem yapmak regresyon modellerini hızlandırarak daha verimli bir hale getirecektir. Sonrasında DVRM, YSA, k -NN, LS regresyon metotları regresyon problemine uyarlanmış ve kabul kriterini sağlayan regresyon modellerinin çıkışları arasında uzlaşım yapılarak bir çıkış elde edilmiştir. Bu çalışmada dört ayrı uzlaşım metodu kullanılmıştır: Ortalama almak, Minimumu almak, Maksimumu almak ve Ortancayı almak. Dört ayrı uzlaşım metodu ve regresyon modelleri iletken sırtlı üstü ekranlanmış EDDK’ nun sentezine uygulanmış ve elde edilen sonuçlar tablo ve şekillerle verilmiştir. Uygulama sonuçlarından görülebileceği gibi regresyon uzlaşım metodu olarak “Ortanca” almak hedef değerlere en yüksek doğrulukla yaklaşan sonuçları vermektedir.

8. SONUÇLAR

Akıllı sistemlerin teknolojiye yaygın kullanımına başlanması ile sistem tasarım yöntemlerinin problem çözümünde verdiği sonuçların doğruluğu ve sonuç üretebilme süreleri önem kazanmıştır. Bu bağlamda, sınıflandırma, optimizasyon, karar verme problemlerinde yaygın kullanılan yöntemler olarak hemen Yapay Sinir Ağları, Bulanık Mantık, Karar Ağaçları ve Genetik Algoritmalar akla gelir. Son on yılda ortaya atılan ve pek çok araştırmacının yapay sinir ağlarına alternatif olduğunu düşündüğü Destek Vektör Makineleri (DVM) öncelikle sınıflandırma problemlerinde kullanılmaya başlanmış ve gayet tatminkâr sonuçlar alındığı gözlenmiştir. Sonra Destek Vektör Regresyon Makineleri (DVRM) oluşturularak başarılı neticeler alınmaya başlanmıştır. Her iki tip Destek Vektör Makinesi de Yapay Sinir Ağlarında kullanılan geleneksel “Ampirik Risk Minimizasyonu (ARM)” yerine “Yapısal Risk Minimizasyonu (YRM)” prensibine dayandırılmıştır. ARM eğitim verisindeki hatayı minimize edecek şekilde çalışırken, YRM de beklendik riski sistem çıkış alt ve üst sınırlarını hesaba katarak minimize eder ki bu DVM’nin genelleştirme yeteneğinin yapay sinir ağlarına göre üstünlüğü olarak kabul edilmektedir.

Günümüzde, mikrodalga teori ve teknolojisinin çok çeşitli alanlarında, başlıca “modelleme” ve “tasarım” amaçları olmak üzere, yapay sinir ağları yaygın olarak kullanılmış ve başarılı sonuçlar elde edilmiştir. Bu tezde, 60’larda Rusya’da geliştirilen “Genelleştirilmiş Portre Algoritması”nın bir nonlinear genelleştirmesi olarak geliştirilmiş olan DV algoritmasının, mikrodalga modelleme ve tasarım problemlerinde, sağlam bir matematiksel araç olarak kullanımı gerçekleştirilmiştir. Bu tezin amacı, yeni bir yöntem olan DVM ile mikrodalga problemlerini çözümlenerek, literatürde bu konuda yapılacak çalışmalara öncü olmak ve örnek teşkil etmektir. Bu tezin literature katkıları şu şekilde özetlenebilir:

- 1) Bir mikrodalga transistörün işaret-gürültü DVRM modeli mikrodalga dünyasına tanıtılmış, işaret-gürültü YSA modelinin yerini alabileceği gösterilmiştir.
- 2) Mikroşerit iletim hatlarının destek vektör tasarımı yapılmıştır. Mikroşerit iletim hatlarının destek vektör tasarımı problemini tanımlayan kara-kutunun iki yönlü kullanılması ile analiz ve sentezin sadece analiz kara-kutusu kullanılarak yapılabileceği gösterilmiştir. Bu, izotropik ve anizotropik dielektrik maddeye sahip mikroşerit hatlara uyarlanarak ispatlanmıştır. Bunu diğer tip mikrodalga sistemlerine uyarlamak mümkündür. Ayrıca uyarlanabilir adım boyutu kullanılarak çok daha hızlı yakınsama elde edilmiştir.
- 3) Dikdörtgen mikroşerit anten rezonans frekansı, band genişliği, ve giriş empedansı, “N”

ölçme verisi kullanılarak DVM ile formüle edilmiştir. Formülasyon sonuçları, literatürde yer almış teorik sonuçlara göre çok yüksek doğruluğa sahip oldukları gözlemlenmiştir. Ayrıca, DVM performansı YSA' nki ile de karşılaştırılarak üstünlükleri belirtilmiştir.

4) Literatürde ilk olarak, bilgi-tabanlı destek vektör makinesi tasarlanmış ve bu metot tektaş ya da hibrit mikrodalga tümleşik devrelerinde kullanılan RF/Mikrodalga düzlemsel iletim hatlarının sentezinde kullanılmıştır. Bu yaklaşımda analiz işlemini tersine çeviren genel bir sentez metodu tanıtılmıştır. Bu sentez metodunun kaba modeller kadar hızlı, hassas modeller kadar yüksek doğruluklu olması amaçlanmıştır. Bu sebeple DVM metodu seçilmiştir. Bu çalışmada tasarlanan bilgi-tabanlı DVR metodu iki ayrı örnekle tanıtılmıştır. Her iki örneğin sonuçları da yapay sinir ağlarının sonuçları ile karşılaştırılmıştır.

5) Regresyon uygulamalarında kullanılacak regresyon algoritması seçimi için yeni bir yöntem geliştirilmiş ve "Mikrodalga Teknolojisinde Uzman Regresyon Sistemlerinin Uzlaşması" adı ile tanıtılmıştır. Bu amaçla dört ayrı regresyon algoritması (DVRM, YSA, k -NN, LS) seçilen bir regresyon problemine uyarlanmış ve dört ayrı regresyon modelinin çıkışları arasında uzlaşım yapılarak bir çıkış elde edilmiştir. Ayrıca, regresyon modellerinin kullanacağı örnek veri kümesi önışlemci olarak seçilen DVM' den geçirilerek elde edilen DV' lerden oluşan yeni veri kümesi regresyon modellerinde kullanılmıştır. Böylece, regresyon modellerinin azaltılmış sayıda örnek verisi ile işlem yaparak hızlandırılması mümkün olmuştur.

KAYNAKLAR

- Angiulli, G., Cacciola, M. ve Versaci, M., (2007), “Microwave Devices and Antennas Modelling by Support Vector Regression Machines”, *IEEE Transactions on Magnetics*, 43(4):1589-1592.
- 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.
- 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.
- 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.
- Bahl, J. ve Bhartia, P., (1980), *Microstrip Antennas*, Artech House, Dedham, MA.
- Bahl, I. ve Bhartia, P., (1988), *Microwave Solid-State Design*, Wiley–Interscience, New York.
- Bakr, M.H., Bandler, J.M., Ismail, M.A., Rayas-Sanchez, J.E. ve Zhang, Q.J., (2000), “Neural Space-Mapping Optimization for EM-Based Design”, *IEEE Trans. Microwave Theory Tech.*, 48:2307–2315.
- Balanis, C. A., (1997), *Antenna Theory*, John Wiley & Sons, Inc.
- Bandler, J.W., Rayas-Sanchez, J.E. ve Zhang, Q.J., (2002), “Yield-Driven Electromagnetic Optimization via Space Mapping-Based Neuromodels”, *Int. J. RF Microwave Computer-Aided Eng.*, 12:79–89.
- Carver, K.R., (1979), “Practical analytical techniques for the microstrip antennas”, In *Proc. Workshop on Printed Circuit Antennas*, New Mexico State University, Las Cruces, pp. 7.1–7.20.
- 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.
- Chang, C. ve Lin, C., (2001), LIBSVM : a library for support vector machines. Software available at <http://www.csie.ntu.edu.tw/~cjlin/libsvm>
- 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.
- Collins, R.E., (1992), *Foundations for Microwave Engineering*, McGraw-Hill, New York.
- Cristianini, N., ve Shawe-Taylor, J., (2000), *An Introduction to Support Vector Machines (and Other Kernel-Based Learning Methods)*, Cambridge University Press.
- Devabhaktuni, V.K., Yagoub, M.C.E. ve Zhang, Q.J., (2001), “A Robust Algorithm for Automatic Development of Neural Network Models for Microwave Applications”, *IEEE Trans. Microwave Theory Tech.*, 49:2282–2291.
- Devabhaktuni, V.K., Chattaraj, B., Yagoub, M.C.E. ve Zhang, Q.J., (2003), “Advanced Microwave Modeling Framework Exploiting Automatic Model Generation, Knowledge

- Neural Networks, and Space Mapping”, *IEEE Trans. Microwave Theory Tech.*, 51(7):1822-1833.
- 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.
- Edwards, T.C., (1981), *Foundations for Microstrip Circuit Design*, Wiley–Interscience, New York.
- 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.
- Ghione, G. ve Naldi, C.U., (1987), “Coplanar Waveguides for MMIC Applications: Effect of Upper Shielding, Conductor Backing, Finite-Extent Ground Planes, and Line-to-Line Coupling”, *IEEE Trans. Microwave Theory Tech.*, 35(3):260-267.
- Giannini, F., Leuzzi, G., Orengo, 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.
- Giannini, F., Colantonio, P., Orengo, G. ve Serino, A., (2006), “Neural Network Modeling of Microwave FETs Based on Third-Order Distortion Characterization”, *Int. J. RF Microwave Computer-Aided Eng.*, 16(2):192-200.
- Gupta, K.C., (1998), “Emerging Trends in Millimeter-Wave CAD”, *IEEE Trans. Microwave Theory Tech.*, 46:747–755.
- 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.
- Güneş, F., Torpi, H. ve Gürgen, F., (1998), “Multidimensional Signal-Noise Neural Network Model”, *IEE Proc.- Circuits, Devices Syst.*, 145(2):111-117.
- Güneş, F. ve Tepe, C., (2002), “Gain-Bandwidth Limitations of Microwave Transistor”, *Int. J. RF Microwave Computer-Aided Eng.*, 12(6):483-495.
- Güneş, F., Türker, N. ve Gürgen, F., (2007), “Signal-Noise Support Vector Model of a Microwave Transistor”, *Int. J. RF Microwave Computer-Aided Eng.*, 17:404–415.
- Güneş, F., Tokan N.T. ve Gürgen, F., (2008), “Support Vector Design of the Microstrip Lines”, *Int. J. RF Microwave Computer-Aided Eng.*, 18: 326–336.
- Güney, K., (1994a), “Radiation quality factor and resonant resistance of rectangular microstrip antennas” *Microwave Opt. Technology. Letters*, 7: 427–430.
- Güney, K., Erler, M. ve Sağıroğlu, S., (2000), “Artificial Neural Networks for the Resonant Resistance Calculation of Electrically Thin and Thick Rectangular Microstrip Antennas”, *Electromagnetics*, 20:387–400.
- Hammerstad, E.O., (1975), “Equations for microstrip circuits design”, *Proceedings of fifth European Microwave Conference*, Sept. 1975, Hamburg, 268-272.
- Howell, J.Q., (1975), “Microstrip antennas”, *IEEE Transactions on Antennas and Propagation*, AP-23: 90-93.
- James, J.R., Hall, P.S. ve Wood, C., (1981) “Microstrip antennas- theory and design”, Peter Peregrinus Ltd, England.

- Jargon, J.A., Gupta, K.C. ve DeGroot, D.C., (2002), "Applications of Artificial Neural Networks to RF and Microwave Measurements", *Int. J. RF Microwave Computer-Aided Eng.*, 12:3–24.
- Kara, M., (1996a), "An efficient technique for the computation of the input resistance of rectangular microstrip antenna elements with thick substrates", *Microwave Opt. Technology Letters*, 13(6):363–369.
- Kara, M., (1996b), "A novel technique to calculate the bandwidth of rectangular microstrip antenna elements with thick substrates", *Microwave Opt. Technology Letters*, 12:59-64.
- Kim, D., Lee, H. ve Cho, S., (2008), "Response modeling with support vector regression", *Expert Systems with Applications*, 34:1102–1108.
- Kruij, 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.
- Kuhn, H., ve Tucker, A., (1951), *Nonlinear Programming*, In Proceedings of 2nd Berkeley Symposium on Mathematical Statistics and Probabilistics, University of California Press.
- Li, Y., Shao, X. ve Cai, W., (2007), "A consensus least squares support vector regression (LS-SVR) for analysis of near-infrared spectra of plant samples", *Elsevier: Talanta*, 72:217–222.
- 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.
- Ramón, M., Xu, N. ve Christodoulou, C.G., (2005), "Beamforming Using Support Vector Machines", *IEEE Antennas and Wireless Propagation Letters*, 4: 439-442.
- 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.
- 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.
- Sagioglu, S., Guney, K. ve Erler, M., (1999), "Calculation of Bandwidth for Electrically Thin and Thick Rectangular Microstrip Antennas with the Use of Multilayered Perceptrons", *Int. J. RF Microwave Computer-Aided Eng.*, 9: 277–286.
- Santamaria, I., (2003), "Design of linear-phase FIR filters using support vector regression approach", *Electronics Letters*, 39(19).
- Shiavi, R., (1999), *Introduction to Applied Statistical Signal Analysis*, Academic Press, San Diego.
- 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.
- Türker, N. ve Güneş, F., (2006), "A Competitive Approach to Neural Device Modeling: Support Vector Machines", *Lecture Notes in Computer Science: Artificial Neural Networks-ICANN 2006*, 4132: 974-981.
- Tokan, N.T. ve Güneş, F., (2008a), "Analysis and Synthesis of the Microstrip Lines by

Support Vector Regressors”, Progress In Electromagnetics Research Symposium, 2-6 Temmuz 2008, Cambridge, ABD.

Tokan, N.T. ve Güneş, F., (2008b), “Support Vector Analysis of the Rectangular Patch Antenna”, Progress In Electromagnetics Research Symposium 2008, 2-6 Temmuz 2008, Cambridge, ABD.

Tokan, N.T., ve Güneş, F., (2008c), “Support Vector Characterisation of Resonance Frequencies of Microstrip Antennas based on Measurements”, Progress In Electromagnetics Research B, 5:49-51.

Tokan, N.T., ve Güneş, F., (2008d), “Analysis and Synthesis of the Microstrip Lines Based on Support Vector Regression”, European Microwave Conference, 27-31 Ekim 2008, Amsterdam, Hollanda.

Vapnik, V., (1995), The Nature of Statistical Learning Theory, Springer-Verlag, New York.

Wang, F. ve Zhang, Q.J., (1997), “Knowledge-Based Neural Models for Microwave Design”, IEEE Trans. Microwave Theory Tech., 45:2333–2343.

Watson, P.M., Gupta, K.C. ve Mahajan, R.L., (1999), “Applications of Knowledge-Based Artificial Neural Network Modeling to Microwave Components”, Int. J. RF Microwave Computer-Aided Eng., 9:254–260.

Zhang, Q.J. ve Gupta, K.C., (2000), Neural Networks for RF and Microwave Design, Artech House, Norwood.

Zhang, Q.J., Gupta, K.C. ve Devabhaktuni, V.K., (2003), “Artificial Neural Networks for RF and Microwave Design-from Theory to Practice”, IEEE Trans. Microwave Theory Tech., 51(4):1339–1350.

EKLER

Ek 1 ATF-551M4 Mikrodalga Transistörünün Üretici Verileri

Ek 1 ATF-551M4 Mikrodalga Transistörünün Üretici Verileri



Agilent ATF-551M4 Low Noise Enhancement Mode Pseudomorphic HEMT in a Miniature Leadless Package

Data Sheet

Description

Agilent Technologies' ATF-551M4 is a high dynamic range, super low noise, single supply E-pHEMT GaAs FET housed in a thin miniature leadless package.


The combination of small device size, super low noise (under 1 dB Fmin from 2 to 6 GHz), high linearity and low power makes the ATF-551M4 ideal for LNA or hybrid module designs in wireless receiver in the 450 MHz to 10 GHz frequency band.

Applications include Cellular/PCS/ WCDMA handsets and data modem cards, fixed wireless infrastructure in the 2.4, 3.5 GHz and UNII frequency bands, as well as 2.4 GHz 802.11b, 5 GHz 802.11a and HIPERLAN/2 Wireless LAN PC-cards.


Note:

- Agilent's enhancement mode E-pHEMT devices are the first commercially available single-supply GaAs transistors that do not need a negative gate bias voltage for operation. They can help simplify the design and reduce the cost of receivers and transmitters in many applications in the 450 MHz to 10 GHz frequency range.

MiniPak 1.4 mm x 1.2 mm Package



Pin Connections and Package Marking



Note:

Top View. Package marking provides orientation, product identification and date code.

"V" = Device Type Code

"x" = Date code character. A different character is assigned for each month and year.

Features

- Very low noise figure and high linearity
- Single Supply Enhancement Mode Technology^[1] optimized for 3V operation
- Excellent uniformity in product specifications
- 400 micron gate width
- Thin miniature package 1.4 mm x 1.2 mm x 0.7 mm
- Tape-and-reel packaging option available

Specifications

- 2 GHz; 2.7V, 10 mA (typ.)
- 24.1 dBm output 3rd order intercept
- 14.6 dBm output power at 1 dB gain compression
- 0.5 dB noise figure
- 17.5 dB associated gain

Applications

- Low Noise Amplifier for:
 - Cellular/PCS/WCDMA handsets and modem cards
 - 2.4 GHz, 3.5 GHz and UNII fixed wireless infrastructure
 - 2.4 GHz 802.11b Wireless LAN
 - 5 GHz 802.11a and HIPERLAN Wireless LAN
- General purpose discrete E-pHEMT for other ultra low noise applications

ATF-551M4 Typical Scattering Parameters, $V_{DS} = 2V, I_{DS} = 10\text{ mA}$

Freq. GHz	S_{11}		dB	S_{21}		S_{12}		S_{22}		MSG/MAG dB
	Mag.	Ang.		Mag.	Ang.	Mag.	Ang.	Mag.	Ang.	
0.1	0.995	-6.0	20.41	10.479	175.9	0.007	86.3	0.803	-3.3	31.75
0.5	0.954	-29.1	19.95	9.946	158.2	0.031	71.6	0.758	-15.6	25.06
0.9	0.906	-50.7	19.35	9.280	144.2	0.052	60.8	0.710	-27.4	22.52
1.0	0.896	-55.7	19.18	9.103	141.0	0.056	58.3	0.692	-30.2	22.11
1.5	0.833	-79.5	18.15	8.080	125.6	0.075	46.8	0.611	-42.3	20.32
1.9	0.790	-96.5	17.22	7.260	114.9	0.085	39.0	0.547	-50.4	19.32
2.0	0.781	-100.4	17.00	7.078	112.5	0.087	37.3	0.532	-52.3	19.10
2.5	0.739	-118.5	15.84	6.197	101.1	0.095	29.8	0.463	-60.6	18.14
3.0	0.710	-134.4	14.74	5.459	91.2	0.099	23.7	0.404	-67.6	17.41
4.0	0.683	-160.0	12.75	4.341	74.5	0.104	14.8	0.318	-79.6	16.21
5.0	0.679	-179.8	11.03	3.559	60.3	0.105	8.6	0.263	-91.2	15.30
6.0	0.680	166.5	9.65	3.036	48.5	0.107	5.0	0.220	-99.5	14.53
7.0	0.681	154.0	8.43	2.638	37.2	0.107	2.1	0.199	-111.0	13.92
8.0	0.683	143.7	7.43	2.353	26.4	0.110	-0.3	0.185	-123.4	13.30
9.0	0.690	132.7	6.53	2.122	15.7	0.113	-2.6	0.181	-137.7	11.27
10.0	0.687	119.7	5.72	1.932	4.5	0.117	-5.4	0.185	-151.1	9.97
11.0	0.691	106.5	4.98	1.775	-6.4	0.122	-8.4	0.196	-163.5	9.14
12.0	0.696	92.6	4.28	1.636	-17.7	0.129	-12.3	0.209	-174.4	8.44
13.0	0.713	81.8	3.53	1.501	-28.6	0.135	-16.2	0.206	-171.4	7.80
14.0	0.747	67.4	2.82	1.384	-40.4	0.143	-21.8	0.211	-151.2	7.62
15.0	0.759	55.5	1.97	1.255	-51.8	0.149	-27.4	0.237	-131.8	6.73
16.0	0.808	45.4	1.00	1.122	-62.4	0.153	-33.3	0.269	-113.3	6.90
17.0	0.828	37.3	-0.01	0.999	-72.7	0.157	-39.2	0.322	-95.4	6.20
18.0	0.870	30.9	-1.04	0.887	-82.6	0.159	-45.2	0.383	-80.1	7.47

Typical Noise Parameters, $V_{DS} = 2V, I_{DS} = 10\text{ mA}$

Freq GHz	F_{min} dB	Γ_{opt} Mag.	Γ_{opt} Ang.	$R_{n/50}$	G_a dB
0.5	0.24	0.62	-4.3	0.14	23.50
0.9	0.24	0.56	8.8	0.13	21.66
1.0	0.28	0.52	13.5	0.12	21.61
1.9	0.45	0.47	38.6	0.11	18.04
2.0	0.39	0.47	42.9	0.11	17.88
2.4	0.47	0.42	52.8	0.11	16.76
3.0	0.55	0.35	74.0	0.09	15.66
3.9	0.61	0.32	105.4	0.08	14.10
5.0	0.74	0.33	144.0	0.06	12.74
5.8	0.89	0.36	164.3	0.05	11.83
6.0	0.90	0.37	166.1	0.05	11.63
7.0	1.03	0.38	-170.9	0.06	10.71
8.0	1.13	0.44	-157.2	0.07	9.99
9.0	1.27	0.48	-142.4	0.09	9.36
10.0	1.53	0.46	-126.0	0.17	8.46

Notes:

1. The F_{min} values are based on a set of 16 noise figure measurements made at 16 different impedances using an ATN NP5 test system. From these measurements F_{min} is calculated. Refer to the noise parameter measurement section for more information.
2. S and noise parameters are measured on a microstrip line made on 0.010 inch thick alumina carrier assembly. The input reference plane is at the end of the gate pad. The output reference plane is at the end of the drain pad.




Figure 26. MSG/MAG and $|S_{21}|^2$ vs. Frequency at 2V, 10 mA.

ATF-551M4 Typical Scattering Parameters, $V_{DS} = 2V$, $I_{DS} = 15\text{ mA}$

Freq. GHz	S_{11}			S_{21}		S_{12}		S_{22}		MSG/MAG dB
	Mag.	Ang.	dB	Mag.	Ang.	Mag.	Ang.	Mag.	Ang.	
0.1	0.995	-6.6	21.93	12.489	175.5	0.006	86.2	0.765	-3.7	33.18
0.5	0.947	-31.6	21.41	11.757	156.7	0.029	70.9	0.715	-17.0	26.08
0.9	0.892	-54.7	20.67	10.804	142.0	0.048	59.7	0.659	-29.6	23.52
1.0	0.880	-60.1	20.46	10.547	138.6	0.052	57.1	0.641	-32.5	23.07
1.5	0.812	-84.9	19.26	9.186	123.0	0.067	46.0	0.555	-45.0	21.37
1.9	0.768	-102.1	18.23	8.153	112.3	0.076	38.7	0.489	-53.1	20.31
2.0	0.758	-106.1	17.98	7.923	109.9	0.077	37.2	0.474	-55.0	20.12
2.5	0.718	-124.1	16.73	6.859	98.9	0.084	30.5	0.407	-63.2	19.12
3.0	0.692	-139.7	15.55	5.991	89.3	0.088	25.3	0.352	-70.2	18.33
4.0	0.671	-164.5	13.47	4.716	73.3	0.092	18.0	0.272	-82.3	17.10
5.0	0.670	176.6	11.70	3.845	59.7	0.095	13.1	0.222	-94.5	16.07
6.0	0.671	163.5	10.30	3.273	48.3	0.098	10.5	0.181	-103.2	15.24
7.0	0.674	151.5	9.06	2.838	37.4	0.101	8.2	0.164	-115.4	14.49
8.0	0.676	141.6	8.06	2.528	27.0	0.105	6.1	0.152	-128.5	12.66
9.0	0.684	130.9	7.14	2.276	16.5	0.111	3.7	0.150	-143.3	11.51
10.0	0.682	118.0	6.33	2.072	5.6	0.117	0.6	0.156	-156.9	10.35
11.0	0.686	105.1	5.59	1.903	-5.0	0.124	-3.1	0.170	-169.0	9.57
12.0	0.691	91.4	4.88	1.753	-16.1	0.132	-7.6	0.183	-179.3	8.87
13.0	0.708	80.9	4.13	1.609	-26.9	0.140	-12.3	0.181	165.9	8.27
14.0	0.744	66.5	3.42	1.483	-38.5	0.148	-18.6	0.188	145.0	8.14
15.0	0.756	54.9	2.59	1.347	-49.7	0.155	-24.9	0.217	125.0	7.23
16.0	0.805	45.0	1.59	1.201	-60.2	0.158	-31.2	0.253	106.8	7.38
17.0	0.825	37.0	0.61	1.073	-70.4	0.161	-37.5	0.310	89.4	6.61
18.0	0.870	30.7	-0.41	0.954	-80.1	0.163	-43.8	0.373	74.9	7.67

Typical Noise Parameters, $V_{DS} = 2V$, $I_{DS} = 15\text{ mA}$

Freq GHz	F_{min} dB	Γ_{opt} Mag.	Γ_{opt} Ang.	$R_n/50$	G_a dB
0.5	0.21	0.61	-6.1	0.12	24.12
0.9	0.21	0.55	7.0	0.12	22.18
1.0	0.27	0.50	11.4	0.11	22.12
1.9	0.42	0.46	38.1	0.10	18.61
2.0	0.37	0.43	42.7	0.10	18.52
2.4	0.44	0.39	52.9	0.10	17.34
3.0	0.52	0.32	74.4	0.08	16.21
3.9	0.57	0.28	108.3	0.07	14.65
5.0	0.71	0.30	149.5	0.06	13.27
5.8	0.85	0.35	170.0	0.05	12.38
6.0	0.86	0.35	171.7	0.05	12.19
7.0	0.97	0.38	-165.9	0.06	11.24
8.0	1.08	0.43	-152.1	0.07	10.49
9.0	1.22	0.47	-138.1	0.10	9.84
10.0	1.44	0.46	-122.5	0.17	8.96




Figure 27. MSG/MAG and $|S_{21}|^2$ vs. Frequency at 2V, 15 mA.

Notes:

1. The F_{min} values are based on a set of 16 noise figure measurements made at 16 different impedances using an ATN NP5 test system. From these measurements F_{min} is calculated. Refer to the noise parameter measurement section for more information.
2. S and noise parameters are measured on a microstrip line made on 0.010 inch thick alumina carrier assembly. The input reference plane is at the end of the gate pad. The output reference plane is at the end of the drain pad.

ATF-551M4 Typical Scattering Parameters, $V_{DS} = 2V, I_{DS} = 20\text{ mA}$

Freq. GHz	S_{11}			S_{21}			S_{12}		S_{22}		MSG/MAG dB
	Mag.	Ang.	dB	Mag.	Ang.	dB	Mag.	Ang.	Mag.	Ang.	
0.1	0.994	-6.9	22.85	13.876	175.3		0.006	85.6	0.740	-3.9	33.64
0.5	0.942	-33.3	22.27	12.985	155.7		0.027	70.4	0.687	-17.8	26.82
0.9	0.882	-57.3	21.44	11.806	140.5		0.045	59.0	0.627	-30.9	24.19
1.0	0.869	-62.8	21.21	11.491	137.1		0.048	56.5	0.608	-33.8	23.79
1.5	0.798	-88.1	19.90	9.881	121.3		0.062	45.7	0.520	-46.4	22.02
1.9	0.753	-105.5	18.79	8.704	110.7		0.070	38.9	0.455	-54.4	20.95
2.0	0.744	-109.5	18.53	8.443	108.4		0.071	37.4	0.441	-56.3	20.75
2.5	0.706	-127.4	17.22	7.262	97.5		0.077	31.3	0.376	-64.3	19.75
3.0	0.681	-142.7	16.01	6.314	88.2		0.081	26.7	0.323	-71.0	18.92
4.0	0.663	-167.0	13.88	4.943	72.5		0.085	20.3	0.248	-82.9	17.65
5.0	0.664	174.6	12.09	4.021	59.3		0.089	16.2	0.201	-95.2	16.55
6.0	0.666	161.9	10.68	3.418	48.1		0.093	14.1	0.162	-103.7	15.65
7.0	0.670	150.1	9.43	2.962	37.3		0.097	12.0	0.144	-116.4	14.85
8.0	0.673	140.4	8.42	2.637	27.1		0.103	10.0	0.133	-130.0	12.78
9.0	0.681	129.8	7.51	2.373	16.8		0.109	7.4	0.131	-145.9	11.65
10.0	0.678	117.1	6.68	2.158	6.0		0.117	3.7	0.139	-160.3	10.56
11.0	0.682	104.3	5.94	1.982	-4.6		0.125	-0.2	0.154	-172.7	9.80
12.0	0.688	90.6	5.23	1.826	-15.6		0.133	-5.2	0.168	176.9	9.11
13.0	0.706	80.3	4.48	1.675	-26.3		0.142	-10.3	0.169	161.6	8.56
14.0	0.743	65.9	3.76	1.542	-38.0		0.150	-17.0	0.182	139.6	8.46
15.0	0.753	54.4	2.92	1.400	-48.9		0.157	-23.6	0.212	121.2	7.48
16.0	0.804	44.7	1.93	1.249	-59.3		0.160	-30.1	0.250	103.8	7.76
17.0	0.824	36.7	0.95	1.116	-69.4		0.163	-36.5	0.306	87.0	6.93
18.0	0.869	30.6	-0.05	0.994	-78.9		0.165	-43.0	0.367	73.0	7.80

Typical Noise Parameters, $V_{DS} = 2V, I_{DS} = 20\text{ mA}$

Freq GHz	F_{min} dB	Γ_{opt} Mag.	Γ_{opt} Ang.	$R_n/50$	G_a dB
0.5	0.19	0.59	-7.0	0.11	23.50
0.9	0.20	0.54	6.3	0.11	21.66
1.0	0.25	0.48	10.1	0.10	21.61
1.9	0.41	0.43	38.7	0.09	18.04
2.0	0.36	0.41	43.1	0.09	17.88
2.4	0.43	0.37	53.4	0.09	16.76
3.0	0.51	0.29	76.3	0.08	15.66
3.9	0.58	0.26	112.7	0.07	14.10
5.0	0.70	0.29	154.0	0.05	12.74
5.8	0.85	0.34	173.6	0.05	11.83
6.0	0.86	0.35	175.9	0.05	11.63
7.0	0.94	0.37	-162.3	0.06	10.71
8.0	1.07	0.42	-148.2	0.08	9.99
9.0	1.20	0.48	-135.2	0.10	9.36
10.0	1.43	0.46	-119.5	0.17	8.46

Notes:

1. The F_{min} values are based on a set of 16 noise figure measurements made at 16 different impedances using an ATN NP5 test system. From these measurements F_{min} is calculated. Refer to the noise parameter measurement section for more information.
2. S and noise parameters are measured on a microstrip line made on 0.010 inch thick alumina carrier assembly. The input reference plane is at the end of the gate pad. The output reference plane is at the end of the drain pad.




Figure 28. MSG/MAG and $|S_{21}|^2$ vs. Frequency at 2V, 20 mA.

ATF-551M4 Typical Scattering Parameters, $V_{DS} = 2.7V$, $I_{DS} = 10\text{ mA}$

Freq. GHz	S_{11}			S_{21}			S_{12}		S_{22}		MSG/MAG dB
	Mag.	Ang.	dB	Mag.	Ang.	dB	Mag.	Ang.	Mag.	Ang.	
0.1	0.995	-5.9	20.55	10.656	175.9	20.55	0.006	86.3	0.825	-3.0	32.49
0.5	0.955	-28.7	20.11	10.129	158.4	20.11	0.028	72.0	0.782	-14.0	25.58
0.9	0.907	-50.0	19.52	9.466	144.6	19.52	0.046	61.3	0.735	-24.5	23.13
1.0	0.896	-55.0	19.36	9.292	141.4	19.36	0.050	58.8	0.717	-27.0	22.69
1.5	0.833	-78.6	18.34	8.265	126.1	18.34	0.067	47.6	0.639	-37.6	20.91
1.9	0.789	-95.5	17.43	7.439	115.4	17.43	0.076	40.0	0.577	-44.6	19.91
2.0	0.779	-99.4	17.21	7.255	113.0	17.21	0.078	38.4	0.562	-46.2	19.69
2.5	0.737	-117.4	16.07	6.361	101.7	16.07	0.085	31.0	0.495	-53.1	18.74
3.0	0.707	-133.4	14.98	5.610	91.8	14.98	0.089	25.1	0.439	-58.8	18.00
4.0	0.679	-159.1	13.01	4.471	75.0	13.01	0.093	16.6	0.357	-68.3	16.82
5.0	0.674	-178.9	11.30	3.673	60.8	11.30	0.094	10.9	0.303	-77.6	15.92
6.0	0.675	167.3	9.93	3.136	49.1	9.93	0.095	8.1	0.264	-83.7	15.19
7.0	0.676	154.9	8.72	2.728	37.7	8.72	0.096	5.9	0.244	-93.5	14.54
8.0	0.679	144.5	7.73	2.435	27.0	7.73	0.099	4.3	0.230	-104.1	12.94
9.0	0.686	133.5	6.84	2.198	16.2	6.84	0.102	2.9	0.222	-116.6	11.58
10.0	0.684	120.8	6.03	2.002	5.1	6.03	0.107	0.7	0.222	-129.0	10.44
11.0	0.688	107.5	5.30	1.841	-5.9	5.30	0.113	-1.7	0.230	-140.8	9.69
12.0	0.693	93.7	4.59	1.696	-17.2	4.59	0.121	-5.2	0.239	-151.9	9.02
13.0	0.710	82.7	3.86	1.559	-28.2	3.86	0.129	-8.9	0.232	-164.6	8.47
14.0	0.743	68.6	3.19	1.443	-39.8	3.19	0.139	-14.3	0.222	-176.6	8.42
15.0	0.760	56.5	2.37	1.314	-51.5	2.37	0.147	-20.2	0.232	-155.6	7.69
16.0	0.805	46.2	1.42	1.177	-62.2	1.42	0.153	-26.2	0.251	-134.3	8.26
17.0	0.830	38.1	0.43	1.051	-72.8	0.43	0.158	-32.5	0.293	-112.0	8.07
18.0	0.872	31.5	-0.58	0.935	-83.1	-0.58	0.163	-39.1	0.353	-92.7	7.59

Typical Noise Parameters, $V_{DS} = 2.7V$, $I_{DS} = 10\text{ mA}$

Freq GHz	F_{min} dB	Γ_{opt} Mag.	Γ_{opt} Ang.	$R_n/50$	G_a dB
0.5	0.26	0.64	-4.4	0.14	23.79
0.9	0.27	0.57	7.5	0.13	21.80
1.0	0.30	0.54	11.1	0.13	21.60
1.9	0.46	0.49	36.6	0.11	18.06
2.0	0.41	0.48	40.4	0.12	17.92
2.4	0.47	0.44	50.3	0.11	16.79
3.0	0.55	0.36	69.5	0.10	15.70
3.9	0.61	0.32	101.3	0.08	14.24
5.0	0.74	0.32	139.5	0.06	12.86
5.8	0.88	0.35	161.5	0.05	12.01
6.0	0.90	0.35	163.9	0.05	11.82
7.0	1.00	0.37	-173.6	0.06	10.93
8.0	1.12	0.41	-158.2	0.07	10.24
9.0	1.25	0.46	-143.0	0.09	9.66
10.0	1.46	0.46	-127.2	0.15	8.85




Figure 29. MSG/MAG and $|S_{21}|^2$ vs. Frequency at 2.7V, 10 mA.

Notes:

1. The F_{min} values are based on a set of 16 noise figure measurements made at 16 different impedances using an ATN NP5 test system. From these measurements F_{min} is calculated. Refer to the noise parameter measurement section for more information.
2. S and noise parameters are measured on a microstrip line made on 0.010 inch thick alumina carrier assembly. The input reference plane is at the end of the gate pad. The output reference plane is at the end of the drain pad.

ATF-551M4 Typical Scattering Parameters, $V_{DS} = 2.7V, I_{DS} = 15\text{ mA}$

Freq. GHz	S_{11}			S_{21}			S_{12}		S_{22}		MSG/MAG dB
	Mag.	Ang.	dB	Mag.	Ang.	dB	Mag.	Ang.	Mag.	Ang.	
0.1	0.995	-6.5	21.98	12.559	175.6		0.006	86.4	0.793	-3.2	33.21
0.5	0.949	-31.2	21.47	11.839	156.9		0.026	71.0	0.745	-15.2	26.58
0.9	0.894	-54.0	20.75	10.905	142.3		0.043	60.1	0.691	-26.4	24.04
1.0	0.882	-59.4	20.55	10.650	138.9		0.047	57.5	0.673	-28.9	23.55
1.5	0.814	-84.0	19.37	9.298	123.4		0.061	46.6	0.589	-39.7	21.83
1.9	0.768	-101.1	18.34	8.265	112.7		0.068	39.5	0.526	-46.6	20.85
2.0	0.758	-105.1	18.10	8.034	110.3		0.070	38.0	0.511	-48.1	20.60
2.5	0.718	-123.1	16.86	6.966	99.3		0.076	31.4	0.447	-54.6	19.62
3.0	0.691	-138.7	15.70	6.095	89.7		0.079	26.3	0.393	-59.9	18.87
4.0	0.668	-163.5	13.64	4.806	73.6		0.083	19.4	0.318	-68.8	17.63
5.0	0.667	177.5	11.88	3.928	59.9		0.085	15.0	0.268	-77.7	16.65
6.0	0.668	164.3	10.49	3.345	48.5		0.088	13.1	0.230	-83.3	15.80
7.0	0.671	152.2	9.26	2.904	37.5		0.091	11.4	0.212	-93.0	15.04
8.0	0.673	142.3	8.27	2.591	27.0		0.095	10.0	0.198	-103.4	12.89
9.0	0.682	131.6	7.37	2.335	16.4		0.101	8.4	0.190	-116.2	11.88
10.0	0.677	118.5	6.56	2.128	5.4		0.107	5.6	0.190	-129.6	10.70
11.0	0.684	105.8	5.83	1.956	-5.3		0.115	2.6	0.198	-142.6	10.06
12.0	0.690	91.7	5.12	1.804	-16.7		0.124	-1.7	0.210	-154.2	9.46
13.0	0.707	81.2	4.38	1.656	-27.5		0.133	-6.1	0.205	-167.8	8.93
14.0	0.744	66.4	3.68	1.528	-39.4		0.143	-12.3	0.200	-172.5	9.10
15.0	0.750	55.1	2.85	1.389	-50.6		0.151	-18.7	0.212	-150.9	7.85
16.0	0.806	45.2	1.88	1.242	-61.2		0.156	-25.1	0.236	-129.7	9.01
17.0	0.824	37.1	0.92	1.112	-71.5		0.162	-31.6	0.282	-107.9	8.37
18.0	0.872	31.0	-0.08	0.991	-81.5		0.166	-38.2	0.337	-89.7	7.76

Typical Noise Parameters, $V_{DS} = 2.7V, I_{DS} = 15\text{ mA}$

Freq GHz	F_{min} dB	Γ_{opt} Mag.	Γ_{opt} Ang.	$R_n/50$	G_a dB
0.5	0.18	0.61	-6.0	0.12	24.49
0.9	0.18	0.56	6.8	0.12	22.38
1.0	0.24	0.5	10.7	0.11	22.32
1.9	0.38	0.45	36.9	0.1	18.78
2.0	0.33	0.43	41.9	0.1	18.65
2.4	0.42	0.39	50.9	0.1	17.47
3.0	0.5	0.31	73.0	0.08	16.37
3.9	0.55	0.28	107.0	0.07	14.83
5.0	0.66	0.29	146.6	0.06	13.4
5.8	0.83	0.33	168.7	0.05	12.54
6.0	0.84	0.34	170.7	0.05	12.36
7.0	0.95	0.36	-166.9	0.06	11.44
8.0	1.06	0.41	-152.3	0.07	10.69
9.0	1.18	0.46	-138.1	0.1	10.12
10.0	1.43	0.44	-122.5	0.16	9.21

Notes:

1. The F_{min} values are based on a set of 16 noise figure measurements made at 16 different impedances using an ATN NP5 test system. From these measurements F_{min} is calculated. Refer to the noise parameter measurement section for more information.
2. S and noise parameters are measured on a microstrip line made on 0.010 inch thick alumina carrier assembly. The input reference plane is at the end of the gate pad. The output reference plane is at the end of the drain pad.




Figure 30. MSG/MAG and $|S_{21}|^2$ vs. Frequency at 2.7V, 15 mA.

ATF-551M4 Typical Scattering Parameters, $V_{DS} = 2.7V, I_{DS} = 20\text{ mA}$

Freq. GHz	S_{11}			S_{21}			S_{12}		S_{22}		MSG/MAG dB
	Mag.	Ang.	dB	Mag.	Ang.	dB	Mag.	Ang.	Mag.	Ang.	
0.1	0.995	-6.8	22.92	13.988	175.4		0.005	86.4	0.772	-3.4	34.47
0.5	0.943	-33.0	22.35	13.103	155.9		0.024	70.6	0.72	-15.7	27.37
0.9	0.883	-56.9	21.53	11.932	140.7		0.04	59.4	0.662	-27.1	24.75
1.0	0.87	-62.4	21.30	11.616	137.3		0.043	56.9	0.643	-29.6	24.32
1.5	0.798	-87.6	20.00	10.004	121.6		0.056	46.2	0.557	-40.2	22.52
1.9	0.752	-104.9	18.91	8.822	111.0		0.063	39.6	0.494	-46.7	21.46
2.0	0.743	-108.8	18.65	8.557	108.6		0.064	38.2	0.48	-48.1	21.26
2.5	0.704	-126.7	17.35	7.367	97.8		0.069	32.3	0.417	-54.2	20.28
3.0	0.68	-142.1	16.14	6.411	88.4		0.072	27.8	0.367	-59.0	19.50
4.0	0.66	-166.3	14.02	5.026	72.8		0.076	22.0	0.297	-67.2	18.20
5.0	0.662	175.2	12.25	4.095	59.5		0.079	18.6	0.251	-75.7	17.15
6.0	0.664	162.6	10.84	3.483	48.4		0.083	17.4	0.216	-80.7	16.23
7.0	0.667	150.9	9.61	3.022	37.6		0.087	16.1	0.199	-90.4	14.69
8.0	0.67	141.2	8.61	2.695	27.3		0.093	14.8	0.185	-100.6	13.08
9.0	0.679	130.8	7.71	2.429	16.9		0.099	13.0	0.177	-113.5	12.08
10.0	0.677	118.1	6.90	2.213	6.0		0.107	9.9	0.178	-127.2	11.08
11.0	0.683	105.4	6.17	2.034	-4.6		0.116	6.4	0.186	-140.4	10.44
12.0	0.688	91.4	5.46	1.876	-15.8		0.126	1.8	0.198	-152.2	9.85
13.0	0.705	80.9	4.72	1.722	-26.5		0.136	-3.2	0.193	-165.9	9.37
14.0	0.741	66.5	4.03	1.59	-38.3		0.146	-9.8	0.188	173.7	9.78
15.0	0.75	55.0	3.19	1.444	-49.5		0.154	-16.5	0.2	151.1	8.35
16.0	0.803	45.1	2.22	1.291	-60.1		0.159	-23.2	0.224	129.5	9.10
17.0	0.823	37.2	1.26	1.156	-70.3		0.165	-29.8	0.269	107.3	8.45
18.0	0.872	31.0	0.27	1.032	-80.2		0.168	-36.6	0.325	88.8	7.88

Typical Noise Parameters, $V_{DS} = 2.7V, I_{DS} = 20\text{ mA}$

Freq GHz	F_{min} dB	Γ_{opt} Mag.	Γ_{opt} Ang.	$R_n/50$	G_a dB
0.5	0.18	0.61	-6.7	0.12	24.89
0.9	0.18	0.55	5.9	0.11	22.72
1.0	0.23	0.49	9.9	0.10	22.68
1.9	0.39	0.43	37.8	0.09	19.18
2.0	0.36	0.42	41.6	0.09	18.98
2.4	0.43	0.37	51.7	0.09	17.83
3.0	0.51	0.29	73.6	0.08	16.69
3.9	0.56	0.26	110.7	0.07	15.19
5.0	0.68	0.28	152.8	0.05	13.79
5.8	0.83	0.33	172.9	0.05	12.91
6.0	0.85	0.33	175.6	0.05	12.73
7.0	0.95	0.37	-162.4	0.06	11.80
8.0	1.06	0.41	-148.8	0.08	11.06
9.0	1.19	0.47	-135.5	0.10	10.47
10.0	1.41	0.46	-119.2	0.17	9.59

Notes:

1. The F_{min} values are based on a set of 16 noise figure measurements made at 16 different impedances using an ATN NP5 test system. From these measurements F_{min} is calculated. Refer to the noise parameter measurement section for more information.
2. S and noise parameters are measured on a microstrip line made on a 0.010 inch thick alumina carrier assembly. The input reference plane is at the end of the gate pad. The output reference plane is at the end of the drain pad.




Figure 31. MSG/MAG and $|S_{21}|^2$ vs. Frequency at 2.7V, 20 mA.

ATF-551M4 Typical Scattering Parameters, $V_{DS} = 3V, I_{DS} = 10\text{ mA}$

Freq. GHz	S_{11}			S_{21}			S_{12}			S_{22}			MSG/MAG dB
	Mag.	Ang.	dB	Mag.	Ang.	dB	Mag.	Ang.	dB	Mag.	Ang.	dB	
0.1	0.996	-5.9	20.49	10.578	176.0		0.006	86.1		0.835	-2.8		32.46
0.5	0.957	-28.4	20.05	10.059	158.5		0.027	72.0		0.792	-13.4		25.71
0.9	0.909	-49.6	19.48	9.420	144.8		0.045	61.5		0.747	-23.5		23.21
1.0	0.899	-54.6	19.32	9.246	141.6		0.049	59.1		0.730	-25.9		22.76
1.5	0.836	-78.1	18.32	8.241	126.3		0.065	47.9		0.653	-36.1		21.03
1.9	0.792	-94.9	17.41	7.424	115.7		0.074	40.3		0.593	-42.7		20.01
2.0	0.782	-98.8	17.20	7.241	113.2		0.075	38.6		0.578	-44.2		19.85
2.5	0.740	-116.8	16.07	6.360	101.9		0.082	31.3		0.513	-50.7		18.90
3.0	0.709	-132.8	14.99	5.616	91.9		0.086	25.3		0.458	-56.0		18.15
4.0	0.680	-158.5	13.03	4.481	75.1		0.090	16.9		0.378	-64.9		16.97
5.0	0.675	-178.4	11.33	3.684	60.9		0.091	11.3		0.325	-73.5		16.07
6.0	0.675	167.8	9.96	3.146	49.1		0.092	8.7		0.287	-79.1		15.34
7.0	0.676	155.1	8.75	2.738	37.6		0.093	6.6		0.267	-88.4		14.69
8.0	0.678	144.9	7.77	2.447	26.8		0.095	5.4		0.252	-98.6		12.90
9.0	0.686	133.8	6.88	2.209	16.0		0.099	4.1		0.242	-110.5		11.73
10.0	0.682	120.5	6.09	2.015	4.7		0.104	2.1		0.241	-122.9		10.56
11.0	0.688	107.5	5.37	1.855	-6.3		0.110	0.0		0.247	-135.1		9.88
12.0	0.694	93.3	4.67	1.711	-17.8		0.118	-3.4		0.256	-146.5		9.26
13.0	0.711	82.4	3.92	1.571	-28.8		0.127	-6.9		0.250	-159.0		8.76
14.0	0.746	67.5	3.24	1.452	-40.8		0.137	-12.6		0.240	-176.5		8.90
15.0	0.753	55.9	2.41	1.320	-52.4		0.146	-18.5		0.246	163.0		7.74
16.0	0.807	45.8	1.46	1.183	-63.1		0.152	-24.5		0.260	142.0		8.91
17.0	0.826	37.6	0.48	1.057	-73.7		0.159	-30.8		0.297	119.0		8.23
18.0	0.874	31.3	-0.53	0.941	-84.1		0.164	-37.5		0.349	98.9		7.59

Typical Noise Parameters, $V_{DS} = 3V, I_{DS} = 10\text{ mA}$

Freq GHz	F_{min} dB	Γ_{opt} Mag.	Γ_{opt} Ang.	$R_n/50$	G_a dB
0.5	0.23	0.65	-4.3	0.14	23.81
0.9	0.24	0.58	7.4	0.13	21.82
1.0	0.26	0.54	10.7	0.13	21.62
1.9	0.43	0.50	36.2	0.11	18.05
2.0	0.38	0.48	40.4	0.12	17.96
2.4	0.43	0.44	49.8	0.11	16.84
3.0	0.51	0.36	69.2	0.10	15.76
3.9	0.59	0.31	99.4	0.08	14.23
5.0	0.70	0.32	139.3	0.06	12.94
5.8	0.85	0.35	160.3	0.05	12.04
6.0	0.86	0.35	162.3	0.05	11.85
7.0	0.98	0.36	-173.7	0.06	10.99
8.0	1.09	0.41	-158.6	0.07	10.29
9.0	1.23	0.45	-143.7	0.09	9.71
10.0	1.45	0.44	-126.8	0.15	8.88

Notes:

1. The F_{min} values are based on a set of 16 noise figure measurements made at 16 different impedances using an ATN NP5 test system. From these measurements F_{min} is calculated. Refer to the noise parameter measurement section for more information.
2. S and noise parameters are measured on a microstrip line made on 0.010 inch thick alumina carrier assembly. The input reference plane is at the end of the gate pad. The output reference plane is at the end of the drain pad.




Figure 32. MSG/MAG and $|S_{21}|^2$ vs. Frequency at 3V, 10 mA.

ATF-551M4 Typical Scattering Parameters, $V_{DS} = 3V, I_{DS} = 15\text{ mA}$

Freq. GHz	S_{11}			S_{21}		S_{12}		S_{22}		MSG/MAG dB
	Mag.	Ang.	dB	Mag.	Ang.	Mag.	Ang.	Mag.	Ang.	
0.1	0.995	-6.5	22.02	12.623	175.6	0.005	86.0	0.802	-3.1	34.02
0.5	0.949	-31.2	21.51	11.900	156.9	0.025	71.0	0.754	-14.6	26.78
0.9	0.894	-54.1	20.79	10.958	142.3	0.041	60.1	0.700	-25.4	24.27
1.0	0.882	-59.4	20.59	10.701	138.9	0.045	57.6	0.682	-27.8	23.76
1.5	0.813	-84.0	19.41	9.341	123.3	0.059	46.7	0.599	-38.1	22.00
1.9	0.768	-101.2	18.38	8.301	112.7	0.066	39.7	0.537	-44.5	21.00
2.0	0.758	-105.1	18.14	8.068	110.3	0.067	38.1	0.522	-45.9	20.81
2.5	0.717	-123.1	16.90	6.996	99.2	0.073	31.6	0.459	-52.0	19.82
3.0	0.690	-138.7	15.74	6.120	89.7	0.076	26.7	0.407	-56.9	19.06
4.0	0.668	-163.5	13.68	4.829	73.6	0.080	20.0	0.334	-65.0	17.81
5.0	0.666	177.5	11.93	3.947	59.9	0.082	15.8	0.286	-73.3	16.82
6.0	0.668	164.4	10.53	3.363	48.5	0.084	14.2	0.250	-78.4	16.02
7.0	0.670	152.3	9.31	2.921	37.5	0.087	12.9	0.232	-87.6	14.96
8.0	0.672	142.4	8.32	2.607	27.0	0.092	11.8	0.218	-97.7	12.99
9.0	0.681	131.7	7.43	2.351	16.4	0.098	10.4	0.209	-110.0	12.01
10.0	0.678	118.6	6.62	2.142	5.3	0.104	7.8	0.209	-122.9	10.90
11.0	0.684	105.8	5.89	1.970	-5.5	0.113	4.9	0.215	-135.4	10.28
12.0	0.690	91.8	5.19	1.817	-16.8	0.122	0.7	0.226	-147.1	9.70
13.0	0.707	81.3	4.44	1.667	-27.6	0.132	-3.7	0.221	-160.3	9.23
14.0	0.744	66.6	3.75	1.540	-39.5	0.142	-10.0	0.211	-179.5	9.62
15.0	0.751	55.2	2.93	1.401	-50.7	0.151	-16.4	0.218	159.7	8.26
16.0	0.807	45.3	1.97	1.254	-61.4	0.157	-22.8	0.236	137.8	9.02
17.0	0.824	37.3	1.01	1.123	-71.9	0.163	-29.5	0.277	114.5	8.38
18.0	0.874	31.1	0.02	1.002	-82.0	0.167	-36.2	0.330	95.0	7.78

Typical Noise Parameters, $V_{DS} = 3V, I_{DS} = 15\text{ mA}$

Freq GHz	F_{min} dB	Γ_{opt} Mag.	Γ_{opt} Ang.	$R_{n/50}$	G_a dB
0.5	0.18	0.63	-6.3	0.12	24.41
0.9	0.19	0.56	6.8	0.12	22.45
1.0	0.23	0.51	10.0	0.11	22.29
1.9	0.39	0.46	36.5	0.10	18.75
2.0	0.35	0.44	40.8	0.10	18.61
2.4	0.42	0.39	50.1	0.10	17.46
3.0	0.49	0.31	72.5	0.08	16.42
3.9	0.56	0.27	104.4	0.07	14.80
5.0	0.66	0.29	146.9	0.06	13.48
5.8	0.83	0.33	167.4	0.05	12.58
6.0	0.84	0.33	169.0	0.05	12.38
7.0	0.94	0.35	-166.9	0.06	11.49
8.0	1.05	0.40	-152.7	0.07	10.77
9.0	1.19	0.46	-138.6	0.09	10.23
10.0	1.40	0.44	-121.9	0.16	9.32

Notes:

1. The F_{min} values are based on a set of 16 noise figure measurements made at 16 different impedances using an ATN NP5 test system. From these measurements F_{min} is calculated. Refer to the noise parameter measurement section for more information.
2. S and noise parameters are measured on a microstrip line made on 0.010 inch thick alumina carrier assembly. The input reference plane is at the end of the gate pad. The output reference plane is at the end of the drain pad.




Figure 33. MSG/MAG and $|S_{21}|^2$ vs. Frequency at 3V, 15 mA.

ATF-551M4 Typical Scattering Parameters, $V_{DS} = 3V, I_{DS} = 20\text{ mA}$

Freq. GHz	S_{11}			S_{21}			S_{12}		S_{22}		MSG/MAG dB
	Mag.	Ang.	dB	Mag.	Ang.	dB	Mag.	Ang.	Mag.	Ang.	
0.1	0.995	-6.8	22.91	13.987	175.4		0.005	86.1	0.781	-3.3	34.47
0.5	0.943	-33.0	22.35	13.101	155.8		0.024	70.5	0.730	-15.2	27.37
0.9	0.883	-56.9	21.53	11.932	140.7		0.039	59.5	0.672	-26.1	24.86
1.0	0.870	-62.4	21.30	11.614	137.2		0.042	56.9	0.654	-28.5	24.42
1.5	0.798	-87.6	20.00	10.004	121.5		0.054	46.3	0.569	-38.5	22.68
1.9	0.752	-104.9	18.91	8.820	111.0		0.061	39.7	0.506	-44.6	21.60
2.0	0.743	-108.9	18.64	8.555	108.6		0.062	38.3	0.493	-46.0	21.40
2.5	0.704	-126.7	17.35	7.368	97.7		0.067	32.4	0.431	-51.6	20.41
3.0	0.679	-142.1	16.14	6.412	88.4		0.070	28.1	0.383	-56.0	19.62
4.0	0.660	-166.3	14.03	5.028	72.7		0.074	22.5	0.314	-63.5	18.32
5.0	0.662	175.3	12.25	4.099	59.4		0.076	19.2	0.270	-71.5	17.32
6.0	0.664	162.6	10.85	3.488	48.3		0.080	18.3	0.237	-76.2	16.39
7.0	0.667	150.9	9.62	3.027	37.5		0.084	17.2	0.220	-85.2	14.66
8.0	0.670	141.3	8.63	2.701	27.2		0.090	16.3	0.207	-95.2	13.18
9.0	0.679	130.9	7.73	2.435	16.8		0.096	14.6	0.198	-107.6	12.20
10.0	0.677	118.1	6.92	2.219	5.9		0.104	11.7	0.198	-120.6	11.21
11.0	0.683	105.4	6.19	2.040	-4.8		0.114	8.4	0.205	-133.4	10.64
12.0	0.689	91.4	5.49	1.881	-16.0		0.124	3.8	0.216	-145.2	10.10
13.0	0.705	80.9	4.75	1.727	-26.8		0.134	-1.0	0.210	-158.4	9.62
14.0	0.742	66.4	4.05	1.594	-38.6		0.145	-7.7	0.199	-178.0	10.41
15.0	0.751	55.0	3.23	1.451	-49.8		0.153	-14.4	0.207	160.3	8.80
16.0	0.806	45.1	2.27	1.298	-60.4		0.159	-21.1	0.225	138.1	9.12
17.0	0.826	37.2	1.32	1.164	-70.8		0.165	-27.9	0.265	114.0	8.48
18.0	0.874	31.1	0.33	1.039	-80.8		0.170	-34.9	0.320	94.1	7.86

Typical Noise Parameters, $V_{DS} = 3V, I_{DS} = 20\text{ mA}$

Freq GHz	F_{min} dB	Γ_{opt} Mag.	Γ_{opt} Ang.	$R_{n/50}$	G_a dB
0.5	0.17	0.62	-6.2	0.12	24.92
0.9	0.18	0.55	6.0	0.11	22.79
1.0	0.24	0.50	9.5	0.10	22.59
1.9	0.39	0.43	37.5	0.10	19.22
2.0	0.36	0.41	41.2	0.09	19.00
2.4	0.42	0.37	50.9	0.09	17.83
3.0	0.50	0.29	73.6	0.08	16.72
3.9	0.57	0.25	109.4	0.07	15.18
5.0	0.68	0.28	151.6	0.06	13.80
5.8	0.83	0.32	172.5	0.05	12.93
6.0	0.85	0.33	175.6	0.05	12.77
7.0	0.93	0.36	-162.7	0.06	11.84
8.0	1.05	0.41	-149.1	0.08	11.09
9.0	1.19	0.46	-135.5	0.10	10.53
10.0	1.39	0.45	-119.4	0.17	9.64




Figure 34. MSG/MAG and $|S_{21}|^2$ vs. Frequency at 3V, 20 mA.

Notes:

1. The F_{min} values are based on a set of 16 noise figure measurements made at 16 different impedances using an ATN NP5 test system. From these measurements F_{min} is calculated. Refer to the noise parameter measurement section for more information.
2. S and noise parameters are measured on a microstrip line made on 0.010 inch thick alumina carrier assembly. The input reference plane is at the end of the gate pad. The output reference plane is at the end of the drain pad.

ÖZGEÇMİŞ

Doğum tarihi	03.11.1980	
Doğum yeri	İstanbul	
Lise	1992-1998	Beşiktaş Atatürk Anadolu Lisesi
Lisans	1998-2002	Kocaeli Üniversitesi Mühendislik Fak. Elektronik ve Haberleşme Mühendisliği Bölümü
Yüksek Lisans	2002-2004	Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektronik ve Haberleşme Müh. Anabilim Dalı, Haberleşme Programı
Doktora	2004-2009	Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektronik ve Haberleşme Müh. Anabilim Dalı, Haberleşme Programı

Çalıştığı kurumlar

2003-Devam ediyor	YTÜ Elektrik-Elektronik Fakültesi, Elektronik ve Haberleşme Müh. Araştırma Görevlisi
-------------------	---