

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

GENİŞ ÇALIŞMA BÖLGELİ TRANSİSTÖRLERİN TEK BİR ÇOK KATMANLI
ALGILAYICI İLE MODELLENMESİ



EREN DEMİR

YÜKSEK LİSANS TEZİ
ELEKTRONİK VE HABERLEŞME MÜHENDİSLİĞİ ANABİLİM DALI
HABERLEŞME PROGRAMI

DANIŞMAN
PROF. DR. FİLİZ GÜNEŞ

İSTANBUL, 2017

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**GENİŞ ÇALIŞMA BÖLGELİ TRANSİSTÖRLERİN TEK BİR ÇOK KATMANLI
ALGILAYICI İLE MODELLENMESİ**

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

Tez Danışmanı

Prof. Dr. Filiz GÜNEŞ
Yıldız Teknik Üniversitesi

Jüri Üyeleri

Prof. Dr. Filiz GÜNEŞ
Yıldız Teknik Üniversitesi

Prof. Dr. Fikret GÜRGEN
Boğaziçi Üniversitesi

Doç. Dr. Hamit TORPİ
Yıldız Teknik Üniversitesi

ÖNSÖZ

Bu çalışma Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektronik ve Haberleşme Mühendisliği anabilim dalı Haberleşme programında yüksek lisans tezi olarak hazırlanmıştır.

Yapılan çalışmadaki sonuçlardan görüldüğü üzere mikrodalga transistörlerin YSA tabanlı modelleri oluşturulurken gerilim, akım ve frekans verilerinin bölgelere ayrılması ve ağı bu değerler ile ilgili bilgiler verilmesi sonucunda YSA modellerinin genel performansını basit ve etkili bir şekilde arttırdığı düşünülmüş olup bu yöntem ile eğitim esnasında kullanılan verilerin optimum şekilde seçimi ve kullanımı ile ilerideki çalışmalarda çok daha az veri miktarı ile yüksek performanslı ve doğruluğu yüksek YSA modellerinin oluşturulabilmesi hedeflenmiş ve simulasyon çıktılarının ışığında başarılı olarak sonuçlanmıştır.

Yüksek lisans eğitimim boyunca gösterdiği ilgi ve anlayış ile değerli yardımlarını her zaman yanımda hissettiğim ve bilgisine sürekli başvurduğum, desteğiyle yanımda olan tez danışmanım Prof. Dr. Filiz GÜNEŞ'e teşekkürlerimi sunar, ayrıca gerek bilgi ve gerekse moral açısından bana destek olan, yüksek lisans eğitimim ve tez çalışmam boyunca takıldığım noktalarda ve matlab kodlarının yazımında bana destek veren Peyman MAHOUTI'ye buradan teşekkürlerimi iletmeyi bir borç bilirim.

Bu konu üzerinde çalışacak araştırmacılara tezimin faydalı olması dileğiyle.

Ve son olarak da, hayatım boyunca maddi ve manevi her konuda yanımda olan, bugünlere gelmemde büyük emeği olan sevgili aileme sonsuz sevgi ve teşekkürlerimi sunarım.

Kasım, 2017

Eren DEMİR

İÇİNDEKİLER

	Sayfa
SİMGE LİSTESİ	vi
KISALTMA LİSTESİ.....	vii
ŞEKİL LİSTESİ.....	viii
ÇİZELGE LİSTESİ	ix
ÖZET	x
ABSTRACT.....	xi
BÖLÜM 1	
GİRİŞ.....	1
1.1 Literatür Özeti	1
1.1.1 Transistör.....	1
1.1.2 Yapay Sinir Ağları	2
1.2 Tezin Amacı	3
1.3 Hipotez.....	3
BÖLÜM 2	
MİKRODALGA TRANSİSTÖRÜ ve PARAMETRELERİ	4
2.1 Transistörün Mikrodalga Alanında Kullanımı.....	4
2.2 Saçılma S-Parametreleri.....	4
BÖLÜM 3	
YAPAY SİNİR AĞLARINA GİRİŞ	7
3.1 Yapay Sinir Ağları Avantajları	8
3.2 Yapay Sinir Ağı Dezavantajları.....	8
3.3 Biyolojik Sinir Hücre (Nöron)	8
3.4 Yapay Sinir Ağı Hücre Yapısı	9
3.5 Biyolojik ve Yapay Sinir Hücreleri Karşılaştırılması	10

3.6	Yapay Sinir Ağı Yapısı ve Eğitilmesi	10
3.7	Epoch.....	11
3.8	Yapay Sinir Ağlarında Hata Fonksiyonu.....	11
3.9	Momentum	11
3.10	Durdurma Kriteri.....	11
3.11	Örneklerin Ağa Sunulması.....	11
3.12	Geri Yayılımlı Sinir Ağları [Back Propagation Neural Network (BPNN)]	12
BÖLÜM 4		
ÇOK KATMANLI ALGILAYICI [MULTILAYER PERCEPTRON (MLP)].....		13
BÖLÜM 5		
YSA TABANLI TRANSİSTÖR MODELLEME		15
5.1	Durum İncelemesi 1	15
5.1.1	S-Parametreleri için Eğitim Veri Kümesinin Oluşturulması	16
5.1.2	Vaka Çalışması	19
5.1.3	Sonuçlar	22
5.1.4	Akımın Üç Bölgeye Ayrılması ve N=20 Olduğu Farklı DC Bias Koşulları Altında Bazı S-Parametrelerine ait Simülasyon Sonuçları.....	23
5.2	Durum İncelemesi 2	26
5.2.1	Sonuçlar	28
5.2.2	Akım ve Frekansın Üç Bölgeye Ayrılması ve N=20 Olduğu Farklı DC Bias Koşulları Altında Simülasyon Sonuçları	29
BÖLÜM 6		
SONUÇ VE ÖNERİLER.....		31
KAYNAKLAR.....		32
ÖZGEÇMİŞ.....		35

SİMGE LİSTESİ

[S]	Saçınım matrisi
a_1	Port 1'e giren dalga
a_2	Port 1'den yansıyan dalga
b_1	Port 2'ye giren dalga
b_2	Port 2'den yansıyan dalga
f	Frekans
GHz	GigaHertz
I	Akım
i	Saçılma parametreleri
j	Örnek indis
mA	miliAmper
N	Nöron sayısı
n	Toplam örnek sayısı
S_{11}	Uygun çıkış sonlandırma ile giriş yansıma katsayısı
S_{12}	Uygun giriş sonlandırma ile ters iletim katsayısı
S_{21}	Uygun çıkış sonlandırma ile ileri iletim katsayısı
S_{22}	Uygun giriş sonlandırma çıkış yansıma katsayısı
V	Volt
y_{ij}	Tahmini değer
\hat{y}_{ij}	Amaçlanan değer

KISALTMA LİSTESİ

AB	Akım Bölgesi
ANN	Artificial Neural Network
B	Beyz
C	Kollektör
BPNN	Back Propagation Neural Network
ÇKA	Çok Katmanlı Algılayıcı
E	Emiter
FB	Frekans Bölgesi
MLP	Multilayer Perceptron
NPN	Negatif - Pozitif - Negatif Jonksiyon
OBH	Ortalama Bağlı Hata
OKH	Ortalama Karesel Hata
OMH	Ortalama Mutlak Hata
PNP	Pozitif- Negatif - Pozitif jonksiyon
S-Parametreleri	Saçılma Parametreleri
YSA	Yapay Sinir Ağları
Trainbr	Bayesian Regression
Trainlm	Levenberg Marquardt

ŞEKİL LİSTESİ

	Sayfa
Şekil 2. 1 Gelen ve yansıyan dalgaların gösterimi	5
Şekil 3. 1 Sinir hücresi yapısı	9
Şekil 3. 2 Yapay sinir ağı hücre yapısı	10
Şekil 4. 1 Çok katmanlı algılayıcı yapısı	13
Şekil 5. 1 Üç giriş 8 çıkışlı S-Parametreleri için kara kutu modeli.....	16
Şekil 5. 2 Dört giriş 8 çıkışlı S-Parametreleri için kara kutu modeli.....	18

ÇİZELGE LİSTESİ

	Sayfa
Çizelge 5. 1 BFP181 transistörüne ait akım, frekans ve gerilim besleme değerleri.....	16
Çizelge 5. 2 S-Parametreleri için eğitim veri kümesi.....	17
Çizelge 5. 3 S-Parametreleri için test veri kümesi.....	17
Çizelge 5. 4 İki ve üçlü akım bölgelerine ayrılmış veri kümesi.....	18
Çizelge 5. 5 Akımın bölgelere ayrıldığı örnek veri kümesi.....	18
Çizelge 5. 6 Akım bölgelere ayrılmaksızın S-Parametrelerinin tahminine ait performans sonuçları.....	20
Çizelge 5. 7 Akımın iki bölgeye ayrılması sonucunda S-Parametrelerinin tahminine ait performans sonuçları.....	21
Çizelge 5. 8 Akımın üç bölgeye ayrılması sonucunda S-Parametrelerinin tahminine ait performans sonuçları.....	22
Çizelge 5. 9 S-Parametreleri için eğitim veri kümesi.....	26
Çizelge 5. 10 S-Parametreleri için test veri kümesi.....	26
Çizelge 5. 11 Tüm girişlerin bölgelere ayrıldığı örnek veri kümesi.....	26
Çizelge 5. 12 Akım, frekans ve gerilim giriş verilerinin bölge ayırımı olmaksızın S-Parametreleri tahminine dair performans sonuçları.....	27
Çizelge 5. 13 Akım, frekans ve gerilim giriş verilerinin bölgelere ayrılması sonucunda S-Parametreleri tahminine dair performans sonuçları.....	27
Çizelge 5. 14 Akım ve frekans giriş verilerinin bölgelere ayrılması sonucunda S-Parametreleri tahminine dair performans sonuçları.....	28

GENİŞ ÇALIŞMA BÖLGELİ TRANSİSTÖRLERİN TEK BİR ÇOK KATMANLI ALGILAYICI İLE MODELLENMESİ

Eren DEMİR

Elektronik ve Haberleşme Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Tez Danışmanı: Prof. Dr. Filiz GÜNEŞ

Bu çalışma kapsamında yapay sinir ağları kullanılarak çok geniş bir DC besleme aralığına sahip bir mikrodalga transistörünün kara kutu modeli yapılarak transistöre ait saçılma parametrelerinin tahminin yapılması hedeflenmiştir. Bu amaca yönelik BFP181 transistörüne ait üretici firmanın sağladığı ölçülmüş saçılma parametreleri kullanılmıştır. Kara kutu modelinin tahmin performansının artırılması amacı ile geniş aralığa ait DC besleme değerlerini eğitim ve test aşamalarında birçok alt bölgelere ayırarak artırmayı başardık. Ayrıca yapının hız ve verimlilik analizi için birçok farklı gizli katman nöron ve iki farklı eğitim algoritması olan Levenberg Marquardt ve Bayesian regression yöntemleri ile bir inceleme yapılmıştır. Elde edilen sonuçlar ışığında önerilen yöntem ile çok geniş bir DC besleme aralığına sahip bir mikrodalga transistörünün, geri beslemeli yapay sinir ağları ile modellenmesinin başarılabileceği görülmüştür.

Anahtar Kelimeler: Transistor modellemesi, Yapay sinir ağı, Çok katlı algılayıcı, bölge ayırma, kara kutu modelleme, Mikrodalga Devre Tasarımı.

**DESIGN OF WIDE OPERATION RANGE MICROWAVE TRANSISTORS WITH
A SINGLE MULTILAYER PERCEPTRON NETWORK**

Eren DEMİR

Department of Electronics and Communications Engineering

MSc. Thesis

Adviser: Prof. Dr. Filiz GÜNEŞ

In this work, Back Propagation Neural Network (BPNN) is aimed at building up a black box model of a microwave transistor for predicting the scattering parameter characteristics of the transistor having a wide range operation DC bias and frequency domain. For this purpose, a high technology transistor BFP181 is chosen with its wide range measured scattering parameters provided by the manufacturer's company. In order to increase the accuracy of the modelling in such a wide range of operation domain, this wide range of data is divided into sub -regions for each of which both individual training and testing processing is performed. Finally, accuracy and computational efficiency analysis is made for both different number of sub-regions and two different algorithms which are Levenberg Marquardt and Bayesian regression. It can be concluded that BPNN can also use for the fast and high accurate modelling scattering parameter characteristics of a microwave transistor having the wide range operation DC and frequency range.

Keywords: Transistor modelling, Artificial Neural Network, Multi Perceptron Layer, Black Box modelling, Region Division, Microwave Transistor Design

1.1 Literatür Özeti

1.1.1 Transistör

Gerilim ya da akım kaynağı ile başka bir akım ya da gerilim kaynağını kontrol etmeye yarayan, girişine uygulanan sinyali yükselterek akım ve gerilim kazancı sağlayan transistörler; gerektiğinde anahtarlama elemanı olarak kullanılan yarı iletken bir devre elemanlarıdır. [1]

Transistör yan yana birleştirilmiş iki PN diyotundan oluşmaktadır. Bipolar (NPN ve PNP) ve unipolar olmak üzere iki gruba ayrılır. Transistörler üç kutuplu E,B ve C (Emiter, Beyz, Kollektör) devre elemanlarıdır. Akım taşıyıcıların harekete başladığı bölge Emiter (yayıcı), transistörün çalışmasını etkileyen bölgeye Beyz (taban) ve akım taşıyıcıların toplandığı bölge ise Kollektör (toplayıcı)'dır.

20. yüzyılın en önemli icatlarından biri olan transistörler, 1947 yılında icat edilmesiyle elektronik devrelerin temel yapıtaşlarından biri haline gelen ve günümüz teknolojisine ulaşmamızda büyük rol sahibi olan transistörler, Bell araştırma laboratuvarlarında William Shockley başkanlığında John Bardeen ve Walter Brattain'den oluşan ekip tarafından geliştirilmiştir ve radyo devresinde ilk olarak deneniştir.

Shockley başkanlığındaki ekip 4 yıl boyunca yaptığı çalışmalar ile transistörler alanında yeni gelişmelere yol açmış ve bu gelişmeler sonucunda transistörler 1952 yılında, orijinal boyutunun 1/10 oranında küçültülerek geliştirilmiştir. 1957 yılı ile birlikte otuz milyon transistör üretilebilecek kapasiteye ulaşılmıştır.

Sonraki yıllarda bu alanda meydana gelen gelişmeler ile birlikte işlem sırasında meydana gelebilecek yüksek sıcaklığa dayanıksız olan germanyum transistörü yerine silisyum kullanılmaya başlanmıştır. Süre gelen gelişmeler ile birlikte saniyenin 100 milyonda biri kadar sürede akımı iletebilen transistörler üretilmiştir. [2]

1.1.2 Yapay Sinir Ağları

İnsan beyninin temel özelliklerinden olan öğrenme mekanizmasından esinlenen Yapay Sinir Ağları, birbirine bağlı yapay sinir hücrelerinden oluşmakta ve mevcut örneklerden yararlanarak öğrenme işlemini gerçekleştirmektedir. Birbirine bağlı yapay sinir hücrelerinin oluşturduğu bağlantılar ağırlık değerine sahiptir ve ağırlık sahip olduğu bilgiler bağlantılara dağıtılmıştır. YSA'lar ile ilgili çalışmalara ilk olarak 1943 yılında başlanılmış olsa da YSA alanındaki gözle görülür gelişmeler 1990'lı yıllardan itibaren gerçekleşmiştir. [3-4]

Yapay sinir ağı modeli ilk olarak 1943 yılında nöroloji alanında hekim olan Warren McCulloch ve matematik alanında bilim adamı Walter Pitts tarafından gerçekleştirilmiştir. İnsan beyninin sahip olduğu hesaplama yeteneğinden esinlenmişler ve elektrik devreleriyle basit bir yapay sinir ağı tasarlamışlardır. [5] 1949 yılında bir sinir ağının öğrenmeyi nasıl gerçekleştirebileceği hakkında çalışmalar yapılmış ve Hebb tarafından öğrenme fonksiyonunun (Hebbian Kuralı) bilgisayarlar tarafından oluşturabilecek düzeyde bir yapay sinir ağı tasarlanmıştır. [6]

1957 yılında ise, YSA'lar alanında önemli bir gelişme daha yaşanmış ve algılayıcılar (perceptron) geliştirilmiş ve makinelerin öğrenme algoritmalarının temeli oluşturulmuştur. [7]

1960 yılında öğrenme algoritması Widrow ve Hoff ADALINE tarafından geliştirilmiş ve yapay sinir ağları yeni bir boyut kazanmıştır. Literatüre Widrow-Hoff öğrenme kuralı olarak giren öğrenme algoritmasının en önemli özelliği modelin eğitim boyunca meydana gelen hatayı en aza indirmeye çalışması olmuştur. [8]

1969 yılında tek katmanlı algılayıcıların yetersiz olduğunun ortaya çıkmasıyla beraber 1982 yılında çok katmanlı algılayıcıların geliştirilmesine yol açmış ve çok katmanlı

algılayıcılar için geri yayılım algoritması 1986 yılında geliştirilmiştir. Geri yayılım algoritması günümüzde en çok kullanılan algoritma haline gelmiştir. [9]

1980'li yıllarda bilgisayarların daha etkin kullanılmaya başlanmasına paralel olarak YSA'lar ile ilgili gelişmeler hızlanmıştır ve günümüzde de yeni öğrenme algoritmaları geliştirilmektedir.

1.2 Tezin Amacı

Mikrodalga transistor birçok mikrodalga devre elemanında kilit önem taşımasından sebebiyle, hassas ve büyük ölçekli tasarım/optimizasyon süreçlerinde kullanılmak üzere, hızlı, doğruluğu yüksek, basit ve güvenilir bir transistor modeli gerekmektedir [18]. Bu çalışma kapsamında yapay sinir ağları kullanılarak çok geniş bir DC besleme aralığına sahip bir mikrodalga transistorunun kara kutu modeli yapılarak transistore ait saçılma parametrelerinin tahminin yapılması hedeflenmiştir. Bu amaca yönelik BFP181 transistorüne ait üretici firmanın sağladığı ölçülmüş saçılma parametreleri kullanılmıştır. Kara kutu modelinin tahmin performansının artırılması amacı ile geniş aralığa ait DC besleme değerlerini eğitim ve test aşamalarında birçok alt bölgelere ayırarak artırmayı başardık. Ayrıca yapının hız ve verimlilik analizi için birçok farklı gizli katman nöron ve iki farklı eğitim algoritması olan Leven-berg Marquardt ve Bayesian regression yöntemleri ile bir inceleme yapılmıştır. Elde edilen sonuçlar ışığında önerilen yöntem ile çok geniş bir DC besleme aralığına sahip bir mikrodalga transistorunun, geri beslemeli yapay sinir ağları ile modellenmesinin başarılabileceği görülmüştür.

1.3 Hipotez

Tez kapsamında, firma tarafından temiz edilen ölçülmüş saçılma parametrelerinin belirlenmesi ve istenilen geniş DC besleme aralığına sahip transistorun seçiminden sonra, seçili transistore ait akım bölgelerinin farklı bölgelere ayrılması yapılmıştır.

Oluşturulan eğitim ve test setlerine göre farklı YSA modellerinin oluşturulması yapılarak performans incelenmesi gerçekleştirilmiştir. Daha sonraki aşama da ise hem akım verilerine ek gerilim ve frekans değerlerinde farklı bölgelere ayrılarak önerilen kara kutu modelleme tekniğindeki tahmin performansını nasıl etkilediği incelenmiştir.

MİKRODALGA TRANSİSTÖRÜ ve PARAMETRELERİ

2.1 Transistörün Mikrodalga Alanında Kullanımı

RF/mikrodalga sistemlerinin temel elemanlarından biri olan Transistörler, mikrodalga teknolojisinde basit, hızlı, kesin ve güvenilir modellemelerde oldukça önemli bir yere sahiptir. Transistörler, mikrodalga teknolojisinde gerçekleştirilen güvenilir modellemelerde devam eden simülasyon, optimizasyon ve istatistiksel analiz kapsamındaki matematiksel hesaplamalar için kullanılmaktadır. [10-17]

2.2 Saçılma S-Parametreleri


Mikrodalga mühendisliğinde, doğrusal mikrodalga devrelerini karakterize etmek için çeşitli devre parametreleri kullanılmaktadır. Mikrodalga mühendisliğinde sıklıkla tercih edilen S- parametreleridir. Çünkü, üretiminde iletim hattı süreksizliklerindeki yönlü kuplör yardımıyla kolaylıkla ölçülebilen ilerleyen ve yansıyan dalgalardan faydalanılmaktadır. Bu yüzden, ölçülebilen en kolay parametrelerdir.

Saçılma parametreleri en genel bakışla, devre üzerindeki kapılara gelen ve yansıyan dalgaları temsil eder ve kullanım açısından en pratik parametrelerdir. Tasarım ve yazılım süreçleri açısından bakıldığında da saçılma parametrelerini kullanmak nümerik kararlılık ve hata optimizasyonu konularında elde edilecek sonuçlarla ilgili faydalar sağlamaktadır.

S-parametreleri frekansa bağılıdır ve kazanç, geriye dönüş kaybı, duran dalga oranı gibi birçok özellik S- parametreleri cinsinden verilebilir.

S-parametreleri, "Black Box (Kara Kutu) " olarak gösterilen devreyi ifade etmek için kullanılan bir yöntemdir. Kara kutu, bir ya da daha fazla sayıda kapiya (portlara) sahip olabilmektedir. S-parametrelerin ölçümü, tek bir frekansta sinyal ya da dalganın "kara kutu"ya gönderilip, her bir kapıdan çıkan sinyallerin ya da dalgaların kaydedilmesiyle yapılmaktadır. [10-17]

iki kapılı devre gelen ve yansıyan dalgalar Şekil 2.1'de verilmiştir.



[18]

iki kapılı devrenin Port 1'e giren dalga a_1 , yansıyan dalga ise b_1 ile gösterilirken Port 2'ye giren dalga a_2 , yansıyan dalga ise b_2 ile gösterilmektedir.

Port 1 ve port 2'de ölçülen S_{11} , S_{12} , S_{21} ve S_{22} parametreleri, iki kapılı devrenin saçınım parametreleridir ve gösterim şekli:

$$[S] = \begin{bmatrix} S_{11} & S_{12} \\ S_{21} & S_{22} \end{bmatrix} \quad (2.1)$$

[S] ifadesi bu ağın saçınım matrisidir [19].

$$b_1 = S_{11} a_1 + S_{12} a_2$$

$$b_2 = S_{21} a_1 + S_{22} a_2 \quad (2.2)$$

Denklem 2.1'e göre S-parametrelerinin dalgalar cinsinden formüle edilmiş halleri aşağıdaki gibidir :

$$S_{11} = \left. \frac{b_1}{a_1} \right|_{a_2=0} \quad (\text{Uygun çıkış sonlandırma ile giriş yansımaya katsayısı}) \quad (2.3)$$

$$S_{21} = \left. \frac{b_2}{a_1} \right|_{a_2=0} \quad (\text{Uygun çıkış sonlandırma ile ileri iletim katsayısı}) \quad (2.4)$$

$$S_{22} = \left. \frac{b_2}{a_2} \right|_{a_1=0} \quad (\text{Uygun giriş sonlandırma ile çıkış yansımaya katsayısı}) \quad (2.5)$$

$$S_{12} = \left. \frac{b_1}{a_2} \right|_{a_1=0} \quad (\text{Uygun giriş sonlandırma ile ters iletim katsayısı}) \quad (2.6)$$

İki kapılı devrenin bir transistörü simgelediğini düşünürsek, transistör uygun kutuplandırıldığında belli bir çalışma noktasında S-parametreleri ölçülebilir. S-parametreleri frekansa bağlı değerler olduğu için transistörün farklı frekans davranışları incelenebilir.

YAPAY SINİR AĞLARINA GİRİŞ

İnsan beyninin çalışma mekanizmasından esinlenen Yapay Sinir Ağları, öğrenme sürecinin bilgisayar dünyasında yazılımsal ve donanımsal olarak modellenmesiyle ortaya çıkmış bilgisayar sistemleridir. Ancak, donanımsal olarak elektronik cihazların boyutu ve esnek olmayışı yapay sinir ağlarının daha çok yazılımsal olarak gerçekleştirilmesine yol açmıştır.

YSA ile ilgili yapılan çalışmalar, öncelikle beyni oluşturan biyolojik üniteler olan nöronların modellenmesi ve bilgisayar sistemlerinde uygulanması ile başlamıştır. İlerleyen aşamalarda bilgisayar sistemlerinin gelişimine paralel bir çok alanda kullanılır hale gelmiştir.

Öğrenme işlemi, Yapay sinir ağlarının mevcut verilerden yararlanmasıyla gerçekleşmektedir. Yapay sinir ağları birbirlerine bağlı yapay sinir ağı hücrelerinden oluşmakta ve her bağlantı bir ağırlık değerine sahiptir.

Bilgi; ağı bağlantı ağırlıkları ile temsil edilir ve ağırlıklar YSA zekası olarak tanımlanır. Ağı sahip olduğu ağırlık değerlerinin doğru olduğu ölçüde ağı performansı fazladır. Dağıtık bilgiye sahip olan YSA'larda bilgi bağlantılara dağıtılmıştır ve ağırlık değerlerinin bazıları kaybolursa dahi ağ çalışmasını sürdürebilir.

Yapay sinir ağları, insan beyninde olduğu gibi öğrenebilme ve genelleme yapabilmektedir. Ayrıca, paralel çalışma ve doğrusal olmama özelliklerine sahiptir. [9]

3.1 Yapay Sinir Ağları Avantajları

YSA'lar kullanacağı mevcut verilerde eksik bilgi olsa bile çalışabilme ve gerçekleşmiş örnekleri kullanarak öğrenme özelliğine sahiptirler. Ayrıca YSA'ların yararlanacağı veriler belirsiz bilgilerden oluşuyor olsa da bu bilgileri işleyebilir ve çözülmesi zor problemleri çözebilirler.

Aynı anda birden fazla iş gerçekleştirebilme özelliğine sahip olan YSA'lar Ani bozulma göstermezler. Hata toleransına sahiptirler ve öğrenme işlemini gerçekleştirdikçe hata oranını minimize etmeye çalışırlar. [20]

3.2 Yapay Sinir Ağı Dezavantajları

YSA'lar için eğitimin tamamlanması, ağı örnekler üzerindeki hata oranının belli bir değerin altına indirilmesi ile gerçekleşir. Böylece YSA'lar için kabul edilebilir çözümler üretilebilir. Fakat, bunun optimum çözüm olduğu test edilemeden iddia edilemez.

YSA'lar bir probleme çözüm üretebilir, fakat neden ve nasıl olduğuna ilişkin bir ipucu verme özelliğine sahip değildirler.

Nümerik bilgiler ile çalışabilen YSA'lara, çözülmesi istenen problemlerin öncelikle nümerik değerlere çevrilmesi gerekmektedir. Bu zorunluluk, problemlerin nümerik değerler ile gösterilmesi doğruluğu ağı performansını direkt etkilemektedir.

YSA'ların bir diğer dezavantajı donanıma bağlı olmalarıdır. Bu durum, ağ yapısı gereği paralel işlem gücüne sahip işlemcilerle gerek duymasından dolayıdır.


YSA yapısının belirlenmesinde belirli bir kural olmaması, uygun ağ yapısının deneyim ve deneme yanılma yolu ile elde edilmesine yol açmaktadır. [20]

3.3 Biyolojik Sinir Hücresi (Nöron)

Biyolojik sinir hücresi nöronlar; sinir uçları (dendrit), çekirdek, akson ve ince uzantılar (sinaps) olmak üzere dört bölümden oluşmaktadır. Dendritler, duyu organları ve diğer sinir hücrelerinden gelen sinyalleri çekirdeğe iletir. Çekirdek ise dendritten gelen sinyalleri toplar ve akson tarafından işlenmesi için aksona gönderilirler. İşlenen

sinyaller daha sonra sinapslara gönderilir ve yeni üretilen sinyaller sinapslar tarafından diğer nöronlara iletir.

Gerçek sinir hücreleri simüle edilerek yapay sinir hücreleri oluşturulmaktadır. [21]




Şekil 3. 1 Sinir hücresi yapısı

[21]

3.4 Yapay Sinir Ağı Hücre Yapısı

Yapay sinir ağı hücresi girdiler, ağırlıklar, birleştirme fonksiyonu, aktivasyon fonksiyonu ve çıktılar olmak üzere beş (5) bölümden oluşmaktadır. Girdiler, yapay sinir ağına başka bir yapay sinir ağından veya dış ortamdan gelen verilerdir. Ağırlıklar, dış ortamdan veya diğer hücrelerden alınan veriler ağırlık yardımıyla hücreye bağlanır. Girdilerin çıktıları üzerindeki etkilerinin ayarlanabilmesi için girişler bağlantıların ağırlıklarıyla çarpılmaktadır. Birleştirme fonksiyonu, ağırlıklar ile çarpılan girdilerin toplanmasıyla net girdinin hesaplanmasını sağlamaktadır. Aktivasyon fonksiyonu, üretilecek olan çıktıyı, net girdilerle işlem yaparak hesaplayan fonksiyondur. Bu işlem, aynı zamanda bir hücrenin çıkışını verir. Çıktılar, yapay sinir ağlarında aktivasyon fonksiyonunun çıkışında elde edilen verilerdir.

Her bağlantının bir ağırlık değeri vardır ve YSA, kendisine örnekler gösterildikçe bu ağırlık değerlerini değiştirir. Hedef, ağı gösterilen örnekler için doğru çıkışları verecek ağırlıkları bulmaktır. [22]



Şekil 3. 2 Yapay sinir ağı hücre yapısı

[22]

3.5 Biyolojik ve Yapay Sinir Hücreleri Karşılaştırılması

Biyolojik sinir hücresindeki nöron yapay sinir hücresinde işlem elemanı ile, dentrit toplama fonksiyonu ile, çekirdek aktivasyon fonksiyonu ile, sinaps ise işlem elemanı ile üstlendikleri görevler açısından eşdeğerdirler.

3.6 Yapay Sinir Ağı Yapısı ve Eğitilmesi

Yapay sinir hücreleri birbirlerine bağlanmasıyla oluşan yapılara katman adı verilir. Katmanlarda bir araya gelerek yapay sinir ağlarını oluşturmaktadır. Yapay sinir ağı genellikle, girdi katmanı, ara (gizli) katman ve çıkış katmanı olmak üzere 3 katmanlı olarak modellenmektedir.

Yapay sinir ağı, giriş verilerini ara katmandaki ağırlıklar ile çarpması sonucunda oluşan çıkışları, eğitim setinde verilmiş olan doğru çıkışlar ile kıyaslar ve oluşan çıkışlar ile eğitim setinde verilmiş olan çıkışlar arasındaki hata oranının azaltılması amacıyla ağırlıklar her işlemde değişir. Bu işlem, her bir değer için doğru sonuç bulununcaya kadar devam eder. Doğru ağırlıkların bulunması işlemi "ağın eğitilmesi" işlemidir.

Eğitim setindeki veriler için doğru sonuçlar elde edildikten sonra, test setindeki veriler yapay sinir ağına sistemine verilir. Test seti verileri için doğru çıkış verileri üretilmesi, ağın eğitilme işleminin başarıyla sonuçlandığı anlamına gelmektedir. [23]

3.7 Epoch

Epoch, tüm giriş verilerinin işlenmesindeki tek bir iterasyondur (ardışık işlem). Epoch, sistemin kendini eğitim verisine göre eğitebilmesi için gereklidir.

Her Epoch'da YSA öğrenir ve aynı girişler defalarca uygulandıkça, sistem kendini daha az bir hata ile eğitebilir hale getirir. Çok sayıda epoch ile sistem tam olarak eğitilmiş kabul edilir.

3.8 Yapay Sinir Ağlarında Hata Fonksiyonu

YSA'da hata, çıkış değerlerinin ve bias değerinin çıkışa yansımalarıdır ve hata ölçüm fonksiyonları ile ölçülür. En sık kullanılan hata fonksiyonları; Ortalama Mutlak Hata (OMH), Ortalama Karesel Hata (OKH) ve Ortalama Bağıl Hata (OBH) olmak üzere üç (3) çeşittir.

İyi bir YSA minimum hataya sahip olmalıdır. Hata fonksiyonları, eğitim kümesindeki örneklerin hataların tümünü temsil eder. Problemin tipine ve tasarımcının seçimine göre farklı hata fonksiyonları kullanılabilir.

3.9 Momentum

YSA her işlem adımında daha az hata oranına sahip bir noktaya gelmek isteyecektir ve birden çok iterasyon sonucunda sistem minimum hatalı noktaya erişecektir. Buna bağlı olarak eğitim sırasında, YSA hatanın azaldığı yerde durmayı sürdürmek ister.

3.10 Durdurma Kriteri

Yapay sinir ağlarında eğitim; zaman eşik değerine ulaşılması, önceden tanımlı bir epoch değerine ulaşılması, önceden tanımlı hata değerine ulaşılması ve iki epoch değeri arasındaki hata değeri azalmasına bağlı olarak bitebilir.

3.11 Örneklerin Ağa Sunulması

Yapay sinir ağlarında, veriler n örnek sırası ile ağa sunulurlar. Örnek olarak; 1. iterasyonda 1. örnek, 2. iterasyondan 2. örnek vb. şekilde devam etmektedir. Hepsini tek

tek YSA'ya sunulduktan sonra, başa dönerek sırası ile ağa tekrar sunulur. Bu işlem öğrenme sağlanana kadar devam eder.

Örnekler eğitim kümesinden rastgele seçilirler. Seçilen örnek eğitim verisine atılıp tekrar seçilebilir ya da yeniden seçilmez. Tüm örnekler rastgele ağa sunulduktan sonra öğrenme sağlanana kadar yeniden sunulmaya devam ederler.

3.12 Geri Yayılımlı Sinir Ağları [Back Propagation Neural Network (BPNN)]

Geri Yayılımlı Sinir Ağları (Back propagation neural networks) kısaca "BPNN" olarak tanımlanmaktadır. Bir çeşit Yapay Sinir Ağı olan Geri Yayılımlı Sinir Ağları, birbirine bağlı farklı katmanlardan oluşmaktadır.

BPNN; giriş katmanı, çıkış katmanı ve en az bir katmanında lineer olmayan işlem elemanı olacak şekilde katmanlardan oluşmaktadır. Lineer olmayan işlem elemanları, biyolojik sinir hücrelerindeki nöronlara benzetildikleri için nöron olarak adlandırılmaktadır. Farklı ağırlıklar ile birbirlerine bağlı olan nöronlarda ağırlık ile çarpılan bir nöronun çıkışı, bir sonraki katmandaki nöronun girişini oluşturmaktadır.


BPNN'ler; eğer uygun sayıda gizli katmanlar ile donatılırsa, yüksek düzeydeki kompleks lineer olmayan fonksiyonların hata oranlarını minimize edebilir.

Geri yayılımlı sinir ağlarının özelliklerinden faydalanılarak, mikrodalga transistörlerinin saçılma parametreleri tahmin edilebilmektedir. [24]

ÇOK KATMANLI ALGILAYICI [MULTILAYER PERCEPTRON (MLP)]

Yapay sinir ağlarının en çok kullanılan çeşidi çok katmanlı algılayıcılardır. Çok katmanlı algılayıcı (ÇKA) yapısı birçok birimin oluşturduğu bir kümedir. Bu algılayıcı birimler bir araya gelerek ağı oluşturur. Çok katmanlı algılayıcılar, giriş katmanı, gizli katman ve çıkış katmanına sahiptir. Giriş ve çıkış katmanı dışındaki tüm katmanlar gizli katman olarak adlandırılır.

Perceptron, bir sinir hücresinin birden fazla girdiyi alarak bir çıktı üretmesi prensibine dayalıdır ve YSA hücrelerinin birbirlerine bağlanması sonucu oluşan yapılardır.



Şekil 4. 1 Çok katmanlı algılayıcı yapısı

[25]

Giriş Katmanı: Girdi katmanı olarak adlandırılmaktadırlar. Bu katmanda girdi olarak adlandırılan bilgiler işlenmeden ve değişime uğramadan geldiği gibi ara katmana gönderilir. Her işlem elemanın sadece bir adet girdi ve çıktıya sahiptir. Girdi

katmanındaki her bir işlem elemanı gizli katmanda (ara katman) bulunan işlem elemanlarının hepsine bağlanır.

Gizli Katman: Ara katmanlar olarak da adlandırılırlar. Girdi katmanından iletilen bilgiler işlenerek bir sonraki katman olan çıktı katmanına gönderilir. Çok katmanlı ağlarda birden fazla ara katman ve her katmanda birden fazla işlem elemanı bulunabilir. Bazı sinir ağlarında olmadığı gibi bazılarında da çok sayıda bulunabilir. Katman sayısının artması ile orantılı olarak gerekli süre uzasa da karmaşık problemlerin çözümünde etkilidir.

Çıkış Katmanı: Ara katmanda işlenen bilgiler çıkış katmanına iletilerek çıkış verileri oluşturulur ve çıkış katmanından dış dünyaya gönderilir. Bir çıktı katmanında birden fazla işlem elemanı olabilir. Her işlem elemanı bir önceki katmanda bulunan bütün işlem elemanlarına bağlıdır. Her işlem elemanının bir çıktısı vardır.

Veriler giriş katmanından giriş yapar ve ara katmanda ağırlık değerleri ile çarpılarak işlenir. Bu nedenle ağırlıkların doğru tanımlanması çok önemlidir. İşlenen veriler çıkış katmanına ulaşarak çıkış verileri oluşur. [26]

YSA TABANLI TRANSİSTÖR MODELLEME

5.1 Durum İncelemesi 1

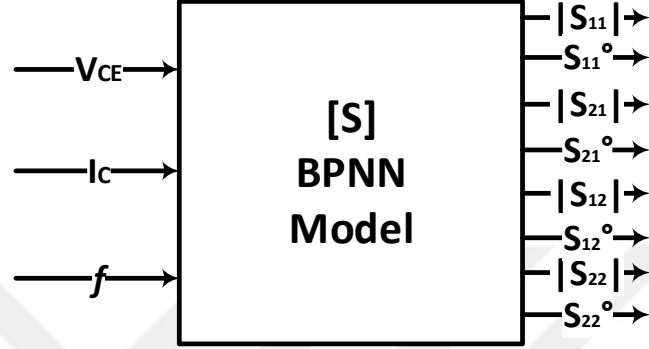
Durum incelemesi 1’de, Geri Yayılımlı Yapay Sinir Ağları [Back Propagation Neural Network (BPNN)] kullanılarak kara kutu modeli ve eğitim verilerinin oluşturulması anlatılmaktadır. Bu çalışma kapsamında, üretici firma tarafından sağlanan farklı frekans, akım, gerilim besleme değerlerine ve geniş değer aralığında saçılma parametrelerine sahip BFP181 transistörü seçilmiştir. [27]

Bu çalışmada, BPNN kullanılarak oluşturulan Kara Kutu modeli ve üretici firma tarafından sağlanan farklı akım, gerilim ve frekans değerlerinde transistörün saçılma parametrelerine ait karakteristiklerinin tahmin edilmesi amaçlanmaktadır.

Mikrodalga transistörlerinin YSA modellemeleri ile ilgili yapılan çalışmalar incelendiğinde, üretici firma tarafından sağlanan veriler ne kadar zenginleştirilmiş olursa başarı oranının aynı doğrultuda arttığı gözlemlenmiştir. Ayrıca, mikrodalga transistörlerinin akım ve frekans değerleri de başarı oranına etki edebilmektedir. Buna bağlı olarak, Durum İncelemesi 1’de YSA modeli için en uygun eğitim verisini oluşturabilmek ve mikrodalga saçılma parametrelerinin tahmininde hızlı ve başarılı olabilmek için akım değerleri, eğitim ve verilen eğitim sonrası test edilme işlemi sırasında farklı bölgelere ayrılmıştır. Akım değerlerine ait bu bölgeler, YSA modelinin giriş parametresi olarak belirlenerek ağın daha yüksek başarı ile eğitilmesi hedeflenmektedir.

5.1.1 S-Parametreleri için Eğitim Veri Kümesinin Oluşturulması

Şekil 5.1’de BPNN kullanılarak oluşturulan “Kara Kutu Modeli” görülmektedir. Şekil 5.1’de görülen “Kara Kutu Modeli”nde görüldüğü üzere 3 (üç) giriş (DC gerilim beslemesi, DC akım beslemesi ve frekans) ve 8 (sekiz) çıkış (4 adet saçılma parametresinin genlik ve faz değerleri) bulunmaktadır.



Şekil 5. 1 Üç giriş 8 çıkışlı S-Parametreleri için kara kutu modeli

[26]

BFP181 transistörüne ait üretici firma tarafından verilen akım, frekans ve gerilim besleme değerleri Çizelge 5.1’de gösterilmiştir.

Çizelge 5. 1 BFP181 transistörüne ait akım, frekans ve gerilim besleme değerleri

Parametreler	Değerler	Veri Sayısı
V_{CE} (V)	0.5, 0.75, 1.0, 1.5, 1.7, 2.0, 2.5, 3, 3.5, 4, 5, 6, 8, 10	14
I_c (mA)	1, 1.2, 1.5, 2, 2.5, 3, 4, 5, 6, 7, 8, 10, 12, 15, 17, 20, 30, 40, 50, 60, 80, 90	22
f (GHz)	0.1, 0.15, 0.20, ..., 1.0, 1.02, ..., 2.0, 2.02 ..., 4.0.. 5.0...6.0	210
Toplam Veri	$14 \times 22 \times 210 = 64680$	

BFP181 transistörüne ait üretici firma tarafından verilen farklı akım, frekans ve gerilim besleme değerlerindeki saçılma parametreleriyle oluşturulan eğitim ve test data verilerine ait çizelgeler sırasıyla Çizelge 5.2 ve 5.3’de gösterilmiştir.

Çizelge 5. 2 S-Parametreleri için eğitim veri kümesi

Parametreler	Değerler	Veri Sayısı
V_{CE} (V)	0.5, 1.7	2
I_c (mA)	1, 1.2, 1.5, 2, 2.5, 3, 4, 5, 6, 7, 8, 10, 12, 15, 17, 20	16
f (GHz)	0.1, 0.3, 0.5, ..., 1.5, 1.7, 1.9, ..., 5.7, 5.9, 6	31
Toplam Veri	$2 \times 16 \times 31 = 992$	

Çizelge 5. 3 S-Parametreleri için test veri kümesi

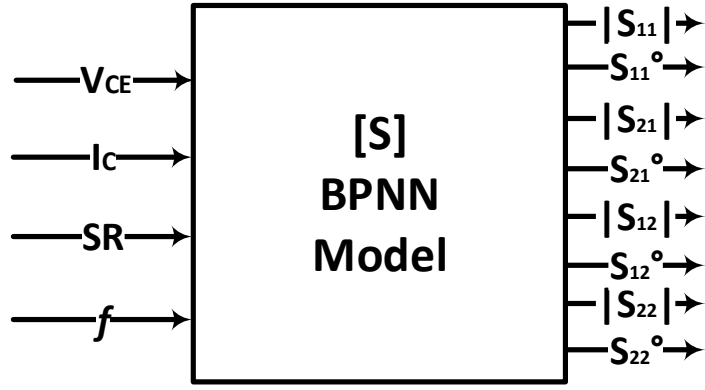
Parametreler	Değerler	Veri Sayısı
V_{CE} (V)	0.75, 1.0, 1.5	3
I_c (mA)	1, 1.2, 1.5, 2, 2.5, 3, 4, 5, 6, 7, 8, 10, 12, 15, 17, 20	16
f (GHz)	0.1, 0.3, 0.5, ..., 1.5, 1.7, 1.9, ..., 5.7, 5.9, 6	31
Toplam Veri	$3 \times 16 \times 31 = 1488$	

Vaka çalışmasında ilk olarak, BPNN modeli giriş kısmında akım değerleri bölgelere ayrılmadan 3 giriş (DC gerilim beslemesi, DC akım beslemesi ve frekans), 8 çıkış (4 adet saçılma parametresinin genlik ve faz değerleri) olacaktır ve “Çizelge 5.2 ve Çizelge 5.3’de ki eğitim ve test verileri olarak kullanılarak YSA performansı incelenecektir.

Daha sonra, S-Parametrelerinin tahmini konusunda YSA performansı ve başarı oranının artırılması amacıyla yeni bir veri eklemeyen BPNN modeli giriş kısmındaki akım değerleri bölgelere ayrılarak veriler zenginleştirilecektir.

Vaka çalışmasında ikinci adımda, akım değerlerine göre düşük akım bölgesi ve yüksek akım bölgesi olmak üzere 2 (iki) bölgeye ayrılarak YSA performansı tekrar incelenecektir.

Vaka çalışmasında üçüncü adımda ise, akım değerlerine göre düşük akım bölgesi, normal akım bölgesi ve yüksek akım bölgesi olmak üzere 3 (üç) bölgeye ayrılarak YSA performansı tekrar incelenecektir.



Şekil 5. 2 Dört giriş 8 çıkışlı S-Parametreleri için kara kutu modeli

[26]

Çizelge 5. 4 İki ve üçlü akım bölgelerine ayrılmış veri kümesi

Vaka	Akım Bölgesi (AB)	Akım Değeri (mA)	Nümerik Temsil
2	Düşük Akım	1, 1.2, 1.5, 2, 2.5, 3, 4, 5, 6	1
	Yüksek Akım	8, 10, 12, 15, 17, 20	2
3	Düşük Akım	1, 1.2, 1.5, 2, 2.5	1
	Normal Akım	3, 4, 5, 6, 8	2
	Yüksek Akım	10, 12, 15, 17, 20	3

Çizelge 5.5'te örnek olarak, önerilen mikrodalga transistör modelinin örnek verileri görülmektedir. Çizelge 5.5'te görüleceği üzere, 2. ve 3. örnek veri kümelerinde ekstra bilgi olarak nümerik temsil edilen akım bölgelerine ayrıldığı görülmektedir.

Çizelge 5. 5 Akımın bölgelere ayrıldığı örnek veri kümesi

Vaka	Gerilim (V)	Akım		Frekans (GHz)	S11		S21		S12		S22	
		Değer (mA)	Akım Bölgesi (AB)		Genlik	Faz	Genlik	Faz	Genlik	Faz	Genlik	Faz
1	1.7	15	-	6.0	0.77	66.2	0.59	-26	0.202	22.5	0.462	-133
2	1.7	15	2	6.0	0.77	66.2	0.59	-26	0.202	22.5	0.462	-133
3	1.7	15	3	6.0	0.77	66.2	0.59	-26	0.202	22.5	0.462	-133

Çalışmanın bir sonraki aşamasında; oluşturulan veri kümeleri kullanılarak Şekil 5.1’de verilen BPNN modeli ile mikrodalga transistörünün saçılma parametreleri tahmin edilecektir. Modelin hedefi; verilen gerilim, akım, akım bölgesi ve frekans verilerine göre karşılık gelen 8 (sekiz) adet saçılma parametresini, eğitim ve test verileri için doğruluğuna bağlı olarak başarı oranı yüksek, hata oranı ise düşük bir biçimde vermesidir.

5.1.2 Vaka Çalışması

Vaka çalışmasında, Çizelge 5.2’de verilen tüm eğitim veri kümeleri akım bölgelere ayrılmış ve ayrılmamış haliyle kullanılarak yapay sinir ağları oluşturulmuştur.

Yapılan bu çalışmada eğitim algoritmaları olan Bayesian Regression (Trainbr) ve Levenberg Marquardt (Trainlm) olmak üzere iki farklı metot kullanılmıştır. Her algoritma için oluşturulan kod, ağın ağırlık değerlerinin YSA çalışmalarında rastgele atanıyor olmasından dolayı en az 30 kez çalıştırılmış ve her defasında bu işlem için bir BPNN “Kara Kutu” modeli oluşturulmuştur.

YSA modelinin oluşturulması için Çizelge 5.2’de verilen eğitim veri kümelerinden oluşturulan ‘.s2p’ uzantılı dosyalardan elde edilen verilerden oluşturulmuş eğitim setleri kullanılmıştır. Ayrıca oluşturulan ağ; 5, 10, 15 ve 20 olmak üzere farklı nöron sayılarına sahip olacak şekilde her nöron sayısı için ağ oluşturma işlemi tekrarlanmıştır. YSA modeli oluşturulduktan sonra bu sefer Çizelge 5.3’de verilen test veri kümelerinden oluşturulan ‘.s2p’ uzantılı dosyalardan elde edilen test setleri kullanılarak Geri Yayılımlı Yapay Sinir Ağı (BPNN) modeli test edilmiş ve test etme işlemi ile BPNN modelinin oluşturduğu sonuçların hata miktarı Ortalama Karese Hata Yöntemi (OKHY) (5.1) ile belirlenmiştir. Bu yöntem ile her saçılma parametresi için ağ çıkış değerleri ve hedef test değerleri kıyaslanmış; maksimum, minimum ve ortalama hata miktarları hesaplanarak Çizelge 5.6 (akım bölgelere ayrılmamış), Çizelge 5.7 (ikili akım bölgelerine ayrılmış) ve Çizelge 5.8 (üçlü akım bölgelerine ayrılmış)’ de verilmiştir.

$$OKHY = \frac{1}{8n} \sqrt{\sum_{i=1}^8 \sum_{j=1}^n (\hat{y}_{ij} - y_{ij})^2} \quad (5.1)$$

İlk olarak 1. durumda akım bölgelere ayrılmamıştır. Bayesian Regression (Trainbr) ve Levenberg Marquardt (Trainlm) eğitim algoritmaları ile nöron sayıları 5,10,15 ve 20 olarak değiştirilmiş ve YSA her defasında 30 kez çalıştırılarak test edilmiştir. OKH yöntemi ile bulunan maksimum, minimum ve ortalama hata değerleri Çizelge 5.6'da verilmiştir. 1. Duruma ait Çizelge 5.6'da görüldüğü üzere nöron sayısı arttıkça her iki eğitim algoritması için 30 defada elde edilen ortalama, minimum ve maksimum hata değeri azalmaktadır.

Çizelge 5. 6 Akım bölgelere ayrılmaksızın S-Parametrelerinin tahminine ait performans sonuçları

Eğitim Algoritması	Nöron Sayısı	Maks.	Min	Ort.
Levenberg Marquardt	N=5	25,9	1,45	4,77
	N=10	17,4	0,99	2,27
	N=15	9,59	0,70	1,43
	N=20	2,36	0,58	0,98
Bayesian Regression	N=5	18,2	1,13	3,19
	N=10	13,5	0,84	2,28
	N=15	6,19	0,61	1,82
	N=20	2,27	0,57	1,01

2. durumda akım; 1. durumdan farklı olarak Çizelge 5.4'de görüldüğü üzere düşük ve yüksek olmak üzere 2 bölgeye ayrılmıştır. Aynı şekilde , Bayesian Regression (Trainbr) ve Levenberg Marquardt (Trainlm) eğitim algoritmaları ile nöron sayıları 5, 10, 15 ve 20 olarak değiştirilmiş ve YSA her defasında 30 kez çalıştırılarak test edilmiştir. OKH yöntemi ile bulunan maksimum, minimum ve ortalama hata değerleri Çizelge 5.7'de verilmiştir. İlk duruma göre; ortalama, minimum ve maksimum hata değerinde azalma görülmektedir ve saçılma parametrelerinin tahminindeki başarı oranı artmıştır.

Çizelge 5. 7 Akımın iki bölgeye ayrılması sonucunda S-Parametrelerinin tahminine ait performans sonuçları

Eğitim Algoritması	Nöron Sayısı	Maks.	Min	Ort.
Levenberg Marquardt	N=5	32,4	2,77	8,33
	N=10	14,4	1,08	2,48
	N=15	5,57	0,63	0,93
	N=20	1,22	0,49	0,69
Bayesian Regression	N=5	22,23	1,85	4,06
	N=10	12,1	1,15	1,83
	N=15	3,18	0,52	0,91
	N=20	1,29	0,51	0,77

3. durumda ise akım; Çizelge 5.4’de görüldüğü üzere düşük, normal ve yüksek olmak üzere 3 bölgeye ayrılmıştır. Aynı işlemler 3. durumda da tekrarlanarak OKH yöntemi ile elde edilen maksimum, minimum ve ortalama hata değerleri tablo 4.7’de verilmiştir. Nöron sayısındaki artış hata miktarını düşürmeye devam ettirmektedir. Ayrıca Çizelge 5.5 ve 5.6 ile kıyaslandığında, akımı ayırdığımız bölge sayısı arttıkça her iki eğitim algoritması için de ortalama hata miktarının azaldığı gözlemlenmektedir.

Çizelge 5. 8 Akımın üç bölgeye ayrılması sonucunda S-Parametrelerinin tahminine ait performans sonuçları

Eğitim Algoritması	Nöron Sayısı	Maks.	Min	Ort.
Levenberg Marquardt	N=5	28,9	2,17	7,16
	N=10	12,6	0,87	1,51
	N=15	3,04	0,51	0,85
	N=20	0,9	0,45	0,6
Bayesian Regression	N=5	22,5	1,88	6,04
	N=10	13,62	0,59	1,08
	N=15	1,84	0,53	0,86
	N=20	0,83	0,51	0,52


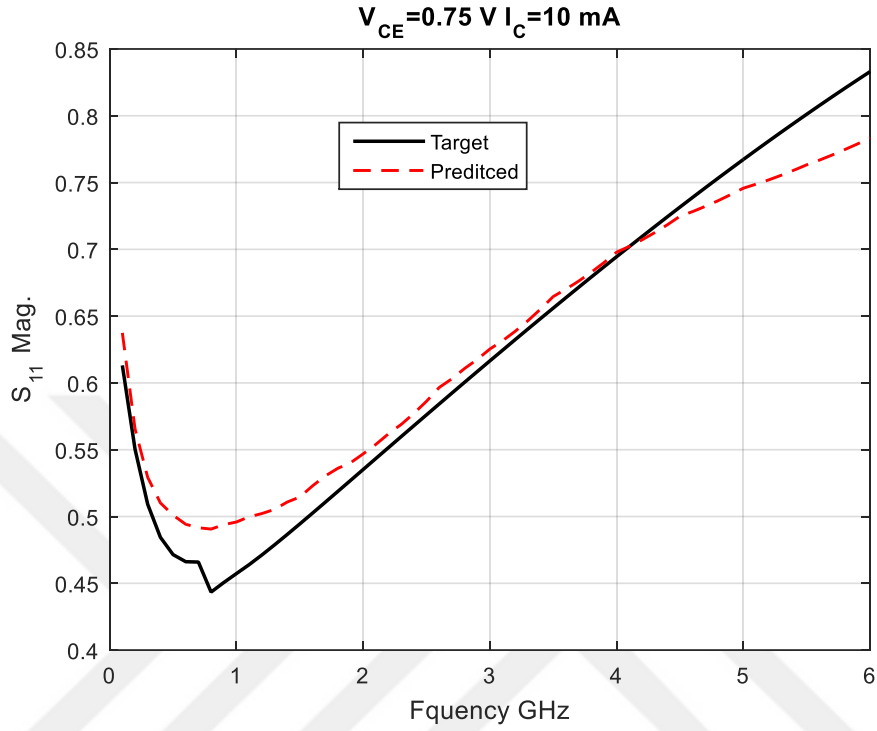
5.1.3 Sonuçlar



“Durum İncelemesi 1” kapsamında yapılan çalışmalar neticesinde, bir mikrodalga transistörünün kısıtlı ölçüm verilerinden yararlanılarak tasarım optimizasyonu işlemlerinde kullanılmak üzere; hızlı ve doğruluğu yüksek bir Geri Yayımlı Yapay Sinir Ağ modeli oluşturulmuştur. Oluşturulan BPNN modeli kullanılarak DC koşullarda bir mikrodalga transistörünün saçılma parametrelerinin kesinliğe yakın bir şekilde karakteristik davranışları tahmin edilmiştir. 3 giriş ve 8 çıkışlı BPNN tabanlı kara kutu modeli yerine, bu durum incelemesi kapsamında transistörün hassas olarak tanımlı olduğu akım; nümerik bir tanımlama ile bölgelere ayrılarak 4 giriş ve 8 çıkışlı BPNN modeli kullanılmıştır.


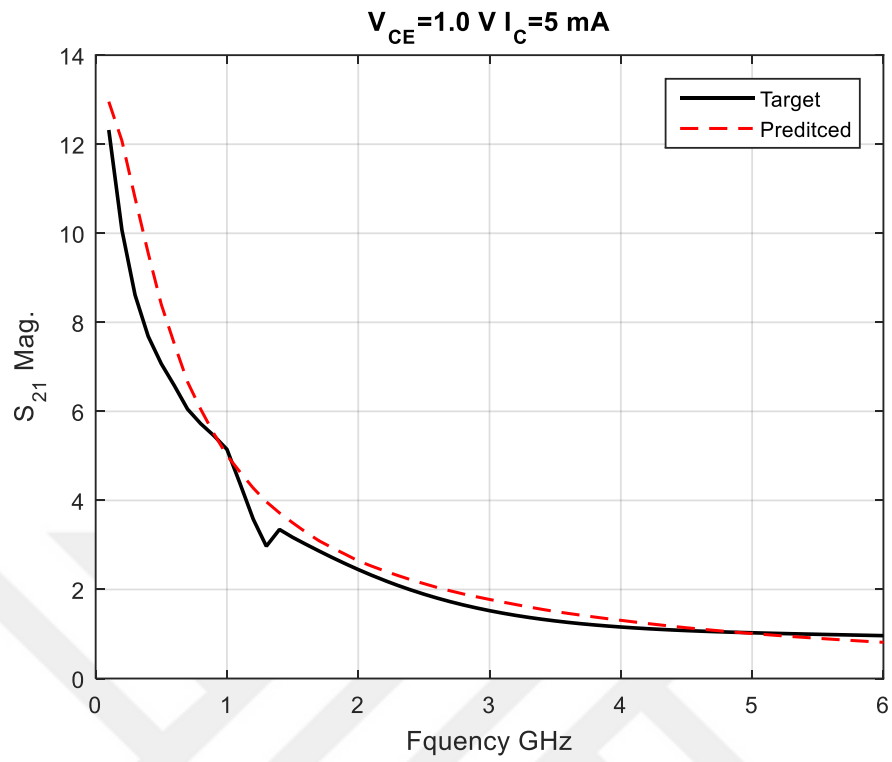
Çizelge 5.6, 5.7 ve 5.8’de görüldüğü üzere akımın bölgelere ayrılması ve bölge sayısının artırılması; her iki eğitim algoritması için de saçılma parametrelerinin tahmininde başarı oranında artış gözlemlendiği ve maksimum ile minimum hata oranları arasındaki ortaya çıkan farkın azalması için etkili bir yöntem olduğu gözlemlenmektedir.

Ayrıca nöron sayısının artmasıyla da ağın verileri rahat işleyebildiği ve performansını artırdığı görülmüştür.

5.1.4 Akımın Üç Bölgeye Ayrılması ve N=20 Olduğu Farklı DC Bias Koşulları Altında Bazı S-Parametrelerine ait Simülasyon Sonuçları







5.2 Durum İncelemesi 2

Çalışmanın bu aşamasında, “Durum İncelemesi 1”den farklı olarak eğitim ve test verilerinde bulunan akım değerlerine ek olarak gerilim ve frekans girişleri de farklı bölgelere ayrılmıştır. Durum İncelemesi 1’dekine benzer benzetim işlemleri bu aşamada da tekrarlanmıştır.

Çizelge 5. 9 S-Parametreleri için eğitim veri kümesi

Parametreler	Değerler	Veri Sayısı
V_{CE} (V)	2, 5, 8	3
I_c (mA)	1.2, 1.5, 2.5, 4, 6, 8, 10, 12, 15 ,17, 20	11
f (GHz)	0.1, 0.2, 0.3, ..., 0.9, 1, 1.2, 1.3, ..., 5.8, 5.9, 6	60
Toplam Veri	3x11x60=1980	

Çizelge 5. 10 S-Parametreleri için test veri kümesi

Parametreler	Değerler	Veri Sayısı
V_{CE} (V)	2.5, 3, 3.5, 4, 6	5
I_c (mA)	1.2, 1.5, 2.5, 4, 6, 8, 10, 12, 15 ,17, 20	11
f (GHz)	0.1, 0.3, 0.5, ..., 1.5, 1.7, 1.9, ..., 5.7, 5.9, 6	60
Toplam Veri	5x11x60=3300	

Çizelge 5. 11 Tüm girişlerin bölgelere ayrıldığı örnek veri kümesi

Vaka	Gerilim		Akım		Frekans		S11		S21		S12		S22	
	Değer (V)	Gerilim Bölgesi (GB)	Değer (mA)	Akım Bölgesi (AB)	Değer (Ghz)	Frekans Bölgesi (FB)	Genlik	Faz	Genlik	Faz	Genlik	Faz	Genlik	Faz
1	8	-	15	-	3.8	-	0.5401	97.4	1.822	20.0	0.1358	35.9	0.3950	-72
2	8	-	15	3	3.8	2	0.5401	97.4	1.822	20.0	0.1358	35.9	0.3950	-72
3	8	3	15	3	3.8	2	0.5401	97.4	1.822	20.0	0.1358	35.9	0.3950	-72

Çizelge 5. 12 Akım, frekans ve gerilim giriş verilerinin bölge ayırımı olmaksızın S-Parametreleri tahminine dair performans sonuçları

Eğitim Algoritması	Nöron Sayısı	Maks.	Min	Ort.
Levenberg Marquardt	N=5	1,2	0,7	0,8
	N=10	1,7	0,5	0,7
	N=15	1,2	0,4	0,6
	N=20	1,2	0,3	0,6
Bayesian Regression	N=5	1,9	0,7	1,0
	N=10	0,7	0,5	0,5
	N=15	1,2	0,3	0,5
	N=20	1,3	0,3	0,6

Çizelge 5. 13 Akım, frekans ve gerilim giriş verilerinin bölgelere ayrılması sonucunda S-parametreleri tahminine dair performans sonuçları

Eğitim Algoritması	Nöron Sayısı	Maks.	Min	Ort.
Levenberg Marquardt	N=5	21,1	2,7	6,8
	N=10	18,3	1,7	6,0
	N=15	8,9	1,7	3,8
	N=20	11,8	1,7	5,0
Bayesian Regression	N=5	11,6	0,8	3,9
	N=10	5,7	0,8	2,9
	N=15	3,1	0,8	1,6
	N=20	2,2	0,8	1,1


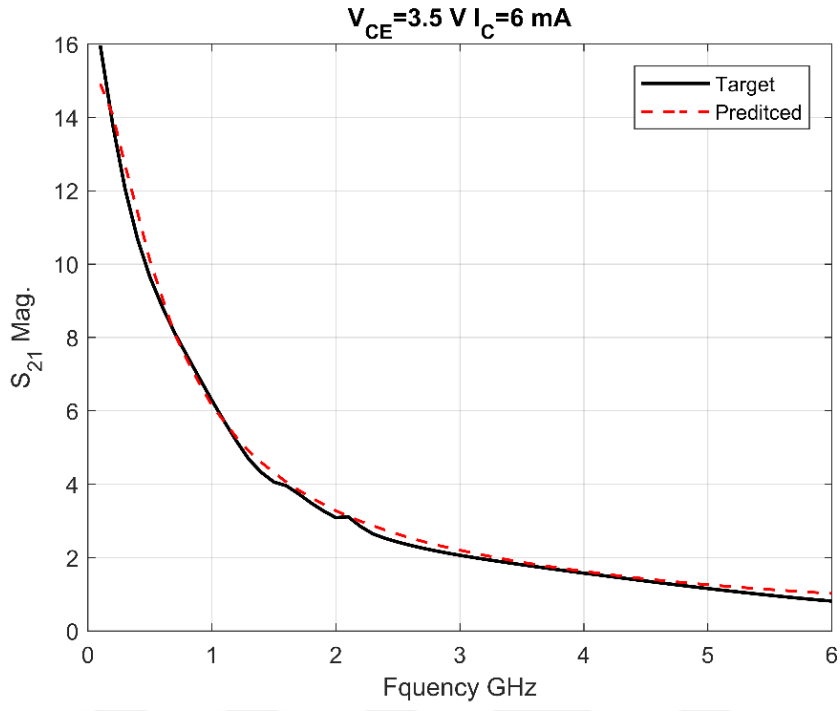
Çizelge 5. 14 Akım ve frekans giriş verilerinin bölgelere ayrılması sonucunda S-parametreleri tahminine dair performans sonuçları



Eğitim Algoritması	Nöron Sayısı	Maks.	Min	Ort.
Levenberg Marquardt	N=5	0,7	0,5	0,6
	N=10	1,3	0,4	0,6
	N=15	2,0	0,3	0,6
	N=20	1,1	0,2	0,5
Bayesian Regression	N=5	0,8	0,5	0,6
	N=10	0,6	0,3	0,5
	N=15	1,2	0,3	0,4
	N=20	1,0	0,2	0,4

5.2.1 Sonuçlar

Çizelge 12-14'te görüleceği üzere tüm giriş verilerinin bölgelere ayrılması, ağın başarısını son derece kötü yönde etkilemektedir. Bu durumu sadece gerilime verilen ek bilginin ağın başarı performansını olumsuz yönde etkilemesi ile yorumlayabiliriz. Bunun nedeni, akım ve frekans verilerinin bölgelere ayrılması ile elde edilen modelin standart modelden (giriş verilerinin bölgelere ayrılmadığı durum) daha yüksek başarıya sahip olduğu rahatlıkla görülmektedir.

5.2.2 Akım ve Frekansın Üç Bölgeye Ayrılması ve N=20 Olduğu Farklı DC Bias Koşulları Altında Simülasyon Sonuçları





SONUÇ VE ÖNERİLER

Tez kapsamında yapılan çalışmalar neticesinde, bir mikrodalga transistörünün kısıtlı ölçüm verilerinden yararlanılarak tasarım optimizasyonu işlemlerinde kullanılmak üzere; hızlı ve doğruluğu yüksek bir Geri Yayımlı Yapay Sinir Ağ modeli oluşturulmuştur. Oluşturulan BPNN modeli kullanılarak DC koşullarda bir mikrodalga transistörünün saçılma parametrelerinin kesinliğe yakın bir şekilde karakteristik davranışları tahmin edilmiştir. 3 giriş ve 8 çıkışlı BPNN tabanlı kara kutu modeli yerine, bu kapsamda transistörün hassas olarak tanımlı olduğu akım; nümerik bir tanımlama ile bölgelere ayrılarak 4 (Durum İncelemesi 1) ve 5 (Durum İncelemesi 2) giriş ve 8 çıkışlı BPNN modeli kullanılmıştır.

Sonuçlardan görüldüğü üzere ilk aşamada akımın, daha sonra frekans verilerinin bölgelere ayrılması ve bölge sayısının artırılması; her iki eğitim algoritması için de saçılma parametrelerinin tahmininde başarı oranında artış gözlemlendiği ve maksimum ile minimum hata oranları arasındaki ortaya çıkan farkın azalması için etkili bir yöntem olduğu gözlemlenmektedir. Ayrıca yapay sinir ağının, eğitim veri kümesindeki toplam veri sayısı arttıkça mikrodalga transistörünün saçılma parametrelerinin tahminine dair performansının olumlu yönde etkilendiği, Durum İncelemesi 1’de standart modelimiz (giriş verilerinin bölgelere ayrılmadığı) için sonuçları içeren Çizelge 5.6 ile Durum İncelemesi 2’de standart modelimiz için sonuçları içeren Çizelge 5.12 kıyaslandığında gözlemlenmektedir.

Son olarak, nöron sayısının artmasıyla da ağın verileri rahat işleyebildiği ve performansını artırdığı görülmüştür.

KAYNAKLAR

- [1] Robotiksystem, Transistör
http://www.robotiksystem.com/transistor_nedir_transistor_cesitleri.html
15 Eylül 2017
- [2] Vikipedi, Transistör, <https://tr.wikipedia.org/wiki/Transistör>
15 Eylül 2017
- [3] Vikipedi, Yapay Sinir Ağları, https://tr.wikipedia.org/wiki/Yapay_sinir_ağları
15 Eylül 2017
- [4] Prezi, Yapay Sinir Ağları, <https://prezi.com/zdxb35xe8ut/yapay-sinir-aglar/>
15 Eylül 2017
- [5] McCulloch W., Pitts W. , (1943), "A Logical Calculus of Ideas Immanent in Nervous Activity", Bulletin of Mathematical Biophysics 5:115–133.
- [6] Hebb, D.O. (1949). The Organization of Behavior. New York: Wiley & Sons.
- [7] Rosenblatt, Frank (1957), The Perceptron--a perceiving and recognizing automaton. Report 85-460-1, Cornell Aeronautical Laboratory.
- [8] Widrow B., Hoff T., (1960) ,An adaptive "ADALINE" neuron using chemical "memistors"
- [9] Öztemel E., (2003), Yapay Sinir Ağları, Papatya Yayıncılık, İstanbul
- [10] Zhang QJ, Gupta KC. Neural Networks for RF and Microwave Design. Artech House, Inc.:Norwood, MA, USA, 2000.
- [11] Marinković Z, Crupi G, Caddemi A, Avolio G, Raffo A, Marković V, Vannini G, Schreurs DMM-P. Neural approach for temperature dependent modeling of GaN HEMTs. Int J Numer Model El doi: 10.1002/jnm.2011.

- [12] Alam MS, Kranti A, Armstrong GA. An efficient neural network approach for nanoscale Fin-FET modelling and circuit simulation. Int J Numer Model El doi: 10.1002/jnm.715.
- [13] Güneş F, Gürgeç F, Torpi H. Signal – noise neural network model for active microwave de-vices. IEE P-Circ Dev Syst 1996; 143:1–8.
- [14] Güneş F, Torpi H, Gürgeç F. Multidimensional signal-noise neural network model. IEE P-Circ Dev Syst 1998; 145:111–117.
- [15] Giannini F, Leuzzi G, Orenço G, Albertini M. Small-signal and large-signal modeling of ac-tive devices using CAD-optimized neural networks. Int J RF Microw C E 2002; 12:71–78.
- [16] Marinkovic ZD, Markovic VV. Temperature-dependent models of low-noise microwave tran-sistors based on neural networks. Int J RF Microw C E 2005; 15:567–577.
- [17] Marinkovic Z, Pronic -Rancic O, Markovic V. Small-signal and noise modeling of class of HEMTs using knowledge-based artificial neural networks. Int J Rf Microw C E 2013; 23:34–39.
- [18] Güneş F, Mahouti P, Kalaycı H. Mikrodalga Transistörlerin Yapay Sinir Ağları Modellemeleri için Optimum Eğitim Veri Mimarisi. Yıldız Teknik Üniversitesi Yüksek Lisans Tezi (2016).
- [19] Gonzalez G, (1997). Microwave Transistor Amplifiers Analysis and Design, Prentice-Hall, Inc.
- [20] Elektrikport, Yapay Sinir Ağları Avantaj ve Dezavantajları <http://www.elektrikport.com/teknik-kutuphane/yapay-sinir-aglari-avantaj-ve-dezavantajlari/15007>
15 Eylül 2017
- [21] Yenibiyoloji, Sinir Hücresi <http://www.yenibiyoloji.com/sinir-hucresinin-noronun-yapisi-gorevleri-ve-noron-cesitleri-1556/>
15 Eylül 2017
- [22] Psikolojik, Yapay Sinir Ağları <http://www.psikolojik.gen.tr/yapay-sinir-aglari.html>
15 Eylül 2017

- [23] Laurene V. Fausett, Prentice Hall, 1994, Fundamentals of Neural Networks: Architectures, Algorithms and Applications
- [24] Güneş F, Mahouti P, Demir E, "Prediction of Scattering Parameter Characteristics of a Microwave Transistor using Artificial Neural Networks" 2017 Mathematical Methods in Engineering International Symposium, (2017) Çankaya University, Ankara
- [25] Slideplayer, Çok Katmanlı Yapay Sinir Ağı Modelleri
<http://slideplayer.biz.tr/slide/2298469/>
15 Eylül 2017
- [26] Specht, D. F., (1991). A General Regression Neural Network, IEEE Trans. Neural Netw. 2 (6): 568–576.
- [27] BFP181 Transistörü, <http://www.infineon.com/cms/en/product/rf-and-wireless-control/BFP181>
15 Eylül 2017

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Eren DEMİR
Doğum Tarihi ve Yeri : 24.01.1990 - Yenimahalle
Yabancı Dili : İngilizce
E-posta : erendytu@gmail.com

ÖĞRENİM DURUMU

Derece	Alan	Okul/Üniversite	Mezuniyet Yılı
Yüksek Lisans	Elektronik ve Haberleşme Mühendisliği	YTÜ	2017
Lisans	Elektronik ve Haberleşme Mühendisliği	YTÜ	2013

İŞ TECRÜBESİ

Yıl	Firma/Kurum	Görevi
Kasım 2014-...	T.C Başbakanlık TİKA	Uzman/Mühendis
2013-2014	EMPA Electronics	Uygulama Mühendisi

YAYINLARI

Bildiri

1."Prediction of Scattering Parameter Characteristics of a Microwave Transistor using Artificial Neural Networks" 2017, International Workshop on Mathematical Methods in Engineering, MME-Cankaya University, Ankara, 27-29 April

