

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

136450

İLERİ BESLEMELİ VE ELMAN GERİ BESLEMELİ
YAPAY SİNİR AĞLARINI KULLANARAK
HARMONİKLERİN KOMPANZASYONU

DOKTORA TEZİ

Rüştü GÜNTÜRKÜN

136450

Enstitü Anabilim Dalı : Elektrik – Elektronik Müh.
Enstitü Bilim dalı : Elektronik
Tez Danışmanı : Yrd. Doç. Dr. Nejat YUMUŞAK

TEMMUZ 2003

T.C. YÖRÜKÖZGÜTTÜM KURULU
KURUMUN KURULU
KURUMUN KURULU

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**İLERİ BESLEMELİ VE ELMAN GERİ BESLEMELİ
YAPAY SİNİR AĞLARINI KULLANARAK
HARMONİKLERİN KOMPANZASYONU**

DOKTORA TEZİ

Rüştü GÜNTÜRKÜN

Enstitü Anabilim Dalı : Elektrik – Elektronik Mühendisliği
Enstitü Bilim dalı : Elektronik


Bu tez 05 / 08 / 2003 tarihinde aşağıdaki jüri tarafından Oybirliği/Oyçokluğu ile kabul edilmiştir.



Doç. Dr. Osman GÜRDAL
Jüri Başkanı



Doç. Dr. Etem KÖKLÜKAYA
Jüri Üyesi



Doç. Dr. Sadettin AKSOY
Jüri Üyesi



Doç. Dr. Bekir ÇAKIR
Jüri Üyesi



Yrd. Doç. Dr. Nejat YUMUŞAK
Jüri Üyesi

TEŐEKKÖR

Bu alıřmanın bÖtÖn ařamalarında yardımlarını esirgemeyen sayın Yrd. Do. Dr. Nejat YUMUŐAK, ve sayın Yrd. Do. Dr. Fevzullah TEMURTAŐ'a, ve katkılarından dolayı Yrd. Do. Dr. Abdurrahman ÖNSAL'a teőekkÖr ederim. Ayrıca doktora eėitimi süresince hibir fedakarlıktan kaçınmayan aileme müteőekkirim.



İÇİNDEKİLER

TEŞEKKÜR.....	ii
İÇİNDEKİLER.....	iii
SİMGELER ve KISALTMALAR LİSTESİ.....	ix
ŞEKİLLER LİSTESİ.....	x
TABLolar LİSTESİ	xvii
ÖZET.....	xxiii
SUMMARY	xxiv

BÖLÜM 1.

GİRİŞ	1
-------------	---

BÖLÜM 2.

AKTİF GÜÇ FİLTRELERİ.....	7
2.1. Aktif Filtrelerin Bağlantı Şekilleri	8
2.1.1. Paralel aktif filtrenin yapısı ve çalışması	8
2.1.2. Paralel aktif filtrenin üç fazlı güç sistemine bağlanması	11
2.1.3. Aktif filtrenin seri bağlanması.....	11
2.1.4. Aktif filtre ile pasif filtrenin birlikte bağlanması	12
2.1.5. Paralel ve seri aktif filtrenin beraber kullanılması	13
2.2. Aktif Filtrelerin Sınıflandırılması	13
2.2.1. Voltaj beslemeli aktif filtrenin yapısı	14
2.2.2. Akım beslemeli aktif filtrenin yapısı	14
2.3. P-Q Teorisi.....	15
2.4. Pasif Filtreler	16

BÖLÜM 3.

HARMONİKLER	17
3.1. Harmoniklerin Tanımı	17
3.2. Harmonik Kirlenmesi	19
3.3. İzin Verilen Toplam Harmonik Değerleri	20
3.4. Harmonik Kaynakları	21
3.5. Harmoniklerin Zararları	21
3.5.1. Kondansatörlerde delinme ve ömürlerinin kısalması	21
3.5.2. Enerji kayıpları ve Yüksek Faturalar.....	22
3.5.3. Rezonans etkisi	22
3.5.4. Isınma	22
3.5.5. Frekans etkisi	23

BÖLÜM 4.

HARMONİK KOMPANZASYONUNDA KULLANILAN İLERİ BESLEMELİ ve ELMAN GERİ BESLEMELİ YAPAY SİNİR AĞLARININ YAPILARI ve ÖRNEKLEME TEOREMİ.....	24
4.1. Harmonik Kompanzasyon Yöntemleri.....	24
4.2. Örneklem Teoremi	26
4.2.1. Örneklem dizisi	28
4.4. Yapay Sinir Ağları İçin Verilerin Hazırlanması.....	31
4.5. İleri Beslemeli Yapay Sinir Ağları	34
4.5.1. Ağı öğrenmesi	36
4.5.2. Simülasyon için yapay sinir ağının kurulması.....	36
4.6. İki Gizli Katmanlı İleri Beslemeli Yapay Sinir Ağı.....	38
4.7. Geri beslemeli Yapay Sinir Ağı	40
4.7.1. Harmonik kompanzasyonu için Elman geri beslemeli yapay sinir ağı.....	40
4.8. İki Katmanlı Elman Geri Beslemeli Yapay Sinir Ağı	41

BÖLÜM 5.

İLERİ BESLEMELİ ve ELMAN GERİ BESLEMELİ YAPAY

SİNİR AĞLARININ SİMÜLASYON SONUÇLARI..... 43

5.1. İleri Beslemeli Yapay Sinir Ağında Simülasyon Sonuçları	43
5.2. Gizli katman nöron sayılarına göre simülasyon sonuçları	43
5.2.1. Gizli katman nöron sayısı 90 alındığında simülasyon sonuçları ...	43
5.2.2. Gizli katman nöron sayısı 60 alındığında simülasyon sonuçları ...	48
5.2.3. Gizli katman nöron sayısı 30 alındığında simülasyon sonuçları	52
5.2.4. Gizli katman nöron sayısı 20 alındığında simülasyon sonuçları	56
5.3. Gizli Katman Nöron Sayısının Değişimine Göre Harmoniklerin Değişimi	60
5.4. İki Gizli Katmanlı İleri Beslemeli Yapay Sinir Ağında Simülasyon Sonucu.....	64
5.5. Elman Geri beslemeli (Recurrent) Ağda Simülasyon Sonuçları	65
5.5.1. Gizli katman sayısı 90 kullanıldığında	65
5.5.2. Gizli katman sayısı 20 kullanıldığında	69
5.5.3. İki gizli katmanlı Elman geri beslemeli sinir ağında harmonik simülasyonu	72

BÖLÜM 6.

SONUÇLARIN KARŞILAŞTIRILMASI..... 74

6.1. Öğrenim algoritmalarının karşılaştırılması	74
6.1.1. Gizli katman nöron sayısı 90 alındığında.....	74
6.1.2. Gizli katman sayısı 60 alındığında	76
6.1.3. Gizli katman sayısı 30 alındığında	78
6.1.4. Gizli Katman Sayısı 20 alındığında.....	80
6.2. İleri Beslemeli Ağ ile Elman Geri Beslemeli Ağın Karşılaştırılması	82

6.2.1. Gizli katman nöron sayısı 90	82
6.2.2. Gizli katman nöron sayısı 20	87
6.3. Elman Geri Beslemeli Ağda Farklı Gizli Katman Sayılarına Göre Simülasyon Sonuçları (Gizli Katman nöron Sayısı 90–20’nin Karşılaştırılması).....	91
6.4. Gizli Katman Nöron Sayılarına Göre Harmonik Tanımada Öğrenme Algoritmalarının Karşılaştırılması.....	95
6.5. Tek ve İki Gizli Katmanlı İleri Beslemeli ve Elman Geri Beslemeli Ağların Performans Analizi	98
6.6. Elman Geri Beslemeli Ağda Aktivasyon Fonksiyonlarının Karşılaştırılması	99
6.7. İleri Beslemeli Ağda Simülasyon Sonuçlarının Birlikte Gösterimi	100
6.8. Elman Geri Beslemeli Ağda Simülasyon sonuçlarının birlikte gösterimi.....	104
6.9. İleri Beslemeli ve Elman Geri Beslemeli Yapay Sinir Ağı Tarafından Düzeltilen Dalga Şekilleri.....	106
 BÖLÜM 7.	
TARTIŞMA ve ÖNERİLER.....	108
 KAYNAKLAR.....	113
 EK. A.	
YAPAY SİNİR AĞLARI	120
A.1. Yapay Sinir Ağı'nın Tarihi Gelişimi	120
A.2. Biyolojik sinir sistemi	122
A.3 Yapay Sinir Modeli	155
A.3.1 Yapay sinir ağlarının özellikleri	126
A.3.1.1. Paralellik	127
A.3.1.2. Hata Toleransı.....	127
A.3.1.3. Gerçekleme Kolaylığı	127
A.3.1.4.Öğrenebilirlik ve Adaptasyon	127

A.3.1.5.Genelleme	128
A.3.1.6. Özetleme	128
A.3.1.7. Yapay sinir ağlarının paralel mimarisi	128
A.3.1.8. YSA'ların gerçek zamanlı çalışması.....	129
A.4. Yapay Sinir Ağlarının Temel Bileşenleri	129
A.4.1. Girdi elemanları	130
A.4.2. Ağırlıklar	130
A.4.3. Toplama fonksiyonu	130
A.4.4. Aktivasyon fonksiyonu.....	131
A.4.5. Çıktı fonksiyonu	133
A.5. Tek Katmanlı Ağlar	133
A.5.1. Genel mimarisi	133
A.6. Çok Katmanlı Ağlar	134
A.7. Sinir Ağlarının Sınıflandırılması	136
A.7.1. İleri ve geri beslemeli ağlar	136
A.8.Yapay Sinir Ağlarının Eğitilmesi	137
A.8.1. Öğretmenli öğrenme	137
A.8.2. Öğretmensiz öğrenme.....	138
A.8.3. Takviyeli öğrenme	139
A.9. Geriye yayılımla(GY) Öğrenme	139
A.9.1. Eğitim algoritması	140
A.9.1.1. Çıkış Katmanı Öğrenmesi	142
A.9.1.2. Gizli Katman Öğrenmesi	144
A.9.2. Standart geri yayılım algoritması	147
A.10. Adaptif Öğrenme.....	148
A.11. Geri beslemeli sinir ağının yapısı.....	150
A.11.1. Elman ağının yapısı	151
A.12. Yapay Sinir Ağının Uygulama Alanları	152

EK.B

İLERİ BESLEMELİ VE ELMAN GERİ BESLEMELİ AĞLARDA HARMONİKLERİ HESAPLAMADA KULLANILAN PROGRAMLARDAN BAZILARI VE AKIŞ ŞEMASI	153
---	-----

B1. İleri Beslemeli Ağda Harmonikleri Hesaplayan Programlardan

Biri (1000 İterasyon için) 153

B2. Elman Geri Beslemeli Ağda Harmonikleri Hesaplayan

Programlardan Biri(1000 İterasyon için) 154

B3. İleri Beslemeli Ağda Harmoniklerin Hesaplanmasında

Kullanılan Programın Akış Şeması 155

ÖZGEÇMİŞ 156



SİMGELER ve KISALTMALAR LİSTESİ

AF	: Aktif filtre
APF	: Aktif güç filtre
BP	: Backpropagation
e	: Hata
FFYSA	: İleri beslemeli yapay sinir ağı
GY	: Geriye yayılım
GYA	: Geriye yayılım algoritması
N	: Nöron sayısı
PF	: Pasif filtre
RNN	: Geri beslemeli sinir ağı
THD	: Toplam harmonik değeri
YSA	: Yapay sinir ağları
η	: Momentum katsayısı
α	: Öğrenme oranı

ŞEKİLLER LİSTESİ

Şekil 2.1. Paralel aktif filtrenin doğrusal olmayan yüke bağlanması	9
Şekil 2.2. Değişken karakteristikli aktif güç filtrenin doğrusal olmayan yüke bağlanması.....	10
Şekil 2.3. Harmonik kompanzasyonu için kullanılan aktif filtre	10
Şekil 2.4. Paralel aktif filtrenin üç fazlı güç sistemine bağlanması	11
Şekil 2.5. Aktif Filtrenin seri bağlanması	12
Şekil 2.6. Seri aktif filtre ve paralel pasif filtre kombinasyonu	12
Şekil 2.7. Paralel ve seri bağlı aktif filtrelerin birlikte kullanılması	13
Şekil 2.8. Voltaj beslemeli aktif filtre tipi	14
Şekil 2.9. Akım beslemeli aktif filtre tipi	15
Şekil 3.1. Temel dalga 5. ve 7. harmonikler ile bunların bileşkesi olan dalga	18
Şekil 4.1. Harmonik atma yöntemleri: a) Aktif filtre yöntemi, b) Fourier analiz yöntemi, c) Yapay sinir ağı yöntemi.....	26
Şekil 4.2. T'nin tam sayı katlarının belirli değerleri ile üç sürekli zaman sinyalleri ...	27
Şekil 4.3. Pals genlik modülasyonu	28
Şekil 4.4. Ani hareket katarı ile genlik modülasyon palsi.....	29
Şekil 4.5. Zaman boyutundaki örnekleme frekans boyutuna etkisi: a) orijinal sinyal spektrumu; (b) örnekleme fonksiyon spektrumu; (c) $\omega_s > 2\omega_M$ ile örnekleme sinyal spektrumu; (d) $\omega_s < 2\omega_M$ ile örnekleme sinyal spektrumu	30
Şekil 4.6. İdeal alçak geçiren filtre kullanarak örneklemlerden sürekli zaman sinyallerinin yeniden elde edilmesi.....	31
Şekil 4.7. Harmonik analizi için oluşturulan 2520 harmonikli dalgalardan örnek sinyaller	33
Şekil 4.8. Harmonik dedeksiyonu için kullanılan ileri beslemeli sinir ağının yapısı	35
Şekil 4.9. Simülasyon için kurulan ağın yapısı	37
Şekil 4.10. Harmonik kompanzasyonu için iki gizli katmanlı ileri beslemeli	

yapay sinir ağının yapısı.....	39
Şekil 4.11. Harmonik tanımada kullanılan Elman geri beslemeli ağın yapısı	41
Şekil 4.12. Harmonik kompanzasyonu için Elman geri beslemeli(recurrent) ağın yapısı	42
Şekil 5.1. Gizli katman nöron sayısı 90 olan ileri beslemeli YSA'da öğrenme algoritması hızlı GYA, aktivasyon fonksiyonu lineer kullanıldığı zaman harmoniklerin değişim grafiği	44
Şekil 5.2. Gizli katman nöron sayısı 90 olan ileri beslemeli YSA'da öğrenme algoritması hızlı GY, aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişim grafiği.....	45
Şekil 5.3. Gizli katman nöron sayısı 90 olan ileri beslemeli YSA'da öğrenme algoritması standart GY, aktivasyon fonksiyonu lineer kullanıldığı zaman harmoniklerin değişim grafiği	46
Şekil 5.4. Gizli katman nöron sayısı 90 olan ileri beslemeli YSA'da öğrenme algoritması standart GY, aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişim grafiği	47
Şekil 5.5. Gizli katman nöron sayısı 60 olan ileri beslemeli YSA'da öğrenme algoritması hızlı GY, aktivasyon fonksiyonu lineer kullanıldığı zaman harmoniklerin değişim grafiği	48
Şekil 5.6. Gizli katman nöron sayısı 60 olan ileri beslemeli YSA'da öğrenme algoritması hızlı GY, aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişim grafiği	49
Şekil 5.7. Gizli katman nöron sayısı 60 olan ileri beslemeli YSA'da öğrenme algoritması hızlı GY, aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişim grafiği	50
Şekil 5.8. Gizli katman nöron sayısı 60 olan ileri beslemeli YSA'da öğrenme algoritması standart GY, aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişimi	51
Şekil 5.9. Gizli katman nöron sayısı 30 olan ileri beslemeli YSA'da öğrenme algoritması hızlı GY, aktivasyon fonksiyonu lineer kullanıldığı zaman harmoniklerin değişim grafiği	52
Şekil 5.10. Gizli katman sayısı 30, hızlı GY ve aktivasyon fonksiyonu	

sigmoid olduđu zaman iterasyona g�re harmoniklerin deęiřim grafięi	53
řekil 5.11. Gizli katman n�ron sayısı 30 olan ileri beslemeli YSA'da	
�ęrenme algoritması standart GY, aktivasyon fonksiyonu	
lineer kullanıldıęı zaman harmoniklerin deęiřim grafięi	54
řekil 5.12. Gizli katman n�ron sayısı 30 olan ileri beslemeli YSA'da	
�ęrenme algoritması standart GY, aktivasyon fonksiyonu sigmoid	
kullanıldıęı zaman harmoniklerin deęiřim grafięi	55
řekil 5.13. Gizli katman n�ron sayısı 20 olan ileri beslemeli YSA'da	
�ęrenme algoritması hızlı GY, aktivasyon fonksiyonu lineer	
kullanıldıęı zaman harmoniklerin deęiřimi	56
řekil 5.14. Gizli katman n�ron sayısı 20 olan ileri beslemeli YSA'da	
�ęrenme algoritması hızlı GY, aktivasyon fonksiyonu	
sigmoid kullanıldıęı zaman harmoniklerin deęiřim grafięi	57
řekil 5.15. Gizli katman n�ron sayısı 20 olan ileri beslemeli YSA'da	
�ęrenme algoritması standart GY, aktivasyon fonksiyonu	
lineer kullanıldıęı zaman harmoniklerin deęiřim grafięi	58
řekil 5.16. Gizli katman n�ron sayısı 20 olan ileri beslemeli YSA'da	
�ęrenme algoritması standart GY, aktivasyon fonksiyonu sigmoid	
kullanıldıęı zaman harmoniklerin deęiřim grafięi	59
řekil 5.17. Aktivasyon fonksiyonu lineer ve hızlı GY kullanıldıęında gizli	
katman n�ron sayısının toplam harmonik deęerine etkisi.....	60
řekil 5.18. Aktivasyon fonksiyonu sigmoid ve hızlı GY kullanıldıęında	
gizli katman n�ron sayısının toplam harmonik deęerine	
etkisini g�steren grafik	61
řekil 5.19. Aktivasyon fonksiyonu lineer ve standart GY kullanıldıęında	
gizli katman n�ron sayısının toplam harmonik deęerine etkisi.....	62
řekil 5.20. Aktivasyon fonksiyonu sigmoid ve standart GY kullanıldıęında	
gizli katman n�ron sayısının toplam harmonik deęerine etkisi.....	63
řekil 5.21. İleri beslemeli iki gizli katmanlı aęın iterasyon sayısına g�re	
toplam harmonik deęerinin deęiřimi	64
řekil 5.22. Elman geri beslemeli aęda gizli katman n�ron sayısı 90,	
hızlı GY, aktivasyon fonksiyonu lineer kullanıldıęı zaman harmoniklerin	

değişim grafiği.....	65
Şekil 5.23. Elman geri beslemeli ağda gizli katman nöron sayısı 90, standart GY, aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişim grafiği.....	66
Şekil 5.24. Elman geri besleme ağda gizli katman nöron sayısı 90, standart GY, aktivasyon fonksiyonu lineer kullanıldığı zaman harmoniklerin değişim grafiği.....	67
Şekil 5.25. Elman geri besleme ağda gizli katman nöron sayısı 90, standart GY, aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişim grafiği.....	68
Şekil 5.26. Elman geri besleme ağda aktivasyon fonksiyonu lineer, hızlı GY kullanıldığında iterasyona göre harmonik değişim grafiği.....	69
Şekil 5.27. Elman geri besleme ağda aktivasyon fonksiyonu sigmoid, hızlı GY kullanıldığında iterasyona göre harmonik değişim grafiği.....	70
Şekil 5.28. Elman geri besleme ağda aktivasyon fonksiyonu lineer, standart GY kullanıldığında iterasyona göre harmonik değişim grafiği	71
Şekil 5.29. Elman geri besleme ağda aktivasyon fonksiyonu sigmoid, standart GY kullanıldığında iterasyona göre harmonik değişimi.....	72
Şekil 5.30. İki gizli katmanlı Elman ağı kullanıldığında iterasyon sayısına göre harmonik değerinin değişim grafiği	73
Şekil 6.1. Aktivasyon fonksiyonu lineer, hızlı GY ile standart GY simülasyon grafiği.....	75
Şekil 6.2. Aktivasyon fonksiyonu sigmoid, hızlı GY ile standart GY simülasyon grafiği.....	76
Şekil 6.3. Aktivasyon fonksiyonu lineer, hızlı GY ile standart GY simülasyon grafiği.....	77
Şekil 6.4. Aktivasyon fonksiyonu sigmoid, hızlı GY ile standart GY. simülasyon grafiği.....	78
Şekil 6.5. Gizli katman sayısı 30, aktivasyon fonksiyonu lineer, hızlı geriye yayılım ile standart geriye yayılım simülasyon grafiği.....	79
Şekil 6.6. Gizli katman sayısı 30, aktivasyon fonksiyonu sigmoid, hızlı geriye yayılım ile standart geriye yayılım simülasyon grafiği.....	80

Şekil 6.7. Gizli katman sayısı 20, aktivasyon fonksiyonu lineer hızlı geriye yayılım ile standart geriye yayılım'ın simülasyon grafiği	81
Şekil 6.8. Gizli katman sayısı 20, aktivasyon fonksiyonu sigmoid hızlı geriye yayılım ile standart geriye yayılım simülasyon grafiği.....	82
Şekil 6.9. Gizli katman sayısı 90'da ileri beslemeli ağ ile Elman geri beslemeli ağın karşılaştırılması	83
Şekil 6.10. Gizli katman sayısı 90'da ileri beslemeli ağ ile Elman geri beslemeli ağın karşılaştırılması	84
Şekil 6.11. Gizli katman sayısı 90'da ileri beslemeli ağ ile Elman geri beslemeli ağın karşılaştırılması	85
Şekil 6.12. Gizli katman sayısı 90'da ileri beslemeli ağ ile Elman geri beslemeli ağın karşılaştırılması	86
Şekil 6.13. Gizli katman sayısı 90'da ileri beslemeli ağ ile Elman geri beslemeli ağın karşılaştırılması	87
Şekil 6.14. Gizli katman sayısı 90'da ileri beslemeli ağ ile Elman geri beslemeli ağın karşılaştırılması	88
Tablo 6.15. Gizli katman sayısı 20 alındığında ileri beslemeli ağ ile Elman geri beslemeli ağın karşılaştırılması	89
Tablo 6.16. Gizli katman sayısı 20 alındığında ileri beslemeli ağ ile elman geri beslemeli ağın karşılaştırılması	90
Şekil 6.17. Aktivasyon fonksiyonu lineer, hızlı GY kullanılmasıyla elde edilen harmonik değerleri.....	91
Şekil 6.18. Aktivasyon fonksiyonu sigmoid, hızlı GY kullanılmasıyla elde edilen harmonik değerleri.....	92
Şekil 6.19. Aktivasyon fonksiyonu lineer, standart GY kullanılmasıyla elde edilen harmonik değerleri.....	93
Şekil 6.20. Aktivasyon fonksiyonu sigmoid, standart GY kullanılmasıyla elde edilen harmonik değerleri.....	94
Şekil 6.21. Aktivasyon fonksiyonu lineer, öğrenme algoritması hızlı GY ve standart GY kullanıldığında gizli katman nöron sayısına göre harmonik değişimi	95
Şekil 6.22. Aktivasyon fonksiyonu sigmoid, öğrenme algoritması hızlı	

GY ve standart GY kullanıldığında gizli katman nöron sayısına göre harmonik değişimi	96
Şekil 6.23. Aktivasyon fonksiyonu lineer ve sigmoid, öğrenme algoritması hızlı GY ve standart GY kullanıldığında gizli katman nöron sayısına göre harmonik değişimi	97
Şekil 6.24. Gizli katman sayılarına göre harmonik değişim grafiği.....	98
Şekil 6.25. Ortalama toplam harmonik değeri 45.7% olan bozulmuş dalga'nın ileri beslemeli yapay sinir ağı ile 4.08%'e düzeltilmesi	99
Şekil 6.26. Ortalama toplam harmonik değeri 45.7% olan bozulmuş dalga'nın Elman geri beslemeli yapay sinir ağı kullanılarak 4.06 %'ya düzeltilmesi	100
Şekil 6.27. Ortalama toplam harmonik değeri 45.7% olan bozulmuş dalga'nın ileri beslemeli yapay sinir ağı ile 3.9 %'a düzeltilmesi.....	101
Şekil 6.28. Ortalama toplam harmonik değeri 45.7% olan bozulmuş dalga'nın ileri beslemeli Elman geri beslemeli yapay sinir ağı düzeltilmesi	102
Şekil 6.29. Gizli katman 20 kullanıldığında öğrenme algoritmaları ve aktivasyon fonksiyonlarına göre toplam harmonik değerlerinin (THD) değişimi	103
Şekil 6.30 Elman geri beslemeli ağda gizli katman nöron sayısı 90 kullanıldığında öğrenme algoritmaları ve aktivasyon fonksiyonlarına göre toplam harmonik değerlerinin (THD) değişimi	104
Şekil 6.31. Elman geri beslemeli ağda gizli katman nöron sayısı 20 kullanıldığında öğrenme algoritmaları ve aktivasyon fonksiyonlarına göre toplam harmonik değerlerinin (THD) değişimi	105
Şekil 6.32. Ortalama toplam harmonik değeri 45.7% olan bozulmuş dalga'nın ileri beslemeli yapay sinir ağı ile 4.08%'e düzeltilmesi	106
Şekil 6.33. Ortalama toplam harmonik değeri 45.7% olan bozulmuş dalga'nın Elman geri beslemeli yapay sinir ağı kullanılarak 4.06 %'ya düzeltilmesi.....	107
Şekil 7.1. İterasyon sayısına göre ileri beslemeli ve Elman geri beslemeli ağların performansları	110

Şekil 7.2. Ortalama toplam harmonik değeri 45.7% olan bozulmuş dalganın ileri beslemeli ve Elman geri beslemeli yapay sinir ağı düzeltilmesi	111
Şekil A.1 Biyolojik sinir sisteminin blok gösterimi	122
Şekil A.2 Sinirlerin beyne bağlanması	124
Şekil A.3 Biyolojik sinirin yapısı.....	125
Şekil A.4 Yapay sinir modeli	126
Şekil A.5 Yapay sinir ağının temel elamanları	129
Şekil A.6 Çeşitli aktivasyon fonksiyonları.....	133
Şekil A.7 Sigmoid fonksiyon ile tek katmanlı ağı yapısı	134
Şekil A.8 Çok katmanlı ağın yapısı.....	135
Şekil A.9 İleri beslemeli iki katmanlı ağın genel yapısı.....	136
Şekil A.10 Geri beslemeli ağın genel yapısı	137
Şekil A.11 Öğretmenli öğrenme.....	138
Şekil A.12 Öğretmensiz öğrenme	139
Şekil A.13 Çok katmanlı ileri beslemeli ağ yapısı.....	141
Şekil A.14 Geri beslemeli sinir ağının oluşturulması	150
Şekil A.15 İki katmanlı Elman ağının yapısı	151
Şekil B1. Harmoniklerin hesaplanmasında kullanılan programın akış şeması	155

TABLÖLAR LİSTESİ

Tablo 4.1. Maksimum harmonik değeri.....	37
Tablo 5.1. Gizli katman nöron sayısı 90 olan ileri beslemeli YSA'da öğrenme algoritması hızlı geriye yayılım, aktivasyon fonksiyonu lineer kullanıldığı zaman harmoniklerin değişimi	44
Tablo 5.2. Gizli katman nöron sayısı 90 olan ileri beslemeli YSA'da öğrenme algoritması hızlı geriye yayılım, aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişimi.....	45
Tablo 5.3. Gizli katman nöron sayısı 90 olan ileri beslemeli YSA'da öğrenme algoritması standart geriye yayılım, aktivasyon fonksiyonu lineer kullanıldığı zaman harmoniklerin değişimi	46
Tablo 5.4. Gizli katman nöron sayısı 90 olan ileri beslemeli YSA'da öğrenme algoritması standart geriye yayılım, aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişimi	47
Tablo 5.5. Gizli katman nöron sayısı 60 olan ileri beslemeli YSA'da öğrenme algoritması hızlı geriye yayılım, aktivasyon fonksiyonu lineer kullanıldığı zaman harmoniklerin değişimi	46
Tablo 5.6. Gizli katman nöron sayısı 60 olan ileri beslemeli YSA'da öğrenme algoritması hızlı geriye yayılım, aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişimi.....	49
Tablo 5.7. Gizli katman nöron sayısı 60 olan ileri beslemeli YSA'da öğrenme algoritması hızlı geriye yayılım, aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişimi.....	50
Tablo 5.8. Gizli katman nöron sayısı 60 olan ileri beslemeli YSA'da öğrenme algoritması standart geriye yayılım, aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişimi	51
Tablo 5.9. Gizli katman nöron sayısı 30 olan ileri beslemeli YSA'da öğrenme algoritması hızlı geriye yayılım, aktivasyon fonksiyonu lineer	

kullanıldığı zaman harmoniklerin değişimi	52
Tablo 5.10. Gizli katman nöron sayısı 30 olan ileri beslemeli YSA'da öğrenme algoritması hızlı geriye yayılım, aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişimi	53
Tablo 5.11. Gizli katman nöron sayısı 30 olan ileri beslemeli YSA'da öğrenme algoritması standart geriye yayılım, aktivasyon fonksiyonu lineer kullanıldığı zaman harmoniklerin değişimi	54
Tablo 5.12. Gizli katman nöron sayısı 30 olan ileri beslemeli YSA'da öğrenme algoritması standart geriye yayılım, aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişimi	55
Tablo 5.13. Gizli katman nöron sayısı 20 olan ileri beslemeli YSA'da öğrenme algoritması hızlı geriye yayılım, aktivasyon fonksiyonu lineer kullanıldığı zaman harmoniklerin değişimi	56
Tablo 5.14. Gizli katman nöron sayısı 20 olan ileri beslemeli YSA'da öğrenme algoritması hızlı geriye yayılım, aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişimi.....	57
Tablo 5.15. Gizli katman nöron sayısı 20 olan ileri beslemeli YSA'da öğrenme algoritması standart geriye yayılım, aktivasyon fonksiyonu lineer kullanıldığı zaman harmoniklerin değişimi	58
Tablo 5.16. Gizli katman nöron sayısı 20 olan ileri beslemeli YSA'da öğrenme algoritması standart geriye yayılım, aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişimi	59
Tablo 5.17. Aktivasyon fonksiyonu lineer, hızlı öğrenme ve gizli katman nöron sayısına göre harmoniklerin değişimi	60
Tablo 5.18. Aktivasyon fonksiyonu sigmoid, hızlı öğrenme ve gizli katman nöron sayısına göre harmoniklerin değişimi	61
Tablo 5.19. Aktivasyon fonksiyonu lineer, standart öğrenme ve gizli katman nöron sayısına göre harmoniklerin değişimi	62
Tablo 5.20. Aktivasyon fonksiyonu sigmoid, standart öğrenme ve gizli katman nöron sayısına göre harmoniklerin değişimi	63
Tablo 5.21. İki gizli katmanlı ileri beslemeli hızlı backpropagation, aktivasyon fonksiyonu sigmoid kullanıldığı zaman	

harmoniklerin deęiřimi	64
Tablo 5.22. Elman geri beslemeli aęda gizli katman nron sayısı 90, hızlı GY, aktivasyon fonksiyonu lineer kullanıldıęı zaman harmoniklerin deęiřimi	65
Tablo 5.23. Elman geri beslemeli aęda gizli katman nron sayısı 90, hızlı GY, aktivasyon fonksiyonu sigmoid kullanıldıęı zaman harmoniklerin deęiřimi	66
Tablo 5.24. Elman geri beslemeli aęda gizli katman nron sayısı 90, standart geriye yayılım., aktivasyon fonksiyonu lineer kullanıldıęı zaman harmoniklerin deęiřimi	67
Tablo 5.25. Elman geri beslemeli aęda gizli katman nron sayısı 90, standart geriye yayılım, aktivasyon fonksiyonu sigmoid kullanıldıęı zaman harmoniklerin deęiřimi	68
Tablo 5.26. Elman geri beslemeli aęda gizli katman nron sayısı 20, hızlı geriye yayılım , aktivasyon fonksiyonu lineer kullanıldıęı zaman harmoniklerin deęiřimi	69
Tablo 5.27. Elman geri beslemeli aęda gizli katman nron sayısı 20, hızlı geriye yayılım, aktivasyon fonksiyonu sigmoid kullanıldıęı zaman harmoniklerin deęiřimi	70
Tablo 5.28. Elman geri beslemeli aęda gizli katman nron sayısı 20, standart geriye yayılım, aktivasyon fonksiyonu lineer kullanıldıęı zaman harmoniklerin deęiřimi	71
Tablo 5.29. Elman geri beslemeli aęda Gizli katman nron sayısı 20, standart geriye yayılım, aktivasyon fonksiyonu sigmoid kullanıldıęı zaman harmoniklerin deęiřimi	72
Tablo 5.30. İki gizli katmanlı Elman geri besleme aęda hızlı geriye yayılmada aktivasyon fonksiyonu Sigmoid kullanıldıęı zaman harmoniklerin deęiřimi.....	73
Tablo 6.1. Gizli katman nron sayısı 90 alındıęında ileri beslemeli aęda aktivasyon fonksiyonu lineer, hızlı GY. ile standart GY'in simlasyon sonuları	74
Tablo 6.2. Gizli katman nron sayısı 90 alındıęında ileri beslemeli aęda	

aktivasyon fonksiyonu sigmoid, hızlı GY. ile standart GY'in simülasyon sonuçları	75
Tablo 6.3. Gizli katman nöron sayısı 60 alındığında ileri beslemeli ağda aktivasyon fonksiyonu lineer, hızlı GY ile standart GY'in simülasyon değerleri	76
Tablo 6.4. Gizli katman nöron sayısı 60 alındığında ileri beslemeli ağda aktivasyon fonksiyonu sigmoid, hızlı GY ile standart GY'in simülasyon sonuçları	77
Tablo 6.5. Gizli katman nöron sayısı 30 alındığında ileri beslemeli ağda aktivasyon fonksiyonu lineer, hızlı geriye yayılım ile standart geriye yayılım'ın simülasyon sonuçları.....	78
Tablo 6.6. Gizli katman nöron sayısı 30 alındığında ileri beslemeli ağda aktivasyon fonksiyonu sigmoid, hızlı GY ile standart GY'in simülasyon değerleri	79
Tablo 6.7. Gizli katman nöron sayısı 20 alındığında ileri beslemeli ağda aktivasyon fonksiyonu lineer, hızlı GY ile standart GY'in simülasyon sonuçları	80
Tablo 6.8. Gizli katman nöron sayısı 20 alındığında ileri beslemeli ağda aktivasyon fonksiyonu sigmoid, hızlı GY ile standart GY'in simülasyon değerleri	81
Tablo 6.9. İleri beslemeli ağ ile Elman geri beslemeli ağın karşılaştırılması	83
Tablo 6.10. İleri beslemeli ağ ile Elman geri beslemeli ağın karşılaştırılması	84
Tablo 6.11. İleri beslemeli ağ ile Elman geri beslemeli ağın karşılaştırılması	85
Tablo 6.12. İleri beslemeli ağ ile Elman geri beslemeli ağın karşılaştırılması	86
Tablo 6.13. Gizli katman sayısı 20 alındığında ileri beslemeli ağ ile Elman geri beslemeli ağın karşılaştırılması	87
Tablo 6.14. Gizli katman sayısı 20 alındığında ileri beslemeli ağ ile Elman geri beslemeli ağın karşılaştırılması	88
Tablo 6.15. Gizli katman sayısı 20 alındığında ileri beslemeli ağ ile Elman geri beslemeli ağın karşılaştırılması	89
Tablo 6.16. Gizli katman sayısı 20 alındığında ileri beslemeli ağ ile Elman geri beslemeli ağın karşılaştırılması	90

Tablo 6.17. Gizli katman sayılarına göre Elman geri beslemeli ağlarında harmonik değişimi.....	91
Tablo 6.18. Gizli katman sayılarına göre Elman geri beslemeli ağlarda harmonik değişimi.....	92
Tablo 6.19. Gizli katman sayılarına göre Elman geri beslemeli ağlarında harmonik değişimi.....	93
Tablo 6.20. Gizli katman sayılarına göre Elman geri beslemeli ağında harmonik değişimi.....	94
Tablo 6.21. İleri beslemeli ağda gizli katman nöron sayısına göre harmonik değişimi.....	95
Tablo 6.22. İleri beslemeli ağda gizli katman nöron sayısına göre harmonik değişimi.....	96
Tablo 6.23. İleri beslemeli ağda gizli katman nöron sayısına göre harmonik değişimi.....	97
Tablo 6.24. İki ve tek gizli katmanlı ağlarda sigmoid aktivasyon fonksiyonu ve hızlı GY kullanıldığında harmonik değişimi.....	98
Tablo 6.25. Elman geri beslemeli ağda lineer ve sigmoid aktivasyon fonksiyonlarının karşılaştırılması.....	99
Tablo 6.26. Gizli katman sayısı 90 olduğu zaman iterasyon sayısına göre yüzde harmonik değerleri.....	100
Tablo 6.27. Gizli katman sayısı 60 olduğu zaman iterasyon sayısına göre harmonik değerlerinin değişimi	101
Tablo 6.28. Gizli katman sayısı 30 olduğu zaman iterasyon sayısına göre harmonik değerlerinin değişim.....	102
Tablo 6.29. Gizli katman sayısı 20 olduğu zaman aktivasyon fonksiyonu ve öğrenme algoritmalarına göre harmoniklerin aldığı değer değişimleri.....	103
Tablo 6.30. Elman geri beslemeli ağda gizli katman nöron sayısı 90, aktivasyon fonksiyonu ve öğrenme algoritmalarına göre harmoniklerin aldığı değer değişimleri	104
Tablo 6.31. Elman geri beslemeli ağda gizli katman nöron sayısı 20,	

aktivasyon fonksiyonu ve öğrenme algoritmalarına göre harmoniklerin aldığı değerin değişimleri	105
Tablo 7.1. Orijinal ağ yapıları ve bu çalışmada önerilen ağların simülasyon sonuçları	109
Tablo 7.2. Bu çalışmada önerilen yöntemlerden elde edilen sonuç ile diğer yöntemlerden elde edilen sonuçların karşılaştırılması	111
Tablo A.1. Sinir sistemi ile yapay sinir ağının benzerlikleri	123
Tablo A.2. En çok kullanılan Toplama Fonksiyonları	131
Tablo A.3. Aktivasyon Fonksiyon Türleri	132



ÖZET

Anahtar kelimeler: İleri beslemeli sinir ağı, Geri beslemeli sinir ağı, Hızlı geriye yayılım, Standart geriye yayılım, Harmonik bozulması, Aktif filtre, Güç kalitesi.

Bu çalışmada harmonik dedeksiyonu için aktif filtre işlemlerinde iki gizli katmanlı ileri beslemeli ve Elman geri beslemeli sinir ağları önerilmiştir. Bu amaç için tek gizli katmanlı ve iki gizli katmanlı iki tip sinir ağı kullanılmıştır. İlk adım olarak standart geriye yayılım ve hızlı geriye yayılım öğrenme algoritması ile üç katmanlı(giriş, gizli ve çıkış) bir ağ kullanılmıştır. Bu ağın gizli katmanında ve çıkış katmanında doğrusal olmayan aktivasyon fonksiyonu kullanılmıştır. Karşılaştırma yapabilmek için ağların çıkış nöronlarında lineer aktivasyon fonksiyonu kullanılmıştır. İkinci adım olarak hızlı geriye yayılım öğrenme algoritması ile dört katmanlı(giriş, iki gizli katman ve çıkış) bir ağ kullanılmıştır. Gizli katman ve çıkış katman nöronlarında sigmoid aktivasyon fonksiyonu kullanılmıştır.

Eğitim ve test işlemlerinde, sinir ağlarının giriş sinyalleri, bir periyodluk bozulmuş dalgaların genlikleridir. Genliklerden zaman ekseninde düzenli aralıklarla 128 örnekleme sinyali alınmıştır. Genlikler hiçbir ön işleme tabi tutulmadan sinir ağlarının giriş sinyalleri olarak kullanılmıştır. Sinir ağının bozulmuş dalgadan harmonikleri ayırabilmesi için öğrenmede bazı örnek bozulmuş dalgaları kullanması gerekmektedir. Bu bozulmuş dalgalar temel dalga içinde 5., 7., 11. ve 13. harmoniklerin bileşimlerinin karıştırılmasıyla oluşturulmuştur. Bu amaçla 5. harmonik 70%, 7. harmonik 40%, 11. harmonik 10% ve 13. harmonik 5% kullanılarak 2520 örnek bozulmuş dalga eğitim için oluşturulmuştur. Eğitim esnasında bozulmuş dalgalar tanıma için kullanılmıştır. Sinir ağlarının performanslarını geliştirmek için 5. harmonik 70%, 7. harmonik 40%, 11. harmonik 10%, 13. harmonik 5%, 17. harmonik 5%, 19.harmonik 2.5%, 23. harmonik 2.5% ve 25. harmonik 2% kullanılmış ve yaklaşık 250 örnek bozulmuş dalga test setinde oluşturulmuştur. Eğitim tamamlandıktan sonra oluşturulan bozulmuş dalgalar test setinde tanıma için kullanılmıştır. Eğitim ve test safhasında oluşan tanıma sonuçlarına göre yapay sinir ağları çıkışlarında alınan her bir çıkış girişteki bozulmuş dalganın içerdiği her bir harmoniğin değerini ifade etmektedir ve bu harmonikler bozulmuş dalgada ayrıştırılarak düzeltilir.

Sonuç olarak ileri beslemeli ve Elman geri beslemeli yapay sinir ağlarının harmonikleri bulmasının mümkün olduğu, bozulmuş dalgaları düzeltmesiyle doğrulanmaktadır. İleri beslemeli ve Elman geri beslemeli yapay sinir ağlarının aktif filtreler için etkili bir şekilde kullanılabileceği gösterilmiştir.

HARMONICS COMPENSATION USING FEED FORWARD AND ELMAN RECURRENT ARTIFICIAL NEURAL NETWORKS

SUMMARY

Keywords : Feed forward neural network, Elman's recurrent neural network, Fast and Standart backpropagation, Harmonics distortion, Active filter, Power quality

In this study, the methods to apply the feed forward with two hidden layers and Elman's recurrent neural network for harmonic detection process in active filter are proposed. Two type neural networks with one and two hidden layers are used for this purpose. At the first step, we used three layers networks (input layer, hidden layer and output layer) with standart backpropagation and fast backpropagation learning algorithm. The hidden layer neurons and the output layer neurons use nonlinear sigmoid activation functions. In alternative networks, the output layer neurons use linear activation functions for comparison. At the second step, we used four layers networks (input layer, two hidden layers and output layer) with fast backpropagation learning algorithm. The hidden layer neurons and the output layer neurons use nonlinear sigmoid activation functions.

For the training and test processes, input signals of the neural networks are the amplitudes of one period distorted wave. The amplitudes are taken 128 point at regular interval of time axis. The amplitudes are used to be input signals of the neural networks without any pre-processing. In order to make neural network enable to detect harmonics from distorted wave, it is necessary to use some representative distorted waves for learning. These distorted waves are made by mixing the component of the 5th, 7th, 11th, and 13th harmonics in fundamental wave. For this purpose, 5th harmonic up to 70%, 7th harmonic up to 40%, 11th harmonic up to 10% and 13th harmonic up to 5% were used and approximately 2500 representative distorted waves were generated for training process. During the training process, the distorted waves were used for recognition. For the performance evaluation of the neural network structures, 5th harmonic up to 70%, 7th harmonic up to 40%, 11th harmonic up to 10% and 13th harmonic up to 5%, 17th harmonic up to 5%, 19th harmonic up to 2.5%, 23th harmonic up to 2.5%, 25th harmonic up to 2% were used and approximately 250 representative distorted waves were generated as a test set. After the training process is completed, the general distorted waves (test set) were used for recognition. As the result of recognitions at the training and test phase, output signal from each output unit means the content of each harmonic including the input distorted wave and these harmonics are eliminated from the distorted wave.

As the result, the possibility of the feed forward and Elman's recurrent neural networks to detect harmonics is confirmed by compensating the distorted waves and it can be said that the feed forward and Elman's recurrent neural networks are effectively to be used for active filter.

BÖLÜM 1. GİRİŞ

Sanayi kalkınma hamlesi içinde bulunan ülkemiz için enerji özellikle, elektrik enerjisinin ne denli önemli olduğu açıktır. Diğer taraftan ülkemizde yıldan yıla artmakta olduğu elektrik enerjisi ihtiyacının yeni yatırımlarla karşılanmasının yanı sıra, mevcut kaynakların en verimli bir şekilde kullanılması tartışılmaz bir gerçektir[1].

Ülkemizin halen içinde bulunduğu enerji dar boğazından çıkabilmesi için alması gerekli tedbirlerin başında, enerjinin kullanımında tasarrufa önem vermesi gerekmektedir. Bu tasarruf tedbirlerinin en önemlisi ise elektrik tesislerinde harmonik kompanzasyonu yapılarak güç katsayısının düzeltilmesidir. Güç katsayısını düzeltmekle, mevcut şebekeden yeni talepleri karşılama imkanı doğacağı gibi, gerilim düşümü ve tesislerdeki toplam kayıplar da asgariye inmiş olacaktır.

Türkiye elektrik kurumunun yayınladığı bir broşüre göre Türkiye'deki tüm elektrik şebekelerinde güç faktörü 0.96'ya yükseltilecek şekilde kompanzasyon tesisleri yapıldığı takdirde, yıllık tüketimin takriben %20 tutarında olan hat kayıpları %10'a düşeceği belirtilmektedir[2].

Ülkemizin yıllık elektrik tüketimi yaklaşık 250 Milyar Kwh olduğu düşünülürse, harmonik kompanzasyonundan dolayı 25 Milyar Kwh'lık bir tasarruf sağlanmış olacakki buda 1980'li yıllarda kullandığımız bir yıllık elektrik enerjisine denk düşmektedir [2].

Amerika birleşik devlerindeki fabrikaların yıllık harmonikten dolayı kayıpları 25 milyar dolardan daha çoktur[3].

Son yıllarda elektrik sistemlerinde kullanılan nonlineer yüklerin artmasıyla enerji kalitesi, enerji tüketicileri ve üreticileri tarafından düşünülmesi gereken önemli bir

konu haline gelmiştir. Elektrik enerji fiyatları enerji üreticilerini ve elektrik cihazları üreticilerini yüksek verimli cihazları üretmeye ve geliştirmeye zorlamıştır. Elektrik enerjisinin yüksek verimli olması için artan talep, elektrik sistemlerinde ve kullanıcı uygulamalarında artan miktarda elektronik cihazların kullanılmasına sebep olmuştur.

Doğrusal olmayan yükler enerji kalitesini düşürürler ve modern elektronik cihazların enerji sistemlerinde meydana gelen bozulmalara karşı hassasiyetini önemli ölçüde etkilerler. Doğrusal olmayan yükler, enerji sistemlerinin içine harmonik enjekte ederler bunun sonucu olarak düşük kaliteli enerjiye ve düşük güç katsayısına sebep olurlar[4].

Akım ve gerilim harmonikleri, duyarlı cihazların çalışmalarını olumsuz yönde etkilerler. Harmonik bozulmalarına en çok duyarlı olan cihazlar, yarı iletken cihazlar, ölçüm cihazları, trafolar, endüksiyon makinaları (Asenkron makinalar) ve bunların kontrol sistemleridir. Endüstriyel uygulamalar(Endüstride kullanılan fabrikalar), büyük ölçüde elektronik olarak kontrol edilen örneğin zamanlayıcılar, tepe voltaj değerinin düşmesinden dolayı büyük kayıplar verebilirler, örneğin bilgi kayıpları ve fabrikaların uzun süre devre dışı kalması v.b. gibi.

Uygulamada en çok 5., 7., 11. ve 13. harmoniklerle karşılaşılır. Ancak 11. ve 13. harmoniklerin genlikleri ana bileşene göre çok küçük olduğundan özel haller dışında önemsenmezler. Daha çok 5. ve 7. harmoniklere ilişkin önlemler alınmaya çalışılır. Elektrikli aygıtlara en büyük zararı 5 kHz' den küçük olan harmoniklerin verdiği kabul edilmektedir[5].

Güç elektroniği teknolojisinin gelişmesiyle aktif güç filtrelerinin çekiciliği sürekli olarak artmaktadır. Aktif güç filtre(APF) teknolojisi, doğrusal olmayan yükler tarafından meydana getirilen düşük seviyedeki harmoniklerin yok edilmelerini ve reaktif güçlerin kompanzasyonunda en etkili yoldur. Güç sistemlerindeki harmonik akımları hat voltajında bozulma ve elamanların fazla ısınmalarına, yarı iletken elamanların zarar görmelerine ve haberleşme sistemlerinde karışıklık gibi bir çok ters etkiye yol açarlar[6].

AC güçte yarı iletkenlerin kontrolü, tristörler ve diğer yarı iletken devreler kullanırken bir çok elektrik beslemeli yükler örneğin ASD(Adjustable Speed Driver), elektrik ark kaynakları, bilgisayar güç kaynakları v.b.'nın kullanımı devamlı artmaktadır. Bu elektrik yükler doğrusal olmayan yükler gibi ac kaynaklardan akım bileşenli reaktif güç ve harmonik çekerler. Bu istenmeyen özellikler, düşük verime, yetersiz güç faktörüne, haberleşme ağlarında karışmalara sebep olmaktadır. Güç sistemlerinde harmoniklerin yükselmesi, mühendisleri güç kalite problemlerinde ayarlanabilir ve dinamik bir çözüm bulmak için çalışmalara sevk etmiştir. Genel olarak bilinen gereçlerde, etkili bir alternatif olarak aktif filtre(AF), doğrusal olmayan yükler tarafından üretilen harmonikle eşit miktarda fakat 180^0 faz farklı sinyal üreterek harmonikleri yok etmektedir[7].

Yapay sinir ağları(YSA), birbirlerine belirli ağırlık değerleri üzerinden bağlanmış bir çok elemanın oluşturduğu bütünsel paralel bir yapıdır ve biyolojik sinir sisteminin anlaşılmasından sonra oluşturulmuştur. Bir yapay sinir ağı, örnekleri, dağıtılmış kodlama ile saklar ve eğitilebilir lineer olmayan dinamik bir sistem oluşturur[8]. Ayrıca bir yapay sinir ağı ardışıl sayısal bir bilgisayardan, insan beyninin paralel kabiliyetine benzemesine çalışması ile daha hızlı bir cevap ve daha yüksek bir performansa sahiptir[9,10]. Yapay sinir ağlarının ortaya çıkan günümüz teknolojisi, sınıflandırma, kontrol, işaret işleme, arıza erken tanısı gibi bir çok alanda başarılı bir şekilde kullanılmaktadır[11].

Yapısal olarak sinir ağları ileri besleme ve geri besleme olarak ikiye ayrılır. İleri beslemeli sinir ağlarında nöronlar gizli katmanlardan oluşur. Bir katmandan bir sonraki katmana ağırlıklarla bağlantılar yapılır. Değişik isimlerde bir çok ileri beslemeli sinir ağları mevcuttur. İkincisi, geri beslemeli sinir ağlarıdır. Bu ağlar dinamik sinir ağları olarak da isimlendirilir. En popüler olanı Hopfield ve Elman ağıdır. Geri beslemeli ağların en önemlisi hopfield ağıdır. Fakat hopfield ağ yapısı tek katmanlı bir yapıya sahip olduğu için çalışmamıza uygun düşmemiştir. Çalışmamızda kullandığımız Elman geri beslemeli yapay sinir ağı, giriş katman, gizli katman ve çıkış katman olmak üzere çok katmanlı bir ağ yapısına sahiptir. Elman geri beslemeli sinir ağının yapısında, gizli katman çıkışında sigmoid, çıkışında ise lineer aktivasyon fonksiyonu kullanılmıştır. Çalışmamızda karşılaştırma yapabilmek

için ağıın çıkış katmanında hem sigmoid hemde lineer aktivasyon fonksiyonu kullanılmıştır. Aynı zamanda Elman geri beslemeli ağıın yapısında olmayan gizli katman sayısı ikiye çıkarılarak simülasyon yapılmıştır. Bu yapılarda ağıın büyük olması, parametre (ağırlık) sayısının çok fazla olması ve eğitim zamanının uzun olması problemleri ile karşılaşmaktadır. Yapay sinir ağıında kullanılan lineersizliği belirleyen aktivasyon fonksiyonları için değişik fonksiyonlar kullanılmaktadır. En çok kullanılan fonksiyonlardan birisi sigmoid fonksiyonudur. Çok değişkenli bir sürekli fonksiyon bir sigmoid fonksiyonunun süperpozisyonları ile yaklaşık olarak ifade edilebilmektedir[12].

Harmonik kompanzasyonunda en etkili yol aktif güç filtre kullanmaktır. Aktif güç filtre, güç hattı içindeki bozulan dalgadan harmonikli akımı ayırır. Bununla beraber aktif güç filtre karmaşık bir yapıya sahip olduğu için harmonik kompanzasyonunda zaman kaybına sebep olur. Burada dikkat çekilen, düşünülen durumun harmonik kompanzasyonu için işlemlerin karmaşıklılığıdır. İşlemler için uzun zamana ihtiyaç vardır, bu zaman aktif filtre davranışlarını etkiler. Harmonik kompanzasyonunda işlem zamanını kısaltmak için, ileri beslemeli ve Elman geri beslemeli yapay sinir ağıları kullanılmıştır.

Harmonik dedeksiyonu için Fourier dönüşüm metodu kullanılarak yapılan harmonik kompanzasyonunda toplam harmonik değeri(THD) (Kompanzasyondan önce THD=28%, kompanzasyondan sonra 12%) 28%'den 12%'ye kadar düşürülmüştür[4]. İçerdiği yoğun matematiksel ifadeler bu metodun modellenmesini karmaşık hale getirmektedir. Genetik algoritma kullanılarak yapılan harmonik kompanzasyonunda, harmonik değeri kompanzasyondan önce THD =46%, kompanzasyondan sonra THD = 4.1%'dir[13]. P-Q teorisi kullanılarak yapılan harmonik kompanzasyonunda, harmonik değeri kompanzasyondan sonra THD = 10%''a düşürülmüştür[14].

Bu çalışmada, tek ve çift gizli katmanlı ileri beslemeli ve Elman geri beslemeli sinir ağıları kullanılarak harmonik analizi yapılmıştır. Her ağ için hızlı (fast) geriye yayılım algoritması ve standart geriye yayılım algoritması(GYA) kullanılmış, aynı zamanda karşılaştırma yapmak için ağların çıkışında lineer ve sigmoid transfer

fonksiyonları kullanılmıştır. Yapay sinir ağının harmonikli dalgayı tanıyabilmesi için içerisinde 5., 7., 11. ve 13. harmoniklerin bulunduğu 2520 tane harmonikli dalga oluşturulmuştur. 13'den büyük harmoniklerin genlikleri çok küçük ve taşıdıkları akım önemsiz olduğu için hesaplamalarda gözönüne alınmamıştır. Harmonikli dalganın oluşumunda kullanılan maksimum harmonik değerleri 5. harmonik için %70, 7. harmonik için %40, 11. harmonik için %10 ve 13. harmonik için de %5 olarak alınmıştır[15]. Oluşturulan her bir harmonikli dalgadan yapay sinir ağının girişleri için 128 örnekleme sinyali alınmıştır. Harmonikli dalgaların her biri farklı harmonik değerlerine sahiptir.

Kullanılan ağlarda, gizli katman nöron sayısı değiştirilerek optimum harmonik kompanzasyonu sağlayan gizli katman nöron sayısı bulunmuştur. Ayrıca kullanılan ağlara ikinci bir gizli katman eklenerek ağın performansını etkileyip etkilemediği araştırılmıştır.

Bu çalışmanın ikinci bölümünde aktif filtreler konusunda bilgi verilmiş, aktif filtrelerin bağlantı şekilleri, yapıları, çalışma prensipleri ve harmonik kompanzasyonunun nasıl yapıldığı anlatılmıştır.

Tezin üçüncü bölümünde , harmoniklerin tanımı, zararları, harmonik standartları, ve harmonik kaynakları incelenmiştir.

Tezin dördüncü bölümünde harmonik kompanzasyon metotları olarak aktif filtre, Fourier dönüşümü ve yapay sinir ağları metotları incelenmiştir. Bu çalışmada önerdiğimiz ileri beslemeli yapay sinir ağının iki gizli katmanlı ve Elman geri beslemeli yapay sinir ağının tek ve iki gizli katmanlı kullanılarak harmonik analizi yapılmıştır. Örnekleme teoremi incelenmiştir.

Tezin beşinci bölümünde; İleri beslemeli ve Elman geri beslemeli ağların gizli katman sayıları ve gizli katman nöron sayıları değiştirilerek simülasyon sonuçları verilmiştir.

Tezin altıncı bölümünde elde edilen simülasyon sonuçları karşılaştırılarak verilmiştir.

Tezin yedinci bölümünde: Elde edilen sonuçların yorumu yapılarak ileriye yönelik çalışma önerilerine yer verilmiştir.

Tezin EK A'da ileri beslemeli yapay sinir ağlarında sırasıyla giriş katmanı, gizli katman ve çıkış katmanındaki öğrenme formülleri çıkarılmış, biyolojik sinir sistemi ile yapay sinir ağları arasındaki benzerlikler karşılaştırılmıştır.

EK B'de ileri beslemeli ve Elman geri beslemeli ağların harmonim hesabında kullanılan program ve akış şeması verilmiştir.



BÖLÜM 2. AKTİF GÜÇ FİLTRELERİ

Paralel ve seri olarak sınıflandırılan aktif güç filtreleri, reaktif güç, harmonik ve endüstriyel güç sistemleri içindeki dalgalanmaları yok etmek için 1970'lerde önerilmiştir. Fakat 1970'lerde devre teknolojisi pratik olarak uygulamada çok yetersiz olduğu için aktif güç filtrelerinde, laboratuvar test safhası boyunca hemen hemen hiç ilerleme sağlanamamıştır. Üzerinden geçen beş on yıl zarfında yarı iletken elamanlardaki olağanüstü gelişmeler, örneğin Bipolar Junction Transistörler ve statik indüksiyon tristörleri, harmonikleri yok etmek için paralel ve seri aktif güç filtrelerindeki çalışmaları teşvik etmiştir[16]-[21]. Bunlara ilaveten PWM(Pulse Wide Modulation) inverter teknolojisinin bulunması ve “p-q” teorisinin geliştirilmesi aktif filtrelerinin test safhasından uygulama safhasına geçmesine imkan tanımıştır[21].

1982 yılında akım beslemeli PWM inverterli 800kVA paralel aktif filtre dünyada ilk defa harmonikleri yok etmek için pratik olarak Japonya'da uygulanmıştır[21].

Aktif güç filtreleri(APF) güç sistemi içinde doğrusal olmayan yüklerin artmasından dolayı geniş bir şekilde kullanılmaktadır. Aktif güç filtrelerinin temel hedefi doğrusal olmayan yükler tarafından meydana getirilen istenilmeyen harmonikleri kompanzasyon etmektir. Aktif filtrelerin paralel bağlanmaları güç akışında herhangi bir karışıklığa sebep olmadığı için güç sistemlerinde en geniş kullanımı ve çekicisi olmuştur[13]

Güç elektroniği teknolojisinin gelişmesiyle aktif güç filtrelerinin çekiciliği sürekli olarak devam etmektedir. APF teknolojisi doğrusal olmayan yükler tarafından meydana getirilen düşük seviyedeki harmoniklerin yok edilmelerini ve reaktif güçlerin kompanzasyonunda en etkili yoldur. Güç sistemlerindeki hermonik akımları hat voltajında bozulma ve elamanların fazla ısınmalarına, yarı iletken elamanların

zarar görmelerine ve haberleşme sistemlerinde karışıklık gibi bir çok ters etkiye yol açarlar[6].

Büyük miktarda doğrusal olmayan yükler uygulamada çeşitli güç seviyelerinde kullanılmaktadır. Doğrusal olmayan yüklere örnek olarak değişken hız sürücüler, ışık sistemleri, güç kaynakları ve bir çok diğer tipler verilebilir. Bu devreler harmonik akım ve gerilim çekmesiyle ana kaynakta bozulmaya neden olurlar. APF kullanımı pasif filtre kullanımından daha avantajlıdır. APF boyut olarak küçük, daha ucuz, kullanıma göre değişken ve daha çok seçicilik özelliğine sahiptir.

Yükteki harmonik bozulmayı yok etmede APF kullanıldığı zaman bozulma tipine göre akım tipli veya gerilim tipli olarak sınıflandırılabilir[22]. Son yıllarda güç konverterleri veya doğrusal olmayan yüklerin sebep olduğu güç sistemlerindeki harmonik kirlenmesi çok ciddi bir problem olmaktadır. Bu ciddi güç kirlenmesi ac kaynak içine enjekte edilerek düşük güç faktörüne, voltaj dalgalanmasına ve güç sisteminin etkisinin azalmasına yol açmaktadır. APF'nin bir çok değişik tipteki yapısı bu problemi çözmek için önerilmiştir. APF bu görüş[4] tarafından reaktif güç ve hat akım harmoniklerini yok etmede veya seri aktif güç filtreleri tarafından yükteki son(terminal) voltajının dengesizliği ve voltaj dalgalanmasının yok edilmesi için önerilmiştir[6],[8]. Karışık bağlı APF [9] hem aktif hem de pasif filtreleri içine alır. Pasif filtreler pratik harmonik kompanzasyonu ve uygun fiyat sağlar. APF'ler kaynaklar ile paralel bağlanarak voltaj kaynaklı inverter'e uygulanabilir[7].


2.1. Aktif Filtrelerin Bağlantı Şekilleri

2.1.1. Paralel aktif filtrenin yapısı ve çalışması


Doğrusal olmayan yük akımı(i_L), temel bileşen(i_1) ve harmonik bileşen(i_H) akımlarını içermekte, bu akımlar güç şebekesinden yük tarafından çekilmektedir. Filtre işlemlerinde kaynağın içine akım sinyalinin(i_F) enjekte etmek için genellikle bir birleşme noktası kullanılır. İdeal şartlar altında enjekte edilen bu akım doğrusal olmayan yükün akımı ile aynı genlikte fakat 180° faz kaymalıdır($i_F = -i_H$). Şekil 2.1.'deki aktif filtre blok diyagramının içinde sistemin çalışması için kullanılan devre

mevcuttur. Çoğunlukla aktif filtre içinde dc kenar üzerinde büyük değerli dc bağlantılı kondansatör ve akım kontrollü döngü ile voltaj beslemeli dönüştürücü (inverter) kullanılmaktadır[18]. Dönüştürücüdeki frekans dönüştürme aktif güç filtre tabanında 20-30 kHz aralığındadır. Bir çok diğer konfigürasyonlar vardır, örneğin değişken karakteristikli devreler[23]-[24], karışık bağlı yapılar ve voltaj düzenleyici tip aktif filtre[25].


Şekil 2.1’de görülen değişken karakteristikli filtrenin temel avantajı ~4kHz gibi çok düşük anahtarlama frekansına sahip olmasıdır.



Şekil 2.1. Paralel aktif filtrenin doğrusal olmayan yüke bağlanması




Şekil 2.2. Değişken karakteristikli aktif güç filtrenin doğrusal olmayan yüke bağlanması



Şekil 2.3. Harmonik kompanzasyonu için kullanılan aktif filtre

2.1.2. Paralel aktif filtrenin üç fazlı güç sistemine bağlanması


Şekil 2.4.'de hem harmonik akımını hemde güç faktörünü kompanze edebilen nötr hatlı üç fazlı güç sistemi için paralel aktif filtrenin elektriksel şeması görülmektedir. Güç safhası, temelde DC kenardaki sadece bir tek kondansatör ile voltaj kaynaklı değıştirici (inverter), akım kaynaklıya benzer şekilde kontrol edilir. Faz voltajları (v_a , v_b ve v_c) ve yük akımları (i_a , i_b ve i_c)'nın ölçülen değerlerinden kontrol devresinde hesaplanan referans akımları (i_{ca} , i_{cb} , i_{cc} ve i_{cd}) değıştirici tarafından kullanılarak kompanzasyon akımları oluşturulur[14].



Şekil 2.4. Paralel aktif filtrenin üç fazlı güç sistemine bağlanması

2.1.3. Aktif filtrenin seri bağlanması


Şekil 2.5'de tek başına kullanılan seri aktif filtrenin yapısı görülmektedir. Seri aktif filtre dc bağlantılı büyük kapasiteli kondansatör ile diyot doğrultucularının oluşturduğu harmonikleri yok edebilmek için dönüştürücüye seri olarak bağlanır[26].



Şekil 2.5. Aktif Filtrenin seri bağlanması

2.1.4. Aktif filtre ile pasif filtrenin birlikte bağlanması


Şekil 2.6’de görülen devrede (Hybrid bağlı) temel amaç, maliyeti azaltmak ve verimi arttırmaktır. Paralel aktif ve pasif filtre kombinasyonunda çelik milli sürücüler için büyük oranda cycloconverter’ler harmonikleri yok etmek için kullanılmaktadır[26].



Şekil 2.6. Seri aktif filtre ve paralel pasif filtre kombinasyonu

2.1.5. Paralel ve seri aktif filtrenin birlikte kullanılması

Şekil 2.7’de paralel ve seri bağlı aktif filtrelerin birlikte kullanılmaları görülmektedir[26-30]. DC bağlantılı depolama elemanı veya sürücü kondansatör iki akım kaynaklı veya voltaj kaynaklı aktif seri ve aktif paralel telafi ediciler için köprü işlemiyle ikisi arasında paylaşılır. Şekil 2.7’deki devre tek fazlı sistemlerde kullanılmasına ilaveten üç fazlı sistemler içinde kullanım şekli vardır[26-30]. Şekil 2.7’deki devrenin sakıncaları çok sayıda yarı iletken eleman içermesi yüzünden kontrolünün zor ve maliyetinin yüksek olmasıdır.




Şekil 2.7. Paralel ve seri bağlı aktif filtrelerin birlikte kullanılması

2.2. Aktif Filtrelerin Sınıflandırılması

Çeşitli tiplerdeki aktif filtreler bir çok teknik literatürde önerilmiştir[31]-[33]. Aktif filtrelerin sınıflandırılmaları, farklı görünüm noktasından kaynaklanmaktadır. Aktif filtreler kendi aralarında ac ve dc olarak ikiye ayrılırlar. Aktif dc filtreler HVDC [34],[35] sistemler için tristör converter’deki akım ve gerilim harmoniklerini kompanze etmek için tasarlanmıştır. Aktif filtre terimi çoğu zaman ac aktif filtre anlamındadır.

2.2.1. Voltaj beslemeli aktif filtrenin yapısı


Akım beslemeli ve voltaj beslemeli PWM deęiřtiriciler olmak üzere aktif filtrelerin içinde kullanılan iki tip deęiřtirici vardır. Voltaj beslemeli PWM’de büyük bir kondansatör, voltaj kaynaęı gibi deęiřtirici hareketleri DC yolla birleřtirilir. Bu tip aktif filtre güç kaynaklarında popöler olarak kullanılmaktadır. Düşük maliyetli çözümlerde ve performansı düzeltmede kullanılabilir. Şekil 2.8’de voltaj beslemeli aktif filtre görölmektedir[36].



Şekil 2.8. Voltaj beslemeli aktif filtre tipi

2.2.2. Akım beslemeli aktif filtrenin yapısı

Akım kaynaklı deęiřtiricide, enerji depolamak için bobin elamanı kullanılır. Bobinin hareketleri, sinüs olmayan kontrol edilebilir kaynak akımları için doğrusal olmayan yüklerin harmonik akımlarını yok eder. Kapısı yalıtılan bipolar transistörler, (IGBT’s) ve GTO tristörler bu aktif filtrenin içinde anahtarlama elamanları gibi kullanılır. Şekil 2.9’da akım beslemeli aktif filtre görölmektedir.



Şekil 2.9. Akım beslemeli aktif filtre tipi

2.3. “P-Q” Teorisi

“p-q” teorisi veya ani güç teorisi olarak bilinen üç fazlı devrelerde genelleştirilmiş ani reaktif güç teorisi 1983 yılında Akagi tarafından önerilmiştir. Nötr hatlı veya nötr hatsız üç fazlı güç sistemleri ile ani değer tabanlı ve yarı iletkenler için veya transistor işlemlerinde geçerli bunlara ilaveten voltaj ve Akım dalga formlarında “p-q”teorisi üretkendir.

“p-q” teorisi üç fazlı sistemlerde voltaj ve akımların a,b,c koordinatlarından $\alpha, \beta, 0$ koordinatlarına cebirsel dönüşümlerini içerir. Aşağıda ani güç bileşenlerinin “p-q”teori hesaplamalar gösterilmektedir.

$$\begin{bmatrix} V_0 \\ V_\alpha \\ V_\beta \end{bmatrix} = \frac{1}{\sqrt{3}} \begin{bmatrix} \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \\ 1 & -\frac{1}{2} & -\frac{1}{2} \\ 0 & \frac{\sqrt{3}}{2} & -\frac{\sqrt{3}}{2} \end{bmatrix} \begin{bmatrix} V_a \\ V_b \\ V_c \end{bmatrix}, \quad \begin{bmatrix} i_0 \\ i_\alpha \\ i_\beta \end{bmatrix} = \frac{1}{\sqrt{3}} \begin{bmatrix} \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \\ 1 & -\frac{1}{2} & -\frac{1}{2} \\ 0 & \frac{\sqrt{3}}{2} & -\frac{\sqrt{3}}{2} \end{bmatrix} \begin{bmatrix} i_a \\ i_b \\ i_c \end{bmatrix} \quad 2.1$$

$P_0 = V_0 \cdot i_0$ ani sıfır ardışık güç

$P = V_{\alpha}i_{\alpha} + V_{\beta}i_{\beta}$ ani gerçek güç

$q = V_{\alpha}i_{\beta} - V_{\beta}i_{\alpha}$ ani hayali güç

Güç parçaları p ve q aynı α β voltaj ve akımlarıyla ilişkilidir ve benzer yazılabilir.

$$\begin{bmatrix} p \\ q \end{bmatrix} = \begin{bmatrix} V_{\alpha} & V_{\beta} \\ -V_{\beta} & V_{\alpha} \end{bmatrix} \quad 2.2$$

Bu miktarlar a,b,c koordinatlarında gösterilen elektrik sistemler için şekil 2.4'de gösterilmektedir[14].

2.4. Pasif Filtreler

Geleneksel pasif filtreler harmonik bozulmalar için kullanılmışlardır. LC filtreler hat akım harmoniklerinin yok edilmesi ve sistemin güç faktörünün düzeltilmesinde kullanılmıştır. Bununla beraber pasif bileşenlerin hacimliliği, seri ve paralel rezonans ve kompanzasyon karakteristiğinin sabitliliği pasif filtrelerin temel sakıncalarıdır.

Pasif filtre teknolojisinin sınırlamalarını yok etmek amacıyla Aktif Filtre kullanımı araştırılmıştır. Pasif filtreler pratik uygulamalara sahiptir fakat bazı dezavantajlara sahiptir.


1. Frekans değişikliklerinde kompanzasyon yapamazlar
2. Pasif L C filtrelerin çalışması doğrusal olmayan yüklerin karakteristiklerine ve elektrik kaynaklarının ağ empedansına bağlıdır.
3. Harmonik akım bileşenleri yükseldiği zaman pasif filtre aşırı yüklenmiş olabilir.
4. Pasif filtrenin elamanlarının yeniden ayar problemleri vardır.
5. L C pasif filtrenin boyutları ve ağırlıkları büyüktür[37]


BÖLÜM 3. HARMONİKLER

3.1 Harmoniklerin Tanımı

Güç sistemlerinin başlangıcından beri doğrusal olmayan elemanlar ve doğrusal olmayan yükler var olmuştur. Örneğin; transformatörler nominal çalışma koşullarının dışına çıktığında doğrusal olmayan şebeke elemanı olarak davranırlar. Doğrusal olmamanın etkisi ve doğrusal olmayan eleman sayısı, harmonik üreten elemanların güç sistemine bağlanmasıyla hızlı bir şekilde artmıştır. Bu artışın temel sebebi yüksek güçlü yarı iletken anahtarların gelişimi ve onların doğrultucu, evirici ve çeşitli elektronik devrelerde uygulanmasıdır. (Örneğin; D.C. iletim konverter istasyonları, motor kontrol devreleri, statik VAR generatörleri, v.b.[38].

Yarı iletken elemanların tabiatı gereği ve sanayide kullanılan bazı doğrusal olmayan yüklerin (transformatör, ark fırınları, v.b.) etkisiyle; akım ve gerilim dalga biçimleri, periyodik olmakla birlikte, sinüsoidal dalga ile frekans ve genliği farklı diğer sinüsoidal dalgaların toplamından meydana gelmektedir. Temel dalga dışındaki sinüsoidal dalgalara “harmonik” adı verilir. Temel dalga ile 5. ve 7. harmonikler ve bunların bileşkesi olan bileşke dalga şekil 3.1. de verilmiştir.





Şekil 3.1. Temel dalga 5. ve 7. harmonikler ile bunların bileşkesi olan dalga

Doğrusal olmayan yükler enerji kalitesini düşürürler ve modern elektronik cihazların enerji sistemlerinde meydana gelen bozulmalara karşı hassasiyetini önemli ölçüde etkilerler. Doğrusal olmayan yükler enerji sistemlerinin içine harmonik enjekte ederler bunun sonucu olarak düşük kaliteli enerjiye ve düşük güç katsayısına sebep olurlar.

Akım ve gerilim harmonikleri, duyarlı cihazların çalışmalarını olumsuz yönde etkilerler. Harmonik bozulmalarına en çok duyarlı olan cihazlar, yarı iletken cihazlar, ölçüm cihazları, trafolar, endüksiyon makineleri (Asenkron makineler) ve bunların kontrol sistemleridir. Endüstriyel uygulamalar, büyük ölçüde elektronik olarak kontrol edilen örneğin zamanlayıcılar, tepe voltaj değerinin düşmesinden dolayı büyük kayıplar verebilirler, örneğin bilgi kayıpları ve fabrikaların uzun süre devre dışı kalması v.b.

Harmonikler, 50Hz'lik temel frekansın tam sayı katlarındaki ($50 \times 1,50 \times 2$, 50×3 , 50×4 , ...) frekansta olan gerilim ve akımlar olup doğrusal olmayan cihazlar tarafından üretilirler. Bir fazlı enerji sistemlerinde tek harmonikler 3, 5, 7 50 Hz temel harmonik için 150, 250 ve 350 Hz olurlar. 3. harmonik dominanttır(Genliği en

yüksek). Üç fazlı enerji sistemlerinde sadece üçün tam katsayısı olmayan tek harmonikler örnek olarak (5,7,11,13...) görülür. Üç fazlı bir güç sisteminde 50 Hz için tipik değerler 5. harmonik için 250Hz, 7. harmonik için 350Hz, 11. harmonik için 550Hz ve 13. harmonik için 650Hz'dir[39].

Uygulamada en çok 5., 7., 11. ve 13. harmoniklerle karşılaşılır. Ancak 11. ve 13. harmoniklerin genlikleri ana bileşene göre çok küçük olduğundan özel haller dışında önemsenmezler. Daha çok 5. ve 7. harmoniklere ilişkin önlemler alınmaya çalışılır. Elektrikli aygıtlara en büyük zararı 5 kHz' den küçük olan harmoniklerin verdiği kabul edilmektedir.

Sinüsoidal alternatif akım uygulanan bir alıcının şebekeden harmonikli akım çekmesi, alıcının yapısı gereğidir. Yani; alıcı nominal çalışması sırasında harmonik meydana getirecek akım çekiyor demektir. Harmonik üreten bu alıcılardan başka, karakteristikleri itibariyle lineer oldukları halde harmonikli akımlara sebebiyet veren alıcılarda vardır. Bu durum ise alıcıya uygulanan gerilimin nonsinüsoidal olmasından kaynaklanmaktadır. Alternatif akımın üretilmesi sırasında alternatörlerde yapılan gerekli iyileştirici önlemler yardımıyla elektrik enerjisi mümkün olduğunca sinüsoidal' e yaklaştırılmaktadır. Fakat lineer bir alıcıya aynı şebekeye bağlı diğer doğrusal olmayan yükler tarafından etki edilmektedir.

3.2. Harmonik Kirlenmesi

Elektrik şebekelerinde elektrik kalitesini etkileyen ve sinüsoidal olması gereken 50 Hz'lik gerilimin, değişik etkenlerle bozularak kullanım cihazlarında birtakım arızalara yol açmasına harmonik kirlenme denir. Harmonikli Akım/Gerilim, 50 Hz'in genellikle tek katlarında (50×3 , 50×5 , 50×7 ... gibi) oluşur ve temel frekansla birlikte etkisini sürdürür. Harmonikler etkenlerin büyüklüğü oranında ve şebekede kullanılan diğer cihazların özelliklerine göre bu cihazlarda arızalar meydana getirir. Harmonik bozulma, başka bir deyişle şebekenin kirlenme oranı toplam harmonik değeri (THD) olarak isimlendirilir. Bu değer, temel frekansın akım veya gerilimin yüzdesi olarak ifade edilmektedir[40].

doğrusal olmayan yükler (doğrultucular, akım kırıyıcıları, eviriciler, güç regülatörleri, UPS'ler, ark fırınları, manyetik devrelerin doyması, demir çekirdekli aygıtların doyma bölgesinde çalışmaları, DC Motorlar, frekans çeviriciler,...) şebekeden sinüs formunda olmayan akım çekerler. Bu akımlar, 50 Hz temel bileşen ve harmonik akımları şeklinde tanımladığımız temel bileşenin üzerine binen ve temel frekansın tam katlarında olan seri bileşenlerden oluşur. Harmonik akımlarının varlığı, şebeke empedansında yaratacağı gerilim düşümleri sebebi ile şebeke geriliminde de bozulmalara neden olur.

3.3. İzin Verilen Toplam Harmonik Değeri(THD)

TEDAŞ'ın yayınlamış olduğu ve müşterilerin uymak zorunda olduğu ilgili yönetmeliğe göre gerilimde harmonik bozulmanın sınırı alçak gerilimde %7 , orta gerilimde ise %5 ' tir. Akım harmonik sınırları belirli yük akımlarına göre verilmekle birlikte pratikte %5 ile %12 arasında değişmektedir. Dikkat edilmesi gereken husus, bu değerlerin sınır değerler olduğu, sanayi tesislerinin kendi özel durumları için bu sınırların oldukça altında çalışmaları gerekebileceğidir[41].

Uluslararası standartlara göre IEC (Interantional Electric Cooperation) toplam harmonik değeri(THD), akım bazlı olarak % 6'dır. IEEE 519 harmonik standardının müsaade ettiği düşük şebeke voltajında toplam harmonik değeri (THD) %5'dir [42].

THD 3.1'deki formülle hesaplanır. Güç sistemlerdeki akımların ve voltajların kalitesini belirlemede kullanılan ortak gösterge toplam harmonik değeri (THD) aşağıda tanımlanmıştır.

$$THD = \sqrt{\frac{\sum_{h=2}^{\infty} I_h^2}{I_1^2}} \quad 3.1$$

Burada I_h akım harmoniklerini ve I_1 yük akımındaki temel bileşeni göstermektedir.

3.4. Harmonik Kaynakları

Doğrusal olmayan yükler, elektrik sistemlerinde ana harmonik kaynaklarıdır. Bu yükler akımı kesintili olarak çeken veya empedansı besleme voltajının frekansının bir çevrimi(cycle) boyunca değişen yüklerdir. Diyot doğrultucular ve elektronik güç converter'leri çok bilinen örneklerdir. Fax makinaları, ASD, bilgisayar gibi bu yükler günümüzde çok geniş olarak kullanılmaktadır. Aşağıda bazı harmonik kaynakları verilmiştir[38] .

1. Transformatörler
2. Asansörler
3. Güç elektroniği devre elemanları
4. Doğru akım ile enerji nakli (HVDC)
5. Statik VAR generatörleri
6. Elektrik ark fırınları
7. Kesintisiz güç kaynakları
8. Gaz deşarjlı aydınlatma
9. Elektronik balastlar
10. Fotovoltaik sistemler
11. Bilgisayarlardaki güç kaynakları
12. Flüoresan lambası
13. Klimalar ve kompresörler
14. Fotokopi makineleri, yazıcılar

3.5. Harmoniklerin Zararları

3.5.1. Kondansatörlerde delinme ve ömürlerinin kısılması

Bir kondansatörün kapasitif reaktansı olan $1/\omega c$, yüksek frekanslı harmoniklerde küçülür. Akımın tepe değeri n . harmonik için $I_{nm} = V_{nm} \times n\omega c$ olacağından, kondansatörler tesiste yüksek frekanslı harmonikler bulunması durumunda üzerlerinden aşırı akım akıtacakları için yüksek risk altına girerler. Bir kondansatörün uçlarındaki gerilim $v = V_{1m}\sin\omega t + V_{2m}\sin 2\omega t + \dots$ şeklinde iken, akımı

da $i = V_{1m} \omega c \sin(\omega t + 90) + V_{2m} 2 \omega c \sin(2\omega t + 90) + \dots$ şeklinde ifade edilir. Bu ifadeler de, kondansatörlerin akımının harmonik yüzde etkisinin, gerilimine göre daha yüksek olduğunu gösterir. İlgili standartlarda kondansatörler, nominal çalışma akımının 1,3 katında sürekli çalışabilecek şekilde imal edilirler. Harmonik akımlar sebebi ile çalışma akımı bu sınırların üzerine çıkar ise, kondansatörlerin ömürleri kısalar veya delinmeler meydana gelir.

3.5.2. Enerji kayıpları ve yüksek faturalar

Harmonikler işletmelerde gereksiz enerji tüketimine sebep olmaktadır. Harmonim akımlarının ortadan kaldırılmasıyla işletmelerde 1%-10% arasında enerji tasarrufu sağlanmaktadır.

3.5.3. Rezonans Etkisi

Harmonik içeren bir gerilim, eğer endüktif ve kapasitif yükün birlikte bulunduğu bir devreye uygulanmış ise harmonik frekanslarından birinde rezonans meydana gelebilir. Devrenin yapısına bağlı olarak seri rezonans oluşur ise, toplam empedans minimum değerini alır ve sistem kısa devre etkisi göstererek yüksek akım çeker; paralel rezonans oluşur ise toplam empedans maksimuma ulaşır ve sistemin çektiği akım düşer.

3.6.3. Isınma

Sistemdeki bakır kayıpları 50 Hz faydalı frekansta genel olarak $P_{cu} = I^2 \times R$ 'dir.

Sistemde harmonik akımları oluşması durumunda eğer çift sayıdaki harmonikler ihmal edilirse,

$$P_{cu}(\text{tot}) = I^2 \times R + I_3^2 \times R + I_5^2 \times R + I_7^2 \times R + \dots + I_n^2 \times R$$

Her bir harmonik genliklerine göre bakır kayıplarını artırır. Harmoniklerin görüldüğü hatlarda bakır kayıpları oluşur, ancak en büyük kayıplar;

- Motorlar

- Kapasitörler
- Transformatörler'de oluşur.

Bu kayıplar, ciddi maddi yük getirmekle birlikte özellikle yukarıdaki üç elektrik makinasında soğutma problemleri, bakır ve elektrot yorulması ve karbonlaşması gibi sebeplerden dolayı hem işletme maliyetlerini hem de yatırım maliyetlerini artırır.

3.5.5. Frekans Etkisi

Harmonik akımları, (2-15) x 50 Hz salınımlı şebeke gerilimlerine neden olabilir. Bu salınımların meydana geldiği yere yakın olan cihazlar, 50 Hz frekansta çalışmak üzere üretildikleri için zarar görebilirler. Aydınlatma aygıtlarının, elektronik kartların, PC'lerin arızalanması, program hafızalarının silinmesi gibi olaylar yaşanabilir.

BÖLÜM 4. HARMONİK KOMPANZASYONUNDA KULLANILAN İLERİ BESLEMELİ ve ELMAN GERİ BESLEMELİ YAPAY SİNİR AĞLARININ YAPILARI ve ÖRNEKLEME TEOREMİ

Modern elektronik teknolojisinin gelişmesiyle elektronik devrelerde kullanılan yarı iletken uygulamaları hızlı bir şekilde artmaktadır. Son yıllarda yarı iletkenlerin endüstride geniş bir şekilde kullanılmasıyla güç hattında oluşan harmonikler, ciddi problemler oluşturmaktadır. Güç hattındaki akım harmoniklerinin etkileri bozulmuş dalga oluşturmakta, oluşturulan bozulmuş dalgada devrelerin tamamına zarar vermektedir. Elektrik güç sistemlerinin kararlılığını muhafaza edebilmesi, doğrusal olmayan yüklerin oluşturduğu harmoniklerin bazı yöntemler kullanılarak yok edilmesi gerekmektedir.



4.1. Harmonik Kompanzasyon Yöntemleri


Harmonikleri yok etmede en etkili yöntem aktif filtre kullanarak harmonik kompanzasyonudur(Şekil 4.1.a). Bununla beraber aktif filtrenin kontrolünün zorluğu, maliyetinin yüksekliği gibi bazı sakıncaları vardır. Bir diğer yöntem ise fourier dönüşüm ve alçak geçiren filtre kullanarak harmonik analizidir(Şekil 4.1.b).

Bu çalışmada yapay sinir ağları tabanlı metotlar önerilmiştir. Bilginin akış yönüne göre yapısal olarak ileri beslemeli (Feedforward Neural Network) ve geri beslemeli olmak üzere iki temel tip yapay sinir ağı vardır. İleri beslemeli sinir ağının içindeki sinirler arasındaki bağlantılardaki bilgiler sadece giriş sinirlerden çıkış sinirlere doğru tek yönlü akmaktadır. Geri beslemeli sinir ağında (Recurrent neural network) bağlantılar, ileri beslemeli ve geri beslemeli olmak üzere bilginin iki yönde yayılmasına izin verir[43].

Burada iki gizli katmanlı ileri beslemeli ve Elman geri beslemeli yapay sinir ağıları kullanılarak orijinal metotlar gibi harmonik bileşenlerden her birinin kompanse edilmesi amaçlanmaktadır. İleri beslemeli ve Elman geri beslemeli ağların kullanılmasıyla harmonik bileşenleri fourier dönüştürsüz kompanse edilmiştir.

Aşağıda harmonik dedeksiyonunda kullanılan orijinal metot ve bu çalışmada kullanılan yapay sinir ağı metotlarının yapıları blok şema olarak verilmiştir.





c)

Şekil 4.1. Harmonik atma yöntemleri: a) Aktif filtre yöntemi, b) Fourier analiz yöntemi, c) Yapay sinir ağı yöntemi


Harmonik dedeksiyonu için karmaşık işlemleri göz önünde bulundurmak gerekir. İşlemler için çok fazla zamana ihtiyaç vardır, bu zaman aktif filtre davranışlarını etkiler. Harmonik kompanzasyonunda işlem zamanını kısaltmak ve işlemleri basitleştirmek için yapay sinir ağı kullanılmıştır.

4.2. Örnekleme Teoremi

Genellikle aksi belirtilmedikçe , bir sinyal eşit aralıklara bölünmüş diziler halinde tanımlanabilir. Örneğin aşağıdaki şekilde üç farklı sürekli-zaman sinyali görülmektedir. Tüm bu sinyaller T'nin tamsayı katları şeklinde aşağıdaki değerlere sahiptir.

$$x_1(kT)=x_2(kT)=x_3(kT)$$


4.1



Şekil 4.2. T 'nin tam sayı katlarının belirli değerleri ile üç sürekli zaman sinyalleri

Genellikle verilen örnekleri üreten sonsuz sayıda sinyaller vardır. Eğer sinyal bant genişliği sınırlı ve örnekler birbirine yeterince yakın seçilmişse, sinyalde var olan yüksek frekans ile ilişkili olarak, örneklemeler sinyali tam olarak tanımlar, buradan da biz sinyali yeniden ve hatasız olarak oluşturabiliriz. Özellikle, eğer bant sınırlı sinyal $x(t)$, periyodik darbe dizisi ile genlik modülasyonuna tabi ise (eşit aralıklı zaman parçaları ile alakalı olarak), ve eğer modüle edilmiş darbe dizisinin temel frekansı en az $x(t)$ içindeki en yüksek frekanslı sinüsoidal bileşenin iki katı ise, sinyal alçak geçiren filtre ile bilgi kaybı olmadan elde edilebilir. Ayrıca, $x(t)$ 'yi yeniden oluşturabilmek her bir darbenin zaman aralığından bağımsızdır. Bu yüzden şekil 4.3 ve 4.4'de görüldüğü gibi (bu aralıklar keyfi olarak küçük olacak) darbenin genlik modülasyonu zamanda eşit olarak bölünmüş anlık örneklemeler ile $x(t)$ 'yi temsil edecektir.

Şekil 4.4'de görülen darbe genlik modülasyonu sisteminde, darbe dizisi genliği, darbe genişliği Δ 'ya ters orantılı olarak ölçeklendirilmiştir. Herhangi bir darbe genlik modülasyonu sisteminde, modüleli sinyalin ortalama-zaman gücünün sabit tutulması özellikle önem taşımaktadır. Şekil 4.4'de görüldüğü gibi, Δ sıfıra yaklaşırken, modüleli sinyal örneklemeye dizisi halini alır. Bu dizide her özel darbenin değeri, $x(t)$ 'yi özel T aralıkları ile örneklemiş anlık darbe değerleri ile irtibatlıdır.



Şekil 4.3. Darbe genlik modülasyonu

4.3. Örnekleme dizisi

Şekil 4.3’de gösterilen darbe dizisi, darbe genlik modülasyonunun daha genel durumunun analizinde kullanılan dizi ile aynı biçimdir. Söz konusu bu darbe dizisi örnekleme fonksiyonu olarak isimlendirilir. Burada T örnekleme periyodu ve $p(t)$ nin temel frekansı olan $\omega_s = 2\pi/T$ ise örnekleme frekansı olarak isimlendirilir. Örnekleme zaman boyutunda;

$$x_p(t) = x(t)p(t) \quad 4.2$$

ifadesi yazılabilir.

Burada


$$p(t) = \sum_{n=-\infty}^{+\infty} \delta(t - nT) \quad 4.3$$

$$x_p(t) = \sum_{n=-\infty}^{+\infty} x(nT)\delta(t - nT) \quad 4.4$$

$$X_{p(\omega)} = \frac{1}{2\pi} [X(\omega) * P(\omega)] \quad 4.5$$


$$P(\omega) = \frac{2\pi}{T} \sum_{k=-\infty}^{+\infty} \delta(\omega - k\omega_s) \quad 4.6$$

$$X_p(\omega) = \frac{1}{T} \sum_{k=-\infty}^{+\infty} X(\omega - k\omega_s) \quad 4.7$$




Şekil 4.4 İdeal darbe dizisi ile genlik modülasyon işareti

$X_p(\omega)$, şekil 4.5'de gösterilen $1/T$ genlikli $X(\omega)$ 'nin kendisi ve kaydırılmış biçimlerinin toplamından oluşan periyodik bir fonksiyondur. Şekil 4.5.(c)'de $\omega_M < (\omega_s - \omega_M)$ veya $\omega_s > 2\omega_M$ eşitsizlikleri sağlandığından $X(\omega)$ 'nin kendisi ile kaydırılmış biçimleri aralarında çakışma yoktur. Tam tersine şekil 4.5(d) ile $\omega_s < 2\omega_M$ arasında çakışma vardır. Şekil 4.5.(c)'de görülen durum için, $X(\omega)$ örnekleme frekansının tam sayı katlarında yeniden üretilmelidir. Sonuç olarak eğer $\omega_s > 2\omega_M$ ise şekil 4.6'da görülen $(\omega_s - \omega_M)$ 'den küçük ve ω_M 'den daha büyük kesim frekansında ve T kazancına sahip alçak geçiren bir filtre vasıtasıyla $x(t)$, $x_p(t)$ 'den tam olarak yeniden elde edilebilir. Bu temel sonuç örnekleme teoremi olarak bilinir[44].



Şekil 4.5. Zaman boyutundaki örneklemenin frekans boyutuna etkisi: (a) orijinal sinyal spektrumu; (b) örnekleme fonksiyon spektrumu; (c) $\omega_s > 2\omega_M$ ile örnekleme sinyal spektrumu; (d) $\omega_s < 2\omega_M$ ile örnekleme sinyal spektrumu



Şekil 4.6. İdeal alçak geçiren filtre kullanarak örneklemelerden sürekli zaman sinyallerinin yeniden elde edilmesi

4.4. Yapay Sinir Ağları İçin Verilerin Hazırlanması

Bu çalışmada 3 ve 3'ün katları biçimindeki harmonikler ihmal edilerek 5., 7., 11., 13.,...,25. harmonikler incelenmiştir. Bu harmonikler aşağıdaki formülle ifade edilebilir.

$$n = 6r \pm 1 \quad 4.8$$



Burada n: harmonik akımının derecesi, $r=1,2,3,\dots,R$.





$$x(t) = \sum_{i=5,7,11,13}^N \cos(i * \omega t - \psi) \quad 4.9$$

$i = 5, 7, 11, 13, \dots, N$

4.1 ve 4.2 'deki formüller kullanılarak içerisinde farklı değerlerde 5., 7., 11. ve 13. harmoniklerin bulunduğu 2520 tane bozulmuş dalga oluşturulmuş ve oluşturulan her bozulmuş dalgadan 128 örnekleme sinyali alınmıştır. Her bozulmuş dalgadan alınan 128 örnekleme sinyali, yapay sinir ağının giriş sinyalleri olarak kullanılmıştır. Ağın çıkış katmanı 5., 7., 11. ve 13. harmonikler olmak üzere 4 nöron içermektedir.

Bu çalışmada yapay sinir ağının öğrenme kabiliyeti ve yüksek hızda çalışmasından yararlanılmıştır. Yapay sinir ağının öğrenme ve yüksek hızda tanınması özelliğinden dolayı sinir ağı distorsiyonlu dalgadaki harmonik bileşenlerini tanıması mümkündür. Aşağıda oluşturulan 2520 harmonikli dalgadan bir kaçı görülmektedir.






Şekil 4.7. Harmonik analizi için oluşturulan 2520 harmonikli dalgalardan örnek sinyaller

4.5. İleri Beslemeli Yapay Sinir Ağı

İleri beslemeli yapay sinir ağı ilk defa 1986 yılında Rummelhart, Hilton ve Willims tarafından önerilen geriye yayılım eğitme algoritmasıyla eğitilmektedir. Ağın içine dağıtılan ağırlıklar ağın hafıza özelliğiyle birleştirilir. Başlangıçta ağ eğitilmemiştir, ağırlıklar rasgele seçilir, çıkış sinyal örneği verilen giriş örnek için arzu edilen çıkış örneği eşit dengede değildir. Gerçek çıkış örneği arzu edilen çıkış örneği ile karşılaştırılır ve ağırlıklar dengede oluncaya kadar (Örnek hataları kabul edilebilir küçüklükte olana kadar) geriye yayılım eğitim algoritması denetleyicisi tarafından ayarlanır.

Düşük derecedeki 5., 7., 11. ve 13. harmonikler her şeyden önce sinüs olmayan yük akımları içermeleri yüzünden, sistemin güç kalitesini düzeltmek için 5., 7., 11. ve 13. harmonikleri incelenmiştir. İlk adım olarak şekil 4.3’de görülen ileri beslemeli yapay sinir ağı kullanılmıştır. Bu ağın yapısı, giriş, gizli ve çıkış olmak üzere çok katmanlıdır. Gizli katman nöronları ve çıkış katman nöronları doğrusal olmayan sigmoid aktivasyon fonksiyonlarıdır. Buna alternatif ağ ise çıkış katman nöronlarında karşılaştırma için lineer aktivasyon fonksiyonu kullanılmıştır.



Şekil 4.8. Harmonik dedeksiyonu için kullanılan ileri beslemeli sinir ağının yapısı

İleri beslemeli sinir ağları modellerinde kullanılan eşitlikler aşağıda verilmiştir.

Gizli katman nöron çıkışları

$$X_j(n) = 1 / \left(1 + \exp \left(b_j^h(n) + \sum_{i=1}^N W_{ji}^h(n) U_i(n) \right) \right) \quad 4.10$$

Sigmoid aktivasyon fonksiyonunun çıkışları

$$Y_i(n) = 1 / \left(1 + \exp \left(b_i^o(n) + \sum_{j=1}^{N1} W_{ji}^o(n) X_j(n) \right) \right) \quad 4.11$$

Lineer aktivasyon çıkışları içinde aşağıdaki formül yazılabilir.

$$Y_i(n) = b_i^o(n) + \sum_{j=1}^{N1} W_{ji}^o(n) X_j(n) \quad 4.12$$

$N=128$, $N_1=90,60,30,20,15,10,5$ ve $N_2=4$ 'dür.

4.3.1. Ağın öğrenmesi

Geriye yayılım (GY) metot, yapay sinir ağlarının öğretilmesinde geniş bir şekilde kullanılmaktadır. Geriye yayılım metodunun temel avantajı, öğrenme performansının tanımlanan gizli katman tarafından geliştirilmesidir[45].

Öğrenme zamanı adaptiv öğrenme kullanılmasıyla kısaltılabilir[46]. Burada bizim kullandığımız hızlı geriye yayılım (Fast backpropagation) ve standart geriye yayılım algoritması karşılaştırma için kullanılmaktadır.


Yapay sinir ağlarının bozulmuş dalgadan harmonikleri ayırabilmesi için öğrenmede örnek bozulmuş dalgaların kullanılması gerekmektedir. Bu bozulmuş dalgalar temel dalga içine 5., 7., 11. ve 13. harmonik bileşenlerinin karıştırılmasıyla oluşturulur. Bu amaçla 2520 adet distorsiyonlu dalga oluşturulmuştur.

Bu çalışmada distorsiyonlu dalga içindeki 5., 7., 11. ve 13. harmonikler öğrenme seti için yapay sinir ağının giriş sinyali olarak kullanılmıştır. Ağın çıkış katmanı her bir harmonik düzenine göre 4 nöron içermektedir. Harmonik bileşenlerden her biri data örneğinin öğrenilmesinin etkisiyle çıkış nöronla ilişkilendirilerek ayrıştırılır. Yapay sinir ağı kullanılmasıyla harmonik dedeksiyonu için kullanılan zaman kısaltılmış ve aynı zamanda işlemler basitleştirilmiştir.

5.3.2. Simülasyon için yapay sinir ağının kurulması

Sinüs olmayan yük akımları, yüksek düzeydeki örneğin 17.,19., 23., 25 gibi harmonikleri içerirler, fakat bunlar önemli akım taşımazlar. Bu yüzden sinir ağı yapılarının performans geliştirmeleri 5. harmonik %70'e kadar, 7. harmonik %40'a kadar, 11. harmonik %10'a kadar, 13. harmonik %5'e kadar, 17.harmonik %5, 19. harmonik %2.5'e kadar, 23.harmonik %2'ye kadar ve 25. harmonik %2 kullanılarak yaklaşık olarak 250 distorsiyonlu dalgalardan test seti oluşturulmuştur. Eğitim ve test işlemleri için sinir ağlarının giriş sinyalleri distorsiyonlu dalganın bir periyodunun

genliğidir. Genlikler zaman ekseninden düzenli aralıklarla 128 nokta alınmıştır. Genlikler hiçbir ön işlem olmaksızın sinir ağlarının giriş sinyali olarak kullanılmıştır. Eğitim safhasında yüksek harmonikler örneğin 17. 19. 23. ve 25. harmonikler, THD hesaplanmasında gözardı edilmiştir.



Şekil 4.9. Simülasyon için kurulan ağı yapısı

Tablo 4.1. Maksimum harmonik değerleri[47]

Harmonikler	Maksimum harmonik değerleri
5. Harmonik	70 %
7. Harmonik	40 %
11. Harmonik	10 %
13. Harmonik	5 %
17. Harmonik	5 %
19. Harmonik	2.5 %
23. Harmonik	2 %
25. Harmonik	2 %


İleri beslemeli ve Elman geri beslemeli sinir ağları ile giriş, gizli ve çıkış katmanları olmak üzere üç katmanlı bir ağ oluşturulmuştur. Hem ileri beslemeli hemde Elman geri beslemeli ağda standart geriye yayılım ve hızlı (fast) geriye yayılım öğrenme

algoritması karşılaştırma yapmak için kullanılmıştır. Oluşturulan ağlarda 128 giriş katmanı, 4 çıkış katmanı ve optimum gizli katman nöron sayısını bulabilmek için, gizli katman nöron sayısı 90,60,30,20,10, ve 5 kullanılmıştır.

Bu çalışmada 5., 7., 11. ve 13. harmonikler incelenmiş, 13'den büyük harmoniklerin genlikleri çok küçük ve taşıdıkları akımlar önemsiz oldukları için öğrenme işleminin dışında tutulmuştur. Öğrenme için kullanılan harmonik bileşenlerinin maksimum değerleri tablo 4.1'de verilmiştir.

4.6. İki Gizli Katmanlı İleri Beslemeli Yapay Sinir Ağı

İleri beslemeli iki gizli katmanlı sinir ağının nicelik olarak tanıma için kullanılan yapısı aşağıdaki şekil 4.5'de görülmektedir. Bu ağ çok katmanlı bir ağıdır(giriş katmanı, gizli katman ve çıkış katman). Gizli katman nöronları ve çıkış katman nöronlarında doğrusal olmayan sigmoid aktivasyon fonksiyonları kullanılmıştır. Sinir ağı modelinde kullanılan eşitlikler aşağıda (4.4), (4.5) ve (4.6)'da gösterilmiştir.



Şekil 4.10. Harmonik kompanzasyonu için iki gizli katmanlı ileri beslemeli yapay sinir ağının yapısı

Çıkıştaki ilk gizli katman nöronları

$$X_j(n) = 1 / \left(1 + \exp \left(b_j^{th}(n) + \sum_{i=1}^N W_{ij}^{th}(n) U_i(n) \right) \right) \quad 4.13$$

İkinci gizli katman nöronların çıkışları

$$V_j(n) = 1 / \left(1 + \exp \left(b_j^{hh}(n) + \sum_{i=1}^{N1} W_{ij}^{hh}(n) X_i(n) \right) \right) \quad 4.14$$

Ağın çıkışları

$$Y_i(n) = 1 / \left(1 + \exp \left(b_i^o(n) + \sum_{j=1}^{N2} W_{ji}^{ho}(n) V_j(n) \right) \right) \quad 4.15$$

Burada $N=128$, $N_1=90$, $N_2=90$ ve $N_3=4$ olarak alınmıştır.


4.7. Geri beslemeli Yapay Sinir Ağı

Son yıllarda, içerisinde kontrol uygulamaları, konuşma tanıma ve görsel örnek tanımanın da bulunduğu zor, gerçek dünya problemlerinin çözümünde yapay sinir ağı algoritmaların geniş bir şekilde kullanılması dikkat çekmektedir[48].

Bir çok pratik uygulamalarda çok katmanlı ağ mimarisi düşünüldüğü zaman sadece ileri beslemeli yapay sinir ağları akla gelmektedir. Gerçekte ileri beslemeli YSA dışında bir çok alternatif tipler vardır, örneğin self organizing map ve geri beslemeli sinir ağları(RNN) gibi. Geri beslemeli sinir ağlarındaki bağlantılarının tamamı ileri beslemeli çok katmanlı ağlara benzer. Geri beslemeli sinir ağlarındaki farklılık, o anki zaman adımı esnasında değil aynı zamanda önceki zaman adımlarının bazı sayıları esnasında başlangıçta gizli katmandan veya çıkış katmanlarından bir veya daha fazla geri besleme döngüye sahip olmasıdır[49-50].

4.7.1. Harmonik kompanzasyonu için Elman geri beslemeli yapay sinir ağı

Harmonik dedeksiyonu için kullanılan Elman geri beslemeli ağın yapısı şekil 5.6'da görülmektedir. Bu ağ, giriş katman, geri beslemeli gizli katman ve çıkış katmanlara sahip çok katmanlı bir ağıdır[51-52]. Gizli katman düğümlerinde dogrusal olmayan aktivasyon fonksiyonu sigmoid (sigmoid function), çıkış katman düğümlerinde ise lineer aktivasyon fonksiyonu kullanılmaktadır. Çıkış katman düğümlerinde kullanılan lineer ve sigmoid aktivasyon fonksiyonları, karşılaştırma yapmak için alternatif bağlantılardır.



Şekil 4.11. Harmonik tanımda kullanılan Elman geri beslemeli(recurrent) ağı yapısı[51]

Gizli katman nöron çıkışlarında

$$X_j(n) = 1 / \left(1 + \exp \left(b_j^h(n) + \sum_{i=1}^N W_{ij}^{ih}(n) U_i(n) + \sum_{i=N+1}^{N+N1} W_{ij}^{ih}(n) X_i(n-1) \right) \right) \quad 4.16$$

Sigmoid aktivasyon fonksiyonunun çıkışları için

$$Y_i(n) = 1 / \left(1 + \exp \left(b_i^o(n) + \sum_{j=1}^{N1} W_{ji}^{ho}(n) X_j(n) \right) \right) \quad 4.17$$

Lineer aktivasyon fonksiyonunun çıkışları için


$$Y_i(n) = b_i^o(n) + \sum_{j=1}^{N1} W_{ji}^{ho}(n) X_j(n) \quad 4.18$$

N=128, N1=90, 20 ve N2=4'dür.

4.8. İki Katmanlı Elman Geri Beslemeli Yapay Sinir Ağı

Geri beslemeli Elman sinir ağının yapısı aşağıdaki şekilde görüldüğü gibi nicelik tanıma için önerilmiştir. Bu ağ çok katmanlı bir ağıdır(giriş katman, geri beslemeli

gizli katman ve çıkış katman). Gizli katman nöronlarında ve çıkış katman nöronlarında nonlinear sigmoid aktivasyon fonksiyonları kullanılmaktadır. Bu sinir ağı modelinde kullanılan eşitlikler aşağıda gösterilmiştir.



Şekil 4.12. Harmonim kompanzasyonu için Elman geri beslemeli(recurrent) ağı yapısı

Bu çalışmada $N = 128$, $N1 = 90 - 20$, $N2 = 90 - 20$, ve $N3 = 4$ alınmıştır

Birinci gizli katman nöron çıkışları,

$$X_j(n) = 1 / \left(1 + \exp \left(b_j^h(n) + \sum_{i=1}^N W_{ij}^{ih}(n) U_i(n) + \sum_{i=N+1}^{N+N1} W_{ij}^{ih}(n) X_i(n-1) \right) \right) \quad 4.19$$

İkinci gizli katman nöron çıkışları,

$$V_j(n) = 1 / \left(1 + \exp \left(b_j^{hh}(n) + \sum_{i=1}^{N1} W_{ij}^{hh}(n) X_i(n) \right) \right) \quad 4.20$$

Ağın çıkışları,

$$Y_i(n) = 1 / \left(1 + \exp \left(b_i^o(n) + \sum_{j=1}^{N2} W_{ji}^{ho}(n) V_j(n) \right) \right) \quad 4.21$$

BÖLÜM 5. İLERİ BESLEMELİ ve ELMAN GERİ BESLEMELİ SİNİR AĞLARININ SİMÜLASYON SONUÇLARI

5.1. İleri Beslemeli Yapay Sinir Ağında Simülasyon Sonuçları

İleri beslemeli yapay sinir ağı kullanılarak, oluşturulan örnek data ile harmonik analizi yapılmıştır. Kullanılan ağların gizli katman sayıları, öğrenme algoritmaları ve aktivasyon fonksiyonları değiştirilerek karşılaştırma yapılmıştır. Öğrenme için 50000 iterasyon yapılmış, her 1000, 5000, 10000, 30000 ve 50000 iterasyonlarda değerler alınmıştır.

5.2. Gizli Katman Nöron Sayılarına Göre Simülasyon Sonuçları


Yapılan çalışmada gizli katman nöron sayıları değiştirilerek sistemin optimum gizli katman nöron sayısı belirlenmiştir. Gizli katman nöron sayıları sırayla 90, 60, 30, 20, 10 ve 5 atanmış, ileri beslemeli ağın çıkışında kullanılan aktivasyon fonksiyonları sigmoid ve lineer olarak değiştirilmiştir. Öğrenme algoritması olarak standart geriye yayılım(backpropagation) ve hızlı(Fast) geriye yayılım kullanılarak simülasyon yapılmıştır. Bu bölümde 5., 7., 11. ve 13. harmoniklerin eğitim setinde eğitimi yapılmıştır. 17., 19., 23. ve 25. harmoniklerin genliklerinin küçük ve taşıdıkları akımların önemsiz olmasından dolayı eğitimi yapılmamıştır. Atanan her gizli katman değerine göre simülasyon sonuçları bu bölümde sunulmuştur.

5.2.1. Gizli katman nöron sayısı 90 alındığında simülasyon sonuçları

Başlangıçta ortalama harmonik değeri 46.08 %'dir. Aşağıda iterasyona göre, simülasyonda elde edilen toplam harmonik değerlerinin değişimi görülmektedir.

Tablo 5.1. Gizli katman nöron sayısı 90 olan ileri beslemeli YSA'da öğrenme algoritması hızlı GYA, aktivasyon fonksiyonu lineer kullanıldığı zaman harmoniklerin değişimi


İterasyon sayısı	İterasyon sayısına göre harmonik değişimi (%)
0	46.08
1000	13.65
5000	7.63
10000	5.9
30000	3.74
50000	2.67



Şekil 5.1. Gizli katman nöron sayısı 90 olan ileri beslemeli YSA'da öğrenme algoritması hızlı GYA, aktivasyon fonksiyonu lineer kullanıldığı zaman harmoniklerin değişim grafiği

Tablo 5.2. Gizli katman nöron sayısı 90 olan ileri beslemeli YSA'da öğrenme algoritması hızlı GYA, aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişimi


İterasyon sayısı	İterasyon sayısına göre harmonik değişimi(%)
0	46.08
1000	2.84
5000	1.58
10000	1.2
30000	0.68
50000	0.52



Şekil 5.2. Gizli katman nöron sayısı 90 olan ileri beslemeli YSA'da öğrenme algoritması hızlı GYA, aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişim grafiği

Tablo 5.3. Gizli katman nöron sayısı 90 olan ileri beslemeli YSA'da öğrenme algoritması standart GY ve aktivasyon fonksiyonu lineer kullanıldığı zaman harmoniklerin değişimi


İterasyon sayısı	İterasyon sayısına göre harmonik değişimi(%)
0	46.08
1000	18.39
5000	8.37
10000	6.24
30000	4.05
50000	3.21



Şekil 5.3. Gizli katman nöron sayısı 90 olan ileri beslemeli YSA'da öğrenme algoritması standart GY ve aktivasyon fonksiyonu lineer kullanıldığı zaman harmoniklerin değişim grafiği

Tablo 5.4. Gizli katman nöron sayısı 90 olan ileri beslemeli YSA'da öğrenme algoritması standart GY ve aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişimi

İterasyon sayısı	İterasyon sayısına göre harmonik değişimi(%)
0	46.08
1000	11.41
5000	5.28
10000	3.97
30000	2.45
50000	1.96




Şekil 5.4. Gizli katman nöron sayısı 90 olan ileri beslemeli YSA'da öğrenme algoritması standart GY ve aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişim grafiği

5.2.2. Gizli katman nöron sayısı 60 alındığında simülasyon sonuçları

Tablo 5.5. Gizli katman nöron sayısı 60 olan ileri beslemeli YSA'da öğrenme algoritması hızlı GY, aktivasyon fonksiyonu lineer kullanıldığı zaman harmoniklerin değişimi


İterasyon sayısı	İterasyon sayısına göre harmonik değişimi(%)
0	46.08
1000	11.4
5000	5.89
10000	4.39
30000	2.57
50000	1.93



Şekil 5.5. Gizli katman nöron sayısı 60 olan ileri beslemeli YSA'da öğrenme algoritması hızlı GY, aktivasyon fonksiyonu lineer kullanıldığı zaman harmoniklerin değişim grafiği

Tablo 5.6. Gizli katman nöron sayısı 60 olan ileri beslemeli YSA'da öğrenme algoritması hızlı GY, aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişimi


İterasyon sayısı	İterasyon sayısına göre harmonik değişimi(%)
0	46.08
1000	2.97
5000	1.42
10000	1.04
30000	0.66
50000	0.45



Şekil 5.6. Gizli katman nöron sayısı 60 olan ileri beslemeli YSA'da öğrenme algoritması hızlı GY, aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişim grafiği

Tablo 5.7. Gizli katman nöron sayısı 60 olan ileri beslemeli YSA'da öğrenme algoritması hızlı GY, aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişimi


İterasyon sayısı	İterasyon sayısına göre harmonik değişimi(%)
0	46.08
1000	15.83
5000	6.62
10000	4.53
30000	2.92
50000	1.9



Şekil 5.7. Gizli katman nöron sayısı 60 olan ileri beslemeli YSA'da öğrenme algoritması hızlı GY, aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişim grafiği

Tablo 5.8. Gizli katman nöron sayısı 60 olan ileri beslemeli YSA'da öğrenme algoritması standart GY, aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişimi

İterasyon sayısı	İterasyon sayısına göre harmonik değişimi(%)
0	46.08
1000	11.34
5000	5
10000	3.87
30000	2.42
50000	1.34




Şekil 5.8. Gizli katman nöron sayısı 60 olan ileri beslemeli YSA'da öğrenme algoritması standart GY, aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişimi

5.2.3. Gizli katman nöron sayısı 30 alındığında simülasyon sonuçları

Tablo 5.9. Gizli katman nöron sayısı 30 olan ileri beslemeli YSA'da öğrenme algoritması hızlı GY, aktivasyon fonksiyonu lineer kullanıldığı zaman harmoniklerin değişimi


İterasyon sayısı	İterasyon sayısına göre harmonik değişimi(%)
0	46.08
1000	7.31
5000	2.86
10000	1.95
30000	1.18
50000	0.93



Şekil 5.9. Gizli katman nöron sayısı 30 olan ileri beslemeli YSA'da öğrenme algoritması hızlı GY, aktivasyon fonksiyonu lineer kullanıldığı zaman harmoniklerin değişim grafiği

Tablo 5.10. Gizli katman nöron sayısı 30 olan ileri beslemeli YSA'da öğrenme algoritması hızlı GY, aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişimi


İterasyon sayısı	İterasyon sayısına göre harmonik değişimi(%)
0	46.08
1000	2.35
5000	1.12
10000	1.04
30000	0.54
50000	0.5



Şekil 5.10. Gizli katman sayısı 30, hızlı GY ve aktivasyon fonksiyonu sigmoid olduğu zaman iterasyona göre harmoniklerin değişim grafiği

Tablo 5.11. Gizli katman nöron sayısı 30 olan ileri beslemeli YSA'da öğrenme algoritması standart GY, aktivasyon fonksiyonu lineer kullanıldığı zaman harmoniklerin değişimi


İterasyon sayısı	İterasyon sayısına göre harmonik değişimi(%)
0	46.08
1000	14.67
5000	7.44
10000	4.86
30000	2.33
50000	1.45



Şekil 5.11. Gizli katman nöron sayısı 30 olan ileri beslemeli YSA'da öğrenme algoritması standart GY, aktivasyon fonksiyonu lineer kullanıldığı zaman harmoniklerin değişim grafiği

Tablo 5.12. Gizli katman nöron sayısı 30 olan ileri beslemeli YSA'da öğrenme algoritması standart GY, aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişimi

İterasyon sayısı	İterasyon sayısına göre harmonik değişimi(%)
0	46.08
1000	11.46
5000	5.82
10000	4.21
30000	2.62
50000	2.35




Şekil 5.12. Gizli katman nöron sayısı 30 olan ileri beslemeli YSA'da öğrenme algoritması standart GY, aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişim grafiği

5.2.4. Gizli katman nöron sayısı 20 alındığında simülasyon sonuçları

Tablo 5.13. Gizli katman nöron sayısı 20 olan ileri beslemeli YSA'da öğrenme algoritması hızlı GY, aktivasyon fonksiyonu lineer kullanıldığı zaman harmoniklerin değişimi


İterasyon sayısı	İterasyon sayısına göre harmonik değişimi(%)
0	46.08
1000	2.88
5000	1.06
10000	0.76
30000	0.45
50000	0.34



Şekil 5.13. Gizli katman nöron sayısı 20 olan ileri beslemeli YSA'da öğrenme algoritması hızlı GY, aktivasyon fonksiyonu lineer kullanıldığı zaman harmoniklerin değişimi

Tablo 5.14. Gizli katman nöron sayısı 20 olan ileri beslemeli YSA'da öğrenme algoritması hızlı GY, aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişimi


İterasyon sayısı	İterasyon sayısına göre harmonik değişimi(%)
0	46.08
1000	2.88
5000	1.06
10000	0.76
30000	0.45
50000	0.34



Şekil 5.14. Gizli katman nöron sayısı 20 olan ileri beslemeli YSA'da öğrenme algoritması hızlı GY, aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişim grafiği

Tablo 5.15. Gizli katman nöron sayısı 20 olan ileri beslemeli YSA'da öğrenme algoritması standart GY, aktivasyon fonksiyonu lineer kullanıldığı zaman harmoniklerin değişimi


İterasyon sayısı	İterasyon sayısına göre harmonik değişimi(%)
0	46.08
1000	14.31
5000	5.92
10000	4.25
30000	2.59
50000	1.97



Şekil 5.15. Gizli katman nöron sayısı 20 olan ileri beslemeli YSA'da öğrenme algoritması standart GY, aktivasyon fonksiyonu lineer kullanıldığı zaman harmoniklerin değişim grafiği

Tablo 5.16. Gizli katman nöron sayısı 20 olan ileri beslemeli YSA'da öğrenme algoritması standart GY, aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişimi

İterasyon sayısı	İterasyon sayısına göre harmonik değişimi(%)
0	46.08
1000	10.14
5000	5.03
10000	3.74
30000	2.3
50000	1.78




Şekil 5.16. Gizli katman nöron sayısı 20 olan ileri beslemeli YSA'da öğrenme algoritması standart GY, aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişim grafiği

5.3. Gizli Katman Nöron Sayısının Değişimine Göre Harmoniklerin Değişimi

Yapılan bu çalışmada gizli katman nöron sayıları değiştirilerek harmonik analizi için optimum gizli katman sayısı belirlenmiştir. Aşağıdaki grafiklerde nöron sayılarına göre harmonik değişimleri görülmektedir.

Tablo 5.17. Aktivasyon fonksiyonu lineer, hızlı öğrenme ve gizli katman nöron sayısına göre harmoniklerin değişimi


İterasyon sayısı	İterasyon sayısına göre harmonik değişimi(%)
5	2.8
10	0.38
20	0.34
30	0.93
60	1.93
90	2.67



Şekil 5.17. Aktivasyon fonksiyonu lineer ve hızlı GY kullanıldığında gizli katman nöron sayısının toplam harmonik değerine etkisi

Tablo 5.18. Aktivasyon fonksiyonu sigmoid, hızlı GY ve gizli katman nöron sayısına göre harmoniklerin değişimi


İterasyon sayısı	İterasyon sayısına göre harmonik değişimi(%)
5	3.24
10	0.76
20	0.427
30	0.5
60	0.45
90	0.52



Şekil 5.18. Aktivasyon fonksiyonu sigmoid ve hızlı GY kullanıldığında gizli katman nöron sayısının toplam harmonik değerine etkisini gösteren grafik

Tablo 5.19. Aktivasyon fonksiyonu lineer, standart öğrenme ve gizli katman nöron sayısına göre harmoniklerin değişimi


İterasyon sayısı	İterasyon sayısına göre harmonik değişimi(%)
5	4.78
10	3.79
20	1.97
30	1.45
60	1.9
90	3.21



Şekil 5.19. Aktivasyon fonksiyonu lineer ve standart GY kullanıldığında gizli katman nöron sayısının toplam harmonik değerine etkisi

Tablo 5.20. Aktivasyon fonksiyonu sigmoid, standart GY ve gizli katman nöron sayısına göre harmoniklerin değişimi

İterasyon sayısı	İterasyon sayısına göre harmonik değişimi(%)
5	4.21
10	1.87
20	1.78
30	2.35
60	1.34
90	1.96




Şekil 5.20. Aktivasyon fonksiyonu sigmoid ve standart GY kullanıldığında gizli katman nöron sayısının toplam harmonik değerine etkisi

5.4. İki Gizli Katmanlı İleri Beslemeli Yapay Sinir Ağında Simülasyon Sonucu

Tek gizli katmanlı ileri beslemeli ağ ile iki gizli katmanlı ileri beslemeli ağ karşılaştırmak için bu simülasyon yapılmıştır. Simülasyon sonucu Tablo 5.21’de görülmektedir.

Tablo 5.21. İki gizli katmanlı ileri beslemeli hızlı GY, aktivasyon fonksiyonu Sigmoid kullanıldığı zaman harmoniklerin değişimi

İterasyon sayısı	İterasyon sayısına göre harmonik değişimi(%)
0	46.08
1000	2.33
5000	1.21
10000	0.91
30000	0.55
50000	0.43




Şekil 5.21. İleri beslemeli iki gizli katmanlı ağın iterasyon sayısına göre toplam harmonik değerinin değişimi

5.5. Elman Geri Beslemeli (Recurrent) Ağda Simülasyon Sonuçları

5.5.1. Gizli katman nöron sayısı 90 kullanıldığında

Tablo 5.22. Elman geri beslemeli ağda gizli katman nöron sayısı 90, hızlı GY ve aktivasyon fonksiyonu lineer kullanıldığı zaman harmoniklerin değişimi


İterasyon sayısı	İterasyon sayısına göre harmonik değişimi(%)
0	46.08
1000	12.51
5000	6.43
10000	4.9
30000	2.85
50000	2.34



Şekil 5.22. Elman geri beslemeli ağda gizli katman nöron sayısı 90, hızlı GY ve aktivasyon fonksiyonu lineer kullanıldığı zaman harmoniklerin değişim grafiği

Tablo 5.23. Elman geri beslemeli ağda gizli katman nöron sayısı 90, hızlı GY ve aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişimi


İterasyon sayısı	İterasyon sayısına göre harmonik değişimi(%)
0	46.08
1000	3.6
5000	1.71
10000	1.23
30000	0.74
50000	0.65



Şekil 5.23. Elman geri beslemeli ağda gizli katman nöron sayısı 90, standart GY ve aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişim grafiği

Tablo 5.24. Elman geri beslemeli ağda gizli katman nöron sayısı 90, standart GY., aktivasyon fonksiyonu lineer kullanıldığı zaman harmoniklerin değişimi


İterasyon sayısı	İterasyon sayısına göre harmonik değişimi(%)
0	46.08
1000	11.02
5000	4.73
10000	3.63
30000	3.06
50000	2.76



Şekil 5.24. Elman geri beslemeli ağda gizli katman nöron sayısı 90, standart GY., aktivasyon fonksiyonu lineer kullanıldığı zaman harmoniklerin değişim grafiği

Tablo 5.25. Elman geri beslemeli ağda gizli katman nöron sayısı 90, standart GY, aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişimi

İterasyon sayısı	İterasyon sayısına göre harmonik değişimi(%)
0	46.08
1000	7.98
5000	3.75
10000	2.7
30000	2.04
50000	1.35




Şekil 5.25. Elman geri beslemeli ağda gizli katman nöron sayısı 90, standart GY, aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişim grafiği

5.5.2. Gizli katman nöron sayısı 20 kullanıldığında

Tablo 5.26. Elman geri beslemeli ağda gizli katman nöron sayısı 20, hızlı GY, aktivasyon fonksiyonu lineer kullanıldığı zaman harmoniklerin değişimi


İterasyon sayısı	İterasyon sayısına göre harmonik değişimi(%)
0	46.08
1000	3.59
5000	1.88
10000	1.39
30000	0.62
50000	0.37



Şekil 5.26. Elman geri beslemeli ağda aktivasyon fonksiyonu lineer, hızlı GY kullanıldığında iterasyona göre harmonik değişim grafiği

Tablo 5.27. Elman geri beslemeli ağda gizli katman nöron sayısı 20, hızlı GY, aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişimi


İterasyon sayısı	İterasyon sayısına göre harmonik değişimi(%)
0	46.08
1000	2.79
5000	1.26
10000	0.96
30000	0.49
50000	0.26



Şekil 5.27. Elman geri beslemeli ağda aktivasyon fonksiyonu sigmoid, hızlı GY kullanıldığında iterasyona göre harmonik değişim grafiği

Tablo 5.28. Elman geri beslemeli ağda gizli katman nöron sayısı 20, standart GY, aktivasyon fonksiyonu lineer kullanıldığı zaman harmoniklerin değişimi


İterasyon sayısı	İterasyon sayısına göre harmonik değişimi(%)
0	46.08
1000	10.5
5000	5.97
10000	3.24
30000	2.46
50000	1.7



Şekil 5.28. Elman geri beslemeli ağda aktivasyon fonksiyonu lineer, standart GY kullanıldığında iterasyona göre harmonik değişim grafiği

Tablo 5.29. Elman geri beslemeli ağda Gizli katman nöron sayısı 20, standart GY, aktivasyon fonksiyonu sigmoid kullanıldığı zaman harmoniklerin değişimi

İterasyon sayısı	İterasyon sayısına göre harmonik değişimi(%)
0	46.08
1000	10.5
5000	5.97
10000	3.24
30000	2.46
50000	1.7



Şekil 5.29. Elman geri beslemeli ağda aktivasyon fonksiyonu sigmoid, standart GY kullanıldığında iterasyona göre harmonik değişimi


5.5.3. İki gizli katmanlı Elman geri beslemeli sinir ağında harmonik simülasyonu

Elman geri beslemeli ağında tek gizli katmanla çift gizli katman arasındaki harmonik analizinde elde edilen simülasyon sonuçlarını karşılaştırmak ve performans analizi

yapabilmek için iki gizli katmanlı Elman geri beslemeli ağ geliştirilmiştir. Simülasyon sonucu tablo 5.30'da görülmektedir.

Tablo 5.30. İki gizli katmanlı Elman geri beslemeli ağda hızlı GY aktivasyon fonksiyonu Sigmoid kullanıldığı zaman harmoniklerin değişimi

İterasyon sayısı	İterasyon sayısına göre harmonik değişimi(%)
0	46.08
1000	3.31
5000	1.5
10000	1.08
30000	0.62
50000	0.25



Şekil 5.30. İki gizli katmanlı Elman ağı kullanıldığında iterasyon sayısına göre harmonik değerinin değişim grafiği

BÖLÜM 6. SONUÇLARIN KARŞILAŞTIRILMASI

Bu çalışmada tek ve iki gizli katmanlı ileri beslemeli ve Elman geri beslemeli (recurrent) yapay sinir ağlarının öğrenme ve tanıma özelliği kullanılarak aktif filtre işlemi ile harmonik analizi yapılmıştır. Harmonik analizi için içerisinde 5., 7., 11., 13., 17., 19., 23. ve 25. harmoniklerin bulunduğu 2520 tane distorsiyonlu dalga oluşturulmuş, oluşturulan her bir dalgadan yapay sinir ağının girişi için 128 örnekleme sinyali alınmıştır. 17., 19., 23. ve 25. harmoniklerin genlikleri ve taşıdıkları akım değerleri çok küçük oldukları için hesaplamada göz önüne alınmamıştır. Ağların performanslarını karşılaştırmak için lineer ve sigmoid aktivasyon fonksiyonu ile standart ve hızlı(fast) geriye yayılım(backpropagation) öğrenim algoritmaları kullanılmıştır.


6.1. Öğrenim Algoritmalarının Karşılaştırılması

Aşağıda harmonik kompanzasyonunda kullandığımız standart geriye yayılım(GY) ve hızlı (fast) geriye yayılım algoritmalarının performansları verilmiştir.

6.1.1. Gizli katman nöron sayısı 90 alındığında

Tablo 6.1. Gizli katman nöron sayısı 90 alındığında ileri beslemeli ağda, aktivasyon fonksiyonu lineer, hızlı GY ile standart GY'nin simülasyon sonuçları

İterasyon	Lineer, hızlı GY	Lineer, standart GY
0	46.08	46.08
1000	13.65	18.39
5000	7.63	8.37
10000	5.9	6.24
30000	3.74	4.05
50000	2.67	3.21




Şekil 6.1. Aktivasyon fonksiyonu lineer, hızlı GY ile standart GY'ın simülasyon grafiği

Tablo 6.1.'de öğrenme algoritmalarının karşılaştırılması yapılmıştır. Her iki öğrenme algoritmada da lineer aktivasyon fonksiyonu kullanılmasına rağmen 50000 iterasyon süresince hızlı geriye yayılım öğrenme algoritması, standart geriye yayılım öğrenme algoritmasına göre daha iyi bir performans göstermiştir. Bu durum şekil 6.1'de görülmektedir.

Tablo 6.2. Gizli katman nöron sayısı 90 alındığında ileri beslemeli ağda aktivasyon fonksiyonu sigmoid, hızlı GY ile standart GY'ın simülasyon sonuçları

İterasyon	Sigmoid, hızlı GY	Sigmoid, standart GY
0	46.08	46.08
1000	2.84	11.41
5000	1.58	5.28
10000	1.2	3.97
30000	0.68	2.45
50000	0.52	1.96




Şekil 6.2. Aktivasyon fonksiyonu sigmoid, hızlı GY ile standart GY simülasyon grafiği

Tablo 6.2’de öğrenme algoritmalarının simülasyon sonuçları görülmektedir. Hızlı GY öğrenme algoritması, standart GY öğrenme algoritmasına göre daha iyi bir performans göstermiştir. Hızlı GY öğrenme algoritması harmonik değerini %0.52’ye düşürürken, standart GY algoritması harmonik değerini %1.96’ya düşürebilmiştir. Bu sonuca göre hızlı geriye yayılım öğrenme algoritması standart öğrenme algoritmasından oldukça iyidir. Bu durum şekil 6.2’de görülmektedir.

6.1.2. Gizli katman nöron sayısı 60 alındığında

Tablo 6.3. Gizli katman nöron sayısı 60 alındığında ileri beslemeli ağda aktivasyon fonksiyonu lineer, hızlı GY ile standart GY’in simülasyon değerleri

İterasyon	Lineer, hızlı GY.	Lineer, standart GY
0	46.08	46.08
1000	11.4	15.83
5000	5.89	6.62
10000	3.39	4.53
30000	2.57	2.92
50000	1.93	1.9




Şekil 6.3. Aktivasyon fonksiyonu lineer, hızlı GY ile standart GY simülasyon grafiği

Tablo 6.3'deki simülasyon sonuçlarına göre hızlı GYA ile standart GYA'nın sonuçları yaklaşık aynıdır. Sonuçları karşılaştırdığımızda standart GYA, hızlı GYA'dan biraz daha iyi olduğu söylenebilir.

Tablo 6.4. Gizli katman nöron sayısı 60 alındığında ileri beslemeli ağda aktivasyon fonksiyonu sigmoidr, hızlı GY ile standart GY'in simülasyon sonuçları

İterasyon	Sigmoid, hızlı GY	Sigmoid, standart GY
0	46.08	46.08
1000	2.97	11.34
5000	1.42	5.0
10000	1.04	3.87
30000	0.66	2.42
50000	0.45	1.34




Şekil 6.4. Aktivasyon fonksiyonu sigmoid, hızlı GY ile standart GY'nin simülasyon grafiği

Tablo 6.4'deki simülasyon sonuçları karşılaştırıldığında, aktivasyon fonksiyonu sigmoid, hızlı GYA, Sigmoid, standart GYA göre çok iyi bir performans gösterdiği görülmektedir. Bu durum şekil 6.4'de açık bir şekilde görülmektedir.

6.1.3. Gizli katman nöron sayısı 30 alındığında

Tablo 6.5. Gizli katman nöron sayısı 30 alındığında ileri beslemeli ağda aktivasyon fonksiyonu lineer, hızlı geriye yayılım ile standart geriye yayılım'ın simülasyon sonuçları

İterasyon	Lineer, hızlı GY(%)	Lineer, standart GY(%)
0	46.08	46.08
1000	7.31	14.67
5000	2.86	7.44
10000	1.95	4.86
30000	1.18	2.35
50000	0.93	1.45




Şekil 6.5. Gizli katman nöron sayısı 30, aktivasyon fonksiyonu lineer, hızlı geriye yayılım ile standart geriye yayılım simülasyon grafiği

Tablo 6.5’de görüldüğü gibi, gizli katman nöron sayısı 30’da, hızlı geriye yayılım algoritması, standart geriye yayılım algoritmasına göre daha iyi bir performans göstermiştir.

Tablo 6.6. Gizli katman nöron sayısı 30 alındığında ileri beslemeli ağda aktivasyon fonksiyonu sigmoid, hızlı GY ile standart GY’ın simülasyon değerleri

İterasyon	Sigmoid, hızlı G.Y.(%)	Sigmoid, standart G.Y.(%)
0	46.08	46.08
1000	2.35	11.46
5000	1.12	5.82
10000	1.04	4.21
30000	0.54	2.62
50000	0.5	2.35




Şekil 6.6. Gizli katman nöron sayısı 30, aktivasyon fonksiyonu sigmoid, hızlı geriye yayılım ile standart geriye yayılım simülasyon grafiği

Tablo 6.6'daki simülasyon sonuçlarına göre hızlı geriye yayılım öğrenme algoritması, standart geriye yayılım öğrenme algoritmasına göre oldukça iyi olduğu görülmektedir. Bu sonuçlardan sonra hızlı geriye yayılım öğrenme algoritmasının kullanılmasının daha uygun olduğu söylenebilir.

6.1.4. Gizli katman nöron sayısı 20 alındığında

Tablo 6.7. Gizli katman nöron sayısı 20 alındığında ileri beslemeli ağda aktivasyon fonksiyonu lineer, hızlı GY ile standart GY'nin simülasyon sonuçları

İterasyon	Lineer, hızlı GY(%)	Lineer, standart GY(%)
0	46.08	46.08
1000	2.88	14.31
5000	1.06	5.92
10000	0.76	4.25
30000	0.45	2.59
50000	0.34	1.97




Şekil 6.7. Gizli katman nöron sayısı 20, aktivasyon fonksiyonu lineer hızlı geriye yayılım ile standart geriye yayılım'ın simülasyon grafiği

Tablo 6.7'deki simülasyon sonuçlarına göre gizli katman nöron sayısı 20 olduğunda hızlı GYA, standart GYA'a göre oldukça iyi olduğu görülmektedir.

Tablo 6.8. Gizli katman nöron sayısı 20 alındığında ileri beslemeli ağda aktivasyon fonksiyonu sigmoid, hızlı GY ile standart GY'nin simülasyon değerleri

İterasyon	Sigmoid hızlı G.Y.	Sigmoid standart G.Y
0	46.08	46.08
1000	3.12	10.14
5000	1.35	5.03
10000	1.02	3.74
30000	0.6	2.3
50000	0.427	1.78



Şekil 6.8. Gizli katman nöron sayısı 20, aktivasyon fonksiyonu sigmoid hızlı geriye yayılım ile standart geriye yayılım simülasyon grafiği

Tablo 6.8'deki simülasyon sonuçlarına göre gizli katman nöron sayısı 20 olduğunda hızlı GYA, standart GYA'a göre oldukça iyi olduğu görülmektedir.


6.2. İleri Beslemeli Ağ ile Elman Geri Beslemeli Ağın Karşılaştırılması

6.2.1. Gizli katman nöron sayısı 90 alındığında

Yapmış olduğumuz çalışmada harmonik analizi için hem ileri beslemeli yapay sinir ağı hem de Elman geri beslemeli yapay sinir ağı kullanılmıştır. Elde edilen simülasyon sonuçları karşılaştırılarak hangi ağın harmonik analizinde daha iyi sonuç verdiği belirlenmiştir.

Tablo 6.9. İleri beslemeli ağ ile Elman geri beslemeli ağın karşılaştırılması

İterasyon	İleri beslemeli ağ Lineer, hızlı GY(%)	Elman geri beslemeli ağ Lineer, hızlı GY(%)
0	46.08	46.08
1000	13.65	12.51
5000	7.63	6.43
10000	5.9	4.9
30000	3.74	2.85
50000	2.67	2.34




Şekil 6.9. Gizli katman nöron sayısı 90'da ileri beslemeli ağ ile Elman geri beslemeli ağın karşılaştırılması

İleri beslemeli ve geri beslemeli ağlardan elde edilen simülasyon sonuçları tablo 6.9'da görülmektedir. 50000 iterasyon sonunda geri beslemeli ağın öğrenmesi biraz daha iyi olmakla birlikte simülasyon zamanı ileri beslemeli ağa göre oldukça fazladır(Yaklaşık 10 kat).

Tablo 6.10. İleri beslemeli ağ ile Elman geri beslemeli ağın karşılaştırılması

İterasyon	İleri beslemeli ağ, sigmoid, hızlı GY(%)	Elman geri beslemeli ağ, sigmoid, hızlı GY(%)
0	46.08	46.08
1000	2.84	3.6
5000	1.58	1.71
10000	1.2	1.23
30000	0.68	0.74
50000	0.52	0.65




Şekil 6.10. Gizli katman nöron sayısı 90'da ileri beslemeli ağ ile Elman geri beslemeli ağın karşılaştırılması

İleri beslemeli ve geri beslemeli ağlardan elde edilen simülasyon sonuçları tablo 6.10'da görülmektedir. Ağların simülasyon sonuçları birbirlerine çok yakın olmasına rağmen ileri beslemeli ağın harmonik analizi daha iyidir. Şekil 6.10'da görüldüğü gibi sonuçlar birbirlerine çok yakındır.

Tablo 6.11. İleri beslemeli ağ ile Elman geri beslemeli ağın karşılaştırılması

İterasyon	İleri beslemeli ağ Lineer, standart GY(%)	Elman geri beslemeli ağ Lineer, standart GY(%)
0	46.08	46.08
1000	18.39	8.82
5000	8.37	5.52
10000	6.24	3.46
30000	4.05	2.35
50000	3.21	1.97




Şekil 6.11. Gizli katman nöron sayısı 90'da ileri beslemeli ağ ile Elman geri beslemeli ağın karşılaştırılması

İleri beslemeli ve geri beslemeli ağlardan elde edilen simülasyon sonuçları tablo 6.11'de görülmektedir. Bu simülasyon sonuçlarına göre Elman geri beslemeli ağın harmonik analizi ileri beslemeli ağa göre oldukça iyidir. İleri beslemeli ve Elman geri beslemeli ağların sonuçları şekil 6.11'de görülmektedir.

Tablo 6.12. İleri beslemeli ağ ile Elman geri beslemeli ağın karşılaştırılması

İterasyon	İleri beslemeli ağ sigmoid, standart GY(%)	Elman geri beslemeli ağ Sigmoid, standart GY(%)
0	46.08	46.08
1000	11.41	11.02
5000	5.28	4.73
10000	3.97	3.63
30000	2.45	3.06
50000	1.96	2.76




Şekil 6.12. Gizli katman nöron sayısı 90'da ileri beslemeli ağ ile Elman geri beslemeli ağın karşılaştırılması

İleri beslemeli ve Elman geri beslemeli ağlardan elde edilen simülasyon sonuçları tablo 6.12'de görülmektedir. Simülasyon sonuçlarına göre ileri beslemeli ağ, Elman geri beslemeli ağa göre harmonik analizinde daha iyidir. İleri beslemeli ve Elman geri beslemeli ağların sonuçları şekil 6.12'de görülmektedir.

6.2.2. Gizli katman nöron sayısı 20 için

Tablo 6.13. Gizli katman nöron sayısı 20 alındığında ileri beslemeli ağ ile Elman geri beslemeli ağın karşılaştırılması

İterasyon	İleri beslemeli ağ Lineer, hızlı GY(%)	Elman geri beslemeli ağ Lineer, hızlı GY(%)
0	46.08	46.08
1000	2.88	3.59
5000	1.06	1.88
10000	0.76	1.39
30000	0.45	0.62
50000	0.34	0.32




Şekil 6.13. Gizli katman nöron sayısı 90'da ileri beslemeli ağ ile Elman geri beslemeli ağın karşılaştırılması

Gizli katman nöron sayısı 20 alındığında ileri beslemeli ağ ile Elman geri beslemeli ağdan elde edilen simülasyon sonuçları tablo 6.13 ve şekil 6.13'de görüldüğü gibidir. Simülasyon sonunda elde edilen değerler yaklaşık aynıdır.

Tablo 7.14. Gizli katman nöron sayısı 20 alındığında ileri beslemeli ağ ile Elman geri beslemeli ağın karşılaştırılması

İterasyon	İleri beslemeli ağ sigmoid, hızlı GY(%)	Elman geri beslemeli ağ sigmoid, hızlı GY(%)
0	46.08	46.08
1000	3.12	2.79
5000	1.35	1.26
10000	1.02	0.96
30000	0.6	0.49
50000	0.427	0.26




Şekil 6.14. Gizli katman nöron sayısı 90'da ileri beslemeli ağ ile Elman geri beslemeli ağın karşılaştırılması

Tablo 6.14'teki simülasyon sonuçlarına göre Elman ağının sonuçları ileri beslemeli ağa göre daha iyidir.

Tablo6.15. Gizli katman nöron sayısı 20 alındığında ileri beslemeli ağ ile Elman geri beslemeli ağın karşılaştırılması

İterasyon	İleri beslemeli ağ, Lineer, standart GY(%)	Elman geri beslemeli ağ, Lineer, standart GY(%)
0	46.08	46.08
1000	14.31	10.5
5000	5.92	5.97
10000	4.25	3.24
30000	2.59	2.46
50000	1.97	1.7




Tablo 6.15. Gizli katman nöron sayısı 20 alındığında ileri beslemeli ağ ile Elman geri beslemeli ağın karşılaştırılması

Tablo 6.15’de görüldüğü gibi ileri beslemeli ağ ile Elman geri beslemeli ağın simülasyon sonuçları birbirine yakın olmakla birlikte geri beslemeli ağın simülasyon sonucunun daha iyi olduğu görülmektedir.

Tablo 6.16. Gizli katman nöron sayısı 20 alındığında ileri beslemeli ağ ile Elman geri beslemeli ağın karşılaştırılması

İterasyon	İleri beslemeli ağ sigmoid, standart GY(%)	Elman geri beslemeli ağ, sigmoid, standart GY(%)
0	46.08	46.08
1000	10.14	7.98
5000	5.03	3.75
10000	3.74	2.7
30000	2.3	2.04
50000	1.78	1.35



Tablo 6.16. Gizli katman nöron sayısı 20 alındığında ileri beslemeli ağ ile elman geri beslemeli ağın karşılaştırılması


Tablo 6.16'daki simülasyon sonuçlarına göre Elman geri beslemeli ağ daha iyi bir performans göstermektedir.

6.3. Elman Geri Beslemeli Ağda Farklı Gizli Katman Nöron Sayılarına Göre Simülasyon Sonuçları (Gizli Katman Nöron Sayısı 90 – 20'nin Karşılaştırılması)

Harmonik analizinin hangi gizli katman nöron sayısında daha iyi sonuç verdiğini araştırmak için farklı sayılar denenmiştir. Burada gizli katman nöron sayısının 20 alındığında, gizli katman nöron sayısı 90'a göre daha iyi sonuç verdiği simülasyon sonuçlarına göre belirlenmiştir.

Tablo 6.17. Gizli katman sayılarına göre Elman geri beslemeli ağlarında harmonik değişimi

İterasyon	Gizli katman nöron sayısı 90, lineer , hızlı GY (%)	Gizli katman nöron sayısı 20, lineer, hızlı GY(%)
0	46.08	46.08
1000	12.51	3.59
5000	6.43	1.88
10000	4.9	1.39
30000	2.85	0.62
50000	2.34	0.37




Şekil 6.17. Aktivasyon fonksiyonu lineer, hızlı GYA kullanılmasıyla elde edilen harmonik değerleri

Tablo 7.17 incelendiği zaman gizli katman nöron sayısının harmonik analizinde

önemli olduğu görülmektedir. Gizli katman nöron sayısı 20, gizli katman nöron sayısı 90'a göre çok daha iyi olduğu görülmektedir.

Tablo 6.18. Gizli katman nöron sayılarına göre Elman geri beslemeli ağda harmonik değişimi

İterasyon	Gizli katman nöron sayısı 90, sigmoid, hızlı GY(%)	Gizli katman nöron sayısı 20, sigmoid, hızlı GY(%)
0	46.08	46.08
1000	3.6	2.79
5000	1.71	1.26
10000	1.23	0.96
30000	0.74	0.49
50000	0.65	0.26




Şekil 6.18. Aktivasyon fonksiyonu sigmoid, hızlı GY kullanılmasıyla elde edilen harmonik değerleri

Tablo 6.18'deki simülasyon sonuçlarına göre gizli katman nöron sayısı 20 kullanıldığında Elman geri beslemeli ağın performansının daha iyi olduğu görülmektedir.

Tablo 6.19. Gizli katman nöron sayılarına göre Elman geri beslemeli ağda harmonik değişimi

İterasyon	Gizli katman nöron sayısı 90 lineer, standart GY(%)	Gizli katman nöron sayısı 20 lineer, standart GY(%)
0	46.08	46.08
1000	8.82	10.5
5000	5.52	5.97
10000	3.46	3.24
30000	2.35	2.46
50000	1.97	1.7




Şekil 6.19. Aktivasyon fonksiyonu lineer, standart GY kullanılmasıyla elde edilen harmonik değerleri

Standart geriye yayılım öğrenme algoritması kullanıldığında simülasyon sonuçları birbirlerine yakın olmakla birlikte gizli katman nöron sayısının 20 olması Elman geri beslemeli ağın daha iyi bir performans göstermesini sağlamaktadır.

Tablo 6.20. Gizli katman nöron sayılarına göre Elman geri beslemeli ağda harmonik değişimi

İterasyon	Gizli katman nöron sayısı 90 sigmoid, standart GY(%)	Gizli katman nöron sayısı 20 sigmoid, standart GY(%)
0	46.08	46.08
1000	11.02	7.98
5000	4.73	3.75
10000	3.63	2.7
30000	3.06	2.04
50000	2.76	1.35



Şekil 6.20. Aktivasyon fonksiyonu sigmoid, standart GY kullanılmasıyla elde edilen harmonik değerleri


Tablo 6.20’de görüldüğü gibi gizli katman nöron sayısının 20 olduğu simülasyon sonucu, gizli katman nöron sayısı 90’a göre çok daha iyi bir performans göstermiştir.

6.4. Gizli Katman Nöron Sayılarına Göre Harmonik Tanımda Öğrenme Algoritmalarının Karşılaştırılması

Değişik gizli katman sayılarında simülasyon yapılarak, hangi gizli katmanda maksimum performansın alındığı belirlenmiştir.

Tablo 6.21. İleri beslemeli ağda gizli katman nöron sayısına göre harmonik değişimi

Gizli katman Sayısı	İleri beslemeli ağ, Lineer, hızlı GY(%)	İleri beslemeli ağ Lineer, standart GY(%)
5	2.8	4.78
10	0.7	3.79
20	0.34	1.97
30	0.93	1.45
60	1.93	1.9
90	2.67	3.21




Şekil 6.21. Aktivasyon fonksiyonu lineer, öğrenme algoritması hızlı GY ve standart GY kullanıldığında gizli katman nöron sayısına göre harmonik değişimi

Tablo 6.21’de gizli katman nöron sayılarına göre harmonik analizi için yapılan simülasyon sonuçları görülmektedir. Lineer aktivasyon fonksiyonu kullanılmış olup,

öğrenme algoritması olarak hızlı ve standart GYA kullanılmıştır. Bu değişkenlere göre harmonik analizin en iyi yapıldığı gizli katman nöron sayısının 20 olduğu şekil 6.21’de görülmektedir.

Tablo 6.22. İleri beslemeli ağda gizli katman nöron sayısına göre harmonik değişimi

İterasyon	İleri beslemeli ağ Sigmoid, hızlı GY(%)	İleri beslemeli ağ sigmoid, standart GY(%)
5	3.24	2.99
10	0.7	1.87
20	0.427	1.78
30	0.5	2.35
60	0.45	1.34
90	0.52	1.96




Şekil 6.22. Aktivasyon fonksiyonu sigmoid, öğrenme algoritması hızlı GY ve standart GY kullanıldığında gizli katman nöron sayısına göre harmonik değişimi

Tablo 6.22 ve şekil 6.22’de görüldüğü gibi en iyi performans gizli katman nöron sayısı 20 alındığında sağlanmaktadır.

Tablo 6.23. İleri beslemeli ağda gizli katman nöron sayısına göre harmonik değişimi

Gizli katman nöron sayısı	Lineer hızlı GY	Sigmoid hızlı GY	Lineer standart GY	Sigmoid standart GY
5	2.8	3.24	4.78	2.99
10	0.7	0.76	3.79	1.87
20	0.34	0.427	1.97	1.78
30	0.93	0.5	1.45	2.35
60	1.93	0.45	1.9	1.34
90	2.67	0.52	3.21	1.96




Şekil 6.23. Aktivasyon fonksiyonu lineer ve sigmoid, öğrenme algoritması hızlı GY ve standart GY kullanıldığında gizli katman nöron sayısına göre harmonik değişimi

Şekil 6.23’de simülasyonu yapılan ileri beslemeli ağların gizli katman nöron sayılarına göre performansları görülmektedir. Şekil 6.23 incelendiğinde gizli katman nöron sayısı 20 olduğunda maksimum performans elde edilmektedir.

6.5. Tek ve İki Gizli Katmanlı İleri Beslemeli ve Elman Geri Beslemeli Ağların Performans Analizi

Tablo 6.24. İki ve tek gizli katmanlı ağlarda sigmoid aktivasyon fonksiyonu ve hızlı GY kullanıldığında harmonik değişimi

İterasyon	İki gizli kat. geri beslemeli ağ	Tek gizli kat. geri beslemeli ağ	İki gizli kat. ileri bes. ağ	Tek gizli kat. ileri bes. ağ
1000	3.31	3.6	2.33	2.84
5000	1.5	1.71	1.21	1.58
10000	1.08	1.23	0.91	1.2
30000	0.62	0.74	0.55	0.68
50000	0.25	0.65	0.43	0.52



Şekil 6.24. Gizli katman sayılarına göre harmonik değişim grafiği


Tablo 6.24'deki simülasyon sonuçları birbirlerine yakın olmakla birlikte en iyi performansı iki gizli katmanlı ağlar vermiştir. 50000 iterasyon sonunda en iyi performansı iki gizli katmanlı geri beslemeli ağ vermiştir. Bu takiben iki gizli katmanlı ileri beslemeli ağ, bunu takiben tek gizli katmanlı ileri beslemeli ağ ve tek

gizli katmanlı geri beslemeli ağ vermiştir. En iyi performansı iki gizli katmanlı ağ vermesine rağmen, gizli katman ikileştiği zaman simülasyon zamanı oldukça uzamaktadır.

6.6. Elman geri beslemeli ağda aktivasyon fonksiyonların karşılaştırılması

Tablo 6.25. Elman geri beslemeli ağda lineer ve sigmoid aktivasyon fonksiyonlarının karşılaştırılması

İterasyon	Lineer	Sigmoid	Sigmoid(2 giz. kat)
1000	12.51	3.6	3.31
5000	6.43	1.71	1.5
10000	4.9	1.23	1.08
30000	2.85	0.74	0.62
50000	2.34	0.65	0.25



Şekil 6.25. Elman ağında aktivasyon fonksiyonlarının karşılaştırılması


Tablo 6.25'deki simülasyon sonuçlarına göre Elman geri beslemeli ağda kullanılan aktivasyon fonksiyonu sigmoid, aktivasyon fonksiyonu lineer'e göre oldukça iyi bir performans göstermiştir.

Bu çalışmada bizim önerdiğimiz Elman geri beslemeli ağıın çıkışında sigmoid aktivasyon fonksiyonu kullanmak, ağıın orijinal yapısında kullanılan lineer aktivasyon fonksiyonundan daha iyidir. Bu durum hem tek gizli katman hemde iki gizli katman için doğrudur.

6.7. İleri Beslemeli Ağda Simülasyon Sonuçlarının Birlikte Gösterimi

Tablo 6.26. Gizli katman nöron sayısı 90 olduğu zaman iterasyon sayısına göre yüzde harmonik değerleri

İterasyon	Akt.fonk.lineer hızlı GY(%)	Akt.fonk.sigm. hızlı GY(%)	Akt.fonk.lineer standart GY(%)	Akt.fonk.sigm standart GY(%)
0	46.08	46.08	46.08	46.08
1000	13.65	2.84	18.39	11.41
5000	7.63	1.58	8.37	5.28
10000	5.9	1.2	6.24	3.97
30000	3.74	0.68	4.05	2.45
50000	2.67	0.52	3.21	1.96




Şekil 6.26. Öğrenme algoritmaları ve aktivasyon fonksiyonlarına göre toplam harmonik değerlerinin (THD) değişimi

Tablo 6.26. incelendiği zaman iterasyon sayısına göre en iyi öğrenmenin aktivasyon fonksiyonu sigmoid ve öğrenme algoritması hızlı GY kullanıldığı zaman elde edildiği görülmektedir. Bu durum şekil 6.26'da görülmektedir.

Tablo 6.27. Gizli katman nöron sayısı 60 olduğu zaman iterasyon sayısına göre harmonik değerlerinin değişimi

İterasyon	Akt.fonk.lineer hızlı GY(%)	Akt.fonk.sigm. hızlı GY(%)	Akt.fonk.lineer standart GY(%)	Akt.fonk.sigm standart GY(%)
0	46.08	46.08	46.08	46.08
1000	11.4	2.97	15.83	11.34
5000	5.89	1.42	6.62	5
10000	4.39	1.04	4.53	3.87
30000	2.57	0.66	2.92	2.42
50000	1.93	0.45	1.9	1.34




Şekil 6.27. Gizli katman nöron sayısı 60 kullanıldığında öğrenme algoritmaları ve aktivasyon fonksiyonlarına göre toplam harmonik değerlerinin (THD) değişimi

Tablo 6.27’de iterasyon sayısına göre toplam harmonik değerinin değişimi görülmektedir. Tabloyu incelediğimiz zaman öğrenme algoritması hızlı GY’ın en iyi performans gösterdiği söylenebilir.

Tablo 6.28. Gizli katman nöron sayısı 30 olduğu zaman iterasyon sayısına göre harmonik değerlerinin değişim

İterasyon	Akt.fonk.lineer hızlı GY(%)	Akt.fonk.sigm. hızlı GY(%)	Akt.fonk.lineer standart GY(%)	Akt.fonk.sigm standart GY(%)
0	46.08	46.08	46.08	46.08
1000	7.31	2.35	14.67	11.46
5000	2.86	1.12	7.44	5.82
10000	1.95	1.04	4.86	4.21
30000	1.18	0.54	2.33	2.62
50000	0.93	0.5	1.45	2.35




Şekil 6.28. Gizli katman nöron sayısı 30 kullanıldığında öğrenme algoritmaları ve aktivasyon fonksiyonlarına göre toplam harmonik değerlerinin (THD) değişimi

50000 iterasyon sonucunda simülasyon sonuçları tablo 6.28’de görülmektedir. Simülasyon sonuçlarına göre hızlı GY kullanıldığında toplam harmonik değerinin en aza indiği görülmektedir.

Tablo 6.29. Gizli katman nöron sayısı 20 olduğu zaman aktivasyon fonksiyonu ve öğrenme algoritmalarına göre harmoniklerin aldığı değer değişimleri

İterasyon	Akt.fonk.lineer hızlı GY(%)	Akt.fonk.sigm. hızlı GY(%)	Akt.fonk.lineer standart GY(%)	Akt.fonk.sigm. standart GY(%)
0	46.08	46.08	46.08	46.08
1000	2.88	3.12	14.31	10.14
5000	1.06	1.35	5.92	5.03
10000	0.76	1.02	4.25	3.74
30000	0.45	0.6	2.59	2.3
50000	0.34	0.427	1.97	1.78




Şekil 6.29. Gizli katman nöron sayısı 20 kullanıldığında öğrenme algoritmaları ve aktivasyon fonksiyonlarına göre toplam harmonik değerlerinin (THD) değişimi

50000 iterasyon sonucunda simülasyon sonuçları tablo 6.29’da görülmektedir. Simülasyon sonuçlarına göre lineer hızlı GY algoritmasında en iyi öğrenmenin olduğu görülmektedir.

6.8. Elman Geri Beslemeli Ağda Simülasyon sonuçlarının birlikte gösterimi

Tablo 6.30. Elman geri beslemeli ağda gizli katman nöron sayısı 90, aktivasyon fonksiyonu ve öğrenme algoritmalarına göre harmoniklerin aldığı değer değişimleri

İterasyon	Akt.fonk.lineer hızlı GY(%)	Akt.fonk.sigm. hızlı GY(%)	Akt.fonk.lineer standart GY(%)	Akt.fonk.sigm. Standart GY(%)
0	46.08	46.08	46.08	46.08
1000	12.51	3.6	8.82	11.02
5000	6.43	1.71	5.52	4.73
10000	4.9	1.23	3.46	3.63
30000	2.85	0.74	2.35	3.06
50000	2.34	0.65	1.97	2.76




Şekil 6.30 Elman geri beslemeli ağda gizli katman nöron sayısı 90 kullanıldığında öğrenme algoritmaları ve aktivasyon fonksiyonlarına göre toplam harmonik değerlerinin (THD) değişimi

Tablo 6.30'daki simülasyon sonuçları incelendiğinde 50000 iterasyona karşılık en iyi sonucun aktivasyon fonksiyonu sigmoid, öğrenme algoritmasının hızlı GY olduğu görülmektedir. Bu değişim, grafik 6.30'da görülmektedir.

Tablo 6.31. Elman geri beslemeli ağda gizli katman nöron sayısı 20, aktivasyon fonksiyonu ve öğrenme algoritmalarına göre harmoniklerin aldığı değerin değişimleri

İterasyon	Akt.fonk.lineer hızlı GY(%)	Akt.fonk.sigm. hızlı GY(%)	Akt.fonk.lineer standart GY(%)	Akt.fonk.sigm. standart GY(%)
0	46.08	46.08	46.08	46.08
1000	3.59	2.79	10.5	7.98
5000	1.88	1.26	5.97	3.75
10000	1.39	0.96	3.24	2.7
30000	0.62	0.49	2.46	2.04
50000	0.32	0.26	1.7	1.35




Şekil 6.31. Elman geri beslemeli ağda gizli katman nöron sayısı 20 kullanıldığında öğrenme algoritmaları ve aktivasyon fonksiyonlarına göre toplam harmonik değerlerinin (THD) değişimi

Elman geri beslemeli yapay sinir ağları kullanılarak elde edilen simülasyon sonuçları tablo 6.30 ve 6.31'de verilmiştir. Elde edilen simülasyon sonuçlarına göre gizli katman nöron sayısı 20, öğrenme algoritması hızlı geriye yayılım ve aktivasyon

fonksiyonunu sigmoid kullanılması Elman geri beslemeli ağda maksimum verimi sağlamaktadır.


6.9. İleri Beslemeli ve Elman Geri Beslemeli Yapay Sinir Ağı Tarafından Düzeltilen Dalga Şekilleri

Aşağıda ileri beslemeli ve Elman geri beslemeli yapay sinir ağları tarafından düzeltilen, sinyallerden bir kaçı görülmektedir. Test setinde yaklaşık 250 sinyal incelenmiştir. Aşağıdaki sinyaller test setinden elde edilen sonuçlardır. Bu sinyallerin içinde, eğitim setinde kullanılmayan fakat yapay sinir ağlarının harmonikleri tanınması için oluşturulan veri matrisinde 17., 19., 23. ve 25. harmonikler mevcuttur. Eğitim setinde kullanılmayan 17., 19., 23. ve 25. harmonikler toplam harmonik değerini yükseltmektedir. Bu harmoniklerin oranı yaklaşık olarak 3.5 %'dur. Şekil 6.32 ve şekil 6.33'de test setinden elde edilen yapay sinir ağları tarafından düzeltilmiş dalga şekilleri görülmektedir.



Şekil 6.32. İleri beslemeli sinir ağı kullanılarak düzeltilen dalga şeklinden bir tanesi

Şekil 6.32 incelendiği zaman kompanzasyondan önce oldukça harmonikli 45.7%'lik bir dalga vardır. Fakat ileri beslemeli ağ tarafından düzeltilen sonra bu harmonikli dalganın değeri 3.9 %'a indirilmiştir. Bu oldukça iyi bir sonuçtur.



Şekil 6.33. Elman geri beslemeli sinir ağı kullanılarak düzeltilen dalga şeklinden bir tanesi

Şekil 6.33'de Elman geri beslemeli yapay sinir ağı kullanılarak düzeltilmiş bir dalga şekli görülmektedir. Elman geri beslemeli ağ ile toplam harmonim değeri 45.7%'den 3.8%'ye düşürülmüştür. Bu sonuç oldukça iyidir.

BÖLÜM 7. TARTIŞMA ve ÖNERİLER

Bu çalışmada tek ve iki gizli katmanlı ileri beslemeli ve Elman geri beslemeli yapay sinir ağları kullanılarak doğrusal olmayan yükler tarafından oluşturulan harmonik kompanzasyonu yapılmıştır. Harmonik kompanzasyonunda kullanılan yapay sinir ağları, giriş katman, gizli katman ve çıkış katman olmak üzere çok katmanlı ağ yapısına sahiptir. Yapay sinir ağları ile harmonik kompanzasyonu yapabilmek için 2520x128'lik bir veri matrisi oluşturulmuştur.

Yapılan bu çalışmanın simülasyon sonuçlarına, göre öğrenim algoritması için kullanılan hızlı(fast) geriye yayılım algoritması(GYA) hem eğitim hemde test safhaları karşılaştırıldığında standart geriye yayılım algoritmasına göre oldukça iyidir(Bkz. Tablo 6.26, 27, 28, 29, 30, 31). Aynı zamanda hızlı geriye yayılım algoritmasının, standart geriye yayılım algoritmasına göre simülasyon zamanı daha kısa ve sonuçlar daha doğrudur.


İleri beslemeli ve Elman geri beslemeli ağların optimum gizli katman nöron sayılarını bulabilmek için, gizli katman nöron sayıları 90, 60, 30, 20, 10 ve 5 olarak değiştirilerek her biri için ayrı, ayrı simülasyon yapılmıştır. Gizli katman nöron sayısına göre elde edilen simülasyon sonuçlarını karşılaştırıldığında gizli katman nöron sayısı 20 olduğu zaman kullanılan ağlarda en iyi performans alınmıştır(Bkz. Şekil 6.21).

Bu çalışmada önerilen iki gizli katmanlı ileri beslemeli ağ ile tek ve iki gizli katmanlı Elman geri beslemeli ağlarının simülasyon sonuçları tablo 8.1'de görülmektedir. Aynı zamanda bu tabloda tek gizli katmanlı ileri beslemeli ağ ile Elman geri beslemeli ağın orijinal yapısında çıkış katmanında bulunan lineer aktivasyon fonksiyonuna göre alınmış simülasyon sonuçları da mevcuttur. Simülasyon sonuçları incelendiğinde iki gizli katmanlı ileri beslemeli yapay sinir ağının simülasyon sonucu

tek katmanlı ileri beslemeli yapay sinir ağının sonucundan daha iyi olduğu görülmektedir. Elman ağının yapısında, çıkış katmanında lineer aktivasyon fonksiyonu kullanılmaktadır. Çalışmada Elman ağının çıkış katmanında sigmoid aktivasyon fonksiyonu kullanılmıştır. Eğer tablo 7.1'deki sonuçları karşılaştıracak olursak, Elman ağının yapısında kullanılan lineer aktivasyon fonksiyonu kullanılırsa, toplam harmonik değeri 46.08%'den, 2.34%'e düşerken, önerilen Elman geri beslemeli ağın çıkışında sigmoid aktivasyon fonksiyonu kullanılırsa toplam harmonik değeri 46.08%'den, 0.65%'e düşüyor. Yine bizim önerdiğimiz iki gizli katmanlı Elman ağının çıkış katmanında, sigmoid aktivasyon fonksiyonu kullanılırsa toplam harmonik değeri 46.08%'den 0.25%'e düşmektedir.

Tablo 7.1. Orijinal ağ yapıları ve bu çalışmada önerilen ağların simülasyon sonuçları

İterasyon	İleri bes. ağ tek.giz.kat	İleri bes. ağ iki giz. kat.	Elman geri bes. ağ, lineer tek.giz.kat	Elman geri bes. ağ sigmoid tek.giz.kat	Elman geri bes. ağ sigmoid iki giz. kat.
0	46.08	46.08	46.08	46.08	46.08
1000	2.84	2.33	12.51	3.6	3.31
5000	1.58	1.21	6.43	1.71	1.5
10000	1.2	0.91	4.9	1.23	1.08
30000	0.68	0.55	2.85	0.74	0.62
50000	0.52	0.43	2.34	0.65	0.25



Şekil 7.1. İterasyon sayısına göre ileri beslemeli ve Elman geri beslemeli ağların performansları


IEEE 519 harmonik standardında, müsaade edilen toplam harmonik bozulması düşük voltajlarda %5'dir. THD ortalaması, kompanzasyondan önce %46.08'dir. Kompanzasyondan sonra ise bütün ağlar için yapılan simülasyon sonuçları %5'in altındadır(Bkz.Tablo 7.1). Elde edilen toplam harmonik değerlerinin tamamı IEEE 519'da tavsiye edilen THD 'den daha düşüktür. Yaklaşık %3.5 eğitimde kullanılmayan 17., 19., 23. ve 25. harmoniklerden gelmektedir. Elman geri beslemeli ve ileri beslemeli ağlardan sağlanan THD yaklaşık aynıdır ve oldukça iyidir(şekil 7.2).

Tezin giriş bölümünde diğer yöntemlerle elde edilen sonuçlar hakkında bilgi verilmiştir. Diğer yöntemlerle elde edilen sonuçlar ve bu çalışmada elde edilen sonuçların karşılaştırılması tablo 7.2'de verilmiştir.

Tablo 7.2. Bu çalışmada önerilen yöntemlerden elde edilen sonuç ile diğer yöntemlerden elde edilen sonuçların karşılaştırılması

Fourier Dönüşümü	P-Q Teorisi	Genetik Algoritma	İleri beslemeli YSA(iki giz. katman)	Elman geri bes. ağ(tek gizli katman)	Elman geri bes. ağ(iki gizli kat.)
12%	10%	4.1%	0.43%	0.65%	0.25%

Tablo 7.2'deki sonuçlar karşılaştırıldığında bu çalışmada önerilen yöntemin oldukça iyi olduğu görülmektedir.



Şekil 7.2. Ortalama toplam harmonik değeri 45.7% olan bozulmuş dalganın ileri beslemeli ve Elman geri beslemeli yapay sinir ağı düzeltilmesi

Sonuç olarak ileri beslemeli ve Elman geri beslemeli yapay sinir ağlarının harmonikleri tanımasının mümkün olduğu şekil 6.32, 6.33, ve şekil 7.2'de bozulmuş

dalgayı düzeltmesiyle doğrulanmaktadır. Elde edilen bu sonuçlara göre ileri beslemeli ve Elman geri beslemeli yapay sinir ağlarının aktif filtre olarak harmonik kompanzasyonu için etkili bir şekilde kullanılabileceği gösterilmiştir.



KAYNAKLAR

- [1]. MORİ, B., "Kompanzasyon kondansatörleri imalat teknolojisi ve kontrol olayı", TMMOB Elektrik Mühendisleri Odası İstanbul Şubesi, Reaktif güç kompanzasyonu seminer notları, s. 308, 1983.
- [2]. ESER, H., "Şehir, kasaba ve içme suyu elektrik tesislerinde kompanzasyon uygulamaları", TMMOB Elektrik Mühendisleri Odası İstanbul Şubesi, Reaktif güç kompanzasyonu seminer notları, s. 262, 1983.
- [3]. ÜNSAL, A., JOUANNE, A.R, STONIC, V.L., "A DSP controlled resonant active filter for power conditining in three phase industrial power systems", ELSEVIER Signal Processing 82(2002) 1749
- [4]. QIAO, C., SMEDLY, K.M., "Three phase bipolar mode active power filters", IEEE Transactions on industry applications, vol. 38, no.1, january / february 2002., s.149
- [5]. BHATTACHARYA, S., FRANK, T.M., DIVAN, D.M., and BANERJEE, B., "Active Filter System Implementation", IEEE Industry Applications Magazine, September/October 1998, s. 47-63.
- [6]. KIM S., ENJETI P., "Anew Hybrid Active Power Filter(APF) Topology", IEEE Transactions on Power Electronics, Vol. 17, No. 1, January 2002., s.48
- [7]. LIN, B.R. and HOU, Y.L., "Single phase Integrated power Quality Compensator Based on capasitor – Clamped Confuguration.", IEEE Transactions on Industrial Electronics, Vol. 49, No. 1, February 2002 , S. 173-185.
- [8]. ABULAFYA, N., "Neural networks for system indetification and control", MSc Thesis Universitf of London 1995.

- [9]. ALEXANDER, I., and MORTON, H., "An introduction to neural computing", london 1990.
- [10]. ARBID, K.J., and WITTENMARK, B., "Brains, machines and mathematics ", 2nd ed. Springer Verlag 1987.
- [11]. YUMUŞAK, N., "Güç sistemi devre elamanlarının elektriksel özelliklerinin elde edilmesinde yapay sinir ağı tabanlı algoritmaların kullanılması", Doktora tezi, Sakarya Üniversitesi, s. 3., Nisan 1998,
- [12]. OYSAL, Y., "Ferro modelleme ve optimal bulanık kontrol", Sakarya Üniversitesi Fen Bil. Ens. Doktora tezi, Mart/2002, s. 4.
- [13]. HABROUK, M.E., DARWISH, M.K., "A new control technique for active power filters using a combined genetic algorithm/conventional analysis", IEEE Transaction on industrial electronics, vol. 49, no. 1, February/2002, pp. 58
- [14]. J. AFONSO, C., COUTO and JULIO, M., "Active Filters with Control Based on [the p-q Theory", Departamento de Electronica Industrial Universidade do Minho, IEEE Industrial Electronics Society Newsletter, Ekim/2001
- [15]. GÜNTÜRKÜN, R., YUMUŞAK, N., TEMURTAS, F., "Detection of Harmonics by Using Artificial Neural Networks", TAIN 2003
- [16]. KAWAHIRA, T. NAKAMURA, and NAKAVAZA, S., "Active power filters", in proc. JIEE IPEC – Tokyo, 1983, pp. 981.
- [17]. AKAGI, H., NABAE, A. and ATOH, S. "Control strategy of active power filters using multiple voltage source PWM converter", IEEE Transaction Ind. Application vol. IA-22, pp.460, May / June 1986
- [18]. KOMATSUGI, K., IMURA, T. , " Harmonic current compensator composed of static power converter", in IEEE Power Electronics Specialist Conf., 1986, pp. 283

- [19]. TAKEDA, M. "Harmonic current compensation with active filter", in IEEE/IAS Ann. Meeting, 1987, pp. 808.
- [20]. NAKAJIMA, A., "Development of active filter with series resonant circuit", in IEEE Power Electronics Specialist Conf., 1988, pp. 1168.
- [21]. AKAGI, H., "Trends in active power line conditioners", IEEE Transaction on power electronics, vol. 9, no. 3, May 1994, pp. 263.
- [22]. JOHN, H., GREEN, T.C., "Predictive Transient Following Control of Shunt and Series Active Power Filter ", IEEE Transactions on Power Electronics, Vol. 17, No. 4, July 2002. pp. 574
- [23]. MEHTA, P., DARWISH, M.K. and THOMSON, T., "Switched capacitor filters", IEEE Transactions on Power Electronics, Vol. 5, pp. 331-336, July 1990
- [24]. KOOZEHKANANI, Z.D., "Active filters : Unified approach," Ph.D. dissertation, Dept. Elect. Eng. Electron., Brunel Univer., Uxbridge, U.K., 1996.
- [25]. HABROUK, M.E., DARWISH, M.K. and MEHTA, P., "Analysis and design of a novel active power filter configuration ", Proc. IEEE-Elec. Power Applicat., vol. 147, no.4, pp. 320-328, July. 2000.
- [26]. MORAN, S.A., BRENNEN, M.N., "Active power line conditioner with fundamental negative sequence compensation", U.S. Patent no. 5,384,696, January/1995.
- [27]. BHATTACHARYA, S., DIVAN, D.M., "Hybrid series active /parallel passive power line conditioner with controlled harmonic injection", U.S. Patent no. 5,465,203, Nov. 1995
- [28]. ENSLIN, W.H., STEYN, R.S., "A New unified approach to power quality management", IEEE-PSEC Record 1995, pp.183-188.

- [29]. KAMRAN, F., HABETLER, T.G., "A Novel On-Line UPS with universal filtering capabilities", IEEE-PSEC Record 1995, pp. 500-506.
- [30]. AKAGI, H., "New trends in active filters for improving power quality", IEEE-PEDES conference Record 1996, pp. 417-425.
- [31]. GRADY, W.M., SAMOTYJ, J., and NOYOLA, A.H., "Survey of active power line conditioning methodologies.", IEEE Transactions on Power Delivery , Vol. 5, pp. 1536-1542, 1990
- [32]. PENG, F.Z., AKAGI, H., NABAE, A., "A new approach to harmonic compensation in power system - A combine system of shunt passive and series active filters", IEEE Transaction Industry Application vol. 26, pp. 983-990. 1990.
- [33]. WYK, J.V., "Power Quality , Power electronics and control" in Proc. 1993 european Conf. Power Electronics and Application, vol.1 pp. 17-32, 1993.
- [34]. WONG, C., MOHAN, N., WRIGHT, S.E., Mortensen, K.N., "Feasibility study of ac and dc side active filters for HVDC converter terminals, IEEE Transactions Power Delivery , Vol. 4, pp. 2067-2075, 1989.
- [35]. VATANABE, E.H., "Series active filters for the dc side of HVDC Transmission system", in Proc. 1990 Int. Power electronics Conf., Tokyo Japan, 1990, pp. 1024-1030.
- [36]. AKAGI, H., "New trend in active filters for power conditioning", IEEE, Transaction on Industry Applications, vol. 32. no.6, November/December 1996
- [37]. GAO, D., SUN, X., "A Shunt Active Power Filter with Control Method Based on Neural Networks", 0-7803-6338-8/00/\$10.00©2000 IEEE, PP. 16191624.
- [38]. PHILIPS, J.K., NELSON, P.J., SEN, K.P., "Power Quality and Harmonics Distorsion on Distribution Systems", IEEE Transactions on industry application, vol. 30, no.2. Marc/April 1994

- [39]. HENDERSON, R.D., ROSE, J.P., "Harmonics: The Effect on Power Quality and Transformers", IEEE Transactions on industry application, vol. 30, no.3. May/June 1994.
- [40]. SUBJAK, J.S., MCQUILKIN, J.S., "Harmonics Caused, Effects, Measurements and Analysis- Update", 89CH2738-3/89/0000-0093\$1.00©1989 IEEE
- [41]. EMO Denizli şubesi
- [42]. ESTHER, T., POMILIO, A., "Shunt active power filter synthesizing resistive loads", IEEE Transactions on Power Electronics, vol. 17, no.2. March 2002. pp. 273-278
- [43]. PHAM, D.T., KARABOGA, D., "Training Elman and Jordan networks for system identification using genetic algorithms", Artificial Intelligent in engineering 13(1999) 107-117 Elsevier.
- [44]. OPPENHEIM, A.V., WILLSKY, A.S., YOUNG, I.T., "Signal and Systems", 1983., s. 514-518
- [45]. ABDELHAMEED, M.M., TOLBAH, F.F., "A recurrent neural network based sequential controller for manufacturing automated systems", Vol. 12, (2002) 617-633, 2000
- [46]. HAYKIN, S., "Neural Networks A Comprehensive Foundation", Macmillan Publishing Company, Englewood Cliffs, N.J. (1994)
- [47]. REID, E.W., "Power Quality Issues – Standarts and Guidelines", IEEE Transactions on industry applications, vol. 32. no. 3, pp. 629, May /June 1996
- [48]. DELEONE, R, CAPPARUCCIA, R., MERELI, E.A., "A successive over relaxsion back propagation algorithm for neural network training", IEEE Transaction NN 1998;9(3):381-8.

[49]. CLOUSE, DS., GILES, CL., HORNE, BG., COTTEL, GW., "Timedelay neural network: Representation and induction of finite state machines", IEEE Tran. NN 1997;8(5):1065-70.

[50]. SUNDARESHAN, MK, CONDERCURE, TA., "Recurrent neural network training by a learning automaton approach for trajectory learning and control system design", IEEE Tran. NN 1998;9(3):354-68.

[51]. ELMAN, JL., "Distributed representations, simple recurrent networks, and grammatical structure", Machine learning 1991;7:195-225.

[52]. RODRIGUEZ, P., WILES, J., ELMAN, JL., "A recurrent neural network that learns to count", Connection Science 1999; 11(1):5-40.

[53]. BOSE, K.B., "Fuzzy logic and neural networks in power electronics and drivers", IEEE Industry Applications Magazine May/June 2000, pp. 57.

[54]. MCCULLAH, W.S., and PITTS, W., "A Logical calculus of the ideas immanent in nervous activity", Buletin of mathematical biophysics, 5:115-113.

[55]. YUMUŞAK, N., "Güç sistemi devre elamanlarının elektriksel özelliklerinin elde edilmesinde yapay sinir ağı tabanlı algoritmaların kullanılması", Doktora tezi, Sakarya Üniversitesi, s. 6., Nisan 1998.

[56]. BARTO, A.G., SUTTON, R.S., and ANDERSON, C.H., "Neuronlike adaptive elements that can solve difficult learning control problems", in IEEE Transaction on systems, and cybernetics vol. 13, no 5, pp. 480-846, 1983

[57]. ÇİKOĞLU, S. "Yapay sinir ağları ile imza tanıma", Sakarya Üniversitesi Fen Bil. Enst. Yüksek Lisans Tezi, Mayıs/2003.

[58]. CHARALAMBOUS, C., "Conjugate gradient algorithm for efficient training of artificial neural networks" in IEEE proceedings -G, vol.139.no 3, pp.301-310, 1992.

- [59]. CHEN, F.C., KHALIL, H.K., "Adaptive control of nonlinear systems using neural networks", proceeding of the 29th IEEE conference on decision and control, vol. 3, pp. 1707-12,1990.
- [60]. ABULAFYA, N., "Neural networks for system identification and control", MSc Thesis University of London 1995.
- [61]. NARENDRA, K.S., MUKHOPADHYAY, S., "Disturbance rejection on nonlinear systems using neural networks", IEEE Transaction on neural networks, vol. 4, no.1, pp. 63-72, 1993.
- [62]. GROSSBERG, S., CARPENTER, G.A., "The art of adaptive pattern recognition by a self organizing neural networks", IEEE computer, pp. 80-88,1988.
- [63]. HSU, Y.Y., YANG, C.C., "Electrical load forecasting in application of neural networks", Kluwer academic publisher, 1995.
- [64]. BOSE, K.B., "Fuzzy logic and neural networks in power electronics and drivers", IEEE Industry Applications Magazine May/June 2000, pp. 61.
- [65]. KÖKER, R., "Üç eklemlı bir robot kolunun görmeye dayalı olarak model tabanlı zeki yörlünge kontrolü", Sakarya Üniversitesi Fen Bil.Enst. Temmuz 2002.
- [66]. FUNAHASKI, K., "On the approximate realization of continuous mapping by neural networks", Neural networks , vol. 2. pp. 183-192,1989.
- [67]. WADA, Y., PECHARANIN, N., TAGUCHI, A., "Application of recurrent neural network for active filter", 0-7803-2768-3/95/\$4.00©1995 IEEE

EK A. YAPAY SİNİR AĞLARI

A.1. Yapay Sinir Ağının Tarihi Gelişimi

Yıllardır, büyük sayıda basit elamanlar ile zeki makinalar geliştirmek bilim adamlarının ve mühendislerin en büyük hedefi olmuştur. Bu konuyla ilgili referanslar 19. yüz yıl bilim literatüründe bulunabilir. Yapay sinir ağları(YSA) insan beynindeki bir çok sinirin (hücrenin) yapay olarak basit işlemcilerin birbirine değişik etki seviyeleri ile bağlanması sonucu oluşan karmaşık bir sistemdir. İnsan beyinin çalışma sisteminin yapay olarak benzetimi çalışmalarının bir sonucu olarak ortaya çıkmıştır

Yapay Sinir ağı, bulanık mantık ve bilinen uzman sistemle karşılaştırıldığı zaman insan düşüncesine benzeyen yapay zekanın en genel formudur. Temelde insan beyni sinirler olarak isimlendirilen milyarlarca sinir hücresini içine alır ve bu sinirler bizim düşüncemizi oluşturan biyolojik sinir ağı formunda birbirlerine bağlanır. Yapay sinir ağlarında (YSA), insan beyin sinir sistemine benzer şekilde sinirler birbirlerine bağlanır[53].

1940'larda araştırmacılar insan beyin fonksiyonunun benzerini arzu ederek biyolojik sinirlerin basit donanımını(daha sonra yazılımını) ve etkileşim sistemlerini geliştirmişlerdir. Mc Cullah ve Pitts ilk hücre modelini ortaya koyarak hücrelerin lojik fonksiyonlarını sağlayan bir cihaz geliştirmişlerdir. Dört yıl sonra Mc Cullah ve Pitts tek katmanlı ağ kullanarak tanımayı öğretmek için örnekleme ağını geliştirmişlerdir[54]. 1949'da Donald Hebb tarafından yazılan 'Organization Behavior' isimli kitapta hücresel seviyede öğrenme mekanizmaları anlatılmıştır[55]. Hebb'in biyolojik öğrenme kuralına göre, bir sinirden dentrit yoluyla gelen bir aksonel giriş işareti onun bir darbe üretmesine neden olmaktadır. Aynı şekilde sonraki aksonel girişler'de benzer darbe üretmeye başlar. Böylece bir davranış biçimi ortaya çıkar. 1950 ve 1960'da bir grup araştırmacı birleşerek biyolojik ve sosyolojik

olarak ilk yapay sinir ağını üretmişlerdir. YSA başlangıçta elektronik devrelere, daha sonra esnek bilgisayar simülasyonlarına uygulanmıştır.

YSA olayları öğrenerek karar verme prensibi üzerine kurulmuştur. Öğrenme, zeki sistemlerin bilgi yetenek ve tecrübelerini arttırma olayı olarak düşünülebilir. Genel şekliyle öğrenme, sistemlerin aynı veya benzeri işleri yaptıklarında, o işi veya işleri bir önceki yapıldığı şeklinden daha verimli ve etkin olarak gerçekleştirecek değişiklikleri oluşturma süreci olarak tanımlanır.

Bir çok bilimsel araştırmacılar insan beyni ile bilgisayar arasında bir çeşit ilişki kurabilmek için çalışmışlardır. Bu çalışmalar beynin çalışma şeklinin bir seri bilgisayardan daha farklı olduğu sonucunu ortaya koymuştur. Bilgisayarlar (paralel olarak tasarlanmadıkları sürece) komutları seri olarak işlerler. İki komutun seri bilgisayarlarda aynı anda işlenmesi mümkün değildir. Gerçekte bir bilgisayar beyinden daha hızlı işlem ünitesi içerir[56].


Bir bilgisayar saniyede birkaç milyon işlem yapabilirken beyindeki üniteler ancak saniyede on işlem yapabilir. Fakat, beyin bir defada bir çok değişik şeylerle çalışabilir. Beynin bu yüksek seviyeli paralellik özelliği çok önemlidir. Bu açıdan bakıldığında yüksek işlem karmaşıklığına sahip problemlerde bilgisayarlarla insan beyninin yarışabilmesi düşünülemez. Fakat görme, konuşma ve anlama gibi bir çok girişlerin ve yüksek derecede paralelliğin olduğu problemlerde beyin çok daha üstündür. Bir insanın karşılaştığı problemler çok yüksek yoğunlukta paraleldir. Bu problemler farklı bir çok bilginin işlenmesi ile çözülebilir. Beynin paralel yapısı, farklı bilgilerin çok daha kolay bir şekilde gösterilmesini sağlar.

Yukarıda da belirtildiği gibi önemli olan işlem ünitelerinin hızı değil paralellik derecesidir. YSA beynin bu yüksek yoğunluktaki paralel ve kendi arasında bağlantılı yapısının modellemeye çalışır. Beynin yüksek seviyeli bilgiyi nasıl sembolize ettiği bilinmemekle beraber beynin kendi arasında yüksek yoğunlukta bağlı bir çok yavaş üniteler kullandığı bilinmektedir.

Sinir ağlarının ilginçliği, insan beyninin öğrenme yeteneğine (kabiliyet) ilaveten öğrenme ve cevabı ağlardan sağlamasıdır. Sonuç olarak yapay sinir ağları büyük sayıdaki uygulamada kullanılmakta ve çok çeşitli alanlarda karmaşık fonksiyonların çözümünde kullanılabileceği ispat edilmiştir. Bunların içinde model örnek tanıma, sınıflandırma, gürültü, kontrol sistemleri ve önceden algılama gibi konulardır. Adaptasyon veya öğrenmeyi sinir ağı modelinin hatasız olarak sağlaması araştırmacıları bu konuya odaklanmıştır. Yapay sinir ağlarının son zamanlarda yeniden ilgi görmesinin başlıca faktörleri; Rosenblatt, Widrow ve Hoff'un karmaşık öğrenmede çalışmaları, çok katmanlı ağlar, dinamiklerin anlaşılması için Hopfield matematik kuramının ağların sınıflandırılmasındaki önemi, bunlara ilaveten daha hızlı bilgisayarların üretilmesidir.

A.2. Biyolojik sinir sistemi

Biyolojik sinir sistemi, merkezinde sürekli olarak bilgiyi alan, yorumlayan ve uygun bir karar üreten beyin (merkezi sinir ağı) bulunduğu 3 katmanlı bir sistem olarak açıklanır. Alıcı sinirler (receptor) organizma içerisinde ya da dış ortamlardan algıladıkları uyarıları, beyne bilgi ileten elektriksel sinyallere dönüştürür. Tepki sinirleri (effector) ise, beyin ürettiği elektriksel darbeleri organizma çıktısı olarak uygun tepkilere dönüştürür. Şekil 4.1'de bir sinir sisteminin blok gösterimi verilmiştir.



Şekil A.1. Biyolojik sinir sisteminin blok gösterimi

Yapay sinir ağları, insan beyninin çalışma prensibi örnek alınarak geliştirilmeye çalışılmış ve aralarında yapısal olarak bazı benzerlikler oluşturulmuştur. Bu benzerlikler Tablo 4.1'de verilmiştir.

Tablo A.1. Sinir sistemi ile YSA'nın benzerlikleri


Sinir sistemi	YSA sistemi
Neuron	İşlem elemanı
Dendrit	Toplama fonksiyonu
Hücre gövdesi	Transfer fonksiyonu
Aksonlar	Eleman çıkışı
Sinapslar	Ağırlıklar

Merkezi sinir ağında bilgiler, alıcı ve tepki sinirleri arasında ileri ve geri besleme yönünde değerlendirilerek uygun tepkiler üretilir. Bu yönüyle biyolojik sinir sistemi, kapalı çevrim denetim sisteminin karakteristiklerini taşır. Merkezi sinir sisteminin temel işlem elemanı, sinir hücresidir (nöron) ve insan beyninde yaklaşık 10 milyar sinir hücresi olduğu tahmin edilmektedir. Sinir hücresi; hücre gövdesi, dendritler ve axonlar olmak üzere 3 bileşenden meydana gelir. Dendritler, diğer hücrelerden aldığı bilgileri hücre gövdesine bir ağaç yapısı şeklinde ince yollarla iletir. Axonlar ise elektriksel darbeler şeklindeki bilgiyi hücreden dışarı taşıyan daha uzun bir yoldur. Axonların bitimi, ince yollara ayrılabilir ve bu yollar, diğer hücreler için dendritleri oluşturur. Şekil 4.3 de görüldüğü gibi axon-dendrite bağlantı elemanı synapse olarak söylenir. Synapse gelen ve dendritler tarafından alınan bilgiler genellikle elektriksel darbelerdir ancak, synapse'deki kimyasal ileticilerden etkilenir. Belirli bir sürede bir hücreye gelen girişlerin değeri, belirli bir eşik değerine ulaştığında hücre bir tepki üretir. Hücrenin tepkisini artırıcı yöndeki girişler uyarıcı, azaltıcı yöndeki girişler ise önleyici girişler olarak söylenir ve bu etkiyi synaps belirler.

Şekilde 4.2'de beyin ve sinir sisteminin temel yapı elemanlarını oluşturan unsurlar görülmektedir. Beyin ve sinir sisteminde fiziksel katmana bakıldığında, işlemci, sinyal iletim ortamı ve yol verici olarak, sinir sisteminin temel ögesi olan nöron, ya da sinir hücresi görülmektedir. Sinir hücresini oluşturan Dendrit, hücre gövdesi, akson ve akson uçları (sinaps) şekil 4.3'de gösterilmiştir. Dendritler sinaptik sinyalleri girdi olarak almakta, hücre gövdesi bu sinyalleri bilindiği kadarıyla analog

bir yöntemle işlemekte ve üretilen denetim sinyali ya da sinyalleri aksonlar aracılığı ile denetlenecek hedef hücrelere iletilmektedir.


Tipik bir nöron, hücre gövdesi ve dendritleri üzerine dış kaynaklardan gelen elektrik darbelerinden üç şekilde etkilenir. Gelen darbelerden bazıları nöronu uyarır, bazıları bastırır, geri kalanı da davranışında değişikliğe yol açar. Nöron yeterince uyarıldığında çıkış kablosundan (aksonundan) aşağı bir elektriksel işaret göndererek tepkisini gösterir. Genellikle bu tek akson üzerinde çok sayıda dallar olur. Aksondan inmekte olan elektrik işareti dallara ve alt dallara ve sonunda başka nöronlara ulaşarak onların davranışını etkiler. Nöron, çok sayıda başka nöronlardan genellikle elektrik darbesi biçiminde gelen verileri alır. Yaptığı iş bu girdilerin karmaşık ve dinamik bir toplamını yapmak ve bu bilgiyi aksonundan aşağı göndererek bir dizi elektrik darbesi biçiminde çok sayıda başka nörona iletmektir. Nöron, bu etkinlikleri sürdürmek ve molekül sentezlemek için de enerji kullanır fakat başlıca işlevi işaret alıp işaret göndermek, yani bilgi alışverişidir[57].



Şekil A.2. Sinirlerin beyne bağlanması[54]

Ortalama bir beyinde 10 milyar kadar sinir hücresi vardır. Dolayısıyla sayıları arttıkça beyin işlevlerinin de artacağı açıktır. Nöron sayısı kadar önemli olan bir diğer özellik; nöronların uzantıları aracılığı ile diğer nöronlarla oluşturdukları

ilişkilerdir. Bilgi alışverişinin yapıldığı bu ilişki noktaları (sinaps'lar) nöron başına 1000 ile 10000 arasında değişir. Sinapslar, etkiye akım var / akım yok şeklinde tepki gösterir. Demek ki, bir nöron 10^3 hatta 10^4 tepki verebilir 10^{10} nöron olduğuna göre, sinir sistemindeki tepki sayısı ya da bilgisayar deyimiyle söylersek bit sayısı, 10 trilyon ile 100 trilyon arasında değişecektir. Bu bit sayısı 500 sayfalık bir milyon kitabı dolduracak kadar çoktur.



Şekil A.3. Biyolojik sinirin yapısı[57]


A.3. Yapay Sinir Modeli

Yapay sinir önceki bölümlerde anlatılan gerçek biyolojik sinirin birinci dereceden karakteristiklerini göstermek üzere tasarlanmıştır. Bu sinire herbiri diğer sinirlerin çıkışlarını göstermek üzere bir girişler kümesi uygulanmıştır. Herbir giriş ise biyolojik sinirdeki sinaptik dayanımla benzer olarak ağırlıklarla çarpılmıştır. Bütün bu ağırlıklı girişler ise nöronun aktivasyon düzeyini belirlemek için toplanmıştır . Bu fonksiyonel açıklamayı gerçekleyen model Şekil 2.2’de görülmektedir.

$$y_{NET} = w_1 x_1 + w_2 x_2 + \dots + w_n x_n$$

$$= \sum_{j=1}^n w_j x_j$$

Ek A1



Şekil A.4. Yapay sinir modeli

Ağ yapılarının farklı olmasına rağmen YSA'ların tamamına yakını yukarıdaki nöron tanımıyla işlemektedir. Burada $x_1, x_2, \dots, x_n$ nöron girişleridir. Herbir nöron girişi toplama işlemine girmeden önce $w_1, w_2, \dots, w_n$ ağırlıkları ile çarpılmaktadır. Toplam olarak girişler X vektörü ile ağırlıkları ise W vektörü ile gösterilebilir. Bu durumda 2.1 denklemi vektör notasyonu ile

$$Y_{NET} = W \cdot X$$

Ek.A2

şeklinde gösterilebilir. Daha sonra çok katmanlı perseptron ve geri yayılım modeli incelendiğinde W , vektör yerine bir matris olarak tanımlanacaktır [58-59].

A.3.1. Yapay sinir ağlarının özellikleri

YSA öğrenerek karar verme prensibi üzerine kurulmuştur. Öğrenme, sistemlerin aynı veya benzeri işlemleri yaptıklarında, o işleri bir önceki yaptıkları şekilden daha verimli ve etkin olarak gerçekleştirerek değişiklikleri oluşturma süreci olarak tanımlanabilir. İnsan beynini taklit etme esasına üzerine kurulan YSA, bir bilgi işleme yöntemi olup, birbirine paralel olarak bağlanmış işlem birimlerinde ve bu birimlerin hiyerarşik organizasyonundan oluşurlar.

YSA lineer olmayan sistemlerin kontrolü ve modellemesinde büyük kolaylıklar sağlamaktadır. Mühendislik problemlerinde ve bir çok pratik uygulamalarda verimli bir kullanım için YSA'ların şu özelliklerini bilmek gerekmektedir.

A.3.1.1. Paralellik

Bilgi işlem yöntemlerinin çoğu ardışık seri işlemlerden oluşmaktadır. Bu durum beraberinde özellikle hız problemlerini getirmektedir. Bilgisayarlar insan beynine göre çok hızlı çalışmasına rağmen beynin toplam hızı bilgisayarlara göre kıyaslanmayacak kadar yüksektir. YSA paralel bir yapıya sahip olduğundan ağa gelen girişler, diğer katmanlar boyunca paralel olarak işleme alınır. Aynı katmanlardaki hücreler arasında zaman bağımlılığı yoktur. Böylece diğer yöntemlere göre işlem hızı arttığından daha kısa zamanda işlem sonucuna ulaşır. [60-61]

A.3.1.2. Hata Toleransı

Bilgisayarlarda herhangi bir işlem elamanının yerinden çıkarılması veya değiştirilmesiyle bilgisayar iş yapamaz hale gelir. YSA'da birkaç elamanın olmaması toplam ağ performansında önemli bir azalma meydana getirmez. Çünkü YSA yapısında paralel çalışma bulunması ile sistemde bulunan elamanlar eksik elamanların işlerini yapabilecek hale gelir.

A.3.1.3. Gerçekleme Kolaylığı

Yapay sinir ağları, karışık fonksiyonlar yerine basit işlemler içerdiği için gerçekleme işlemi diğerlerine göre daha kolaydır. YSA'da her bir işlem birimi çözülecek problemin tümüyle ilgilenmek yerine yalnızca bir kısmıyla ilgilenmektedir. Hücrelerin çok basit işlemleri yapmasına rağmen sağlanan görev paylaşımı nedeniyle çok karmaşık ve zor problemler daha kolay çözülebilmektedir [62]

A.3.1.4. Öğrenebilirlik ve Adaptasyon

Veri işleme yöntemlerinin çoğu programlama yoluyla hesaplamaya dayanır. Bu yöntemlerle herhangi bir problemin çözümü için uygun bir algoritmanın geliştirilmesi zorunluluğu vardır ve ispatı mümkün olmayan durumların çözülmesinde kullanılamaz. Yapay sinir ağları nicel ve nitel verilerle işlem yapabilir ve bir sistemin çalışmasından alınan verilerle eğitilir. Bu eğitim sonucunda ağ

sisteminin çalışmasını öğretir. Uygun bir şekilde eğitilen ağ, daha sonra kendisine sunulan ve eğitim setinde bulunmayan bir girişe de uygun cevabı verecektir. YSA'da problemler verilen örneklerle göre çözülür. Öğrenme yapay sinir ağlarında ağırlıklarla olmaktadır. YSA bir çok girişi işleme sokarak bu girişlere uygun çıkışlar üretebilme özelliğinden dolayı çok değişkenli sistemlere kolayca uygulanabilmektedir.

A.3.1.5. Genelleme

Öğrenme işlemi bitmiş bir ağ, bir dereceye kadar ona verilen girdilerdeki ufak değişikliklere karşı duyarsız olabilir. Bu yetenek gerçek dünyadaki çevreden gelen faktörlerle ufak bozulmalara uğramış girdileri fark edebilmek açısından önemlidir[63].

A.3.1.6. Özetleme

Yapay sinir ağları örnek setinde verilmiş olan girdi setine karşılık verilen çıktı setini öğrenerek, verilen bu dizinin esasını, özünü çıkarma yeteneğine sahiptir. Sinir ağlarının bu özelliği bozuk örüntülerden doğru örüntünün bulunması uygulamalarında kullanılmaktadır. Örneğin, sinir ağına bozuk harf girdilerine karşılık düzgün yazılmış harfler çıktı olarak verilirse öğrenme işlemini tamamladıktan sonra ağ, bozuk harflere karşılık düzgün harfleri verilebilecektir.

A.3.1.7. Yapay sinir ağlarının paralel mimarisi

YSA'ların paralel bir yapıya sahip olmaları, alternatif bilgi işleme yöntemlerine göre daha başarılı kılmıştır. Klasik bilgi işleme yöntemlerinin çoğu seri işlemlerden oluşmaktadır. Bu da hız ve güvenilirlik problemlerini beraberinde getirmektedir. Seri bir işlem gerçekleştirilirken bir birimin yavaş işlemesi tüm sistemi doğrudan yavaşlatırken, paralel bir sistemde bünyede bulunan yavaş bir sistemin sisteme etkisi çok azdır. YSA'ların paralel çalışması hızlı olmasının yanı sıra yüksek hata toleransı da sağlamaktadır. Oluşan hatalar ağ üzerine dağıtılır. Seri bilgi işleme yapan bir sistemde, bir birimdeki hata tüm sistemi olumsuz etkileyecekken, paralel yapıya

sahip sinir ağılarında sistemin genel performansını büyük ölçüde etkilemeyecektir. Genel başarının, sadece hatalı birimlerde küçük oranda düşmesine sebep olacaktır.


A.3.1.8. Yapay sinir ağlarının gerçek zamanlı çalışması

Yapay sinir ağlarının, gerçek zamanlı çalışması önemli bir üstünlüğü olarak görülebilir. Öğrenme işlemini tamamlamış bir sinir ağında prosesin gerçekleştirilmesi için girdilere karşılık doğru çıktıları verilmesini sağlayacak ağırlıklar netleşmiştir. Tasarlanan sinir ağı, bir programlama dili yardımı ile hesaplanan ağırlık değerlerine sahip bağlantılarla oluşturulur.

A.4. Yapay Sinir Ağlarının Temel Bileşenleri

Bir YSA modeli birbirinden bağımsız ve paralel olarak çalışabilen proses elamanlarının (Yapay Sinir Hücrelerinin, sinirlerin) hiyerarşik bir şekilde organizasyonundan oluşur. YSA' yı oluşturan proses elamanlarının her biri beş temel parçadan oluşur.

1. Girdi elamanları
2. Ağırlıklar
3. Toplama fonksiyonu
4. Aktivasyon fonksiyonu
5. Çıktı elamanı



Şekil A.5. Yapay sinir ağının temel elamanları

Şekil 4.5’de gösterilen yapay sinir, sinir ağının temel elamanlarıdır. İçinde ağırlıklar, eşik değeri ve tek aktivasyon fonksiyonu bulunan üç tane temel bileşeni içermektedir.

A.4.1. Girdi elamanları

YSA’da girdi (input) bir dış kaynaktan gelebileceği gibi diğer bir sinirden de gelebilir. Bir sinire birden fazla girdi gelebilir. Sinir hesaplama sadece sayıları işler. Eğer problem sayılardan oluşmuyorsa problemin girdileri sayısallaştırılır. 0 ve 1 arasında temsil edilir. Örneğin problem onaylama veya onaylamama olarak ifade ediliyorsa onaylama ‘1’, onaylamama ‘0’ olarak ifade edilir. Bunun gibi YSA’ da girdi karakterlerinin veya grafiklerinin piksel değerleri de 0-1 arasında ağı verilir. Örneğin 5*10 piksellik bir karakter 50 bit vektör girişi ile ağı girdi olarak verilir.

A.4.2. Ağırlıklar

YSA’nın en önemli unsurlarındandır. Sinir hücresinde girdilerin etkisini tespit eder. Ağırlıklar bir proses elamanının her bir girdisinin önemini gösterir. Ağırlıklar değişken veya sabit olabilir. Ağırlık değerinin (-) olması etkinin ters yönde olduğunu gösterir. Ağırlıklar bir yerde YSA’nın hafızaları olarak ifade edilebilirler.

A.4.3. Toplama fonksiyonu

Sinir hücresine net girdiyi açıklar. Toplama fonksiyonu her bir ağırlığı girdi ile çarpar daha sonra bunları tek bir proses elamanı olacak şekilde toplar. Kısacası bir proses elamanından gelen bilgileri birleştirme işlevini yürütür.

Tablo A.2. En çok kullanılan Toplama Fonksiyonları

Toplam : $Net_i = \sum Wij I_j$	Çarpım : $Net_i = \prod Wij I_j$
Maksimum : $Net_i = \max (Wij I_j)$	Minimum : $Net_i = \min (Wij I_j)$
Çoğunluk : $Net_i = \sum Sgn(Wij I_j)$	Küm. Top : $Net_{yeni} = Net_{eski} + \sum Wij I_j$
$I_{i,j}$: Proses elamanı I_j : Proses elamanının çıktısı Wij : i ve j proses elamanları arasındaki bağlantının ağırlığını gösterir Net_i : Proses elamanlarına giren net girdi	

En çok kullanılan toplama fonksiyonu tipleri maksimum, minimum, çoğunluk, çarpım, toplam ve kümülatif toplam fonksiyonlarıdır. Yukarıdaki tabloda bu fonksiyonlar görülmektedir.

A.4.4. Aktivasyon fonksiyonu

Aktivasyon fonksiyonu toplama fonksiyonunun sonucunu alır, ilgili fonksiyonla bunu işler, proses elamanının nihai çıktısını üretir. Burada elde edilen çıktılar diğer proses elamanlarını dış dünyaya iletir. Aktivasyon fonksiyonları her bir proses elamanının ürettiği çıktının (0 , 1) aralığında olmasını sağlar. Bunun sebebi yapılan işlemlerde aşırı değerlerin üretilmesinin önlenmesi ve belli sınırlar içerisinde çalışmayı gerçekleştirmesidir. Problemin yapısına göre aktivasyon ve toplama fonksiyonları tercih edilir.


Hücre modellerinde, hücrenin gerçekleştireceği işleve göre çeşitli tipte aktivasyon fonksiyonları kullanılabilir. Aktivasyon fonksiyonları sabit parametrelili yada uyarlanabilir parametrelili seçilebilir. Tablo 4.3’de, hücre modellerinde yaygın olarak kullanılan çeşitli aktivasyon fonksiyonları tanıtılmıştır.

Tablo A.3. Aktivasyon Fonksiyon Türleri


Lineer Fonksiyon $f(x) = x$	Sinüsoidal Fonksiyon $f(x) = \sin(x)$
Sigmoidal Fonksiyon $f(x) = 1/(1+e^{-x})$	Hiperbolik Tanjant Fonksiyonu $f(x) = (e^x - e^{-x}) / (e^x + e^{-x})$
Adım Fonksiyonu $f(x) = \begin{cases} 1 & \text{eğer } x > \text{ eşik değeri} \\ 0 & \text{diğer durumlarda} \end{cases}$	Eşit Mantıksal Fonksiyonu $f(x) = \begin{cases} 0 & \text{eğer } x \leq \text{ eşik değeri} \\ x & \text{eğer } 0 < x < 1 \\ 1 & \text{eğer } x \geq 1 \end{cases}$

Doğrusal bir problemi çözmek amacıyla kullanılan doğrusal hücre ve YSA' da yada genellikle katmanlı YSA' nın çıkış katmanında kullanılan doğrusal fonksiyon, hücrenin net girdisini doğrudan hücre çıkışı olarak verir.


Şekil 4.6.d' de grafiği verilen çift yönlü sigmoid (tanh) fonksiyonu, türevi alınabilir, sürekli ve doğrusal olmayan bir fonksiyon olması nedeniyle doğrusal olmayan problemlerin çözümünde kullanılan YSA tercih edilir.




a) Simetrik Hard-Limit Transfer fonksiyonu



b) Log-Sigmoid Transfer fonksiyonu



c) Purelin Transfer Fonksiyonu



d) Tansigmoid Transfer Fonksiyonu

Şekil A.6. Çeşitli aktivasyon fonksiyonları


A.4.5. Çıktı fonksiyonu

Çıktılar ağların sonuçlarıdır. Her bir proses elamanı sadece bir çıktı üretebilir ama birden fazla girdiye sahip olabilir.

A.5. Tek Katmanlı Ağlar

A.5.1. Genel mimarisi

Genel düşünce, ağırlıkların ayarlanması işleminde ağırlıkların birbirlerine yaklaştırılması 1950 sonlarında Rosenblatt tarafından geliştirilmiştir. Rosenblatt'ın ağında girişler ikilik(binary) ve içerisinde dengeleyici(bias) yoktu. Aktivasyon fonksiyonu hard limitation ile McCulloch – Pitts sinir modeli yapısındaydı. Tek katmanlı bir ağ yapısı şekil 4.7. de gösterilmektedir.




Şekil A.7. Sigmoid fonksiyon ile tek katmanlı ağı yapısı

Bağlantı ağırlıkları ve ağıdaki eşik değeri bir çok farklı algoritma kullanılarak uygunlaştırılabilir. Burada Papert ve Minsky tarafından geliştirilen ağı başlangıç işlemlerinin birbirlerine yaklaştırılma işlemi tanımlanmaktadır. Birinci, ağırlıkların bağlanması $w_1, w_2, \dots, w_n$ ve eşik değeri w_0 küçük sıfır olmayan değerlerle kurulmaktadır. Ağırlıkların bağlantıları sadece hata olduğu zaman uygunlaştırılır. Bu işlemler bütün girişler tamamlanıp sınıflandırılincaya kadar tekrarlanır.

A.6. Çok Katmanlı Ağlar

Son zamanlardaki uygulamaların çoğu (yaklaşık 90%) ileri beslemeli mimaride kullanılmaktadır. Şekil 4.8'de iki çıkış sinyali, üç giriş sinyali olan ileri beslemeli çok katmanlı bir ağı yapısı görülmektedir. Ağ, giriş, gizli ve çıkış olmak üzere üç katmana sahiptir. Şekil 4.8'deki ağ yapısı 3-5-2 olarak tanımlanır. Gizli katman giriş ve çıkış katmanlarının birleştirilmesi için kullanılır. Giriş ve çıkış katmanları sinyaller için aynı sayıda sinirlere sahiptir. Giriş katman sinirleri transfer fonksiyonuna sahip değildir, fakat girişler ölçü faktörlerinin denkleğinin normalizasyonunda kullanılmaktadırlar. Gizli katman sayıları ve her gizli katman sinirleri karmaşık problemlerin çözülmesine bağlıdır. Sinyal daima ileri yönde akar. Ağ giriş ve çıkış sinyalleri mantıksal, ayrık iki yönlü veya sürekli değişken olabilirler.



Şekil A.8. Çok katmanlı ağı yapısı[64]


Temelde sinir ağı, paralel giriş, paralel çıkış çok yönlü hesaplama sistemidir. Sinir ağının öğrenmesi insan beynine benzer, girişteki örneklerden herbiri büyük sayıdaki çıkış örneklerine eşitlenerek birleştirilebilir. Ağ ağırlar tarafından yardım edilen zeki dağıtım sonucunda öğrenme kabiliyetine sahip olur. Giriş/çıkış örnek denkliği eğer uygun ağırlıklar seçilirse mümkün olur. Ağı ağırlıkları rasgele seçilirse başlangıçta öğretilmemiş olacak ve çıkış örnekleme arzu edilen örnekleme hatalarının toplamı olacaktır. Gerçek çıkış örnekleme arzu edilen çıkış örnekleme ile karşılaştırılabilir ve algoritma eşitleninceye kadar ağırlıklar ayarlanabilir ve hata kabul edilebilir küçüklükte olur. Böyle öğrenmeye büyük sayıdaki giriş çıkış örneklerin örneklemeyle devam edilebilir[64].

Geriye yayılım çok katmanlı ileri beslemeli sinir ağı için en popüler öğrenme metodudur. Ağa (şekil 4.8) başlangıçta pozitif ve negatif ağırlıklar rasgele atanır. Verilen giriş sinyal örnekleme için adım adım hesaplamalar çıkış örnekleme ileri yöndeki türevi alınır. Ağırlıklar bütün örnekleme öğrenilmesi için iterasyon tarafından yükseltilir.

A.7. Sinir Ağlarının Sınıflandırılması


A.7.1. İleri ve geri beslemeli ağlar

İleri beslemeli sinir ağlarının yapısı, sadece uygun bağlantılarda her katman çıkışlarında ve gelecek katmanların girişleri arasındadır. Bu yüzden aynı katman girişlerinden birisi ve çıkış katman arasında bağlantı yoktur. Şekil 4.10'da iki katmanlı ileri beslemeli ağ yapısı görülmektedir. Bu yapıda her bir sinir girişleri önceki katman çıkışlarının toplam ağırlıklarıdır. Gelecek katman girişlerinde ve çıkıştaki her bir katman arasındaki bağlantıların ağırlıkları vardır. Eğer dallardaki ağırlıklar sıfır olarak atanırsa uygun düğümler arasında eşit bağlantı olmaz. Girişler, gizli katmandaki her bir sinire uygun ağırlıkları vasıtasıyla bağlanırlar.



Şekil A.9. İleri beslemeli iki katmanlı ağın genel yapısı

Geri beslemeli ağlarda her katmanın girişleri önceki katmanın çıkışları tarafından etkilenebilir. Buna ilaveten kendi kendine geri beslemeye müsaade edilir. Şekil 4.10 de basit tek katmanlı geri beslemeli sinir ağı görülmektedir. Ağın girişleri hem harici girişleri hemde bazı gecikme ile ağın çıkışını içermektedir. Ağın birbirine yaklaştırılması ve kararlılığı geri beslemeli ağlarda önemli bir konudur.



Şekil A.10. Geri beslemeli ağı genel yapısı

A.8. Yapay Sinir Ağlarının Eğitilmesi

Yapay sinir ağlarının en önemli özelliği öğrenme yeteneğidir. Öğrenmeleri insanların zeka gelişimine paralellik içerir. Bu açıdan öğrenme olayının belli başlı kısımlarını inceleyeceğiz. Ancak bu olayın sağlıklı olmasına dikkatlice yaklaşılmalıdır. Çünkü yapay sinir ağında öğrenme sınırlıdır ve doğru yolda olsak bile çözümlemeyi önce bir çok zorlukla karşılaşılabılır.


Yapay sinir ağının eğitimi, girdi kümesinin uygulanması ile erişilmek istenen çıktıların elde edilmesidir. Her girdi ve çıktı bir vektörle gösterilir. Eğitilme girdi vektörünün sıra ile uygulanması ile yapılır. Bu arada ağı ağırlıkları daha önceki prosedüre göre uygulanır. Eğitim esnasında ağı ağırlıkları büyüklük olarak değerlere dönüşür ve her girdi vektörü beklenen çıktı vektörüne dönüştürülür.

Yapay sinir ağlarında eğitim algoritması; öğretmenli, öğretmensiz ve takviyeli olmak üzere üç kısımda incelenir.

A.8.1. Öğretmenli öğrenme

Öğretmenli öğrenme geniş bilgileri birleştiren ve öğrenmeyi kontrol eden harici bir öğretmen gerektirir. Öğretmen performans derecesini gözlemler veya bilgi setini öğretir. Öğretmenli öğrenme algoritmasına örnek geri yayılım algoritması olarak bilinen LMS(Least Mean Square) algoritması ve onun genellenmesidir. Öğretmenli


öğrenmede sinir ağlarındaki amaç giriş / çıkış örneklerine göre ağırlıkların değiştirilmesidir. Ağdan sonra minimum hata değeri ile giriş çıkış bilgileri(mapping) kurularak, öğrenme görevi tamamlanır. Sonuç olarak ağ, yeni girişler için çıkışları bulmak amacıyla yeniden kullanılabilir. Önemli bir faktör öğrenme seti, üzerinde pratik uygulama yapılacak şekilde kapsamlı olmasıdır. Bu yüzden öğrenme seti uygun seçilerek ağdan iyi performans alınmalıdır. Şekil 4.11’de öğretmenli öğrenme blok diyagramı olarak verilmiştir.



Şekil A.11. Öğretmenli öğrenme[65]

A.8.2.Öğretmensiz öğrenme

Burada harici bir öğretmene ihtiyaç yoktur, sistem ağ içinde bulunan bilgilerin orada dizaynı ve iç kritikleri tarafından kendi kendini organize etmek zorundadır. Öğretmensiz öğrenme bazen kendi kendine öğrenme organizasyonunu sunar. Bu kategoride sadece giriş örnekleri mevcuttur ve farklı gruplar içinde giriş örnekleri ağda sınıflandırılır. Kohonen ağı öğretmensiz öğrenmeye bir örnektir. Şekil 4.12’de öğretmensiz öğrenme blok diyagramı olarak verilmiştir.



Şekil A.12. Öğretmensiz öğrenme[65]

A.8.3. Takviyeli öğrenme

Bu öğrenmede de bir öğretmene ihtiyaç vardır. Öğretmenli öğretmeden farkı ise, bu durumda öğretmenin ağın üretmesi gereken sonucun yerine, onun ürettiği sonucun sadece doğru veya yanlış olduğunu söylemesidir. Bu ise ağı bir takviye sinyalinin gönderilmesi ile gerçekleşir[65].

A.9. Geri Yayımla (Back Propagation) Öğrenme

Uzun yıllar çok katmanlı ağlar için teorik destekli bir ağırlık adaptasyon algoritması yoktu. Dolayısıyla geri yayılım algoritmasının bulunuşu YSA'ların gelişimi üzerinde çok etkili oldu. Rumelhart , Hinton ve Williams geri yayılım algoritmasını açık bir şekilde makalelerinde ortaya koymuşlardır. Bu çalışmada kısa bir süre sonra Parkes'in Rumelhart'ın çalışmasını daha önce ortaya koyduğu ortaya çıkmıştır. Bu olaydan kısa bir süre sonra da Werbos'un bu metodu onlardan daha önce tanımladığı bulunmuştur. YSA gibi disiplinler arası bir araştırma alanında böyle birden fazla aynı çalışma bağımsız olarak yapılması çok ilginçtir [66].

Geri yayılım algoritmasını ilk geliştiren kişi olan Paul Werbos, bu konudaki ilk sezgilerinin Sigmund Freud'tan olduğunu söylemiştir. Burada ise Freud'un psikodinamik teorisini kasetmektedir. Bu teoriye göre beyin sinir ağı olarak tanımlanmakta ve Freud zaman içinde beyin adaptasyonunun nedensel yolunu, sinirden sinire elektriksel uyarının ters yönünde olan bir kimyasal akışla izah etmektedir.

Bir ağı eğitmekteki amaç, bir giriş setine karşılık olarak özel bir fonksiyonel karakteristiği elde edebilmek için çıkışlar oluşturmak üzere ağırlıkların ayarlanmasıdır. Eğitmenin tam olabilmesi için her bir giriş vektörüne karşılık istenen çıkış vektörünü gösteren bir hedef çıkış vektörü olmalıdır. Bu giriş ve hedef çıkış vektörleri bir eğitim çifti oluşturur. Bir geri yayılım ağındaki öğrenme aşağıdaki basamaklardan oluşur [50].

1. Ağda ağırlıklar ayarlanır(Initialize edilir).
2. Giriş / Çıkış bilgisi ölçülür.
3. Ağın yapısı seçilir(Örneğin her katman için sinirlerin sayısı ve gizli katman sayısı).
4. Sinirler için aktivasyon fonksiyonları seçilir. Bu aktivasyon fonksiyonları aynı olabilir veya farklı katmanlarda farklı olabilirler.
5. Öğrenme setinden öğrenme çiftleri seçilir. Giriş vektörü ağın girişine uygulanır.
6. Arzu edilen çıkış ve ağın çıkışı arasındaki hata hesaplanır.
7. Geriye yayılım hatası ve ağırlıkların ayarlanması yoluyla minimum hata bulunur.
8. Öğrenme seti içindeki vektörün her biri için 5-8. adımlar gerekli olan minimum hatadan daha düşük oluncaya kadar tekrarlanır.


Yukarıdaki basamaklar yeterli sayıda tekrarlanır. Hata limiti elde edildiğinde ise ağ yapılacak işi “öğrendi” denilir. Ağ bir kere öğretildiği zaman elde edilen ağırlık değerleri saptanır ve bu ağırlık değerleri ağın ihtiyacı durumunda tekrar kullanılabilir. Daha sonraki uygulamalarda ağ bu öğrenilen ağırlıkları kullanacaktır.

A.9.1. Eğitim algoritması

Burada detaylı olarak çok katmanlı ileri beslemeli ağın diyagramı ile geri yayılım algoritmasına çıkarılışı verilecektir.

Burada şekil 4.13'teki notasyonlar kullanılmış ve notasyonu daha açık hale getirmek için çıkıştan başlayıp gizli katmana doğru giden bir notasyon kullanılmıştır. Örnek olarak $y_{OUT1,2}$ birinci çıkış katmanının ikinci çıkışıdır ve $w_{2,34}$ ise ikinci (gizli)

katmanını üçüncü nöronu ile bir önceki (giriş) katmanının dördüncü nöronu arasındaki ağırlıktır.



Şekil A.13. Çok katmanlı ileri beslemeli ağ yapısı [63]

Bir basit nöronun tanımından yararlanarak her bir katman sonundaki çıkışlar şöyle yazılabilir [50].

Gizli katman:

$$y_{NET2,j} = \sum_{i=1}^n w_{2,ji} u_i$$

Ek.A3

$$y_{OUT2,j} = f_j[y_{NET2,j}] \quad j = 1, 2, \dots, m$$

Çıkış katmanı:

$$y_{NET1,k} = \sum_{j=1}^m w_{1,kj} y_{OUT2,j}$$

Ek.A4

$$y_{OUT1,k} = f_k[y_{NET1,k}] \quad k = 1, 2, \dots, p$$

Burada $f(x)$ aktivasyon fonksiyonudur ve

$$f(x) = \frac{1}{1 + e^{-\alpha x}}$$

Ek.A5

denklemleri ile ifade edilir.

A.9.1.1. Çıkış katman öğrenmesi

Ağırlıkların diferansiyel artış değerleri özel bir ağırlığa göre, karşı gelen hatanın eğimi (gradyen) bulunur [50].

$$\Delta w_{1,kj} = -\eta \frac{\partial e}{\partial w_{1,kj}} \quad \text{Ek.A6}$$

Diferansiyelde ki zincir kuralı denklem 4.6'ya uygulanırsa ;

$$\Delta w_{1,kj} = -\eta \frac{\partial e}{\partial y_{NET1,k}} \frac{\partial y_{NET1,k}}{\partial w_{1,kj}} \quad \text{Ek.A7}$$

$\delta_{1,k}$;

$$\delta_{1,k} = -\frac{\partial e}{\partial y_{OUT1,k}} \frac{\partial y_{OUT1,k}}{\partial y_{NET1,k}} \quad \text{Ek.A8}$$

şeklinde tanımlanır. $\delta_{1,k}$ 'ları oluşturmak için zincir kuralının bir kez daha kullanıldığına dikkat edilmesi gerekir. Dolayısıyla ağırlıklardaki değişim denklem 4.9'da olduğu gibi formüle edilebilir.

$$\Delta w_{1,kj} = -\eta \delta_{1,k} \frac{\partial y_{NET1,k}}{\partial w_{1,kj}} \quad \text{Ek.A9}$$

Yukarıdaki eşitlik hesaplanmak üzere üç tane kısmi türev içerir. İlk ikisi $\delta_{1,k}$ teriminde ve üçüncüsü ise $y_{NET1,k}$ 'nin $w_{1,kj}$ 'ye göre kısmi türevidir. Bu kısmi türevler, denklem 4.5'de verilen ve hatayı $y_{OUT1,k}$ değerine bağlayan bir hata fonksiyonu kullanarak hesaplanabilir. Hata fonksiyonunu formül 4.10 olarak seçilsin;

$$e = f_{\text{err}} = \frac{1}{2} \sum_{k=1}^p (y_{\text{TAR1},k} - y_{\text{OUT1},k})^2 \quad \text{Ek.A10}$$

Ayrıca aktivasyon fonksiyonunun keskinlik ayarlayıcısı olan α 'da 1 olarak seçilirse 4.5 elde edilir

Bundan başka $\Delta w_{1,kj}$ ifadesinin türevsel terim içermeyecek şekilde açılması gerekir. Böylece algoritmanın uygulanabilirliği daha kolay olacaktır. Denklem 4.3'deki ilk kısmi türev formül 4.5'deki hata fonksiyonu kullanılarak şöyle açılabilir [43].

$$\begin{aligned} \frac{\partial e}{\partial y_{\text{OUT1},k}} &= \frac{\partial}{\partial y_{\text{OUT1},k}} \left(\frac{1}{2} \sum_{k=1}^p (y_{\text{TAR1},k} - y_{\text{OUT1},k})^2 \right) \\ &= (-1)(y_{\text{TAR1},k} - y_{\text{OUT1},k}) \end{aligned} \quad \text{Ek.A11}$$

Böylece ilk türevsel ifade için bilinen değerler cinsinden basit bir eşitlik elde edilmiş olur. Formül 4.3'deki ikinci türevsel ifadedeki aktivasyon fonksiyonunun türevi alınarak denklem 4.12 elde edilebilir.

$$\frac{df_{\text{act}}[x]}{dx} = f_{\text{act}}[x](1 - f_{\text{act}}[x]) \quad \text{Ek.A12}$$

Bu sonuç 4.8'deki ikinci kısmi türev için kullanılırsa 4.9 formülü elde edilir.

$$\begin{aligned} \frac{\partial y_{\text{OUT1},k}}{\partial y_{\text{NET1},k}} &= \frac{\partial}{\partial y_{\text{NET1},k}} (f_{\text{act}}[y_{\text{NET1},k}]) \\ &= f_{\text{act}}[y_{\text{NET1},k}] (1 - f_{\text{act}}[y_{\text{NET1},k}]) \\ &= y_{\text{OUT1},k} (1 - y_{\text{OUT1},k}) \end{aligned} \quad \text{Ek.A13}$$

4.11 ve 4.13 eşitlikleri kullanılarak 4.9 tekrar yazılırsa

$$\delta_{1,k} = -(-1)(y_{\text{TAR1},k} - y_{\text{OUT1},k})(1 - y_{\text{OUT1},k})y_{\text{OUT1},k} \quad \text{Ek.A14.a}$$

elde edilir. Buradan sonra $\delta_{1,k}$, bilinen terimler kullanılarak yazılmak istenirse,

$$\delta_{1,k} = (y_{TAR1,k} - y_{OUT1,k})(1 - y_{OUT1,k})y_{OUT1,k} \quad \text{Ek.A14.b}$$

eşitliğine ulaşılır.

Böylece eşitlik 2.11'deki $\Delta w_{1,kj}$ ifadesinin ilk iki diferansiyel terimleri sadece çıkış terimlerine bağlı olarak ifade edilmiş olur. Çıkış değerleri de 4.3 ve 4.4 eşitlikleri ile kolayca bulunabilir. Ayrıca ağırlık ileri yayılım esnasında bu değerler hesaplanabilmektedir. Dolayısıyla geri yayılım aşaması önceki bu bilgiyi kullanabilir. Bu aşamada 4.10 eşitliğindeki üçüncü kısmi türevin işlenmesi gerekmektedir. Bu iş için 4.4 eşitliği dikkate alınarak diferansiyel işlemi gerçekleştirilirse,

$$\frac{\partial y_{NET1,k}}{\partial w_{1,kj}} = \frac{\partial}{\partial w_{1,kj}} \left(\sum w_{1,kj} y_{OUT2,j} \right) \quad \text{Ek.A15}$$

eşitliği elde edilir.

Eşitlik 4.15 ve 4.14.b eğer 4.10 eşitliği ile birleştirildiği takdirde ağırlık değişimi ile ilgili aşağıdaki basit terimli eşitlik elde edilmiş olur.

$$\Delta w_{1,kj} = \eta (y_{TAR1,k} - y_{OUT1,k})(1 - y_{OUT1,k})y_{OUT1,k}y_{OUT2,j} \quad \text{Ek.A16}$$

Çıkış katmanındaki öğrenme tamamlandığında yani çıkış katmanı ağırlıkları için Δw hesaplandığında kolay bir şekilde gizli katman nöronlarının eğitimine geçilebilir.

A.9.1.2. Gizli katman öğrenmesi

Çıkış katmanındaki ağırlık adaptasyonu öncelikle yapıldıktan sonra gizli katmandaki ağırlık adaptasyonuna geçilir. Dolayısıyla gizli katmandaki öğrenme aşamasında daha önceki çıkış katmanındaki ağırlık değişimi yapılırken elde edilen bazı bilgiler

geriye doğru transfer edilerek kullanılır. Gizli katmandaki ağırlık değişiminin hesaplanması çıkış katmanındaki ile benzer şekilde yapılır [63].

$$\Delta w_{2,ji} = -\eta \frac{\partial e}{\partial w_{2,ji}} \quad \text{Ek.A17}$$

Zincir kuralı kullanılarak 4.17 eşitliğinden;

$$\Delta w_{2,ji} = -\eta \frac{\partial e}{\partial y_{NET2,j}} \frac{\partial y_{NET2,j}}{\partial w_{2,ji}} \quad \text{Ek.A18}$$

eşitliği elde edilir.

Çıkış katmanındakine benzer olarak δ tanımlaması şu şekilde yapılır.

$$\delta_{2,j} = -\frac{\partial e}{\partial y_{OUT2,j}} \frac{\partial y_{OUT2,j}}{\partial y_{NET2,j}} \quad \text{Ek.A19}$$

Bu durumda diferansiyel ağırlık artışı aşağıdaki biçime gelir.

$$\Delta w_{2,ji} = \eta \delta_{2,j} \frac{\partial y_{NET2,j}}{\partial w_{2,ji}} \quad \text{Ek.A20}$$

Görüldüğü gibi burada da üç adet kısmi türev ifadesi bulunmaktadır. Bu ifadeler dikkatli bir biçimde teker teker ele alınıp işe yarar hale getirilecektir. Eğer 4.20 eşitliğindeki birinci terim ile işe başlanırsa;

$$\frac{\partial e}{\partial y_{OUT2,j}} = -\sum_{k=1}^p -\frac{\partial e}{\partial y_{OUT1,k}} \frac{\partial y_{OUT1,k}}{\partial y_{NET1,k}} \frac{\partial y_{NET1,k}}{\partial y_{OUT2,j}} \quad \text{Ek.A21}$$

Burada işaretin (-) olması çıkış katmanındaki öğrenme fazına benzerlik elde edilebilmesi içindir. Bu değer esasında $\delta_{1,k}$ 'dir. Dolayısıyla eşitlik 4.16, eşitlik 4.17'de olduğu gibi sade hale getirilebilir.

$$\frac{\partial e}{\partial y_{OUT2,j}} = - \sum_{k=1}^p \delta_{1,k} \frac{\partial y_{NET1,k}}{\partial y_{OUT2,j}} \quad \text{Ek.A22}$$

Daha önce verilen 4.5 eşitliği kullanılarak 4.23 eşitliğindeki toplam ifadesinde yer alan ikinci terim şöyle yazılabilir;

$$\frac{\partial y_{NET1,k}}{\partial y_{OUT2,j}} = \frac{\partial}{\partial y_{OUT2,j}} \left(\sum_{j=1}^m w_{1,kj} y_{OUT2,j} \right) = w_{1,kj} \quad \text{Ek.A23}$$

Ayrıca 4.13 kullanılarak 4.20 eşitliğindeki ikinci diferansiyel terim aşağıdaki gibi değiştirilebilir :

$$\begin{aligned} \frac{\partial y_{OUT2,j}}{\partial y_{NET2,j}} &= \frac{\partial}{\partial y_{NET2,j}} \left(f_{act} \left[y_{NET2,j} \right] \right) \\ &= fact \left[y_{NET2,j} \right] \left(1 - f_{act} \left[y_{NET2,j} \right] \right) \\ &= y_{OUT2,j} \left(1 - y_{OUT2,j} \right) \end{aligned} \quad \text{Ek.A24}$$

Eşitlik 4.20 ile birlikte 4.23, 4.24 ve 4.25.a eşitlikleri kullanılarak $\delta_{2,j}$ ifadesi daha anlaşılır bir şekilde aşağıdaki gibi ifade edilebilir.

$$\delta_{2,j} = - \left(- \sum \delta_{1,k} w_{1,kj} \right) y_{OUT2,j} (1 - y_{OUT2,j}) \quad \text{Ek.A25.a}$$

Eğer bu eşitlik düzenlenirse;

$$\delta_{2,j} = \left(\sum \delta_{1,k} w_{1,kj} \right) (1 - y_{OUT2,j}) y_{OUT2,j} \quad \text{Ek.A25.b}$$

elde edilecektir. Son olarak eşitlik 4.21'deki son diferansiyel terim hesaplanırsa;

$$\frac{\partial y_{NET2,j}}{\partial w_{2,ji}} = \frac{\partial}{\partial w_{2,ji}} \left(\sum_{i=1}^n w_{2,ji} u_i \right) = u_i \quad \text{Ek.A26}$$

Yine eşitlik 4.26.b ve 4.27'deki ifadeler eşitlik 4.21'de toparlanırsa ağırlık değişimi

$$\Delta w_{2,ji} = \eta \left(\sum_{k=1}^p \delta_{1,k} w_{1,kj} \right) (1 - y_{OUT2,j}) y_{OUT2,j} u_i \quad \text{Ek.A27}$$

elde edilir.

Aşağıdaki analiz geri yayılım eğitimine dayalı olan YSA'ların temelini oluşturur. Hata fonksiyonu ve aktivasyon fonksiyonunun farklı olarak seçimi bu sistemi öğrenme için ileri ve geri salınım yaparak kolay işleyen bir sistem haline getiren algoritmanın temel fikri olduğuna dikkat edilmelidir. Yukarıdaki derivasyonun neticesinde aşağıdaki eğitme algoritmasına ulaşılır.

A.9.2. Standart geri yayılım algoritması:

1. Eşitlik 4.4, 4.5 ve 4.6 kullanılarak $y_{OUT2,j}$ ve $y_{OUT1,k}$ hesaplanır.
2. Eşitlik 4.17, 4.15.b ve 4.28 kullanılarak, $\Delta w_{1,kj}$ ve $\Delta w_{2,ji}$ hesaplanır.
3. Bir önceki aşamada hesaplanan ağırlık değişimleri kullanılarak YSA'nın yeni ağırlıkları hesaplanır.

$$w_{1,kj}(t+1) = w_{1,kj}(t) + \Delta w_{1,kj} \quad \text{Ek.A28}$$

$$w_{2,ji}(t+1) = w_{2,ji}(t) + \Delta w_{2,ji} \quad \text{Ek.A29}$$

Yukarıda sıralanmış basamaklar hata istenilen bir düzeye indirgeninceye kadar tekrarlanır [58].

A.10. Adaptif Öğrenme

GY(Backpropagation) hata yüzeyindeki minimum noktanın araştırılmasında işlemi uzattığı için istenmeyen bir durumdur. Buna ilaveten bir çok metotlar önerilmiştir. Bir çok ilginç ve çekici metotlardan birisi öğrenme oranının uygunlaştırılmasıdır. Bu metotta hedefe varmak için sınır oranlarını hızlandıracak dört tane heuristic tanımlanmıştır. Bunlardan birincisi, momentum katsayısının(teriminin) artırılması. İkincisi, hem ağırlıkların hemde öğrenmenin yükseltilmesinde delta-delta kuralının uygulanması. Üçüncüsü ve en önemlilerinden bir tanesi ikisinden biri değiştirilerek delta-bar-delta kuralı, sonuncusu ise hybrid algoritmadır.

Delta - delta kuralı hem ağırlıkların yükseltilmesi, hemde öğrenmenin yükseltilmesi kuralını içine alır. Ağırlığın yükseltilmesi kuralı steepest descent algoritmasına benzer, sadece öğrenme oranı parametre olmasının dışında ağırlık işlemlerinin herbirisi sahip oldukları parametredir. Ağırlık yükseltme kuralı aşağıdaki gibi yazılabilir.

$$w(t+1) = w(t) - \varepsilon(t+1) \frac{\partial j(t)}{\partial w(t)} \quad \text{Ek.A30}$$

Burada $w(t)$ özel synaptic ağırlık ve $\varepsilon(t)$ uygun öğrenme oranı, t zamandır. Hata yüzeyi üzerinde dik eğim (gradient descent) performansı öğrenme oranı parametre üzerinde tanımlanır. Basitçe tek bir doğrusal elaman durumunda türev için düşünülür. İlk olarak giriş ve çıkış ilişkisi tanımlanır. $W(t)$ ağırlık vektörünün doğrusal elamanı olsun $x(t)$ giriş vektörü olsun bu durumda $y(t)$ şöyle tanımlanır.

$$y(t) = w^T(t)x(t) \quad \text{Ek.A31}$$

$\varepsilon(t)$ köşegen (diagonal) matris t zaman ve $d(t)$ hedef çıkış vektör eşitliğinin arzu edilen cevabıdır. Bu elamanların ağırlık yükseltme algoritması aşağıdaki gibi yazılabilir.

$$w(t) = w(t) + \varepsilon(t+1)[d(t) - y(t)]x(t) \quad \text{Ek.A32}$$

Şimdi hata fonksiyonu, güncelleştirilen öğrenme kuralı tarafından minimize edilmesiyle tanımlanır. Bu hata fonksiyonu ağırlığın güncelleştirilmesiyle minimize edilen hata fonksiyonundan farklıdır. İlk olarak G ve daha sonra J olarak isimlendirilir. G aşağıdaki gibi tanımlanır.

$$G(t) = \frac{1}{2} [d(t) - y(t)]^2 \quad \text{Ek.A33}$$

Eşitlik 31'i eşitlik 33'de yerine yazarsak

$$G(t) = \frac{1}{2} [d(t) - w^T(t)x(t)] \quad \text{Ek.A34}$$

Eşitlik 32'yi eşitlik 34'de yerine yazarsak

$$G(t) = \frac{1}{2} [d(t) - (w(t-1) + \varepsilon(t)[d(t-1) - y(t-1)]x(t-1))^T x(t)]^2 \quad \text{Ek.A35}$$

$y(t)$ 'nin tanımını tekrar kullanarak

$$G(t) = \frac{1}{2} [d(t) - (w(t-1) + \varepsilon(t)[d(t-1) - w^T(t-1)]x(t-1))^T x(t)]^2 \quad \text{Ek.A36}$$

Şimdi öğrenme oranının her birine göre $G(t)$ farklılaştırılır. ε_1 w_1 ağırlığının i. Öğrenme oranı. Bu değer (i,i). ε köşegen matrisin bileşenidir. I eşitliğinin bir teriminin dışındaki bütün bileşenleri sıfır ile karesel matris olmasıdır.

$$\begin{aligned} \frac{\partial G(t)}{\partial \varepsilon_1(t)} &= \frac{\partial}{\partial \varepsilon_1(t)} \left\{ \frac{1}{2} (d(t) - y(t))^2 \right\} = [d(t) - y(t)]^* \\ \frac{\partial}{\partial \varepsilon_1(t)} &\left\{ d(t) (\varepsilon(t) [w(t-1) + d(t-1)w^T(t-1)x(t-1)]x(t-1))^T x(t) \right\} \quad \text{Ek.A37} \\ \frac{\partial G(t)}{\partial \varepsilon_1(t)} &= [d(t) - y(t)] \left\{ -d(t-1)I_1 x(t-1)^T x(t) + [w^T(t-1)x(t-1)I_1 x(t-1)]^T x(t) \right\} \end{aligned}$$


Ek.A38

$$\frac{\partial G(t)}{\partial \varepsilon_1(t)} = \{[d(t) - y(t)]I_1 x(t)\}^T \{[d(t-1) - y(t-1)]I_1 x(t-1)\} = -\frac{\partial j(t)}{\partial w_1(t)} \frac{\partial j(t-1)}{\partial w_1(t-1)}$$

Ek.A39

A.11. Geri beslemeli sinir ağıının yapısı

Popüler sinir ağı tipi (Feed Forward Net) giriş katman, gizli katman ve çıkış katman olmak üzere üç katmana sahiptir. Her katman ağırlık ile dal kombinasyonu biçiminde ileri beslemeli olarak giriş katmandan, gizli katmana, gizli katmandan çıkış katmana bağlanır. Genel olarak geri beslemeli sinir ağı(RNN) üç katman ve ileri beslemeye sahiptir. Bu bağlantılara ilaveten geri beslemeli ağda gizli katmandan giriş katmana ve çıkış katmandan giriş katmana geri beslemeye sahiptir.




Şekil A.14. Geri beslemeli sinir ağıının oluşturulması[67]

A.11.1. Elman ağıının yapısı

Elman bağlantı çoğunlukla birinci katman çıkışından birinci katman girişine geri besleme ile iki katmanlı bir ağıdır. Bu geri beslemeli (recurrent) bağlantı elman ağıında hem ayırmayı (detect) hem de zamana göre değişen örneklerin meydana gelmesine müsaade eder. Aşağıda iki katmanlı bir elman ağıının yapısı görülmektedir.

Elman ağı gizli katmanında tansig ve çıkış katmanında purelin transfer fonksiyonuna sahiptir. Bu kombinasyon, bu transfer fonksiyonları ile iki katmanlı ağlara özeldir bir fonksiyon rasgele doğrulukta tahmini olarak hesaplanabilir. Sadece gizli katman ihtiyacı kadar nöronlara sahip olmak zorundadır. Elman ağının ilk katmanı geri beslemeli(recurrent) olduğu için geleneksel iki katmanlı ağlardan farklıdır. Bu bağlantıdaki gecikme önceki zaman adımından tutulan değerler ileri yön zaman adımında kullanılabilir. Bu yüzden iki elman ağı olsa bile aynı ağırlıklar ve bias'lar ile verilen zaman adımı belirli girişlere verilir, onların çıkışları farklı geri besleme durumları yüzünden farklı olabilir. Ağda gelecek referans için bilgi depolanabilir. Uzaysal örneklemler gibi geçici örnekleri öğrenebilir. Elman ağının cevabı ve oluşumu beraber bir çok örnekleri eğitebilir.



Şekil A.15. İki katmanlı Elman ağının yapısı

A.12. Yapay Sinir Ağının Uygulama Alanları

Son yıllarda YSA, özellikle günümüze kadar çözümü güç ve karmaşık olan yada ekonomik olmayan çok farklı alanlardaki problemlerin çözümüne uygulanmış ve genellikle başarılı sonuçlar alınabilmektedir. YSA çok farklı alanlara uygulanabildiğinden bütün uygulama alanlarını burada sıralamak zor olmakla

birlikte genel bir sınıflandırma ile YSA uygulama alanları aşağıdaki gibi 6 grup içerisinde toplanabilir.

Arıza Analizi ve Tespiti: Bir sistemin, cihazın yada elemanın düzenli (doğru) çalışma şeklini öğrenen bir YSA yardımıyla bu sistemlerde meydana gelebilecek arızaların tanımlanma olanağı vardır. Bu amaçla YSA; elektrik makinelerinin, uçakların yada bileşenlerinin, entegre devrelerin v.s. arıza analizinde kullanılmıştır.

Tıp Alanında: EEG ve ECG gibi tıbbi sinyallerin analizi, kanserli hücrelerin analizi, protez tasarımı, transplantasyon zamanlarının optimizasyonu ve hastanelerde giderlerin optimizasyonu v.s gibi uygulama yeri bulmuştur.

Savunma Sanayi: Silahların otomasyonu ve hedef izleme, nesneleri/görüntüleri ayırma ve tanıma, yeni algılayıcı tasarımı ve gürültü önleme v.s gibi alanlara uygulanmıştır.

Haberleşme: Görüntü ve veri sıkıştırma, otomatik bilgi sunma servisleri, konuşmaların gerçek zamanda çevirisi v.s gibi alanlarda uygulama örnekleri vardır.

Üretim: Üretim sistemlerinin optimizasyonu, ürün analizi ve tasarımı, ürünlerin (entegre, kağıt, kaynak v.s.) kalite analizi ve kontrolü, planlama ve yönetim analizi v.s. alanlarına uygulanmıştır.

Otomasyon ve Kontrol: Uçaklarda otomatik pilot sistemi otomasyonu, ulaşım araçlarında otomatik yol bulma/gösterme, robot sistemlerin kontrolü, doğrusal olmayan sistem modelleme ve kontrolü, elektrikli sürücü sistemlerin kontrolü v.s. gibi yaygın bir uygulama yeri bulmuştur.

EK B. İLERİ BESLEMELİ VE ELMAN GERİ BESLEMELİ AĞLARDA HARMONİKLERİ HESAPLAMADA KULLANILAN PROGRAMLARDAN BAZILARI VE AKIŞ ŞEMASI


B1. İleri Beslemeli Ağda Harmonikleri Hesaplayan Programlardan Biri (1000 İterasyon için)

```
ff.trainParam.epochs = 1000
ff.trainParam.show = 100
[ff,tr]=train(ff,x,t)
save ff
y = sim(ff,x)
h=t-y
th( : )=0
thd( : )=0
athd=0
for i=1:2520
for j=1:4
thd(i)=thd(i)+h(j,i)*h(j,i)
end
th(i)=realsqrt(thd(i))
athd=athd+th(i)
end
avtdh=athd/2520
```

B2. Elman Geri Beslemeli Ağda Harmonikleri Hesaplayan Programlardan Biri(1000 İterasyon için)

```
rc.trainParam.epochs = 1000
rc.trainParam.show = 100
rc = train(rc,xseq,tseq)
save rc
y2 = sim(rc,xseq)
y = seq2con(y2)
h=t-y{1,1}
th(:)=0
thd(:)=0
athd=0
for i=1:2520
for j=1:4
thd(i)=thd(i)+h(j,i)*h(j,i)
end
th(i)=realsqrt(thd(i))
athd=athd+th(i)
end
avtdh=athd/2520
```

B3. İleri Beslemeli Ağda Harmoniklerin Hesaplamasında Kullanılan Programın Akış Şeması



Şekil B1. Harmoniklerin hesaplanmasında kullanılan programın akış şeması

ÖZGEÇMİŞ

11.05.1963 yılında Osmaniye’de doğdu. İlk ve orta Okulu Osmaniye’de Liseyi Ankara Yeni Mahalle Teknik Lise’de tamamladı. 1986 yılında Gazi Üniversitesi Teknik Eğitim Fakültesi Elektronik Bölümünde Lisans eğitimine başladı. 26.01.1991 yılında lisans eğitimini tamamladı.

Bir süre özel bir şirkette kalite kontrol şefi olarak çalıştıktan sonra 03.10.1991 yılında Niğde Teknik ve Endüstri Meslek Lisesi Elektronik Bölümde Öğretmenliğe başladı. Ekim 1992’de bölüm şefliğine atandı. Mart 1994 yılında Niğde’deki görevinden ayrılarak Dumlupınar Üniversitesi Simav Teknik Eğitim Fakültesi Elektronik-Bilgisayar Eğitimi Bölümünde Araştırma görevlisi olarak göreve başladı. Şubat 1995 yılında Gazi Üniversitesi Fen Bilimleri Enstitüsü Elektronik Bilgisayar Eğitiminde Yüksek Lisansa başladı. Şubat 1997’de Yüksek Lisansı tamamladı. Şubat 1998’de Sakarya Üniversitesi Fen Bilimleri Enstitüsü Elektrik-Elektronik Mühendisliğinde doktora başladı. Eylül 2002’de 2547 sayılı YÖK kanununun 35. maddesine göre Sakarya Üniversitesi Fen Bilimleri Enstitüsünde görevlendirildi. Halen Sakarya Üniversitesi Teknik Eğitim Fakültesi Elektronik Bilgisayar Eğitiminde araştırma görevlisi olarak çalışmakta olan Rüştü GÜNTÜRKÜN evli ve iki çocuk babasıdır.