

**KURU TİP TRANSFORMATÖRLERİN SARGI SICAKLIK
DAVRANIŞININ YAPAY SİNİR AĞLARI KULLANARAK
MODELLENMESİ**

Dildade AŞKIN

**YÜKSEK LİSANS TEZİ
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ**

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**NİSAN 2011
ANKARA**

Dildade AŞKIN tarafından hazırlanan “KURU TİP TRANSFORMATÖRLERİN SARGI SICAKLIK DAVRANIŞININ YAPAY SİNİR AĞLARI KULLANARAK MODELLENMESİ” adlı bu tezin Yüksek Lisans tezi olarak uygun olduğunu onaylarım.

Doç. Dr. İres İSKENDER
Tez Danışmanı, Elektrik Elektronik Mühendisliği Anabilim Dalı

Bu çalışma, jürimiz tarafından oy birliği ile Elektrik Elektronik Mühendisliği Anabilim Dalında Yüksek Lisans Tezi olarak kabul edilmiştir.

Prof. Dr. Sezai DİNÇER
Elektrik Elektronik Mühendisliği Anabilim Dalı, G.Ü.

Doc. Dr. İres İSKENDER
Elektrik Elektronik Mühendisliği Anabilim Dalı, G.Ü.

Prof. Dr. Ömer Faruk BAY
Elektronik ve Bilgisayar Eğitimi Anabilim Dalı, G.Ü.

Tarih: 12/04/2011

Bu tez ile Gazi Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu Yüksek Lisans derecesini onamıştır.

Prof. Dr. Bilal TOKLU
Fen Bilimleri Enstitüsü Müdürü

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

Dildade AŞKIN

KURU TİP TRANSFORMATÖRLERİN SARGI SICAKLIK DAVRANIŞININ YAPAY SİNİR AĞLARI KULLANARAK MODELLENMESİ

(Yüksek Lisans Tezi)

Dildade AŞKIN

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

Nisan 2011

ÖZET

Transformatör, büyük maliyeti ve yatırımı açısından enerji taşıma ve dağıtım sistemleri içerisinde en önemli elemanlardan biridir. Transformatörlerde çekirdek ve sargılarda oluşan kayıplar önemli ısı artışlarına neden olur. Transformatör izolasyonunun sıcaklığı transformatörün faydalı ömrünü etkilediğinden izolasyonun hızlı yaşlanmasına neden olan transformatör izolasyon sıcaklığının bilinmesi gerekmektedir. Bu çalışmada kuru tip transformatörlerin sargı sıcaklık davranışını modellemek için yapay sinir ağ modelleri sunulmuştur. Yapay sinir ağlarının kullanılmasındaki amaç, kompleks ve lineer olmayan yapıların öğrenbilme yeteneğidir. Transformatörlerin sargı sıcaklığı davranışı dinamik olduğu için geri beslemeli yapay sinir ağ modelleri kullanılmıştır. Aynı ağ yapısı ve eğitim algoritması 5 KVA ve 3KVA 'lık transformatörlerden alınan iki farklı deney seti verileri için uygulanmıştır. Performans belirleyici faktörü kullanarak yapılan değerlendirmeler sonucunda Bayesian Regulation eğitim algoritması ile eğitilen NARX yapay sinir ağ modelinin sistemimiz için en uygun yapı olduğu belirlenmiştir.

Bilim Kodu : 905.1.033
Anahtar Kelimeler : Kuru tip transformatör, yapay sinir ağları, geri besleme
Sayfa Adedi : 103
Tez Yöneticisi : Doc. Dr. İres İSKENDER

MODELING OF DRY TYPE TRANSFORMER WINDING TEMPERATURE BEHAVIOR USING ARTIFICIAL NEURAL NETWORK

(M.Sc. Thesis)

Dildade AŞKIN

**GAZİ UNIVERSITY
INSTITUTE OF SCIENCE AND TECHNOLOGY**

April 2011

ABSTRACT

Transformer is one of the most important components in terms of high cost and investment in transmission and distribution systems. Losses of core and windings cause to significant temperature rising in transformers. Due to effect of transformer insulation temperature on the transformer life expectancy, the transformer insulation temperature which accelerates the rate of aging of the insulation should be known. In this study, the Artificial Neural Network (ANN) models are presented to model the dry type transformers winding temperature behavior. The aim of using the neural network is its ability to learn complex and nonlinear structures. Because the behavior of transformer winding temperature has dynamic characteristic, Recurrent Neural Network models are used. The same network structure and training algorithms were applied to two different experimental data sets obtained from 5 kVA and 3 kVA transformers. As a result of evaluations of using performance determinant factor, Nonlinear Autoregressive with Exogenous Inputs (NARX) model trained with Bayesian Regularization algorithm was determined as the most suitable structure for our system.

Science Code	: 905.1.033
Key Words	: dry type transformer, artificial neural network, recurrent
Page Number	: 103
Adviser	:Assoc. Prof. Dr. İres İSKENDER

TEŞEKKÜR

Çalışmalarım boyunca değerli yardım ve katkılarıyla beni yönlendiren Hocam Doc. Dr. İres İSKENDER'e yine kıymetli tecrübelerinden faydalandığım Ali Mamizadeh'e, laboratuvarında yardımlarını esirgemeyen Murat TAŞPINAR'a, işyerinde bana desteklerini esirgemeyen amirlerime ve iş arkadaşlarıma, manevi destekleriyle beni hiçbir zaman yalnız bırakmayan çok değerli ailem ve arkadaşlarıma teşekkürü bir borç bilirim.

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT	v
TEŞEKKÜR	vi
İÇİNDEKİLER	vii
ÇİZELGELERİN LİSTESİ	xi
ŞEKİLLERİN LİSTESİ	xii
RESİMLERİN LİSTESİ	xv
SİMGELER VE KISALTMALAR	xvi
1. GİRİŞ	1
2. TRANSFORMATÖRLER	5
2.1. Transformatörlerin Çalışma İlkesi	5
2.2. Transformatör Sınıflandırılması	9
2.3. Transformatör Kayıpları	10
2.3.1. Boştaki kayıplar	10
2.3.2. Yüklü kayıplar	13
2.3.3. Dielektrik kayıpları	14
2.3.4. Transformatörde kaçak kayıplar	14
2.3.5. Kaçak manyetik akılar	15
2.4. Transformatörlerin Soğutulması	16
2.4.1. Transformatörlerde soğutan ortama göre soğutma türleri	17
2.4.2. Transformatörlerde temas sıklığına göre soğutma türleri	18
2.4.3. Transformatörlerin tipine göre soğutma türleri	18

Sayfa

2.5. Transformatörün Termal-Elektriksel Benzeşimin Temel Teorisi	21
2.6. Kuru Tip Transformatörün Dinamik Termal Modellemesi.....	22
3. YAPAY SİNİR AĞLARI	27
3.1 Yapay Sinir Ağlarına Giriş.....	27
3.2. Biyolojik Sinir Sistemi	27
3.3. Yapay Sinir Yapısı	28
3.4. Yapay Sinir Ağlarının Üstünlükleri.....	30
3.5. Yapay Sinir Ağlarının Önemli Dezavantajları	31
3.6. Aktivasyon Fonksiyonu.....	32
3.6.1. Doğrusal fonksiyon	32
3.6.2. Basamak fonksiyonu	33
3.6.3. Sigmoid fonksiyonu	34
3.6.4. Tanjant Hiperbolik fonksiyon	35
3.7. Yapay Sinir Ağlarının Sınıflandırılması.....	35
3.7.1.YSA'ların yapılarına göre sınıflandırılması.....	36
3.7.2. YSA'larında temel öğrenme kuralları.....	39
3.7.3. YSA'ların öğrenme algoritmalarına göre sınıflandırılması	41
3.7.4. YSA'ların temel öğrenme algoritmaları.....	43
3.8. Yapay Sinir Ağ Yapıları.....	50
3.8.1. Adaline	50
3.8.2. Çok katmanlı (Ara katmanlı) ağlar (Multilayer networks-MLP).....	51
3.8.3. Radyal taban fonksiyonlu sinir ağı (RBFNN).....	52

Sayfa

3.8.4. Vektör kuantalamalı öğrenme (Learning vector quantisation -LVQ)	53
3.8.5. ART Ağları (Adaptif Rezonans Theory).....	54
3.8.6. Dinamik ağlar.....	56
3.9. Bir Yapay Sinir Ağının Tasarımı	68
3.9.1. YSA ağ yapısının seçimi.....	69
3.9.2. YSA öğrenme algoritmasının seçimi	69
3.9.3. Ara katman sayısı ve nöron sayısının belirlenmesi.....	70
3.9.4. Normalizasyon	70
3.9.5. Öğrenme oranının ağ üzerindeki etkisi	70
3.9.6. Performans fonksiyonunun seçilmesi	71
4. KURU TİP TRANSFORMATÖRÜN SARGI SICAKLIK DAVRANIŞININ YAPAY SİNİR AĞLARIYLA MODELLENMESİ.....	72
4.1. Giriş.....	72
4.2. 5 kVA'lık Kuru Tip Bir Güç Transformatörünün Sargı Sıcaklığının Yapay Sinir Ağlarıyla Modellenmesi.....	73
4.2.1. Üç giriş değişkeni ile Elman modeli kullanarak sargı sıcaklık tahmini.....	75
4.2.2. Üç giriş değişkeni ile NARX modeli kullanarak sargı sıcaklık tahmini.....	79
4.3. 3 kVA'lık Kuru Tip Bir Güç Transformatörünün Sargı Sıcaklığının Yapay Sinir Ağlarıyla Modellenmesi.....	81
4.3.1. Üç giriş değişkeni ile Elman modeli kullanarak sargı Sıcaklık Tahmini.....	83
4.3.2. Üç giriş değişkeni ile NARX modeli kullanarak sargı sıcaklık tahmini.....	86
5. SONUÇ	89

Sayfa

KAYNAKLAR	91
EKLER.....	94
EK1	95
EK2	99
ÖZGEÇMİŞ	103

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 2.1. Transformatörün soğutma tipi ve soğutucusu türler	21
Çizelge 2.2. Termal-elektriksel benzeşim tablosu	22
Çizelge 2.3. Cu,Al ve Fe ‘in sıcaklığa göre gösterdiği termal kapasitans	24
Çizelge 4.1. 3 tabakalı Elman modelinin Levenberg-Marquardt öğrenme algoritmasını kullanarak elde edilen RMSE ve pik hata değerleri	77
Çizelge 4.2. 3 tabakalı Elman modelinin Bayesian-Regulazition öğrenme algoritmasını kullanarak elde edilen RMSE ve pik hata değerleri	78
Çizelge 4.3. 3 tabakalı NARX modelinin Bayesian-Regulazition öğrenme algoritmasını kullanarak elde edilen RMSE ve pik hata değerleri	81
Çizelge 4.4. 3 tabakalı Elman modelinin Levenberg-Marquardt öğrenme algoritmasını kullanarak elde edilen RMSE ve pik hata değerleri	84
Çizelge 4.5. 3 tabakalı Elman modelinin Bayesian-Regulazition öğrenme algoritmasını kullanarak elde edilen RMSE ve pik hata değerleri	85
Çizelge 4.6. 3 tabakalı NARX modelinin Bayesian-Regulazition öğrenme algoritmasını kullanarak elde edilen RMSE ve pik hata değerleri	88

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 2.1. İdeal Transformatör Modeli a) Fiziksel Model, b) Toroidal biçimli magnetic devre.....	6
Şekil 2.2. İdeal transformatörün sembolik modeli	7
Şekil 2.3. B-H histerisiz eğrisi	11
Şekil 2.4. Kalıcı mıknatıslıkta moleküllerin durumu a) Mıknatıslığı olmayan demir b) Manyetik alan içindeki mıknatıslık c) Kalıcı mıknatıslık	11
Şekil 2.5. Demir gövdede meydana gelen eddy akımının yönleri	12
Şekil 2.6. Tabii soğutmanın çalışma prensibini gösteren blok diyagramı	19
Şekil 2.7. Hava ile zorlanmış soğutmanın çalışma prensibini gösteren blok diyagramı	19
Şekil 2.8. Tabii soğutmalı yağlı transformatör.....	20
Şekil 2.9. Elektrik ve termal-elektrik devresi a) Analog devresi b) RC devresi.....	22
Şekil 2.10. Transformatörün sargı sıcaklık termal devresi	23
Şekil 2.11. Basitleştirilmiş eşdeğer sargı termal modeli	25
Şekil 3.1. Basit bir sinir ağ yapısı	29
Şekil 3.2. Doğrusal ve lineer fonksiyon	33
Şekil 3.3. Tek ve çift kutuplu basamak fonksiyonu	34
Şekil 3.4. Sigmoid fonksiyonu	34
Şekil 3.5. Tanjant hiperbolik fonksiyonu	35
Şekil 3.6. Çok katmanlı ileri beslemeli ağ yapısı.....	36
Şekil 3.7. Çok katmanlı geri beslemeli ağ yapısı.....	38
Şekil 3.8. Danışmanlı öğrenme yapısı	42
Şekil 3.9. Danışmansız öğrenme yapısı	42

Şekil	Sayfa
Şekil 3.10. Geri yayımlı öğrenme algoritmasının yapısı	43
Şekil 3.11. Gradient descent metodu ile karesel hatanın minimizasyonu.....	47
Şekil 3.12. İki katmanlı çok katlı sinir ağ yapısı modeli.....	52
Şekil 3.13. RBFNN modelinin yapısı:Giriş vektöründeki elemanların sayısı,S1:1.tabakadaki nöronların sayısı, S2:2.tabakadaki nöronların Sayısı	53
Şekil 3.14. LVQ'nun yapısı	54
Şekil 3.15. ART ağının genel yapısı	55
Şekil 3.16. Jordan ağı modeli.....	58
Şekil 3.17. Elman ağı modeli	59
Şekil 3.18. Hopfield ağı modeli	60
Şekil 3.19. Gecikme zaman odaklı ağ yapısı modeli	62
Şekil 3.20. İki tabakalı gecikmeli zaman odaklı ağ	63
Şekil 3.21. Dağıtımli zaman gecikmeli ağ modeli yapısı.....	63
Şekil 3.22. Gizli katmanında 3 nöron bulunan NARX ağı	64
Şekil 3.23. NARX ağ yapısı.....	65
Şekil 3.24. Paralel NARX sistemin dinamik sistem tanımı	66
Şekil 3.25. Seri-Paralel NARX sistemin dinamik sistem tanımı	67
Şekil 4.1. Deney elektriksel bağlantı şeması.....	73
Şekil 4.2. 3 girişli-1 çıkışlı Elman modelimizin şematik gösterimi.....	76
Şekil 4.3. Üç giriş değişkenli Elman modelinde Levenberg-Marquardt algoritması kullanarak elde edilen simulasyon.....	76
Şekil 4.4. Şebeke geriliminin değişimi	77
Şekil 4.5. Üç giriş değişkenli Elman modelinde Bayesian-Regulazition algoritması kullanarak elde edilen simulasyon.....	78

Şekil	Sayfa
Şekil 4.6. 3 girişli-1 çıkışlı NARX modelimizin şematik gösterimi	79
Şekil 4.7. Üç giriş değişkenli NARX modelinde Levenberg-Marquardt algoritması kullanarak elde edilen simulasyon.....	80
Şekil 4.8. Üç giriş değişkenli NARX modelinde Bayesian-Regulazition algoritması kullanarak elde edilen simulasyon.....	80
Şekil 4.9. Üç giriş değişkenli Elman modelinde Levenberg-Marquardt algoritması kullanarak elde edilen simulasyon.....	83
Şekil 4.10. Şebeke geriliminin değişimi	84
Şekil 4.11. Üç giriş değişkenli Elman modelinde Bayesian-Regulazition algoritması kullanarak elde edilen simulasyon.....	85
Şekil 4.11. Üç giriş değişkenli NARX modelinde Levenberg-Marquardt Algoritması kullanarak elde edilen simulasyon.....	86
Şekil 4.12. Üç giriş değişkenli NARX modelinde Bayesian-Regulazition Algoritması kullanarak elde edilen simulasyon.....	87

RESİMLERİN LİSTESİ

Resim	Sayfa
Resim 2.1. Demir çekirdek etrafına sarılmış iki farklı bobinin meydana getirdiği transformatör.....	10
Resim 2.2. Isı transfer mekanizmaları	17
Resim 3.1. Biyolojik sinir hücresi yapısı	28
Resim 4.1. 5 KVA lık kuru tip güç transformatörü için kurulan deney seti	74
Resim 4.2. Omik yük bankları	74
Resim 4.3. Ölçüm için kullanılan güç analizörleri.....	75
Resim 4.4. 3 KVA lık kuru tip güç transformatörü için kurulan deney seti	82
Resim 4.5. Ölçüm için kullanılan güç analizörü ve datalogger	82

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış bazı simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur

Simgeler	Açıklama
A	Manyetik malzemenin kesiti
B	Manyetik akı yoğunluğu
B	Bias
C_{el}	Elektriksel direnç
c_{fe}	Transformatörün çekirdeğinin termal kapasitesi
c_{load}	Transformatör yükünün termal kapasitesi
c_{tm}	Transformatörün yapısal parçalarının termal kapasitesi
c_{th}	Termal kapasite
c_{wind}	Transformatörlerin sargılarının termal kapasitesi
E(w)	Ortalama karesel hata fonksiyonu
f	Frekans
F	Kuvvet
F(s)=F(Q_N)	Aktivasyon foksiyonu
H	Manyetik alan şiddeti
I	Birim matris
LW	Yapay sinir ağlarında tabaka ağırlıkları
i	Akım
i_a= i_b	Girdap akımı
i₁	Birincil sargı akımı
i₂	İkincil sargı akımı

Simgeler	Açıklama
J	Jacobian matrisi
K_h	Magnetik malzemenin cinsine, hacmine ve akı yoğunluğunun birimine bağlı bir sabit
I_m	Manyetik akımın manyetik malzemede takip ettiği yolun boyu
N	Yapay sinir ağlarında toplam örnek sayısı
N_1	Birincil sarım sayısı
N_2	İkincil sarım sayısı
P_h	Histerisiz kaybı
$P(d,y)=\zeta(k)$	Hata miktarı
Q	Isı transferi
q_{fe}	Demir kayıpları
q_{load}	Yük kayıpları
q_s	Stray kayıpları
q_{tot}	Toplam kayıplar
q_{wind}	Sargı kayıpları
R	Çekirdek Relüktansı
$R_{Fe-wind}$	Demir-sargı arasındaki direnç
R_{th}	Termal direnç
$R_{wind-amb}$	Sargı-ortam sıcaklığı arasındaki direnç
t_{di}	Yapay sinir ağlarında hedeflenen çıkış
t_i	Yapay sinir ağlarında tahmin edilen çıkış
θ_{Fe}	Transformatör demir sıcaklığı
θ_{amb}	Çevre sıcaklığı

Simgeler**Açıklama** θ_{Wind}

Transformatör sargı sıcaklığı

 μ

Geçirgenlik(Permeabilite)

 μ_r

Manyetik devrenin öz direnci

 μ_o

Havanın geçirgenliği

 Φ

Manyetik akı

 $X_k=x(t)$

Yapay sinir ağları girişleri

 $W_k=IW$

Yapay sinir ağları giriş ağırlıkları

 $W(k+1)$

Ağ ağırlık vektörü

 $Y(k)=y(t)$

Yapay sinir ağları çıkışları

 z^{-1}

Birim gecikme

Kısaltmalar**Açıklama****ANSI**

Amerika Ulusal Standart Enstitüsü

CPU

Merkez İşlem Birimi(Central Processing Unite)

IEEE

Instute of Electrical and Electronics Engineers

LVQ

Vektörel Örneklemeli Öğrenimli Ağ

MLP

Çok Katmanlı Yapay Sinir Ağları

MMF

Magneto Motor Force

MSE

Mean Square Error

NARXNonlieer Autoregressive Network with
Exogenous Input Models

Kısaltmalar	Açıklama
PCP	Poliklorlu Bifenil
RBFNN	Radyal Tabanlı Fonksiyonlu Ağlar(Radial Basis Function Network)
RMSE	Root Mean Square Error
YSA	Yapay Sinir Ağları

1. GİRİŞ

Güç sistemlerinin temel görevi enerjiyi en ekonomik şekilde kabul edilebilir bir güvenilirlik ve kalite seviyesinde nihai kullanıcıya kadar sağlamaktır. Sistemin güvenilirliği de sistemi oluşturan elemanların güvenilirliğine bağlıdır. Bilindiği üzere güç sistemlerinde en temel ve önemli donanım güç transformatörleridir. Arızaların önlenmesi ve trafoların iyi işletme şartlarında çalıştırılması enerji sistemlerinde çok önemlidir [1].

Elektrik piyasa yapısının yeniden düzenlenmesi ile liberal piyasa yapısına doğru hızla ilerlerken finansman dengelerini iyi sağlayabilmeleri için geçmiş yıllara nazaran sektör içinde daha az yatırıma pay ayırmaları halihazırdaki mevcut ekipmanlardan optimum fayda ile işletmecilik yapma isteği önemi tartışılmayacak kadar fazla olan güç transformatörlerinde dikkatleri toplamıştır. Mevcut ekipmandan elde edilecek faydanın arttırılmasının gün geçtikçe sektör içinde talep edilmesi, yatırımların ertelenmesi, bakım ve işletme masraflarının azaltılması isteği elektrik piyasasının ana stratejisi haline gelmiştir.

Son yıllarda küçük ve orta güçlü uygulamalar için kullanılan transformatör tip çeşitliliğinde dikkate değer artış gözlemlenmiştir. Bunlardan en önemli tipleri yağ dolu transformatörler, gaz izoleli transformatörler ve kuru tip transformatörlerdir. Yağ dolu ve gaz izoleli transformatörlerde, gaz ve yağ izolasyon ve soğutucu madde olarak davranır. Kuru tip transformatörlerin şansızlığı soğutma için herhangi bir akışkanın olmamasıdır.

Güç merkezleri, hastaneler, okullar, çok katlı yapılar, kağıt ve çelik fabrikaları, maden ve altgeçitler gibi birçok ticari ve endüstriyel uygulamalarda sıvıya daldırılan transformatörler yerine kuru tip transformatörler tercih edilmektedir. Kuru tip transformatörlerin bir çok avantajı vardır [2].

Bu avantajlar:

- Kuru tip transformatörü kullanarak yangın riskini önemli derecede azaltırız. Bazı sıvı daldırmalı transformatörler ticari ve endüstride kaçınılan yanıcı yağlarla doldurulmaktadır.
- Çevresel olarak kuru tip transformatörler daha çekicidir. Sıvı daldırmalı transformatörlerden özellikle PCB dolu transformatörler olası sızıntılardan dolayı çevreyi tehdit etmektedir. Tehlikeli kimyasal sızıntıları içme suyuna ve toprağa bulaşacağında temizleme maliyetleri fazlaca olabilir.
- Kuru tip transformatörlerin sargıları sıvı daldırmalı transformatörlerinkinden daha büyük olmasına rağmen, soğutucu radyatörlere ihtiyaç duymadığından toplam büyüklüğü daha küçüktür.
- Kuru tip transformatörlerin montaj maliyeti daha düşüktür. Bazı zaman sıvı daldırmalı transformatörler daha fazla toplam montaj maliyeti getiren ek montajlara ihtiyaç duyabilirler. Örneğin sıvı daldırmalı transformatörler sızıntı oluşumunu engellemek için toplama çukuruna ihtiyaç duyar.
- Kuru tip transformatörlerin bakımı daha kolaydır ve işletim maliyeti daha azdır. Sıvı ile soğuyan transformatörler için, çekirdek ve bobinler tamire ihtiyaç duyulduğunda tanktan çıkarılmak durumundadır. Bu da karmaşıklığı ve maliyeti artırır.

Birkaç vatlık transformatörlerden en büyük güç transformatörlerine kadar işletme sırasında karşılaşılan en büyük sorun çekirdek ve sargılarda oluşan kayıplardan dolayı meydana gelen ısınmadır. Isınmanın kullanılan yalıtkan malzemesi üzerine etkisi transformatörün ömrünü belirleyeceğinden, izolasyon malzemelerinin iyi seçilmesi gerekir. Bu nedenle çeşitli güçlerde ve soğutma düzenlerindeki transformatörler için belirlenmiş olan sınır ısınmayı sağlayan yalıtkan sınıfları çeşitli şartnamelerden saptanır (TS 10901 EN 60076-2,1998) Ayrıca transformatör yüklenirken yine bu yalıtkan sınıfının dayanabileceği sınır sıcaklıklar göz önüne

alınır. Ancak standartlarda belirtilmiş olan bu sınır sıcaklıklar, transformatör anma gücünde çalışırken sargılardan küçük zaman aralıklarında doğru akım geçirilmesiyle yapılan ısınma deneyi sonucunda elde edilmiş ortalama sıcaklıklardır. Transformatör sargısının üst kısmında bulunan değeri deneysel olarak ölçülemeyen standartlarda belirtilen ortalama sıcaklıkların üzerinde daha büyük sıcaklıklar oluşmaktadır. Sargının üst tarafında bulunan ve ortalama sıcaklığın üzerinde olan bu noktaların değeri ve yerinin tespiti için birçok deneysel ve teorik çalışmalar yapılmıştır. Yapılan çalışmalarda bazı varsayımlar yapılarak formüllerle sıcak nokta sıcaklığını belirlemek mümkün olabilmektedir. Transformatörün yükleme sınırını belirleyen sıcak nokta sıcaklığını doğrudan ölçümlerle bulmak zordur. Sargının en sıcak noktasını direkt bulmak için birçok araştırmalar yapılmış ve bu araştırmalarda yetersiz kalmıştır. Fluoroptik termometrelerle yapılan ölçümlerde kararsızlıklar görülmüştür. Sargıya imalat sırasında yerleştirilen fiber optik sensörler kullanılarak doğrudan ölçüm yapılabilmesi için, optik sensörlerin doğru yerlere yerleştirilmesini sağlamak üzere matematiksel modeller geliştirilmiştir. Hesaplanan sıcaklık dağılımına göre yerleştirilen optik sensörlerle en doğru sonuca ulaşabildiği sonucuna varılmıştır. Bilgisayar destekli tasarımın hızla ilerlemesiyle birlikte, sayısal yöntemler kullanılarak güç transformatörlerinde detaylı ısı dağılımı büyük doğrulukla elde edilebilir [3].

Standart sınıftaki kuru tip transformatörler için verilen standart ortalama sıcaklık artışı 80,115 ve 150 dereceyken en sıcak nokta sıcaklığı sırayla maksimum 150,185 ve 220°C dir [4]. Transformatörlerin çeşitli çalışma sıcaklıklarında muhtemel ömrü tam olarak bilinmemektedir. İzolasyon ömrü üzerinde çalışma sıcaklığının etkilerini hesaplarken, aşırı yüklenmeler veya yüksek ortam sıcaklığından dolayı oluşan normal çalışma sıcaklığından daha yüksek sıcaklıklar transformatörün izolasyonuna zarar verir ve dolayısıyla transformatörün ömrünü azalttığı konusunda görüş birliği vardır. Bu nedenle transformatör sargılarının normal çalışma koşulları altında sargı ısınmasının sargı yüksekliği boyunca eşit olmamasından dolayı, en çok ısınan yerin sıcaklığının bilinmesi büyük önem taşır. Bu ısınmayı tespit etmek, ancak sargı yüksekliği boyunca detaylı ısı analizi yapmakla mümkündür. Böylece transformatör sargısının en sıcak yeri tespit edilebilirse transformatörün aşırı yüklenme süreleri ve

sınırları artırılabilir. Isınmanın hangi kısımlarda daha fazla olduğunu ve değerlerinin bilinmesi için, sıcaklık dağılımının bilinmesine ihtiyaç vardır.

Bu çalışmada kuru tip bir sargı sıcaklığını tahmin etmek için yapay sinir ağı yöntemi kullanılmıştır. Yapay sinir ağı kullanılması amaç kompleks ve lineer olmayan yapılarda öğrenme yeteneğidir. Hem modelleme de daha hızlı ve herhangi bir algoritmayı model üzerinde kullanmada bize daha fazla kolaylık sağlar. ANSI/IEEE numeriksel teknikleri kullandığımız zaman kesin ve mevcut olmayan transformatör parametrelerine ihtiyaç duyarız. Klasik yöntemlerle modelleme yaptığımızda büyük miktarlarda matematiksel formüllerle uğraşmak zorunda kalacağız. Klasik algoritmalarda tam olarak tanımlı bir çözüm yolu olmayan problemler çözülemezken yapay sinir ağı sayesinde problemler çözüm yöntemi hakkında herhangi bir bilgi verilmeksizin çözülebilir. Yapay sinir ağlarının bu tip problemleri çözebilmesi için gereken tek şey örnek girdiler için sonuçların verilmesidir.

Bu çalışmada; 1. bölümde çalışmanın amacı anlatılmıştır. 2. bölümde transformatörlerin yapısı, çalışma ilkeleri, kayıpları, transformatörün termal ve dinamik modelleri ile soğutma çeşitleri anlatılmıştır. 3. bölümde yapay sinir ağı, yapay sinir ağlarının yapısı, üstünlükleri, dezavantajları, sınıfları, öğrenme algoritma çeşitleri ve bir yapay sinir ağı yapısı nasıl tasarlanır anlatılmıştır. 4. bölümde kuru tip transformatörün sargı sıcaklık davranışının yapay sinir ağı kullanarak modelleme sonucunda elde edilen sonuçlar verilmiştir.

2. TRANSFORMATÖRLER


2.1. Transformatörlerin Çalışma İlkesi

Transformatörler hareket etmeyen elektrik makinelerinden olup sargılardan birisine uygulanan bir alternatif gerilimi elektromanyetik indüksiyon yolu ile diğer sargılarda aynı frekansta fakat değişik gerilim ve akım dönüştüren aletlerdir. Hareketli parçaları olmadığından ve manyetik kayıpları konstrüksiyon yapısı ile en aza indirgenmesi sonucu elektrik makineleri içerisinde verimi en yüksek olan elemanlardır.

Transformatörlerin 3 ana fonksiyonu vardır:

- a) Gerilim veya akımı düşürmek veya yükseltmek
- b) Empedans uygunlaştırmak
- c) İki sistemi birbirinden yalıtma [1].

Transformatörün temel çalışma ilkesini 1831’de Michael Faraday bir deney sonucunda bulmuştur. Faraday demir bir halkanın çevresine iki yalıtkan tel sarmış, sargılardan birinin uçlarını güçlü bir bataryaya, diğer sargının uçlarını da elektrik akımını algılamada kullanılan bir galvanometreye bağlamıştır. Faraday bataryayı devreye aldığı veya devreden çıkardığı zaman galvanometre göstergesinde hafifçe sapma olduğunu tespit etmiştir; bundan yola çıkarak ikinci sargıda anlık bir akım indüklendiğini düşünmüştür. Ayrıca birinci sargıda zamanla değişen bir akı geçirildiğinde ikinci sargıda indükleme olduğu aksi takdirde herhangi bir değişiklik olmadığı gözlemlenmiştir. Faradayın bu düşüncesi bütün transformatörlerin çalışma ilkesi olmuştur [5].



Şekil 2.1. İdeal Transformör Modeli a)Fiziksel Model, b)Toroidal biçimli Magnetik Devre

Şekilde görüldüğü üzere birincil ve ikincil sargıdan bir akım akmaktadır. Her bobindeki akım yönlerine dikkat edersek pozitif akım yönü sayfa dışına, negatif akım yönü de sayfa içine doğrudur [6].

Bir transformatörün birincil ve ikincil sargıdan geçen akımların bağıntısı;

$$MMF_{bobin1} = +n_1 i_1 \quad (2.1)$$

$$MMF_{bobin2} = +n_2 i_2 \quad (2.2)$$

Transformatörün çekirdeğinin relüktansı


$$R = \frac{l_m}{\mu A} \quad (\mu = \mu_r \cdot \mu_0) \quad (2.3)$$

Ampere kanununa kullanarak kapalı bir hat üzerindeki akının meydana getireceği toplam MMF(amper-sarım)

$$\phi.R = n_1 i_1 - n_2 i_2 = F \quad (2.4)$$

İdeal bir transformatörde çekirdeğin relüktansı sıfır olduğundan ($\mu_r = \infty$) $F=0$ olur ve birincil sargıdan geçen akım

$$i_1 = \frac{n_2}{n_1} i_2 \text{ 'dir.} \quad (2.5)$$



Şekil 2.2. İdeal transformatörün sembolik modeli

Transformatörün birincil sargılarına alternatif bir gerilim uygulandığında, bu sargı değişken bir manyetik alan oluşturur. Bu alan ikincil sargının bulunduğu demir nüve üzerinden devresini tamamlar. Kesilen sargılar üzerinde alternatif bir gerilim indüklenir. Birincil ve ikincil sargılar arasında elektriksel hiçbir bağlantı olmadığı halde ikincil tarafında manyetik indüksiyon ile bir gerilim oluşmuştur.

Faraday kanununa göre her sargıda indüklenen gerilimlerin ani değeri

$$e_1 = N_1 \frac{d\phi}{dt} \quad (2.6)$$

Bobinlerin direncinin sıfıra eşit olduğu kabul edilirse, bu durumda $v_1=e_1$ olur. Bu durumda v_1 (primere uygulanan anlık değer) sinüzoidal bir şekilde değiştiği için, ϕ_m değeri de v_1 frekansına göre değişken olur.

$$\phi_m = \phi_{mp} \sin \omega t \quad (2.7)$$

Burada ϕ_{mp} toplam manyetik akının tepe değeridir ve $\omega = 2\pi f$ rad/ sec. ϕ_m değerini Eşitlik 2.6'da yerine koyarsak;

$$e_1 = N_1 \omega \phi_{mp} \cos \omega t \quad (2.8)$$

Primerde indüklenen emk' nin rms değeri olan e_1 , Eşitlik 2.8'de tepe değerini $\sqrt{2}$ bölerek elde edilir.

$$E_1 = 4.44 N_1 f \phi_{mp} \quad (2.9)$$

Sekonder sarımında indüklenen emk ise

$$e_2 = N_2 \frac{d\phi}{dt} \quad (2.10)$$

Burada N_1 ve N_2 her bir sargının sarım sayısı ve ϕ de her iki sargıyı halkalayan akının ani değeridir. Yukarıda verilen iki denklemi birbirine oranlarsak transformatörün dönüştürme oranını bulmuş oluruz.

$$\frac{u_1}{u_2} = \frac{N_1}{N_2} = a \quad (2.11)$$

2.2. Transformatörlerin Sınıflandırılması

Transformatörler çeşitli özellikleri göz önüne alınarak sınıflandırılırlar. Bu sınıflandırmalar aşağıda görüldüğü şekilde özetlenebilir:

1. Manyetik nüvenin yapılış şekline göre:

- a) Çekirdek tipi
- b) Mantel tipi
- c) Dağıtılmış tip nüveli

2. Faz sayısına göre:

- a) Birincil ve ikincil sargılar aynı faza sahip olanlar
- b) Birincil ve ikincil sargılar farklı faza sahip olanlar

3. Soğutma şekline göre:

- a) Kuru transformatörler
- b) Yağlı transformatörler

4. Sargı tiplerine göre

- a) Silindirik sargı
- b) Dilimli sargı

5. Çalışma prensibine göre

- a) Sabit akımlı
- b) Sabit gerilimli

6. Sargı durumlarına göre

- a) Yalıtılmış sargılı
- b) Oto transformatörler

7. Soğutucu cinsine göre

- a) Hava ile soğutma



- b) Yağ ile soğutma
- c) Su ile soğutma

8. Kullanış amaçlarına göre

- a) Güç transformatörleri
- b) Ölçü transformatörleri
- c) Çeşitli aygıt ve makinelerinde kullanılan transformatörler [5].

2.3. Transformatör Kayıpları

Transformatördeki oluşan güç kayıpları ısı şeklinde ortaya çıkar. Bu kayıplar manyetik indüksiyondan dolayı oluşan çekirdek kayıpları, sargılardan geçen elektrik akımı sonucu oluşan bakır kayıplarından oluşur.




Resim 2.1. Demir çekirdek etrafına sarılmış iki farklı bobinin meydana getirdiği transformatör

2.3.1. Boştaki kayıplar


Transformatöre gerilim uygulandığında transformatör yükünden bağımsız olarak ortaya çıkan yüksüz kayıplar transformatörün nüvesinde meydana gelmektedir. Yüksüz kayıplar sabittir ve transformatörün sekonderi açık devre edilerek ölçülür. Yoğun manyetik alana maruz bırakılan demir, çelik, nikel vb. ferromanyetik malzemelerde histerisiz ve eddy (fuko) kayıpları oluşmaktadır. Ferromanyetik malzemelerde oluşan bu kayıplar ısıya dönüşmekte ve malzemenin çok hızlı bir şekilde ısınmasına yol açmaktadır.

Histerisiz Kayıpları: Sargıya değişken gerilim uygulandığında sargıdan geçen akımın yönüne göre demir nüvedeki magnetik dipollerin yönü değişir. Magnetik dipollerin malzeme içerisinde yön değiştirmesi sürtünmesiz olmayacağından bir enerji kaybı oluşur. Bu kayıpları B-H histerisiz eğrisinden görebiliriz.



Şekil 2.3. B-H histerisiz eğrisi

H maksimum değerinden itibaren akım adım adım azaltıldığında magnetik alanında aynı oranda azalmaya başlamadığı görülür. Mıknatıslanmadan önce malzemenin yapısında bulunan düzensiz moleküller akımın artması ile enerji kazanarak manyetik alan yönünde dizilirler [5].




Şekil 2.4. Kalıcı mıknatıslıkta moleküllerin durumu a) Mıknatıslığı olmayan demir b) Manyetik alan içindeki akınatıslık c) Kalıcı mıknatıslık

Daha sonra akımın sıfır olması durumunda moleküllerin çoğunluğu eski yapılarına döner. $H=0$ olmasına rağmen demirde artık bir akı kalır. Çünkü arka arkaya dizilmiş olan moleküllerden bazıları eski haline döneemezler. Biz bu olaya kalıcı mıknatıslık diyoruz. Bunun anlamı artık demirde permanent magnetlerin oluştuğudur. Demirdeki bu artık akı yoğunluğuna Remananz akı denir. Remananzı yok etmek için gerekli olan alan şiddetine de “Kuarsitif Kuvvet” denir. Manyetik bakımdan yumuşak ve sert malzemelerin histerisiz kayıpları birbirinden farklıdır. Histerisiz kayıpları

$$P_h = K_h \cdot f \cdot B_m^x \quad (2.12)$$

denklemleri ile bulunur. Histerisiz kaybı malzemede kendisini basınç şeklinde gösterir. Magnetostroksiyon denilen bu olay sonucunda nüvenin boyu uzar veya kısalmır. Histerisiz kayıpları, özel demir alaşımların kullanılmasıyla ve demirin haddelenmesiyle azaltılabilir. Soğukta haddelenmiş ve kristalleri manyetik yönlendirilmiş transformatör saclarında demir kayıpları, sıcakta haddelenenlere göre daha küçüktür. Bu nedenle soğukta haddelenmiş saclar tercih edilir.

Eddy(Girdap) Akımları Kayıpları: Magnetik çekirdek demir alaşımlı bir malzemedir ve iyi bir elektriksel iletken olduğundan dolayı manyetik alan, çekirdek materyalinin içerisinde kendiliğinden girdap akımlarının akmasına neden olacaktır ve burada joule kaybı meydana getirecektir. Buna fuko kaybı adı verilir [7].



Şekil 2.5. Demir gövdede meydana gelen eddy akımının yönleri

Ferromanyetik malzemeden yapılmış plaka sacın kalınlığı olan t arttığında levhanın direnci azalacağından, fuko akımı artacak ve joule kaybı da akımın karesi ile artacaktır. Bunun sonucunda sac aşırı derecede ısınacak ve üzerinde taşıdığı sargıların izolasyonuna zarar verebilecek seviyeye ulaşarak makinenin sağlıklı çalışmasını tehlikeye sokacaktır.

Fuko akımlarının küçük tutmanın yolu sac kalınlığının mümkün olduğu kadar ince yapılması ve dolayısıyla levhanın direncinin arttırılmasıdır. Fakat bazı durumlarda bu bile yeterli olmamaktadır. Girdap akımına karşı gösterilen direncin arttırılması için sacların bir tarafı yalıtılarak arka arkaya dizilirler. Bu şekilde akımın sacdan saca geçmesi engellenmiş olur [5].

2.3.2. Yüklü kayıplar

Bakır Kayıpları

Transformatörün ikinci devresinde bir yük bağlandığı zaman, hem primer hem de sekonder sargıdan bir akım geçer. Bu akımlar sargıların dirençlerinden dolayı bir ısı kaybı oluştururlar. Bu kayıplara bakır kayıpları adı verilmektedir. Bakır kayıpları kısa devre deneyi ile bulunur. Transformatörün ikincil sargısına bir yük bağlandığı zaman hem birincil sargıdan hem de ikincil sargıdan bir akım akar (I^2R). Bakır kayıplarına joule kayıpları da denilmektedir.

Transformatör sargılarının yalıtımında kullanılan izolasyon maddelerinin belirli bir sıcaklık sınırı vardır. Transformatörün bu sıcaklık değerinin üzerinde çalışması sargı izolasyonlarının bozulması, delinmesi ve kısa devre olması gibi önemli sakıncalar ortaya çıkarmaktadır. Bu ısının dış devreye aktararak transformatör sargı sıcaklığına düşürülmesi gerekir. Bunun çeşitli soğutma yöntemleri kullanılır.

Bakır Sargılarda Deri Etkisi

Tıpkı çekirdekte olduğu gibi bakır iletkenlerde de deri etkisi oluşur. Zamanla değişen $i(t)$ akımını taşıyan bir bakır iletkeni ele alalım. Bu akım manyetik alan oluşturur ve

bu manyetik alan girdap akım kayıplarını üretir. Bu girdap akımları, telin iç kısmında uygulanan $i(t)$ akımına ters yönünde akar ve böylece iletkenin iç kısmından akan akıma ve sonuç olarak ortaya çıkan manyetik alanı engelleme eğilimindedir. Sonuç olarak toplam akı yoğunluğu iletkenin yüzeyinde en büyüktür ve iletkenin iç kısmına doğru olan mesafe ile üstel olarak azalır. Karakteristiğın azalma uzunluğu,

$$\delta = \sqrt{\frac{2}{w\mu\sigma}}$$

eşitliğiyle verilen deri kalınlığıdır. Sargıda kullanılan iletken kesitinin

boyutları deri kalınlığından belirgin olarak büyükse, iletken tarafından taşınan akımın büyük bir kısmı yüzeyde, yaklaşık bir deri kalınlığında, bağlı olarak ince bir tabakayla sınırlanacaktır. Bunun sonucu olarak akım akışı için olan etkin kesit alanı, iletkenin geometrik kesitiyle kıyaslandığında küçük olduğundan, iletkenin etkin direnci d.a direncinden çok daha büyük olacaktır. Bu durumda sargılara d.a uygulanması durumuna göre daha büyük bir sargı kaybı olacağını göstermektedir [8].

2.3.3. Dielektrik kayıpları

Sarım yalıtımındaki dielektrik kayıpları, yüksüz (boştaki) kayıp bileşenlerine, histerisis kayıpları ve farklı indüksiyon akımlarından oluşan demir kayıplarına göre genellikle ihmal edilir. Fakat büyük dağıtım transformatörleri için yapılan doğru ölçümler, %1-2'lik boştaki kayıpları temsilen birkaç onluk watt değerinde dielektrik kaybının bulunabileceğini göstermektedir. Bu durum, birleştirmenin farklı seviyelerinde boştaki kayıtlı kayıplar arasındaki farklara bakıldıktan sonra sonuçlandırılır. Bu sıranın önemli bir farkı, yalıtım malzemesinin dielektrik kaybı açısının sonuçlarıyla birlikte, ancak sarım yalıtımının dehidrasyonu (su kaybıyla) açıklanabilir.

2.3.4. Transformatörlerde kaçak kayıplar

Transformatörlerdeki yük kaybı, sarımların ohm direnci ve kaçak manyetik alan kayıplarından kaynaklanan kayıplar nedeniyle oluşur. Bu kaçak kayıpları yüklü ve yüksüz sarımlarda, sıkıştırma levhalarında ve transformatör tanklarında görülür ve kaçak manyetik alan ve bobin iletkenlerini saran manyetik alana bağlıdır.

Transformatörlerdeki toplam kaçak kaybı genellikle şu elemanlardan oluşur:

- (a) Sarımlardaki kaçak manyetik alandan kaynaklanan transformatör tankındaki kaçak kayıp.
- (b) Tanktaki bobin iletkenlerinden kaynaklanan kaçak kayıp.
- (c) Sarımlardaki kaçak manyetik alandan kaynaklanan sıkıştırma çatısındaki kaçak kayıp.
- (d) Sıkıştırma levhasındaki bobin iletkenlerinden kaynaklanan kaçak kayıp.
- (e) Yüklü sarımlardaki kaçak kayıp.
- (f) Yüksüz sarımlardaki kaçak kayıp.

2.3.5. Kaçak manyetik akılar

Bir transformatörün primerine alternatif bir gerilim uygulandığında, bu sargıdan geçen akımın oluşturduğu manyetik akının tamamı ikinci devre iletkenlerini kesmez. Akımın küçük bir kısmı devresini havadan tamamlar. Devresini havadan tamamlayan bu akıların tamamına “ Kaçak akılar ” denir. Kaçak akı ne kadar çok olursa faydalı akı o kadar azalır. Bunun sonucunda ikinci devrede siper başına indüklenen gerilim birinci devrede indüklenen gerilimden çok daha az olur. Bunun sonucunda sekonderde emk azalır. Boşta çalışma durumunda kaçak akı faydalı akının % 5’i kadardır.

Primer ve sekonder sargılardan geçen akımların oluşturdukları kaçak akılar, faydalı akıyı azalttıklarından, primer ve sekonder iç gerilimlerinin düşmelerine neden olmaktadır. Bunun sonucunda sekonder çıkışında gerilim azalması görülür. Kaçak akıların oluşturdukları gerilim düşümleri tam indüktif özellikte olup, akımdan 90^0 ileridedir. Kaçak akıları transformatör devresine seri bağlanmış reaktanslar şeklinde gösterebiliriz. Bu reaktanslar primer ve sekonder için ayrı ayrı gösterilir ve “Kaçak Akı Reaktansı” adını alırlar. Kaynak makinelerinde, kısa devre akımlarının azaltmada, paralel çalışmayı kolaylaştırmada ve ark fırınlarının güç devrelerinde kullanılan transformatörün kaçak reaktansı büyük istenmektedir [9,10].

2.4. Transformatörlerin Soğutulması


Transformatörlerin çalışmasında demir gövdede oluşan histerisiz kayıpları ve fuko kayıpları ile sargılarda meydana gelen joule kayıpları, sargıların ve çekirdeğin sıcaklıklarını belirli bir zaman içerisinde yükseltir. Sıcaklığın yükselmesini önlemek için transformatörde üretilen ısı enerjisini transformatörden transfer etmek gerekir. Bunu da soğutma işlemiyle yaparız. Isı enerjisinin transferi kondüksiyon, konveksiyon ve ışıınım yollarıyla olmaktadır.

Kondüksiyon ya da iletim, cismin bir tarafından diğer tarafına ısının iletilmesi ile oluşan ısı transferinin bir çeşididir. Isı transferi daima yüksek sıcaklıktan düşük sıcaklığa doğrudurlar.

Konveksiyon ya da taşınım, katı yüzey ile akışkan arasında gerçekleşen ısı transferinin bir çeşididir. Akışkan içindeki akımlar vasıtası ile ısı transfer edilir.

ışıınım yolu ile ısı transferi fotonlar (elektromanyetik radyasyon) yolu ile olan ısı transferidir.

Isı her zaman daha sıcak bir maddeden daha soğuğuna yayılır. Gerçekte hızlı hareket eden moleküller enerjilerinin bir kısmını yavaş olanlarına aktarır. Böylece daha hızlı moleküller biraz yavaşlar ve yavaş olanlar hızlanır.



Resim 2.2. Isı transfer mekanizmaları

Bu ısının oluştuğu yerden çevreye iletilmesinde soğutucu ortam olarak hava veya yağ kullanılmaktadır [5].

Transformatörlerde üç çeşit soğutma türü vardır:

- Soğutan Ortama Göre Soğutma
- Temas Sıklığına Göre Soğutma
- Transformatör Tipine Göre Soğutma

2.4.1. Transformatörlerde soğutan ortama göre soğutma türleri

Bu tür soğutma hava ile soğutma ve yağ ile soğutma olmak üzere ikiye ayrılır. Soğutmanın hava olduğu soğutma türü kuru tip transformatörlerde uygulanır. Soğutan havadır ve iyi bir izolasyon malzemesidir (delinme dayanımı 30Kv/cm). Hava, bobinleri ve demir çekirdeği yalayarak havaya yükselir ve yerini soğuk havaya bırakır. Böylece soğutma işlemi gerçekleşmiş olur.

Soğutmanın yağ olduğu soğutma türü de yağlı tip transformatörlerde kullanılır. Yağın yalıtkanlığı havaya göre 5-7 kat fazla(Delinme dayanımı 150-250kV/cm) olduğundan yüksek gerilimli transformatörlerde kullanılır. Bu soğutma türünün sakıncalı yanı yağın rutubet kapan bir yapıya sahip olmasıdır. Transformatörün emniyetli çalışması açısından, transformatör yağının delinme dayanımı belli aralıklarla kontrol edilmelidir.

2.4.2. Transformatörlerde temas sıklığına göre soğutma türleri


Doğal soğutma ve zorlanmış soğutma olmak üzere iki şekilde uygulanan bu yöntemde soğutan ile soğutulan ortamın temaslarındaki sıklık önemlidir. Zorlanmış soğutmada temas sıklığını arttırmak için soğutan maddeye dışarıdan bir güç uygulanarak soğutulan madde üzerine gönderilir. Örneğin hava bir vantilatör yardımıyla soğutulan maddenin üzerine üfletilirse bu zorlanmış soğutma olur. Zorlanmış soğutma tabi soğutmanın yetersiz kaldığı durumlarda uygulanır.

2.4.3. Transformatörlerin tipine göre soğutma türleri


Kuru tip transformatörlerde soğutma

Bu tip transformatörlerde genellikle doğal soğutma uygulanır. Çünkü kuru tip transformatörler küçük güçlüdür ve kendi kendilerine soğuyabilmektedirler. Yüksek gerilimler için kuru tip transformatör yapmak havanın delinme dayanımının düşük olması nedeniyle oldukça zordur. İzolasyon ve güç problemleri ile karşılaşılır.

Kuru transformatörlerde alçak gerilim sargısı epoksi reçine denilen bir malzeme ile havasız ortamda kaplanır. Bu ortamda yapılan kaplamada hava kabarcığı kalmadığından delinme dayanımı yüksek bir izolasyon yapısı elde edilir. Bu şekilde daha yüksek gerilimlere(30 kV) ve güçlere(2500 kVA) çıkılabilir. Rutubetli ve nemli ortamlarda rahatlıkla kullanılabilir [5].



Şekil 2.6. Tabii soğutmanın çalışma prensibini gösteren blok diyagramı




Şekil 2.7. Hava ile zorlanmış soğutmanın çalışma prensibini gösteren blok diyagramı

Yağlı tip transformatörlerde soğutma

Yağlı tip transformatörler, orta ve büyük güçler için üretilirler ve soğutma tipi doğal soğutma veya zorlanmış soğutma olabilir. Transformatörün içindeki yağın kendiliğinden transformatöre çarparak transformatörü soğutması doğal yağlı soğutmadır. Transformatör içindeki yağın bir pompa ile basılması ile transformatörün soğutulmasına zorlanmış soğutma denir. Kendi kendine soğuyan transformatörlerde çevreye fazla ısı vermek ve dolayısıyla sargı ve demir sıcaklıklarını belirli sınırlar içerisinde tutmak için bazı tedbirler almak gerekir. Bu bakımdan ufak güçteki transformatörlerde, yağ kabini sacı düz sactan yapılırken orta

güçlerde dalgalı ve daha büyük güçlerde dalgalı kazan yüzeyinin çevreye verdiği ısı yetmez ve bu gibi hallerde kazan yüzeyine borular yerleştirmek gerekir.



Şekil 2.8. Tabii soğutmalı yağlı transformatör

Yağlı transformatörlerde soğutucu ortam yağ olup; yağ ısının sargı ve demirden kazan yüzeylerine taşınmasını sağlar. Havaya göre ısı iletimi daha yüksek olduğundan, kuru transformatörlere oranla daha kuvvetli bir soğutma etkisi meydana getiren yağ daha iyi bir izolasyon sağlar. Transformatörlerde soğutma gücünü arttırmak için radyatör kullanılarak yüzey genişletilir. Bu soğutma gücünde yeterli olmazsa radyatörü soğutmak içinde vantilatör kullanılır.

Çizelge 2.1. Transformatörün soğutma tipi ve soğutucusu türleri

Soğutucu Madde	Simge	Soğutucu Maddenin Dolaşımı	Simge
Madensel Yağ veya Sentetik Yalıtkan Sıvı	O	Doğal (Tabii)	N
Yanıcı Olmayan Sentetik Yalıtkan Sıvı	L	Cebri	F
Gaz	G	Yağlı	D
Su	W		
Hava	A		


2.5. Transformatörün Termal-Elektriksel Benzeşimin Temel Teorisi

Bir termal proseste ısı transferi enerji dengesi denklemi kullanılır. Güç transformatöründeki termal davranışı analiz etmek için sistemin termal anolojisini göz önüne alırsak [11].

$$q = C_{th} \frac{d\theta}{dt} + \frac{(\theta - \theta_{amb})}{R_{th}} \quad (2.13)$$

Bu eşitlik Kirchhoff ve Ohm yasası temel alınarak basit bir RC devre anolojisine dönüştürürsek;

$$q = C_{el} \frac{dv}{dt} + \frac{v}{R_{el}} \quad (2.14)$$



Şekil 2.9. Elektrik ve termal-elektrik devresi a) Analog devresi b) RC devresi


Çizelge 2.2. Termal-elektriksel benzeşim tablosu

Termal	Elektriksel
Isı transfer oranı, q , watts	Akım, i , amps
Sıcaklık, θ , derece	Voltage, v , volts
Termal direnç, R_{th} , deg©/watt	Elektriksel direnç, R_{el} , ohms
Termal kapasite, C_{th} , joules/deg©	Elektriksel kapasite, C_{el} , farads

2.6. Kuru Tip Transformatörün Dinamik Termal Modellemesi

Transformatördeki güç kayıpları ısıya dönüşür. Bu kayıplar çekirdek kayıpları, sargılardaki direnç kayıpları ve stray kayıplarından meydana gelir [11, 12, 13, 15].

Kuru tip transformatörlerin termal eşdeğer devresi lineer olmayan ısı dirençleri, ısı iletkenleri, ısı kapasitörleri ve ısı akım kaynakları içermelidir. Güç transformatörünün sargı termal devresi Şekil 2.10.' da gösterilmiştir. Bu şekilde q_s , q_{fe} , q_{wind} sırasıyla stray kayıplarından dolayı üretilen ısı, çekirdek kayıplarından oluşan ısı, primer ve sekonder sargılarının kayıplarından üretilen ısı. C_{tm} , C_{fe} , C_{wind} sırasıyla tank ve diğer metal bileşenlerin termal kapasitansı, nüvenin termal kapasitansı, primer ve sekonder sargı iletkenlerinin termal kapasitansıdır. $R_{fe-wind}$, $R_{wind-amb}$, R_{fe-amb} , $R_{tm-wind}$ sırasıyla transformatörün nüvesi ile sargı arasındaki termal direnç, sargı ile ortam arasındaki termal direnç, nüvesi ile ortam arasındaki termal direnç ve transformatörün metal aksamı ile sargı arasındaki termal dirençtir [14].



Şekil 2.10. Transformatörün sargı sıcaklık termal devresi

Transformatörde üretilen toplam ısı kaybı Eşitlik 2.15' de verilmiştir.

$$q_{tot} = q_s + q_{fe} + q_{wind} \quad (2.15)$$

Transformatör çekirdeğinin termal kapasitansı Eşitlik 2.16' de verilmiştir.

$$C_{fe} = 0.449 \text{ (çekirdek ağırlığı(kg))} \quad (2.16)$$

Transformatörün yapısal parçalarının termal kapasitansı eşitlik 2.17' de verilmiştir.

$$C_{tm} = 0.449 \text{ (demir çerçevenin ağırlığı (kg))} \quad (2.17)$$

Farklı sıcaklıklar için Al,Cu ve Fe'in belirli termal kapasite değerleri arasındaki farklar Çizelge 2.3.' de gösterilmiştir.

Çizelge 2.3. Cu,Al ve Fe ‘in sıcaklığa göre gösterdiği termal kapasitans değerleri


Sıcaklık (K)	İletken Madde		
	Aliminyum	Bakır	Demir
298.15	897 J/kg-K	385 J/kg-K	449 J/kg-K
350	930.6 J/kg-K	392.6 J/kg-K	470.6 J/kg-K
400	955.5 J/kg-K	398.6 J/kg-K	490.5 J/kg-K

Birçok transformatörde primer ve sekonder sargı iletkeni bakırdır, fakat günümüzdeki transformatörleri primer ve sekonder her iki sargı iletkeni aliminyumdan veya; biri bakır diğeri aliminyumdan dizayn edilip yapılmaktadır.

Transformatör sargılarının termal kapasitansı Eşitlik 2.18’te verilmiştir.

$$C_{wind} = 0.385 (\text{Bakır sargının ağırlığı (kg)}) + 0.910 (\text{Aliminyum sargının ağırlığı (kg)}) \quad (2.18)$$

Kuru tip transformatörlerin basitleştirilmiş lineer olmayan termal direnci modeli Şekil 2.11.’ de gösterilmiştir.



Şekil 2.11. Basitleştirilmiş eşdeğer sargı termal modeli

Kaçak yük kayıpları ve sargı kayıpları yük ile değişir, ve yük kayıpları ve yük kapasitesi olarak basitleştirilebilir.

Transformatördeki toplam yük kayıpları Eşitlik 2.19’da verilmiştir.

$$q_{load} = q_s + q_{wind} \quad (2.19)$$

Transformatör yükünün termal kapasitesi Eşitlik 2.20’de verilmiştir.

$$C_{load} = 0.449 \text{ (Demir gövdenin ağırlığı (kg))} + 0.385 \text{ (Bakır sargıların ağırlığı (kg))} + 0.910 \text{ (Aliminyum sargıların ağırlığı (kg))} \quad (2.20)$$

Şekil 2.11.’de verilen transformatörün sargı termal modeli, termal anoloji ve ısı transfer teorisinden gelmektedir. Şekil 2.11.’e uygun olarak yazılan diferansiyel eşitlikler Eşitlik 2.21 ve Eşitlik 2.22 ‘de verilmiştir.

$$q_{fe} = C_{fe} \frac{d\theta_{fe}}{dt} + \frac{\theta_{fe} - \theta_{amb}}{R_{fe-amb}} + \frac{\theta_{fe} - \theta_{wind}}{R_{fe-wind}} \quad (2.21)$$

$$q_{load} = C_{load} \frac{d\theta_{wind}}{dt} + \frac{\theta_{wind} - \theta_{amb}}{R_{wind-amb}} - \frac{\theta_{fe} - \theta_{wind}}{R_{fe-wind}} \quad (2.22)$$

3. YAPAY SİNİR AĞLARI

3.1. Yapay Sinir Ağlarına Giriş


Yapay zeka araştırmaları Turing makinesiyle başlamış, bir bilim dalı olarak kabul edilmesini Newel ve Simon tarafından sağlanmıştır. Son yıllarda yapay zeka konusunda yapılan araştırmalar, insan beyninin öğrenme ve karar verme fonksiyonlarını taklit eden Yapay sinir ağları üzerinde yoğunlaşmıştır.

Yapay sinir ağları, insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme, yeni bilgiler oluşturabilme, keşfedebilme gibi yetenekleri herhangi bir yardım almadan otomatik olarak gerçekleştirmek amacı ile geliştirilen bilgisayar sistemleridir [16].

3.2. Biyolojik Sinir Sistemi

İnsan beyni, nöron olarak adlandırılan yaklaşık 10^{11} hesap elemanından oluşmaktadır. Nöronlar büyüklük ve görünüş bakımından birbirinden önemli ölçüde farklı olsalar da, bazı ortak özellikler taşırlar. Biyolojik sinir ağını oluşturan nöronlar temelde Soma, Akson ve Dendrit olmak üzere üç bölgeye ayrılır [17].

Biyolojik sinir ağları insan beyninin çalışmasını sağlayan temel taşlardan birisidir. İnsanın bütün çevresini anlamasını sağlar. Bu konuda beş duyu organından gelen bilgiler ışığında geliştirdiği algılama ve anlama mekanizmalarını çalıştırarak olaylar arasındaki ilişkileri öğrenir. Duyu organlarından gelen bilgiler(sinyaller) beyin sinir sistemi sayesinde beyne taşınır ve beynin kararları da yine sinir sistemi tarafından vücudun organlarına eylem olarak gönderilir.




Resim 3.1. Biyolojik sinir hücresi yapısı

Sinir hücresi, diğer sinir hücrelerinden gelen uyarıları (elektriksel sinyaller) sinapsları üzerinden dentritlerine alır. Gelen sinyaller sinapslar tarafından güçlendirilir veya zayıflatılır. Dentritler sinyalleri hücre gövdesine taşır. Hücre gövdesi gelen sinyalleri birbirlerini kuvvetlendirme ve zayıflatma etkilerine göre işler. Eğer sinyaller birbirlerini yeteri kadar kuvvetlendirerek bir eşik değerini aşabilirse, aksona sinyal gönderilir ve sinir aktif hale getirilir. Aksi takdirde aksona sinyal gönderilmez ve sinir pasif durumda kalır [18].

3.3. Yapay Sinir Yapısı

Yapay sinir ağları, insan beyninin bilgi işleme teknolojisinden esinlenerek geliştirilmiş bir bilgi işlem teknolojisidir. Yapay sinir ağları ile basit biyolojik sinir sisteminin çalışma şekli simüle edilir. Simüle edilen sinir hücreleri nöronlar içerirler ve bu nöronlar çeşitli şekillerde birbirine bağlanarak ağı oluştururlar. Bu ağlar öğrenme, hafızaya alma ve veriler arasındaki ilişkiyi ortaya çıkarma kapasitesine sahiptirler.



Şekil 3.1. Basit bir sinir ağı yapısı

Şekil 3.1.'de basit bir yapay sinir ağı yapısı gösterilmiştir. Katmanların değişik şekilde birbirleriyle bağlanmaları değişik ağı mimarileri doğurur. YSA 'lar üç katmandan oluşur. Giriş katmanında giriş sinyalleri bulunur. Giriş sinyalleri $X_1, X_2, X_3, \dots, X_N$ normalde sürekli değişkenlerdir fakat ayrık sinyallerde olabilir. Gizli katmanda her giriş sinyali bağlantı ağırlıklarıyla çarpılır. Ağırlıklar elektriksel sinyalin akışına göre pozitif (hızlandırıcı) veya negatif (yavaşlatıcı) olabilir. Toplama noktasında bütün ağırlıklı giriş sinyalleri ve bias sinyali (b) toplanır ve son olarak toplam çıkışından elde edilen sonucu lineer olmayan bir aktivasyon fonksiyonundan geçirilerek çıkış katmanına verilir [19].

Çıkış katmanındaki her nöron değiştirilebilir ağırlıklara bağlantılı gizli katmandaki nöronlar aracılığıyla bütün girişlerden sinyal alır. Uygun öğrenme yöntemini kullanarak bağlantı ağırlıkları ayarlanır [20].

Matematiksel olarak ifade edersek

$$Y = F(S) = F \left[\sum_{K=1}^N X_K W_K + b \right] \quad (3.1)$$

3.4. Yapay Sinir Ağlarının Üstünlükleri

Doğrusal Olmama: Yapay sinir ağları özellikle doğrusal olmayan sistemlerde tahmin yapma açısından istatistik hesaplamalarına göre daha kolay ve doğru sonuç vermesinden dolayı sık kullanılan bir yöntem haline gelmiştir. Özellikle işletmecilik ve finans alanlarında olmak üzere tahmin gerektiren birçok alanda kullanılmaktadır.

Paralellik: Klasik problem çözme algoritmalarının aksine yapay sinir ağları paralel çalışmaya uygun bir yapıya sahiptir. Bu özelliği sayesinde çok daha hızlı problem çözebilme yeteneğine sahiptir.

Hata Toleransı: Yapay sinir ağlarının paralel çalışması hız avantajıyla birlikte hatayı tolere etmek açısından da avantaj sağlar. Seri bilgi işlem yapan bir sistemde herhangi bir birimin hatalı çalışması, hatta bozulmuş olması tüm sistemin hatalı çalışmasına veya bozulmasına sebep olacaktır. Paralel bilgi işleme yapan bir sistemde ise hata ağdaki bütün bağlantılar üzerine yayılacağından sistemin performansında keskin bir düşüşe yol açmadan ağın doğru bilgi üretmesini önemli ölçüde etkilemez.

Öğrenebilirlik: Klasik algoritmaların çoğu verilen formüllerin hesaplanması ile aynı girdiler için daima aynı çıktıları üretirler. Lineer olan bu algoritmaların aksine yapay sinir ağları sayesinde programlar öğrenme yeteneği de kazanmışlardır. Klasik algoritmalarda tam olarak tanımlı bir çözüm yolu olmayan problemler çözülemezken yapay sinir ağları sayesinde problemler çözüm yöntemi hakkında herhangi bir bilgi verilmeksizin çözülebilir. Yapay sinir ağlarının bu tip problemleri çözebilmesi için gereken tek şey örnek girdiler için sonuçların verilmesidir.

Genelleme: Yapay sinir ağları çalıştığı probleme göre eğitildikten sonra eğitim sırasında karşılaşmadığı durumlar için de yanıt verebilir. Örneğin karakter tanıma amacıyla eğitilmiş bir yapay sinir ağı, bozuk karakter girişlerinde de doğru

karakterleri verebilir yada bir sistemin eğitilmiş yapay sinir ağı modeli, eğitim sürecinde verilmeyen giriş sinyalleri içinde sistemle aynı davranışı gösterebilir.

Uyarlanabilirlik: Yapay sinir ağı üzerinde çalıştığı probleme göre kendini düzenleyerek ağırlıklarını belirler. Bir problemi çözmek için eğitilen yapay sinir ağı herhangi bir başka problemde de kolaylıkla kullanılabilir. Bunun için gereken tek şey yeni problemin girdi ve çıktılarıyla ağı tekrar eğitilmesidir.

Hız ve Donanım: Yapay sinir ağları, paralel yapısı nedeniyle büyük ölçekli entegre devre (VLSI) teknolojisi ile gerçekleştirilebilir. Bu özellik, yapay sinir ağlarının hızlı bilgi işleme yeteneğini artırır.

Analiz ve Tasarım Kolaylığı: Yapay sinir ağlarının temel yapı taşı olan yapay sinir yapısı bütün yapay sinir ağlarında aynıdır. Bundan dolayı yapay sinir hücresinin tasarımından sonra bu temel eleman ile yapay sinir ağları kolaylıkla oluşturulabilir ve oluşturulan bu ağ her türlü problemin çözümünde kullanılabilir.

3.5. Yapay Sinir Ağlarının Önemli Dezavantajları

Yapay sinir ağlarının pek çok avantajının yanında bazı dezavantajları da vardır. Bunların en başında donanıma bağımlı çalışmaları sayılabilir. Gerçek zamanlı bilgi işleyebilmeleri için paralel çalışan işlemcilerin varlığına ihtiyaç vardır.

Bir ağı nasıl oluşturulması gerektiğini belirleyecek kuralların olmaması da başka bir dezavantajdır. Probleme uygun ağ yapısının belirlenmesi genellikle deneme yanılma yolu ile yapılmaktadır. Bu ise önemli bir problemdir. Çünkü eğer problem için uygun bir ağ oluşturulamaz ise çözümlü olan bir problemin çözülmemesi veya performansı düşük çözümlerin elde edilmesi söz konusu olabilir. Bazı ağlarda ağı parametre değerlerinin (mesela öğrenme katsayısı, nöron sayısı, katman sayısı v.b.) belirlenmesinde de bir kural olmaması bir dezavantajdır.

Ağın eğitilmesinin ne zaman bitirileceğine karar vermek için geliştirilmiş optimum bir yöntemde yoktur. Ağın örnekler üzerindeki hatasının belirli bir değerin altına indirilmesi eğitimin tamamlanması için yeterli görülmektedir. Fakat neticede optimum öğrenmenin gerçekleştiği söylenememektedir. Sadece iyi çözümler üretebilen bir ağ oluştu denilebilmektedir [21].


3.6. Aktivasyon Fonksiyonu

Transfer fonksiyon olarak da bilinen aktivasyon fonksiyonu, birleştirme fonksiyonundan elde edilen net girdiyi bir işlemde geçirerek hücre çıktısını belirleyen ve genellikle doğrusal olmayan bir fonksiyondur. Aktivasyon fonksiyonları sabit parametrelili ya da uyarlanabilir parametrelili seçilebilir. Aktivasyon fonksiyonları yapay sinir ağlarında nöronun genliğini istenilen değerler arasında sınırlar. Bu değerler genellikle $[0,1]$ veya $[-1,1]$ arasındadır. Aktivasyon fonksiyonunun seçimi büyük ölçüde yapay sinir ağının verilerine ve ağın neyi öğrenme istediğine bağlıdır. Örneğin bir modelin ortalama davranışının öğrenilmesi isteniyorsa sigmoid fonksiyon, ortalama sapmanın öğrenilmesi isteniyorsa hiperbolik tanjant fonksiyon kullanılması önerilmektedir [18].

3.6.1. Doğrusal fonksiyon

YSA'ların çıkış katmanında kullanılan doğrusal fonksiyon Şekil 3.2.' de gösterilmiştir ve işlemci elemanın girişi doğrudan işlemci elemanın çıkışı olarak verir. Formülü ise;

$$y=A*v \quad (A \text{ bir sabit katsayı}) \quad (3.2)$$




Şekil 3.2. Doğrusal ve lineer fonksiyon

3.6.2. Basamak fonksiyonu

Basamak fonksiyonu tek ve çift kutuplu fonksiyon olabilir. Bu fonksiyon Şekil 3.3.’de gösterilmiştir. Bu fonksiyonun matematiksel ifadeleri ise;

$$y=F(v)= \begin{cases} 1 & v \geq 0 \\ 0 & v < 0 \end{cases} \quad (3.3)$$

$$y=F(v)= \begin{cases} 1 & v \geq 0 \\ -1 & v < 0 \end{cases} \quad (3.4)$$




Şekil 3.3. Tek ve çift kutuplu basamak fonksiyonu

3.6.3. Sigmoid fonksiyonu

YSA uygulamalarında en çok kullanılan aktivasyon fonksiyonudur. Fonksiyonun davranışı Şekil 3.4. 'de gösterilmiştir. Bu fonksiyonun en aktif bölgesinin 0,2 ile 0,8 arasında olduğu bilinmektedir. Bu fonksiyonun matematiksel ifadesi ise;

$$y = \frac{1}{1 + e^{-v}} \quad (3.5)$$




Şekil 3.4. Sigmoid fonksiyonu

3.6.4. Tanjant Hiperbolik fonksiyonu

YSA uygulamalarında en çok kullanılan aktivasyon fonksiyonlarından bir diğeri ise bu fonksiyondur. Giriş uzayının genişletilmesinde etkili bir aktivasyon fonksiyonudur. Bu fonksiyon Şekil 3.5.'de gösterilmiştir. Bu fonksiyonun matematiksel ifadesi ise;

$$y = \frac{1 - e^{-2v}}{1 + e^{2v}} \quad (3.6)$$



Şekil 3.5. Tanjant hiperbolik fonksiyonu

3.7. Yapay Sinir Ağlarının Sınıflandırılması


Yapay sinir ağları birbirleri bağlantılı nöronlardan oluşur. Her bir sinir hücresi arasındaki bağlantıların yapısı ağın yapısını belirler. İstenilen hedefe ulaşmak için bağlantıların nasıl değiştirileceği öğrenme algoritması tarafından belirlenir. Yapay sinir ağları ağ yapılarına ve öğrenme algoritmalarına göre sınıflandırılabilir.

3.7.1. YSA'ların yapılarına göre sınıflandırılması

Sinir ağlarının işaretin akış yönüne bağlı olarak, ileri beslemeli (feedforward) ve geri beslemeli (feedback veya recurrent) ağlar olmak üzere iki çeşittir.

İleri beslemeli ağlar

İleri beslemeli ağlar yapay sinir ağların en basit ve en ilk yapısıdır. Bu ağda bilgi sadece ileri yönde gizli veya çıkış katmanına hareket eder. Ağda herhangi bir geri bildirim yoktur [22].




Şekil 3.6. Çok katmanlı ileri beslemeli ağ yapısı

Şekil 3.6.'da çok katmanlı ileri beslemeli ağ yapısını görmekteyiz. 3 girişli (X_1, X_2, X_3), 2 çıkışlı (Y_1, Y_2) ve gizli katmanda 5 tane nöronu olan bir ağ yapısıdır. Sinyaller daima ileri yönde taşınmaktadır.

Çok katmanlı ileri beslemeli ağlar lineer olmayan sistemlerin tanımlanması ve kontrolü, finansal piyasa analizleri, sinyal modelleme, güç yük tahminlerinde danışmanlı öğrenme metodunu kullanarak bazı zor problemlerin çözümünde başarılıdır [23].

Geri Beslemeli Ağlar

Bir geri beslemeli sinir ağı, çıkış ve ara katlardaki çıkışlarının, giriş birimlerine veya önceki ara katmanlara geri beslendiği bir ağ yapısıdır. Bu çeşit sinir ağlarının dinamik hafızaları vardır. Bu yapıda nöronların çıkışı sadece o anki giriş değerlerine bağlı değildir ayrıca önceki giriş değerlerine de bağlıdır. Bundan dolayı, özellikle önceden tahmin uygulamaları için uygundur. Bu ağlar çeşitli tipteki zaman serilerinin tahmininde oldukça başarı sağlamıştır [24].



Şekil 3.7. Çok katmanlı geri beslemeli ağ yapısı

Şekil 3.7 ‘de toplam N tane çıkış nöronu mevcuttur ve M tane giriş elemanından oluşur. Çıkışlar, giriş elemanıymış gibi birim zaman gecikmesiyle geri beslenirler. Böylece toplam (M+N) giriş olmuş olur. $X(k)$ ağa uygulanan dış giriş vektörünü temsil eder ve $Y(k+1)$ ise (k+1) ayrık zamanda bir step sonra üretilen nöron çıkış vektörünü temsil eder. Giriş vektörü $X(k)$ ve bir step gecikmeli çıkış vektörü $Y(k)$ ’ yı içeren toplam giriş vektörü [19];

$$\begin{aligned}
 U(k) &= [U_1(k) \dots U_{N+M}(k)]^T \\
 &= [Y_1(k) \dots Y_N(k) X_1(k) \dots X_M(k)]^T
 \end{aligned}
 \tag{3.7}$$

k anındaki çıkış;

$$Q_j(k) = \sum_{i=1}^{N+M} W_{ij}(k) U_i(k) \quad (3.8)$$

W_{ij} , i. giriş ile j. Nöron arasındaki bağlantı ağırlığıdır. Çıkış matriksi;

$$\begin{pmatrix} Q_1 \\ \vdots \\ Q_N \end{pmatrix} = \begin{pmatrix} w_{11} & \dots & w_{(N+M)1} \\ \vdots & \ddots & \vdots \\ w_{1N} & \dots & w_{(N+M)N} \end{pmatrix} \begin{pmatrix} U_1 \\ \vdots \\ U_{N0} \end{pmatrix} \quad (3.9)$$

Gelecek adım olarak, j. çıkış nöronu aktivasyon fonksiyonu $F()$ den geçirilerek aşağıdaki eşitlik bulunur.

$$Y_j(k+1) = F(Q_j(k)) \quad (3.10)$$

3.7.2. YSA'larında temel öğrenme kuralları

Yapay sinir ağlarında öğrenme kurallarının çoğu Hebb kuralına dayanmaktadır. Bu öğrenme algoritmalarının çoğunluğu matematik tabanlı olup ağırlıkların güncelleştirilmesi için kullanılırlar.

Hebb kuralı

1949 yılında geliştirilen bu kurala göre, bir hücre diğer bir hücreden bilgi alırsa ve her iki hücrede aktif ise her iki hücre arasındaki ağırlık kuvvetlendirilmelidir. Diğer bir deyişle bir hücre aktif ise bağlı olduğu hücreyi aktif yapmaya pasif ise pasif yapmaya çalışmaktadır.

Hopfield kuralı

Yapay sinir ağı elemanlarının bağlantılarının ne kadar kuvvetlendirilmesi veya zayıflatılması dışında Hebb kuralına benzemektedir. Eğer girdi ve çıktılar ikisinde aktif/pasif ise öğrenme katsayısı kadar ağırlık değerlerini kuvvetlendir/zayıflat denmektedir. Ağırlıkların kuvvetlendirilmesi ve zayıflatılması öğrenme katsayısı ile gerçekleştirilmektedir. Öğrenme katsayısı genellikle 0-1 arasında değerler almaktadır [21].

Delta kuralı

Bu kural Hebb kuralının biraz daha geliştirilmiş halidir ve en çok kullanılan algoritmalarından birisidir. Bu kurala göre hedeflenen çıktı ile gerçekleşen çıktı arasındaki farklılığı azaltmak için yapay sinir ağının elemanlarının bağlantılarının ağırlık değerlerinin sürekli değiştirilmesi prensibine dayanmaktadır. Ağın ürettiği çıktı ile hedeflenen çıktı arasındaki hatanın karelerinin hatasını en aza indirmek hedeflenmektedir. Hata, aynı anda bir katmandan bir önceki katmanlara geri yayılarak azaltılır. Ağın hatalarının azaltılma işlemi çıkış katmanından giriş katmanına ulaşınca kadar devam eder.

Kohonen kuralı


Bu kurala göre ağı elemanları ağırlıklarını değiştirmek için birbiri ile yarışır. En büyük çıkışa sahip nöron kazanır ve bağlantı ağırlıkları değiştirilmektedir. Kazanan nöron komşularını uyarma ve yasaklama yetkisine sahiptir. Bu kuralda hedef çıkışa gereksinim duyulmadığı için danışmansız öğrenme metodudur.

3.7.3. YSA'ların öğrenme algoritmalarına göre sınıflandırılması

Yapay sinir ağlarında bilgi, ağdaki bağlantıların ağırlıklarında depolanır. Yapay sinir ağlarında öğrenme, sinirler arasındaki ağırlıkların ayarlanması ile meydana gelir. Bir takım öğrenme algoritmaları kullanılarak sinirler arasındaki ağırlıklar dinamik olarak değiştirilebilir. Temelde bu öğrenme algoritmaları danışmanlı (supervised), danışmansız (unsupervised) ve destekleyici (reinforcement) öğrenme olmak üzere üç gruba ayrılır.

Danışmanlı (Supervised) öğrenme


Öğrenen sistemin olayı öğrenebilmesi için bir öğretmene ihtiyacı vardır. Öğretmen sisteme öğrenilmesi gereken olay ile ilgili girdi/çıkı setini verir. Yani her örnek için hem girdiler hem de o girdiler karşılığında oluşturulması gereken çıktılar sisteme gösterilirler. Sistemin görevi girdileri öğretmenin belirlediği çıktılara haritalamaktır. Bu sayede girdiler ile çıktılar arasındaki ilişki öğrenilmektedir. Çok katmanlı ağlar bu stratejiyi kullanan ağlara örnek gösterilebilir. [21]. Delta kuralı ve geri yayılım (backpropagation) algoritması danışmanlı öğrenme algoritmalarına örnek verilebilir.



Şekil 3.8. Danışmanlı öğrenme yapısı

Danışmansız (Unsupervised) öğrenme

Danışmansız öğrenmede sistemin doğru çıkış hakkında bilgisi yoktur ve girişlere göre kendi kendisini örnekler. Danışmansız olarak eğitilebilen ağlar istenen ya da hedef çıkış olmadan giriş bilgilerinin özelliklerine göre ağırlık değerlerini ayarlar. Daha çok sınıflandırma problemleri için kullanılan bir öğrenme stratejisidir. Danışmansız öğrenmeye Grossberg tarafından geliştirilen ART(Adaptive Resonance Theory) veya Kohonen tarafından geliştirilen SOM(Self Organizing Map) örnek gösterilebilir.



Şekil 3.9. Danışmansız öğrenme yapısı


Destekleyici (Reinforcement) öğrenme

Bu sistemde de öğrenen sisteme bir öğretmen yardımcı olur. Fakat öğretmen her girdi seti için üretmesi gereken çıktı setini sisteme göstermek yerine sistemin bir çıktı üretmesini bekler ve üretilen çıktının doğru veya yanlış olduğunu gösteren bir sinyal üretir. Sistem öğretmenden gelen bu sinyali dikkate alarak öğrenme sürecini devam ettirir. Vektör kuantalamalı öğrenme (LVQ) bu öğrenme stratejisini kullanan ağ yapısıdır.

3.7.4. YSA'ların temel öğrenme algoritmaları

Geri yayılım algoritması (Backpropagation)

Uygulamalarda en yaygın ve en çok kullanılmış olan geri yayımlı (back propagation) algoritmasıdır. Geri yayılım ağında hatalar, ileri besleme aktarma işlevinin türevi tarafından, ileri besleme mekanizması içinde kullanılan bağlantılar aracılığıyla geriye doğru yayılmaktadır.



Şekil 3.10. Geri yayımlı öğrenme algoritmasının yapısı

m nöronunun çıkışı $F_{m,3}$ hedeflenen çıkış D_m ile karşılaştırıldığında hata ξ_m

$$\xi_m = D_m - Y_m \quad (3.11)$$

Eşitlik 3.11’de $Y_m = F_{m,3}$ dir. Fonksiyonu minimize etmek için Eşitlik 3.11 ‘in karesi alınır ve Eşitlik 3.12 elde edilir.

$$(\xi_m = D_m - Y_m)^2 \quad (3.12)$$

Çıkış $F_{m,3}$ ve uygun ξ_m^2 , bütün giriş sinyalleri sabit kalarak $W_{lm,3}$ ağırlığının değişimiyle değişir. ξ_m^2 eğimli düşüş (Gradient descent) metoduna göre minimize edersek, ağırlıkların değişimi ağırlıklara ilişkin karesel hatanın değişim oranına orantılı olmak zorundadır.

$$\Delta w_{lm,3} = -\eta \frac{\partial \xi_m^2}{\partial w_{lm,3}} \quad (3.13)$$

Eşitlik 3.13’ de η öğrenme oranı sabitidir. Bu yüzden yeni ağırlık;

$$\Delta w_{lm,3}(k+1) = w_{lm,3}(k) + \Delta w_{lm,3}(k) \quad (3.14)$$

$$= w_{lm,3}(k) - \eta \frac{\partial \xi_m^2}{\partial w_{lm,3}} \quad (3.15)$$

Eşitlik 3.15’deki $w_{lm,3}(k)$ eski ağırlıktır ve k iterasyon sayısıdır. Eşitlik 3.13’ teki kısmi türev, diferansiyel kurallar zinciriyle değerlendirilirse

$$\frac{\partial \xi_m^2}{\partial w_{lm,3}} = \frac{\partial \xi_m^2}{\partial F_{m,3}} \cdot \frac{\partial F_{m,3}}{\partial S_{m,3}} \cdot \frac{\partial S_{m,3}}{\partial w_{lm,3}} \quad (3.16)$$

Her terim kendi başına değerlendirilir. Eşitlik 3.16’ deki birinci terim

$$\frac{\partial \xi_m^2}{\partial F_{m.3}} = -2(D_m - F_{m.3}) = -2\xi_m \quad (3.17)$$

Eşitlik 3.16'deki 2. terimde aktivasyon fonksiyonu olarak sigmodial fonksiyonu kullanırsak;

$$\frac{\partial F_{m.3}}{\partial S_{m.3}} = \frac{\partial}{\partial S_{m.3}} \left(\frac{1}{1 + e^{-\alpha S_{m.3}}} \right) = \alpha F_{m.3} (1 - F_{m.3}) \quad (3.18)$$

$S_{m.3}$ sinyaline, m nöronunun bütün giriş sinyalleri katkı sağladığı için Eşitlik 3.19 yazabiliriz.

$$S_{m.3} = \sum_{l=1}^p w_{lm.3} F_{l.2} \quad (3.19)$$

Eşitlik 3.19'daki p orta tabakadaki nöronların sayısıdır. $w_{lm.3}$ 'e göre kısmi türev alırsak ;

$$\frac{\partial S_{m.3}}{\partial w_{lm.3}} = F_{l.2} \quad (3.20)$$

Eşitlik 3.20' de $w_{lm.3}$ değiştiğinde $F_{l.2}$ sadece çıkıştaki değişime katkıda bulunur. Eşitlik 3.17 ile Eşitlik 3.18 birleştirirsek;

$$\begin{aligned} \frac{\partial \xi_m^2}{\partial w_{lm.3}} &= -2\alpha (D_m - F_{m.3}) F_{m.3} (1 - F_{m.3}) F_{l.2} \\ &= \delta_{lm.2} \cdot F_{l.2} \end{aligned} \quad (3.21)$$


Veya

$$\Delta w_{lm.3} = \eta \delta_{lm.3} F_{l.2} \quad (3.22)$$

$$\delta_{lm.3} = 2\alpha(D_m - F_{m.3})F_{m.3}(1 - F_{m.3}) = 2\xi_m \frac{\partial F_{m.3}}{\partial S_{m.3}} \quad (3.23)$$

Ağırlıklar Eşitlik 3.14. ,Eşitlik 3.22 ve Eşitlik 3.23 yardımlarıyla bulunur. Benzer prosedür çıkış katmanındaki ağırlıklar içinde uyarlanabilir. Şekil 3.11’ de $w_{lm.3}$ ağırlığı ayarlanarak ξ_m^2 nin eğimli düşüş (gradient descent) metoduyla minimizasyonu gösterilmiştir. Öğrenme katsayısı η yakınsama hızını ve optimum noktayı nasıl hızlı bir şekilde elde edileceğini belirler. Eğimli düşüş (gradient descent) ağırlık optimizasyonundaki problemlerden biri Şekil 3.11.’ de gösterilen lokal minumumdur. Çalışma bu noktada kilitlenebilir Bu noktayı atlamak için Eşitlik 3.15 yanına momentum terimi eklenir[19].

$$w_{lm.3}(k+1) = w_{lm.3}(k) - \eta \frac{\partial \xi_m^2}{\partial w_{lm.3}} + \mu [w_{lm.3}(k) - w_{lm.3}(k-1)] \quad (3.24)$$



Şekil 3.11. Gradient descent metodu ile ξ_m^2 karesel hatanın minimizasyonu

Hafıza alanını azaltmak ve hesaplama zamanını hızlandırmayı amaçlayan BP algoritmasının diğer geliştirilmiş sürümleri son yıllarda önerilmiştir.

Levenberg-Marquardt ve Bayesian Regülasyon (Regulation) GeriYayılım (Backpropagation) Metodu

Levenberg-Marquardt temel olarak bu algoritma maksimum komşuluk üzerine kurulmuş en az kareler hesaplama metodudur. Bu algoritma Gauss-Newton ve Gradient descent algoritmalarının en iyi özelliklerinden oluşur ve bu iki metodun kısıtlamalarını kaldırır. Genel olarak bu metot yavaş yakınsama probleminden etkilenmez.

Gauss-Newton algoritmasının kombinasyonu olan Levenberg-Marquart algoritması optimizasyon problemlerinde eğimli düşüş algoritmasına göre (gradient descent) daha etkindir. Ayrıca daha hızlıdır[20].

k. 'ıncı iterasyondaki ağ ağırlık vektörü

$$w^{(k+1)} = w^{(k)} + \Delta w^{(k)} \quad (3.25)$$

Ortalama karesel hata fonksiyonu (mean square error)

$$E(w) = \frac{1}{2} \sum (e_i^\xi)^2 = \frac{1}{2} \sum (d_i^\xi - y_i^\xi)^2 \quad (3.26)$$

$$\nabla E(w) = J^T(w) e(w) \quad (3.27)$$

$$\nabla^2 E(w) = J^T(w) J(w) \quad (3.28)$$

$$e(w) = (e^1, e^2, e^3, \dots, e^m)^T \quad (3.29)$$

$J(w)$ Jacobian matrisi;

$$J = \begin{pmatrix} \frac{\partial e^1}{\partial w_1} & \frac{\partial e^1}{\partial w_2} & \dots & \dots & \dots & \frac{\partial e^1}{\partial w_N} \\ \frac{\partial e^2}{\partial w_1} & \frac{\partial e^2}{\partial w_2} & \dots & \dots & \dots & \frac{\partial e^2}{\partial w_N} \\ \vdots & \vdots & \dots & \dots & \dots & \vdots \\ \frac{\partial e^m}{\partial w_1} & \frac{\partial e^m}{\partial w_2} & \dots & \dots & \dots & \frac{\partial e^m}{\partial w_N} \end{pmatrix} \quad (3.30)$$

Lineer olmayan en küçük kareler yönteminin birçoğu Newton metodunu taban alır.

$$\Delta w = -[\nabla^2 E(w)]^{-1} \nabla E(w) \quad (3.31)$$

Eş. 3.27 ile Eş. 3.28, Eş. 3.31'de yerlerine koyulduğu zaman

$$\Delta w = -\left[J^T(w)J(w)\right]^{-1} J^T(w)e(w) \quad (3.32)$$

elde edilir. Levenberg-Marquart algoritması Gauss-Newtonun modifiye edilmiş halidir.

$$\Delta w = -\left[J^T(w)J(w) + \mu I\right]^{-1} J^T(w)e(w) \quad (3.33)$$

μ pozitif bir sabittir ve I birim matristir. μ çok büyükse Levenberg Marquart algoritması eğimli düşüş (gradient descent) algoritmasına yaklaşır. Eğer $\mu \rightarrow 0$ ise Levenberg-Marquart algoritması Gauss-Newton metodu olur [23].

Bayesian regülasyonu Levenberg Marquardt optimizasyonuna göre ağırlık ve bias değerlerini günceller. Karesel hata ve ağırlıkların kombinasyonu minimize eder ve ağı üretmek için doğru kombinasyonu belirler. Daha iyi genelleştirme yeteneğine sahip bir ağı oluşturmak için, Mackay regülasyonla ağı parametrelerinin boyutunu sınırlayan method önermiştir. Regülasyon teknikleri ağırlık ve bias değerlerinin daha küçük değerlerde kalması için ağı zorlar. Bu ağı cevabının daha yumuşak olmasına, ağı ezberleme (overfitting) olasılığının azalmasına ve gürültüyü yakalamasına neden olur [24].

Esnek yayılım (Resilient Propagation-RP) algoritması

Çok katmanlı ağlar genellikle saklı katmanlarda sigmoid transfer fonksiyonları kullanırlar. Sigmoid fonksiyonlar eğimleri çok büyük giriş değerleri için sıfıra yakınsayacak şekilde karakterize edilirler. Bu ise ağırlık ve bias değerleri henüz optimum değerlere erişmemişken çok katmanlı YSA'da sigmoid fonksiyonlarının kullanılmasından dolayı gradiyent değerinin çok yavaş değişebilmesi olasılığı karşısında, yüksek gradiyent azaltma ile öğrenmede problemlere neden olur. RP öğrenme algoritmasının amacı ise kısmi türevlerin olumsuz etkilerinin öğrenme sürecinde uzaklaştırılmasıdır. Ağırlıkların güncelleştirilme yönü için sadece

türevlerin işaretleri kullanılır. Türev değerinin ağırlıkların güncelleştirilmesinde önemi yoktur.

Literatürde olan diğer öğrenme algoritmaları [21]:

- Delta-Bar-Delta(DBD) Algoritması
- Geliştirilmiş Delta-Bar-Delta (Extended DBD-EDBD) Algoritması
- Hızlı Yayılım Algoritması(QuickPropagation-QP)
- Genetik Algoritma
- Yönlendirilmiş Rastgele Arama(Directed Random Research)
- Eşleştirmeli Eğim (Conjugate Gradient) Algoritmaları
- Fletcher-Reeves
- Polak-Ribiere
- Powell-Beale
- Ölçeklendirilmiş Eşleştirmeli Eğim
- Kuasi-Newton Öğrenme Algoritmaları
- BGFS Öğrenme Yöntemi
- Tek Adım Sekant Öğrenme Yöntemi

3.8. Yapay Sinir Ağ Yapıları

3.8.1. Adaline

Widrow tarafından önerilen adaptif lineer eleman, her iterasyonda ortalama karesel hatayı(MSE) azaltarak ağırlıkları ayarlayan ve sınıflandırmayı sağlayan basit bir


perceptrondur. Adaline yapısı tüm sinir ağlarının en basitidir. Öğrenme için danışmanlı öğrenmeyi kullanır. Adaline bir çok uygulama için oldukça iyi çalışmasına rağmen lineer problem uzayıyla sınırlıdır. Lineer transfer fonksiyonu kullanırlar. Bu ağ yapısı ses sinyalleri üzerinde bulunan eko gürültülerinin giderilmesi yanında görüntü sinyalleri üzerinde bulunan gürültülerin giderilmesi içinde kullanılır [25].

3.8.2. Çok katmanlı (Ara katmanlı-MLP) ağlar (Multilayer networks)

Girdi ile çıktıları arasındaki ilişkinin doğrusal olmadığı bir problemi Adaline ile çözmek mümkün olmamıştır. Minsky [27] basit algılayıcı modelin bir probleme çözüm getirmediğini göstermiş ve yapay sinir ağlarının doğrusal olmayan problemlerin çözümünde kullanılamayacağını iddia etmiştir.

Doğrusal olmayan ilişkiyi gösteren XOR problemi çözülerek Çok Katmanlı Algılayıcı modeli geliştirilmiştir. Rumelhart ve arkadaşları tarafından geliştirilen bu modele hata yayma modeli veya geriye yayma (backpropagation network) da denilmektedir.

Bir katmandaki bütün işlem elemanları bir üst katmandaki bütün işlem elemanlarına bağlıdır. Bilgi akışı ileriye doğru olup geri besleme yapılmaz. Buradaki nöron sayısı giriş sayısına bağlıdır. Ara katman sayısı ve ara katmanlardaki nöron eleman sayısı deneme yanılma yöntemiyle bulunur.




Şekil 3.12. İki katmanlı çok katlı sinir ağı yapısı modeli

Bu ağı modeli özellikle mühendislik problemlerin çözümünde ve uygulamasında yaygın olarak kullanılmaktadır. Birçok eğitme algoritmasının bu ağı yapısını eğitmede kullanılabilir olması bu modelin yaygın kullanılmasının sebebidir. Giriş örnekleri giriş katmanına uygulanır, ara katmanlarda işlenir ve çıkış katmanında da çıkışlar elde edilir. Ağı eğitildikten sonra istenilen çıkışla ağı çıkışı arasındaki hata tekrar geriye doğru yayılarak hata minimumuna indirgeninceye kadar ağı ağırlıkları değiştirilir.

3.8.3. Radyal taban fonksiyonlu sinir ağı(Radyal basis function neural network-RBFNN)

RBFNN yapısı en genel anlamıyla radyal olarak simetrik olan ara katman işlemci elemanları içeren bir yapıdır. Ara katmandaki işlemci elemanlar girişlerin ağırlıklandırılmış şeklini kullanmamakta ve ara katmandaki işlemci elemanların çıkışları yapay sinir ağı girişleri ile temel fonksiyonun merkezi arasındaki uzaklığa göre belirlenmektedir.


Radyal tabanlı sinir ağıları standart ileri beslemeli geri yayımlı ağı yapılarından daha fazla nöron ihtiyacı vardır [28]. Daha hızlı öğrenme prosedüründen ve daha büyük genelleme yeteneğinden dolayı lineer olmayan yapıların tanımlanması, yaklaşım ve interpolasyon teorileri alanlarında kolaylık sağlar [29].



Şekil 3.13. RBFNN modelinin yapısı: R: Giriş vektöründeki elemanların sayısı, S1: 1. tabakadaki nöronların sayısı, S2: 2. tabakadaki nöronların sayısı

3.8.4. Vektör kuantalamalı öğrenme (Learning vector quantisation-LVQ)

Vektör Kuantalamalı Öğrenme (LVQ) ağı Kohonen tarafından geliştirilmiştir ve bu ağ aynı zamanda Kohonen ağı olarak da bilinir. Bazı modellerde eğitim sırasında ağa hem girdi değerleri için üretilecek çıktı değerlerinin ne olması gerektiği verilir. Fakat bazı durumlarda ağa çıktının ne olduğunun vermek mümkün değildir. Yalnızca ağın üretmiş olduğu çıktının doğru veya yanlış olduğu belirtilebilmektedir.



Şekil 3.14. LVQ'nun yapısı


Temelde rekabetçi öğrenme temeline göre eğitilir. Arakat ile çıkış katı arasındaki ağırlıklar “1” değerine sabitlenmiştir. Giriş ile arakat arasındaki nöron bağlantı ağırlıkları referans vektör olarak isimlendirilir. Her bir nöron için bir referans vektör tanımlanmaktadır. Bu ağırlıklar ağın eğitilmesi sırasında değiştirilir. Arakat (Kohonen) ve çıkış katı nöronları ikili (binary) çıkışlara sahiptir. Bir giriş vektörü ağıya uygulandığı zaman, giriş vektörüne en yakın arakat nöronunun referans vektörünün aktive edilme yarışmasını kazandığı söylenir. Bu kazanan nöron “1” çıkışını verir. Diğer bütün nöronların çıkışlarının “0” olması için bütün nöronlara baskı uygulanır. Çıkış nöronuna bağlı olarak, kazanan nöronu içeren arakat nöron grubuna “1” ve diğer bütün çıkış nöronları “0” değerleri atanır.”1” üreten çıkış nöronu her bir giriş nöronu giriş vektörünün sınıfını verir. Daha çok topografik haritaların biçimlenmesinde kullanılır.

3.8.5. ART Ağları (Adaptif Rezonans Theory)

Danışmansız öğrenme yapısına sahip olan ART ağları gerçek zamanlı olarak oldukça hızlı ve kararlı bir şekilde öğrenme yeteneklerine sahiptirler. Bu yetenek birçok ağda yoktur. ART ağları ağıya sunulan farklı nitelikteki ve değişik durumlardaki örnekler

karşısında kendi kendilerine kararlı bir yapı oluşturabilirler. Ağa yeni bir girdi girdiği zaman ya bilinen sınıfların kodlarına ulaşılacak şekilde ağda iyileşmeler yapılır ya da yeni kod oluşturulur. ART ağları girdi değerlerini otomatik olarak normalize ederler. Çok fazla ve oldukça düşük orandaki gürültülerin girdi işaretindeki etkileri ortadan kaldırırlar.

Adaptif Rezonans Teorisi(ART) ağları genel olarak iki katmandan oluşmaktadır. Bu katmanlar F1 ve F2 olarak isimlendirilmiştir. F1 katmanı girdinin özelliklerini gösterirken F2 katmanı kategorileri göstermektedir. Bu iki katman birbirine uzun dönemli hafıza (UDH) ile bağlanmaktadır. Girdi bilgileri F1 katmanından alınır ve sınıflandırma ise F2 katmanında yapılır.



Şekil 3.15. ART ağının genel yapısı

ART ağlarında girdiler direkt olarak sınıflandırılmazlar. Öncelikle girdilerin özellikleri incelenerek F1 katmanının aktivasyonu belirlenir. UDH' daki bağlantı değerleri ile gelen bilgiler kategorilere ayrılarak F2 katmanına gönderilir. F2

katmanındaki sınıflandırma ile F1 katmanından gelen sınıflandırma birbiri ile eşleştirilerek, eğer örnek belirlenmiş bir sınıfa uyuyorsa o kategoride gösterilir Aksi takdirde ya yeni bir sınıf oluşturulur veya girdinin sınıflandırılması yapılmaz [21].

3.8.6. Dinamik Ağlar

Yapay sinir ağları dinamik ve statik olarak iki gruba ayrılır. Statik ağlar geri beslemesi ve gecikmesi yoktur; Çıkış girişten ileri beslemeli bağlantılarla doğrudan hesaplanır. Dinamik ağlarda çıkış sadece ağdaki o andaki girişe bağlı değildir. O andaki ve önceki girişler, çıkışlara veya ağın durumuna bağlıdır. Kısacası bu sistemlere bellekli sistemlerde diyebiliriz. Statik ağlar ise belleksiz sistem olarak nitelendirebiliriz. Belleksiz sistemlere örnek olarak bir direnç gösterilebilir. Girişin $x(t)$ akım ve çıkışın $y(t)$ gerilim alınması durumunda R direncinin giriş-çıkış bağıntısı Ohm yasası ile verilir.

$$y(t) = Rx(t) \quad (3.34)$$

Kondansötör ise bellekli sistemlere bir örnektir. Akımın $x(t)$ girişi ve gerilimin $y(t)$ çıkışı olması durumunda

$$y(t) = \frac{1}{C} \int_{-\infty}^t x(\tau) d\tau \quad (3.35)$$

yazılabilir [30].

Dinamik ağların eğitimi statik ileri beslemeli ağların eğitimine çok yakındır. Genel bir yapay tasarımı için izlenen prosedür dinamik network dizaynı içinde geçerlidir.

1. Data toplama

2. Ağ yaratma

3. Ağı konfigre etme
4. Ağırlıkları ve biaslara ilk değer atama
5. Ağı eğitme
6. Ağı değerlendirme
7. Ağı kullanma


Geri beslemeli sistemlerin yanıtı ileri beslemeli sistemlerden daha uzundur. İleri beslemeli dinamik ağlar sonlu dürtü yanıtı (Finite Impulse Response-FIR) olarak adlandırılırlar. Çünkü giriş tepkisine göre cevabı belirli bir zaman sonra sıfır olacaktır. Geri beslemeli dinamik sistemlerde ise sonsuz dürtü yanıtı (Infinite Impulse Response-IIR) olarak adlandırılırlar. Çünkü etkiye cevabı sıfıra azalacaktır fakat tamamen sıfıra asla eşit olmayacaktır.

Dinamik ağlar daha zor eğitilmesine rağmen statik ağlardan daha güçlüdür. Çünkü dinamik ağların belleği vardır Dinamik ağlar girişi zaman serili olan ileri beslemeli sistemler ve geri beslemesi olan sistemler olmak üzere ikiye ayrılır.

Elman ve Jordan ağları


Elman ve Jordan Ağları Çok katmanlı ağlara (Multilayer Networks) benzer bir yapıdadır ve çok katlıdır. Jordan ağında çıkış biriminin genel birim olarak nitelendirilen aktivasyon değerleri, giriş tabakasına ekstra giriş birimleri olarak geri beslemesi olur. Çıkış ve genel birim arasındaki bağlantıların ağırlığı “+1” değerine sabitlenmiştir. Öğrenme giriş-gizli katman ve çıkış-gizli katman arasında meydana gelir [31].

Jordan ağı aynı zamanda genel birimdeki her işlemci elemanından kendine bağlantıları vardır [25].



Şekil 3.16. Jordan ağı modeli

Elman Ağı çok katmanlı ağların öğrenme kuralına göre öğrenmektedir. Girdi ve çıkış katmanları dış dünya ile etkileşim halindedir. Çıkış katmanının bilgi işleme fonksiyonları doğrusaldır. Sadece kendilerine gelen bilgileri toplarlar. Durum birimleri (Context units) gizli katmandaki nöronların önceki aktive değerlerini hatırlatmak için kullanılmaktadır. Bu elemanlar bir adım gecikmeyi (one step delay time) içermektedirler. Bir önceki iterasyondaki aktivasyon değerlerini bir sonraki iterasyona girdi olarak taşırlar. İleri beslemeli bağlantıların ağırlıkları eğitim sırasında değiştirilebilir ama geri dönüşümlerin bağlantı ağırlıkları değiştirilemez, sabittirler.




Şekil 3.17. Elman ağı modeli

Şekil 3.17.'de görüldüğü gibi Elman Ağı gizli katmandan bir önceki katmana birim gecikmeli durum birimleriyle geri beslemeyi yaparlar. Durum birimleri bir adım gecikmeli olan gizli tabakadaki nöronların çıkışlarını depolar [32].

Hopfield ağı

1980'lerin başında ilk kez tanınmış bir fizikçi olan Hopfield tarafından sunuldu. Hopfield ağı beyine benzer bir şekilde belirli hafızaları veya desenleri depolayan basit bir yapay sinir ağıdır. Hopfield ağı tek katmanlı ve geri dönüşümlü bir ağıdır. Proses elemanlarının tamamı hem girdi hem de çıktı elemanlarıdır.

Hopfield ağ topolojisi diğer ağ yapılarından farklıdır. Farklı katmanlar yoktur, bağlantılar çift yönlüdür, simetrik ve her birim diğer tüm birimlere bağlıdır. Ağ genellikle ikili (0 veya 1) ve bipolar (+1 veya -1) girişler kabul eder. Tek tabaka işlemci elemanları vardır ve her işlemci eleman bir diğerine bağlanmıştır.



Şekil 3.18. Hopfield ağı modeli

Hopfield ağı'nın eğitilmesi sadece bir adım alır ve w_{ij} ağırlıkları aşağıdaki gibi hesaplanır.

$$w_{ij} = \begin{cases} \frac{1}{N} \sum_{c=1}^p x_i x_j, i \neq j \\ 0, i = j \end{cases} \quad (3.36)$$

N işlemci eleman sayısı ve p öğrenebilecek (saklanacak) eleman sayısını göstermektedir. Bilinmeyen bir bilgi ağı girdiğinde, ağın çıkışları bilinmeyen bir desen elemanlarına eşitlenir.

$$y_i(0)=x_i \quad (3.37)$$


Bu başlangıç değerleri ile başlayarak Hopfield ağı bir sonraki denklemi kullanarak minimum enerji durumuna geçmek için döngüye girer.

$$y_i(k+1) = f \left[\sum_{j=1}^N w_{ij} y_j(k) \right] \quad 1 \leq i \leq N \quad (3.38)$$

Hopfield ağı bir geri yayımlı ağ gibi eğitilemez. Ağın ağırlıklarının başlangıç değerlerini saptamak için örnek desen grupları seçilir. Bu işlem bir kere yapıldıktan sonra herhangi bir desen ağı sunulur ve bu da giriş desenine en çok benzeyen örnek desenlerden biriyle sonuçlandırılır. Çıkış deseni birimlerin durumuna bakılarak ağdan okunabilir [18].

Gecikmeli zaman odaklı ağlar(Focused time delay network-FTDNN)

Girişinde kademeli gecikme hattı ile ileri beslemeli ağ içeren en basit dinamik ağ yapısıdır. Kademeli gecikmeli yapay sinir ağlarında ağ eğitilmeden veya simüle edilmeden önce orijinal veri setinin bir bölümü kaydırılarak ağı başlangıç değerlerine atıyorsun. Sadece giriş tabasında dinamik görülen dinamik yapay sinir ağların genel sınıflarından biridir. Geri besleme çevrimi olmadığından diğer dinamik ağlara göre daha hızlıdır. Bu network zaman serili tahminler için daha uygundur.




Şekil 3.19. Gecikme zaman odaklı ağ yapısı modeli

Çıkış $y(k)$;

$$y(k) = F \left[\sum_{n=0}^N w_{nk} x(k-n) \right] \quad (3.39)$$


w_{nk} ağırlık vektörü ve F aktivasyon fonksiyonudur. Ağ statik geri yayılım algoritmasını kullanarak eğitilebilir.



Şekil 3.20. İki tabakalı gecikmeli zaman odaklı ağ

Dağıtımli zaman gecikmeli ağlar (Distributed time delay neural network)


Gecikmeli zaman odaklı ağların sadece girişinde bellek varken bu ağ yapısında ağ boyunca kademeli gecikme yapmaktayız. İlk olarak ses tanımlamasıyla ilgili problemlere uygulanmıştır. Bu ağ giriş sinyallerinin frekans ayarını ayırt etmektedir.



Şekil 3.21. Dağıtımli zaman gecikmeli ağ modeli yapısı

Harici girişlerle birlikte lineer olmayan özbağlanımlı ağlar(Nonlinear autoregressive network with exogenous inputs models-NARX)


Şuana kadar görmüş olduğumuz yapay sinir ağ yapılarının ya giriş tabakasında ya da ileri besleme ağında dinamik yapı mevcuttu. Lineer olmayan özbağlanımlı ağlar geri beslemeli dinamik ağlardır.



Şekil 3.22. Gizli katmanında 3 nöron bulunan NARX ağı


Bağımlı çıkış sinyali $y(t)$, bağımsız giriş sinyalinin önceki değeri ve çıkış sinyalinin önceki değerleri üzerinden indirgenir. NARX modeli için eşitlik;

$$y(t) = f(y(t-1), y(t-2), \dots, y(t-n_y), u(t-1), u(t-2), \dots, u(t-n_u)) \quad (3.40)$$




Şekil 3.23. NARX ağ yapısı

NARX yapay sinir ağları paralel mod veya seri-paralel modda eğitilebilirler. Her iki metotta giriş ve çıkış verileri zamanın fonksiyonudur. Seri-paralel mod statik geri yayılım algoritması ile eğitilebilir. Fakat paralel modda geri besleme çevriminden dolayı dinamik geri yayılım algoritmasının kullanılması gerekmektedir.



Şekil 3.24. Paralel NARX sistemin dinamik sistem modeli



Şekil 3.25. Seri-Paralel NARX sistemin dinamik sistem modeli

Paralel metotta sistemin hedeflenen çıkışı ile ağıın çıkışı karşılaştırılır ve hata $\xi(k)$ dinamik geri yayılım algoritmasını kullanarak ağırlıkları ayarlar. Paralel modda hata devamlı yakınsanmaz ve ağı eğitmede başarısızlıklar olur. Seri-paralel modda, sistemin çıkışı tanımlanacak sisteme geri beslenir. Seri-paralel eğitimde hata genellikle yakınsanır ve tatmin edici bir model benzetimi elde edilmiş olur [19].

NARX yapay sinir ağlarının birçok kullanım alanı vardır. Giriş sinyalinin gelecek değerini tahmin etmek, hedeflenen çıkışın giriş sinyalinin gürültü etkisinden kurtarmak için lineer olmayan filtreleyici ve lineer olmayan dinamik ağların modellenmesinde kullanılır [28].

3.9. Bir Yapay Sinir Ağıının Tasarımı

Bir sinir ağı modeli oluşturmak için nöronların bağlantı şekli, işlemci elemanlarının kullandıkları toplama ve aktivasyon fonksiyonları, öğrenme metodu, öğrenme kuralı ve algoritması belirlenmelidir. Eldeki veriye göre model tasarlanır. Kurulan modelin başarısı modelin mimarisinin doğru oluşturulması ile doğrudan ilgilidir. Bunun için yapay sinir ağı tasarımcısının, ağı yapısına ve işleyişine ilişkin aşağıdaki kararları vermesi gerekmektedir.

- Ağ mimarisin seçimi ve yapısal özelliklerinin belirlenmesi(katman sayısı ve katmandaki nöron sayısı)
- İşlemci elemanların kullandığı fonksiyonların karakteristik özelliklerinin belirlenmesi
- Öğrenme algoritması ve parametrelerin belirlenmesi
- Eğitim ve test setinin oluşturulması

Bu kararlar doğru verilmediği takdirde sistem karmaşıklığı artacaktır. En doğru kararı verebilmek için literatürdeki benzer çalışmalar gözden geçirilerek uygulanacak problem için belirlenmiş olan parametrelerle yapıyı tasarlamaya ve eğitmeye başlamak en akılcı yaklaşım olacaktır. Ayrıca sistem tasarlanırken uygulamanın ne kadar süreceği, hafızada ne kadar yer kaplayacağı gibi bilgiler düşünülmelidir.

3.9.1. YSA Ağ Yapısının Seçimi

Uygulanan YSA mimarisinin ve yapısının seçimi, uygulama problemine bağlı olarak seçilmelidir. Bunun için hangi YSA yapısının hangi tip uygulama problemlerinde başarılı olacağının önceden bilinmesi gereklidir.

Uygulama problemi bir sınıflandırma problemi ise problemin zorluğuna ve ayrıştırılacak sınıf sayısına göre MLP'den başlayarak, LVQ ve RBFNN gibi yapılar sırayla seçilebilir. Çok sayıda sınıfa sahip problemlerde RBFNN yapısı tercih edilmemelidir. Bunun yerine LVQ tercih edilebilir. Karmaşık uygulamalarda genellikle MLP mimarisi ile başlamak doğru bir yaklaşım olacaktır.

Bir YSA'nın karmaşıklığının azaltılmasında en etkin araç, ağın mimari yapısını değiştirmektir. Gereğinden fazla nöron içeren ağ yapılarında, daha düşük genelleme kabiliyetleriyle karşılaşılacağı unutulmamalıdır [25].

3.9.2. YSA Öğrenme Algoritmasının Seçimi

YSA yapısının seçiminden sonra uygulama başarısını belirleyen en önemli faktör ise öğrenme algoritmasıdır. Genellikle ağ yapısı öğrenme algoritmasının seçiminde belirleyicidir. YSA 'ların az veriyle öğrenebilmeleri ve genelleme yapabilmeleri YSA'ları birçok probleme uygulanması için cazip kılmaktadır. Bunun sebebi ise deneysel olarak fazlaca veri elde etmenin maliyeti arttırmasıdır. YSA sistemlerinin problemi öğrenme başarısı, kullanabilirliğini belirleyen genelleme başarısıyla belirlenir.

3.9.3. Ara Katman Sayısı ve Nöron Sayısının Belirlenmesi

Ağ yapısında kullanılan katman sayısı ve her katmanda bulunan nöron sayısı yapay sinir ağının karmaşıklığını belirler. Katman sayısı ve katmanlardaki nöron sayısı arttıkça yapay sinir ağının işlem ve öğrenme yeteneği artarken yakınsama süresi de artmakta, ağın genelleme kabiliyeti düşmekte ve ağın ezberlemesine (Memorization) neden olmaktadır. Gereğinden az kullanmak ise verilerdeki desenin yeteri kadar öğrenilmemesine yol açar. Gizli katmandaki sinir sayılarının arttırılması simülasyon sırasında hem hafıza hem de CPU'nun yükünü arttırmaktadır.

3.9.4. Normalizasyon

Verilerin normalizasyonu için seçilen yöntem YSA performansını doğrudan etkileyecektir. Çünkü normalizasyon, giriş verilerinin transfer edilirken fonksiyonun aktif olan bölgesinden aktarılmasını sağlar. Genellikle verinin [0,1] veya [-1,+1] aralıklarından birine ölçeklenmesi önerilmektedir. Uygun bir ölçeklendirme seçilmemesi hem uygulama hem de öğrenme algoritması açısından olumsuz sonuçlar ortaya çıkabilmektedir. Eğer öğrenme fonksiyonu bipolar bir fonksiyon ise ölçekleme [-1,+1] aralığına, aksi durumda ölçekleme [0,+1] aralığına yapılmalıdır.

$$x_{norm} = \frac{2(x - x_{min})}{x_{max} - x_{min}} - 1 \quad (3.41)$$

3.8.5. Öğrenme Oranının Ağ Üzerindeki Etkisi

Öğrenme oranının ağ performansı üzerinde önemli bir etkiye sahiptir. Küçük öğrenme oranı değerleri için eğitme işlemi uzun zaman alırken bu değerlerin büyütülmesi ile eğitme işlemi kısa zamanda gerçekleşmektedir. Öğrenme oranının artırılması durumunda öğrenme için gerekli adım sayısında azalma meydana gelmektedir. Öğrenme oranının arttırılması ağın toplam hatası üzerinde bir

iyileştirme meydana getirmektedir. Fakat bu değerin gereğinden fazlaca artırılması pek bir yakınsama meydana getirmez.

3.8.6. Performans Fonksiyonun Seçilmesi

Performans fonksiyonları, istenilen çıktı değerleri ile ağıın ürettiği değerleri arasındaki farkların kümülatif değerleri hesaplanmaktadır. Hesaplanan bu değerler sayesinde ağıın, eğitim setinin gösterdiği desene ne kadar yaklaştığı gözlenmekte ve bağlantıların ağırlık değerleri bu bilgiler kullanılarak değiştirilmektedir. Bu nedenle öğrenme performansını etkileyen önemli hususlardan birisi de performans fonksiyonudur. İleri beslemeli ağlarda kullanılan tipik performans fonksiyon hata kareleri ortalamasıdır (Mean Square Error-MSE).

$$MSE = \frac{1}{N} \sum_{i=1}^N (t_i - t_{di})^2 \quad (3.42)$$

Bu ağlarda kullanılan diğer bir performans fonksiyonu ise karesel ortalama hata karekökü(RMSE) hata fonksiyonudur.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (t_i - t_{di})^2} \quad (3.43)$$


4. KURU TİP BİR TRANSFORMATÖRÜN SARGI SICAKLIK DAVRANIŞININ YAPAY SİNİR AĞLARIYLA MODELLENMESİ

4.1. Giriş

Bu bölümde simulasyon sonuçları sunulacaktır. Kuru tip farklı güçlerdeki iki transformatörün sargı sıcaklık tahminini yapay sinir ağları kullanarak modellenmesi amaçlanmıştır. Sistemimiz dinamik olduğu için kullanacağımız yapay sinir ağı yapısı da dinamik sistem yapıları için uygun olan geri beslemeli yapay sinir ağı yapısıdır. Geri beslemeli yapay sinir ağlardan Elman Ağ modeli ve Harici Girişlerle Birlikte Lineer Olmayan Özbağlanımlı (NARX) Ağ modeli kullanılarak hangi ağ modelinde daha iyi sonuçlar elde edildiğine dair araştırmalar yapılmıştır.

Bilindiği üzere kuru tip transformatörün ömrü izolasyon ömrü ile doğrudan ilişkilidir. Transformatörün izolasyonunun bozulmasına neden olan sıcaklık ve zaman etkenlerinin toplamı transformatörün ömür uzunluğu hakkında bize büyük fikir vermektedir. Ayrıca transformatörün yüklenme kapasitesini belirlerken ortam sıcaklığını da göz önünde bulundurmalıyız. Transformatörün çalışma sıcaklığını, herhangi bir yükteki transformatörün sargılarındaki sıcaklık artışına ortam sıcaklığı eklenerek belirlenmelidir. Ayrıca nominal yükün üzerinde kısa zamanlı yüklemelerde transformatörün izolasyon ömrünü azaltır [33].

Kısaca özetlersek transformatörün sargı sıcaklığı üzerinde yük akımı ve çevre sıcaklığı etkilidir. Yapay sinir ağı yapısı oluşturulurken yük akımı, çevre sıcaklığı ve giriş gerilimi ağın giriş verileri; sargı sıcaklığı ise ağın çıkış verisi olarak ağı sunulmuştur. Deney verileri fakültemizin Elektrik Makinaları laboratuvarında oluşturulan iki ayrı deney setinden elde edilen verilerdir. Yapay sinir ağı modellenmesi için Matlab 2010b paket programı kullanılmıştır. Ekte ağ modelleri için oluşturulan m-file dosyaları bulunmaktadır. Deneyin elektriksel bağlantı şeması Şekil 4.1. 'de gösterilmiştir.




Şekil 4.1. Deney elektriksel bağlantı şeması


Deney verilerini kullanarak en iyi YSA yapısının elde edilmesi için her YSA yapısında ve öğrenme algoritmasının da öğrenme oranı, epoch sayısı, gizli katmandaki nöron sayısı ve gecikme sayısı değiştirilerek eğitim ve test işlemleri yapılmıştır. Gerçek sisteme en yakın ve en düşük hata değerleri (RMSE) yakalanmaya çalışılmıştır.

4.2. 5 KVA'lık Kuru Tip Bir Güç Transformatörünün Sargı Sıcaklığının Yapay Sinir Ağlarıyla Modellenmesi

Transformatörün sargı sıcaklığını ölçmek için sargıların içinde belirlenen 5 noktaya 5 adet PT100 sıcaklık sensörü koyuldu. 5 adet ölçümün ortalaması alınarak elde edilen sonuç, transformatörün sargı sıcaklığı olarak kabul edildi. Transformatörün çevresindeki iki noktadan çevre sıcaklığı ölçülüp ortalaması alınarak çevre sıcaklığı elde edildi. Laboratuvarındaki omik yük bankları kullanarak transformatörün yüklenmesi sağlanmıştır. 5'er dakika aralıklarla deneyden ölçüm verileri alınmıştır. Toplam 333 veri elde edilmiştir. 167 veri yapay sinir ağ yapısında eğitim amaçlı geriye kalan 166 veri de test amaçlı kullanılmıştır. Bütün veriler ağa verilmeden önce normalizasyon işlemine tabi tutulmuştur.



Resim 4.1. 5 KVA lık kuru tip güç transformatörü için kurulan deney seti




Resim 4.2. Omik yük bankları




Resim 4.3. Ölçüm için kullanılan güç analizörleri

4.2.1. Üç giriş değişkeni ile Elman modeli kullanarak sargı sıcaklık tahmini

Giriş değişkenleri olarak ağa çevre sıcaklığı, yük akımı, giriş gerilimi; çıkış değişkenleri olarak da sargı sıcaklık verilerini tanıtıyoruz. En iyi model yapısını bulmak için farklı aktivasyon fonksiyonları ile gizli katmanda farklı katman ve nöron sayıları denenmiştir. Ağımız 3 katmanlı olarak tasarlanmıştır. logsig aktivasyon fonksiyonu kullanılmış; öğrenme oranı=0,4 kabul edilmiş; iterasyon sayısı (epoch number) 200 ve çıkış katmanının aktivasyon fonksiyonu doğrusal (purelin) olarak belirlenmiştir.




Şekil 4.2. 3 girişli-1 çıkışlı Elman modelimizin şematik gösterimi



Şekil 4.3. Üç giriş değişkenli Elman modelinde Levenberg-Marquardt algoritması kullanarak elde edilen simulasyon

Ağ Levenberg-Marquardt geri yayılım algoritmasıyla eğitildiğinde elde edilen tahmin sonucuyla deney setinden elde edilen ölçümler karşılaştırılıp ikisi arasındaki fark (hata miktarı) Şekil 4.2.'de çizdirilmiştir. Ayrıca şekilde yük akımı ve çevre sıcaklığına göre sargı sıcaklık değişimini de görmekteyiz. Kapalı mekanda deney yapıldığı için çevre sıcaklığında maks. 2° 'lik değişim vardır. Şekil 4.3. 'te şebeke geriliminin değişimi çizdirilmiştir.



Şekil 4.4. Şebeke geriliminin değişimi

YSA ‘ ya uygulanan üç girişin (yük akımı, çevre sıcaklığı ve geniş gerilimi) transformatörün sargı sıcaklığı üzerindeki kıyaslandığında yük akımının en büyük etken olduğu sonucuna varılmıştır.

Elman modelinde Levenberg-Marquardt eğitim algoritmasını kullanarak gizli katmanda farklı nöron sayısının performans üzerindeki etkisi Çizelge 4.1. ‘de gösterilmiştir. Çizelgeye göre gizli katmandaki nöron sayısı arttırıldıkça performans değeri de düşmektedir.


Çizelge 4.1. 3 tabakalı Elman modelinin Levenberg-Marquardt öğrenme algoritmasını kullanarak elde edilen RMSE ve pik hata değerleri

Gizli katmandaki nöron sayısı	RMSE	Min	Max
9	0.4938	-2.1997	1.1324
10	0.4545	-1.5210	1.4802
11	0.3785	-1.7922	1.275
12	0.3620	-1.4373	1.2133


Ağ Bayesian-Regulazition geri yayılım algoritmasıyla eğitildiğinde elde edilen tahmin sonucuyla deney setinden elde edilen ölçümler karşılaştırılıp ikisi arasındaki fark (hata miktarı) Şekil 4.4.’ de çizdirilmiştir.

4.2.2. Üç giriş değişkeni ile NARX modeli kullanarak sargı sıcaklık tahmini


Giriş değişkenleri olarak ağı çevre sıcaklığı, yük akımı, giriş gerilimi; çıkış değişkenleri olarak da sargı sıcaklık verilerini tanıtıyoruz. En iyi model yapısını bulmak için farklı aktivasyon fonksiyonları ile gizli katmanda farklı katman ve nöron sayıları denenmiştir. Ağımız 3 katmanlı olarak tasarlanmıştır. Logsig aktivasyon fonksiyonu kullanılmış; öğrenme oranı=0.4 kabul edilmiş; iterasyon sayısı(epoch number) 1000 ve çıkış katmanının aktivasyon fonksiyonu doğrusal (purelin) olarak belirlenmiştir.



Şekil 4.6. 3 girişli-1 çıkışlı NARX modelimizin şematik gösterimi



Şekil 4.7. Üç giriş değişkenli NARX modelinde Levenberg-Marquardt algoritması kullanarak elde edilen simulasyon



Şekil 4.8. Üç giriş değişkenli NARX modelinde Bayesian-Regulazition algoritması kullanarak elde edilen simulasyon

Ağ Bayesian-Regulazition geri yayılım algoritmasıyla eğitildiğinde elde edilen tahmin sonucuyla deney setinden elde edilen ölçümler karşılaştırılıp ikisi arasındaki fark(hata miktarı) Şekil 4.7.'de çizdirilmiştir. Şekil 4.6'da Levenberg-Marquardt eğitim algoritması uygulanarak tahmin edilen sargı sıcaklığı ile ölçülen sargı sıcaklığı arasında büyük farklar oluşmuştur. Deneme yöntemiyle performans belirleyiciden elde edilen değerler 30' un üzerinde olduğu için NARX yapısında

Levenberg-Marquardt eğitimi sonucunda elde edilen tahmin değerleri sunulmayacaktır.

NARX modelinde Bayesian Regulation eğitim algoritmasını kullanarak gizli katmanda farklı nöron sayısının ve gecikme sayısının performans üzerindeki etkisi Çizelge 4.3. 'de gösterilmiştir. Çizelgeye göre gizli katmandaki nöron sayısı arttırıldıkça performans değeri düşmektedir. Gizli katmanda 10 nöron olduğunda gecikme sayısı 3 'den sonra performans değeri artmaktadır.

Çizelge 4.3. 3 tabakalı NARX modelinde Bayesian-Regulation öğrenme algoritmasını kullanarak elde edilen RMSE ve pik hata değerleri

Gizli katman. nöron sayısı	Gecikme Sayısı	RMSE	Min	Max
10	2	0.3240	-1.7276	1.1023
	3	0.3099	-1.8514	1.2779
	4	0.3129	-1.8201	1.3465
	5	0.3202	-1.8377	1.5307
12	2	0.2974	-1.7634	0.9952
	3	0.2819	-1.8874	1.0192
	4	0.2777	-1.8603	1.0202
	5	0.2717	-1.8597	0.9747

4.3. 3 KVA'lık Kuru Tip Bir Güç Transformatörünün Sargı Sıcaklığının Yapay Sinir Ağlarıyla Modellenmesi

Transformatörün sargı sıcaklığını ölçmek için sargıların içinde belirlenen 18 noktaya 18 adet PT100 sıcaklık sensörü koyuldu. 18 adet ölçümün ortalaması alınarak elde edilen sonuç transformatörün sargı sıcaklığı olarak kabul edildi. Transformatörün çevresindeki iki noktadan çevre sıcaklığı ölçülüp ortalaması alınarak çevre sıcaklığı elde edildi. Labaratuvardaki omik yük bankları kullanarak transformatörün yüklenmesi sağlanmıştır. 1' er dakika aralıklarla deneyden ölçüm verileri alınmıştır. Toplam 4318 veri elde edilmiştir. 2159 veri yapay sinir ağ yapısında eğitim amaçlı geriye kalan 2159 veri de test amaçlı kullanılmıştır.




Resim 4.4. 3 KVA lık kuru tip güç transformatörü için kurulan deney seti



Resim 4.5. Ölçüm için kullanılan güç analizörü ve datalogger


4.3.1. Üç giriş değişkeni ile Elman modeli kullanarak sargı sıcaklık tahmini

Giriş değişkenleri olarak ağa çevre sıcaklığı, yük akımı, giriş gerilimi; çıkış değişkenleri olarak da sargı sıcaklık verilerini tanıtıyoruz. En iyi model yapısını bulmak için farklı aktivasyon fonksiyonları ile gizli katmanda farklı katman ve nöron sayıları denenmiştir. Ağımız 3 katmanlı olarak tasarlanmıştır. Logsig aktivasyon fonksiyonu kullanılmış; öğrenme oranı=0,4 kabul edilmiş; iterasyon sayısı(epoch number) 200 ve çıkış katmanının aktivasyon fonksiyonu doğrusal (purelin) olarak belirlenmiştir.



Şekil 4.9. Üç giriş değişkenli Elman modelinde Levenberg-Marquardt algoritması kullanarak elde edilen simulasyon

Ağ Levenberg-Marquardt geri yayılım algoritmasıyla eğitildiğinde elde edilen tahmin sonucuyla deney setinden elde edilen ölçümler karşılaştırılıp ikisi arasındaki fark (hata miktarı) Şekil 4.8.'de çizdirilmiştir. Ayrıca şekilde yük akımı ve çevre sıcaklığına göre sargı sıcaklık değişimini de görmekteyiz. Kapalı mekanda deney yapıldığı için çevre sıcaklığında maks. 2° 'lık değişim vardır. Şekil 4.9. 'da şebeke geriliminin değişimi çizdirilmiştir.




Şekil 4.10. Şebeke geriliminin değişimi

YSA ‘ ya uygulanan üç girişin (yük akımı, çevre sıcaklığı ve girişi gerilimi) transformatörün sargı sıcaklığı üzerindeki kıyaslandığında yük akımının en büyük etken olduğu sonucuna varılmıştır.

Elman modelinde Levenberg-Marquardt eğitim algoritmasını kullanarak gizli katmanda farklı nöron sayısının performans üzerindeki etkisi Çizelge 4.4. ‘de gösterilmiştir. Çizelgeye göre gizli katmandaki nöron sayısı arttırıldıkça performans değeri de düşmektedir.

Çizelge 4.4. 3 tabakalı Elman modelinin Levenberg-Marquardt öğrenme algoritmasını kullanarak elde edilen RMSE ve pik hata değerleri

Gizli katman sayısı	RMSE	Min	Max
10	1.5157	-7.5032	18.2856
11	1.4894	-5.4145	8.4288
12	1.1819	-2.4420	8.6926
13	0.7880	-5.8666	3.5396



Şekil 4.11. Üç giriş değişkenli Elman modelinde Bayesian-Regulazition algoritması kullanarak elde edilen simulasyon

Ağ Bayesian-Regulazition geri yayılım algoritmasıyla eğitildiğinde elde edilen tahmin sonucuyla deney setinden elde edilen ölçümler karşılaştırılıp ikisi arasındaki fark (hata miktarı) Şekil 4.10’da çizdirilmiştir.

Elman modelinde Bayesian Regulation eğitim algoritmasını kullanarak gizli katmanda farklı nöron sayısının performans üzerindeki etkisi Çizelge 4.5. ‘de gösterilmiştir. Çizelgeye göre gizli katmandaki nöron sayısı arttırıldıkça performans değeri de düşmektedir.

Çizelge 4.5. 3 tabakalı Elman modelinin Bayesian-Regulazition öğrenme algoritmasını kullanarak elde edilen RMSE ve pik hata değerleri


Gizli katmandaki nöron sayısı	RMSE	Min	Max
10	1.2692	-7.5326	12.1822
11	1.2246	-7.9201	15.6288
12	0.9827	-3.2562	16.0129
13	0.6326	-2.0335	12.3922

Her iki eğitim algoritmasını karşılaştırdığında (Levenberg-Marquardt ve Bayesian Regulation) bayesian regulation algoritmasıyla eğitilen ağı daha iyi performans


verdiği görülmektedir. Bunun sebebi bu algoritmanın daha iyi genelleştirme yeteneğine sahip olmasından kaynaklanmaktadır.

4.3.2. Üç giriş değişkeni ile NARX modeli kullanarak sargı sıcaklık tahmini

Giriş değişkenleri olarak ağı çevre sıcaklığı, yük akımı, giriş gerilimi; çıkış değişkenleri olarak da sargı sıcaklık verilerini tanıtıyoruz. En iyi model yapısını bulmak için farklı aktivasyon fonksiyonları ile gizli katmanda farklı katman ve nöron sayıları denenmiştir. Ağımız 3 katmanlı olarak tasarlanmıştır. Logsig aktivasyon fonksiyonu kullanılmış; öğrenme oranı=0,4 kabul edilmiş; iterasyon sayısı(epoch number) 1000 ve çıkış katmanının aktivasyon fonksiyonu doğrusal (purelin) olarak belirlenmiştir.



Şekil 4.12. Üç giriş değişkenli NARX modelinde Levenberg-Marquart algoritması kullanarak elde edilen simulasyon



Şekil 4.13. Üç giriş değişkenli NARX modelinde Bayesian-Regulazition algoritması kullanarak elde edilen simulasyon

Ağ Bayesian-Regulazition geri yayılım algoritmasıyla eğitildiğinde elde edilen tahmin sonucuyla deney setinden elde edilen ölçümler karşılaştırılıp ikisi arasındaki fark Şekil 4.12’ de çizdirilmiştir.

Şekil 4.11’ de Levenberg-Marquardt eğitim algoritması uygulanarak tahmin edilen sargı sıcaklığı ile ölçülen sargı sıcaklığı arasında büyük farklar oluşmuştur. Deneme yöntemiyle performans belirleyiciden elde edilen değerler 20’ un üzerinde olduğu için NARX yapısında Levenberg-Marquardt eğitimi sonucunda elde edilen tahmin değerleri sunulmayacaktır.

Çizelge 4.6. 3 tabakalı NARX modelinin Bayesian-Regulazition öğrenme algoritmasını kullanarak elde edilen RMSE ve pik hata değerleri

Gizli katman. nöron sayısı	Gecikme Sayısı	RMSE	Min	Max
10	5	2.4946	-3.8709	10.9485
	6	1.5955	-6.7888	3.9145
	7	2.0444	-12.9432	4.5348
12	5	1.5601	-4.9792	10.8177
	6	0.6248	-2.8375	7.9477
	7	0.7869	-5.3460	1.9462

NARX modelinde Bayesian Regulation eğitim algoritmasını kullanarak gizli katmanda farklı nöron sayısının ve gecikme sayısının performans üzerindeki etkisi Çizelge 4.6. 'de gösterilmiştir. Çizelgeye göre gizli katmandaki nöron sayısı arttırıldıkça performans değeri düşmektedir. Gizli katmanda 10 nöron olduğunda gecikme sayısı 6 'dan sonra performans değeri artmaktadır.

5. SONUÇ

Transformatörlerin çeşitli çalışma sıcaklıklarında muhtemel ömrü tam olarak bilinmemektedir. İzolasyon ömrü üzerinde çalışma sıcaklığının etkilerini hesaplarken, aşırı yüklenmeler veya yüksek ortam sıcaklığından dolayı oluşan normal çalışma sıcaklığından daha yüksek sıcaklıklar transformatörün izolasyonuna zarar verir ve dolayısıyla transformatörün ömrünü azalttığı konusunda görüş birliği oluşmuştur.

Bu çalışmada kuru tip bir sargı sıcaklığını tahmin etmek için yapay sinir ağları yöntemine gidilmiştir. Yapay sinir ağları kullanılmasıdaki amaç kompleks ve lineer olmayan yapılarda öğrenebilme yeteneğidir. Hem modelleme de daha hızlı ve herhangi bir algoritmayı model üzerinde kullanmada bize daha fazla kolaylık sağlar. ANSI/IEEE numeriksel teknikleri kullandığımız zaman kesin ve mevcut olmayan transformatör parametrelerine ihtiyaç duyarız. Klasik yöntemlerle modelleme yaptığımızda büyük miktarlarda matematiksel formüllerle uğraşmak zorunda kalacağız. Klasik algoritmalarda tam olarak tanımlı bir çözüm yolu olmayan problemler çözülemezken yapay sinir ağları sayesinde problemler çözüm yöntemi hakkında herhangi bir bilgi verilmeksizin çözülebilir. Yapay sinir ağlarının bu tip problemleri çözebilmesi için gereken tek şey örnek girdiler için sonuçların verilmesidir. Ayrıca yapay sinir ağları probleme göre eğitildikten sonra eğitim sırasında karşılaşmadığı durumlar içinde yanıt verebilir. Yapay sinir ağları ile çevresel ve çalışma durumuna bağlı olarak çalışan bir transformatörün muhtemel arızalarını önceden tahmin etmek için tam bir teşhis olarak kullanılabilir. Ayrıca bu sayede firmalar planlama ve bakım talimatlarını aldıkları bilgilere göre hazırlayabilirler.

Çalışmamızda ele aldığımız sistem dinamik olduğu için yani şimdiki değeri bir önceki değerleriyle bağlantılı olduğundan dolayı yapay sinir ağlarında geri beslemeli sistem yapısı kullanılmıştır. 5 Kva ve 3 Kva 'lık güç transformatöründen oluşan iki ayrı deney seti kurulmuş ve her iki transformatör içinde ayrı ayrı zamanlarda belirlenen verilerin alınması sağlanmıştır. Bunlar yapay sinir ağlarının girişinde kullanılacak olan çevre sıcaklığı, yük akım ve giriş gerilimi; yapay sinir ağlarının

ıkışına uygulanacak olan sargı sıcaklıđı verileridir. Geri beslemeli yapay sinir ađlarından Elman ve NARX modelleri kullanılmıřtır. Elman modelinde geri beslemeyi bir sonraki katmandan(ıkış katmanı hari), NARX modelinde ise geri beslemeyi ıkış katmanından almaktadır. Dođru ađ yapısını semek farklı sayıda gecikme hattı ve gizli katmanda nron kullanılarak deneme yanılma yntemiyle seilmiřtir. Eđitim setinden alınan veriler normalizasyon iřlemine tabi tutuldu. Eđitim algoritması olarak Levenberg-Marquardt' ın bir eřidi olan Bayesian Regulation algoritmasında eđitimin daha iyi sonulandığı yapılan simlasyon sonularında grlmřtr. Modeller karřılařtırıldığında NARX modeli hem hata miktarı aısından ELMAN modeline gre daha iyi sonular vermiřtir hem de eđitim hızı daha yksektir.

KAYNAKLAR

1. İlkahraman, M., “Güç Transformatör Arızalarının İncelenmesi”, Master Tezi, **Gazi Üniversitesi Fen Bilimleri Enstitüsü**, Ankara, 1-4(2008).
2. Moonhee, L., “Temperature Distribution In Ventilated Dry-Type Transformer Windings”, Phd. Thesis, **The University of Guelph**, 174p. (2008)
3. Kömürgöz, G., Güzelbeyoğlu N., ” Kendi kendine soğuyan kuru tip güç transformatörlerinde sıcaklık dağılımının belirlenmesi”, **itüdergisi/d mühendislik**, 1:1 (2002).
4. “IEEE Recommended Practice for Installation, Application, Operation, and Maintenance of Dry-Type General Purpose Distribution and Power Transformers”, **IEEE**, Standard C57.94-1982 (2006).
5. Büyükbıçakcı, E., “Faz Değiştirici Malzeme (PCM) Kullanılarak Transformatörlerin soğutulması”, Yüksek Lisans Tezi, **Marmara Üniversitesi Fen Bilimleri Enstitüsü**, İstanbul, 3-10 (2006).
6. Veltman, A., Pulle, D., Doncker, R. , “The Transformer”, Fundamentals of Electrical Drives, **Springer**, 45-64 (2007).
7. Erickson, R.W., Maksimovic, D. , “Fundamentals of Power Electronics”, **Kluwer Academic Publishers**, 491-510 (2004).
8. Mamizadeh, A., “Yağlı tip transformatörlerin doğrusal olmayan dinamik termal modellenmesi”,Yüksek lisans tezi, **Gazi Üniversitesi Fen Bilimleri Enstitüsü**, Ankara, 28-35(2010)
9. Fitzgerald, A. E., Kingsley, C.J., Umans, S.D., “Electric Machinery”, **McGraw-Hill**, New York, 50-58 (1990).
10. Mahmoud, S. K., “Yağlı Dağıtım Transformatörlerinde Kayıpların Hesaplanması, Yüksek Lisans Tezi, **Gazi Üniversitesi Fen Bilimleri Enstitüsü**, Ankara, 15-45 (2008)
11. Iskender, İ., Mamizadeh, A., “ Nonlinear thermal modeling of top oil temperature rise for oil-immersed distribution transformers “, **14th Scientific conference on Computer application in electrical engineering**, ZKwE`2009, Poznan , Poland, 227-228, 20-22 (2009).
12. Iskender, İ., Mamizadeh, A., "Thermal Capacitance Calculation of Top-Oil Temperature for Power Transformers", **International Review of Electrical Engineering (IREE)**, 4(5): 882-886 (2009).

13. Mamizadeh, A., Iskender, I., “Analyzing and Comparing Thermal Models of Indoor and Outdoor Oil-Immersed Power”, ***PowerTech 2009 IEEE Bucharest***, 1 – 8 (2009)
14. Iskender, İ, Mamizadeh, A., ”Winding Thermal Analyzing of Dry Type Transformers “, ***5th International Conference on Technical and Physical Problems of Power Engineering***, TPE 2009 University of the Basque Country Bilbao, Spain 3-5 (2009).
15. Iskender, İ. , Mamizadeh, A. , “ Nonlinear Thermal Modeling Of Indoor And Outdoor Oil-Immersed Power Transformers”, ***Journal of Electrical Engineering***, 60: 321-327 (2009).
16. Fırat Bayır, “Yapay sinir ağları ve Tahmin modellemesi Üzerine Bir Uygulama”, Yüksek Lisans Tezi, ***İstanbul Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalı***, İstanbul, 3-10 (2006).
17. Nabiyev, V. V., “Yapay Sinir Ağları”, ***Seçkin***, Ankara, 575-580 (2003).
18. Saraç, T., “Yapay Sinir Ağları”, Seminer, ***Gazi Üniversitesi Fen Bilimleri Enstitüsü***, Ankara, 10-25 (2004).
19. Bose, B., “Neural Network Principles and Applications”, ***Prentice Hall PTR***, United States of America, 625-657 (2002).
20. Foo, J.S. , Ghosh, P.S., “Artificial Neural Network Modelling of Partial Discharge Parameters For Transformer Oil Diagnosis”, ***Annual Report Conference on Electrical Insulation and Dielectric Phenomena***, Malaysia, 470-473 (2002).
21. Öztemel, E., “Yapay Sinir Ağları”, ***Papatya Yayıncılık***, İstanbul, 29-34 (2003).
22. Nguyen, H.H., A neural fuzzy approach to modeling the thermal behaviour of power transformers”, Yüksek Lisans Tezi, ***School of Electrical Engineering Faculty of Health, Engineering&Science Victory University***, 17-24 (2007).
23. He, Q. , Si, J. and Tylavsky, D. , Prediction of top-oil temperature for transformers using neural network, ***IEEE Transactions on Power Delivery***, 1205-1211 (2000).
24. Mackay, D. J. C., “Bayesian interpolation”, ***Neural Computation***, 4: 415-447 (1992).
25. Sağiroğlu, Ş., Beşdok, E., Erler, M., “Yapay Zeka Uygulamaları-1”, ***Ufuk Yayıncılık***, 43 (2003).

26. Elmas, Ç. , “Yapay Sinir Ağları”, **Seçkin Yayıncılık**, Ankara, 95-170 (2003)
27. Hopfield, J.J., Tank, D.W. , “Neural computation of decisions in optimization problems”, **Biological Cybernetics**, 141-152 (1985).
28. Beale, M., Hagan, M., Demuth, H., “Neural Network Toolbox7 Users Guide, Mathswork”, United States, 254-257 (1196).
29. Galdi, V., Ippolito, L. ,Piccola, A., “Neural Diagnostic System for Transformer Thermal Overload Protectio”, **IEE Proc-Electr. Power Appl.**, 147(5): 415-417 (2000).
30. Silindir, V., Dağ, H., Afacan, E., Aydemir, T., “Sinyaller ve Sistemler “, **Nobel Yayın Dağıtım**, Ankara, 15-20 (2001).
31. Alavala, C. , “Recurrent Networks”, Fuzzy Logic and Neural Networks, **New Age International Publishers**, India, 157-189 (2009).
32. Haykin, S., “Dinamically Driven Recurrent Networks”, Neural Networks, **Prentice Hall**, USA, 733-781 (1999).
33. IEEE Guide for Loading Mineral Dry-Type-Distribution and Power Transformers, **IEEE**, Standard C57.96-1999 (1999).

EKLER

EK-1. 3 Girişli ELMAN Model M-file Dosyası

%Geri Beslemeli Ağ Yapılarından Elman Ağ Modelini kullanarak Yapay Sinir
%Ağının Modellenmesi
%5KVA ve 3KA lık kuru tip transformatörler

%Giriş ve çıkış verilerinin ağa sunulması

```
degis1=xlsread('.....\input.xls');
degis2=xlsread('.....\target.xls');
degis3=xlsread('.... \load.xls');
degis4=xlsread('..... \ambient.xls');
```

```
X1=degis1.';
Y1=degis2.';
Xload=degis3.';
Xamb=degis4.';
```

%Verilere normalizasyon işleminin yapıldığı bölüm

```
[x1,PS]=mapminmax(X1);
[y1,TS]=mapminmax(Y1);
```

%Eğitim ve test verilerinin oluşturulduğu kısım

```
trainInd = 1:2:333;
testInd = 2:2:333;
[trainP,testP] = divideind(x1,trainInd,testInd);
[trainT,testT] = divideind(y1,trainInd,testInd);
[loadp]=divideind(Xload,testInd);
[ambientp]=divideind(Xamb,testInd);
```

EK-1.(Devam) 3 Girişli ELMAN Model M-file Dosyası

```
x1=trainP;
y1=trainT;
x2=testP;
y2=testT;
```

```
x11 = con2seq(x1);
x22= con2seq(x2);
y11 = con2seq(y1);
```

%Ağın oluşturulduğu ve ağa ait parametrelerin girildiği bölüm

```
net=newlrm(x1,y1,12,{'tansig' 'purelin'},'trainbr');
```

```
net.trainParam.epochs=100;%iterasyon sayısı(epoch number)
```

```
net.trainParam.lr=0.4;%Öğrenme oranı
```

```
net.trainParam.show=50;
```

```
net.trainParam.goal=0.00000001;
```

```
net.divideFcn='dividerand';
```

```
net.divideMode='sample';
```

%Ağın eğitildiği bölüm

```
[net,tr]=train(net,x11,y11);
```

%Ağın test verilerine göre simule edildiği kısım

```
a=net(x22);
```

%Verilerin denormalizasyon yapıldığı bölüm

```
output = mapminmax('reverse',a,TS);
```

```
target = mapminmax('reverse',y2,TS);
```

%hata miktarının bulunduğu bölüm

EK-1.(Devam) 3 Girişli ELMAN Model M-file Dosyası

```

e = cell2mat(output)-target;
performance=perform(net,con2seq(target),output)
gensim(net)
%Minumum ve Maksimum hataların bulunduğu bölüm
minumum=min(e)
maximum=max(e)

view(net)
plotresponse(target,cell2mat(output))

numPts=length(e);
for i=1:numPts;
p(i)=e(i)^2;
end
s=1:length(e);
t=5*s;

% Sonuçlara göre gerekli grafiksel çizimlerin yapıldığı bölüm

figure(5)
plot(t,e,'g');
hold
plot(t,target,'r');
% plot(t,cell2mat(y22),'r');
hold on
% plot(t,output,'b');
plot(t,cell2mat(output),'b');
hold on
plot(t,load,'k');
```

EK-1.(Devam) 3 Girişli ELMAN Model M-file Dosyası

```
plot(t,ambient,'mx');  
grid;  
ylabel('SICAKLIK(C)');  
xlabel('ZAMAN(Dakika)');  
legend('hata','Ölçüm','Tahmin','Yük akımı','Çevre Sıcaklığı');  
title('ELMAN Yapay Sinir Ağ Modelini Kullanarak Sargı Sıcaklığının Tahmini');
```

%Ağırlık ve biasların gösterildiği bölüm

```
W11=net.IW{1,1}
```

```
b1=net.b{1}
```

```
W21=net.LW{2,1}
```

```
b21=net.b{2}
```

%Ortalama karesel hatanın bulunduğu kısım

```
rmse=sqrt(sum(p)/length(e))
```

EK-2. 3 Girişli NARX Model M-file Dosyası

```

clear all
close all

%Geri Beslemeli Ağ Yapılarından NARX Ağ Modelini kullanarak Yapay Sinir
%Ağının Modellenmesi
%5KVA ve 3KA lık kuru tip transformatörler
%Verilerin ağa sunulduğu bölüm

degis1=xlsread('..... \input2.xls');
degis2=xlsread('..... \target2.xls');
degis3=xlsread('.....\load2.xls');
degis4=xlsread('.....\ambient2.xls');

X1=degis1.';
Y1=degis2.';
Xload=degis3.';
Xamb=degis4.';

%Normalizasyon işleminin yapıldığı bölüm
[x1,PS]=mapminmax(X1);
[y1,TS]=mapminmax(Y1);

%Verilerin test ve eğitim verilerine bölündüğü bölüm
trainInd = 1:2:4318;
testInd = 2:2:4318;
[trainP,testP] = divideind(x1,trainInd,testInd);
[trainT,testT] = divideind(y1,trainInd,testInd);
[loadp]=divideind(Xload,testInd);
[ambientp]=divideind(Xamb,testInd);

x1=trainP;
```

EK-2.(Devam) 3 Girişli NARX Model M-file Dosyası

```

y1=trainT;
x2=testP;
y2=testT;
x11 = con2seq(x1);
x22= con2seq(x2);
y11 = con2seq(y1);
y22 = con2seq(y2);

```

%Gecikme sayılarının belirlendiği bölüm

```

inputDelays = 1:7;
feedbackDelays = 1:7;
hiddenLayerSize = 12;
load=loadp(6:2159);
ambient=ambientp(6:2159);

```

%Ağın oluşturulduğu bölüm

```

net = narxnet(inputDelays,feedbackDelays,hiddenLayerSize);

```

% Ağın özelliklerinin belirlendiği bölüm

```

[inputs,inputStates,layerStates,targets] = preparets(net,x11,{},y11);
net.trainParam.epochs=200;%maks. number of epochs to train
net.trainParam.lr=0.4;%learning rate
net.trainParam.show=50;%epochs between updating display
net.trainParam.goal=0.00000001;%sum-squared error goal
net.trainFcn='trainbr';
net.divideMode='sample';

```

% Ağın eğitildiği kısım

```

[net,tr] = train(net,inputs,targets,inputStates,layerStates);

```

EK-2.(Devam) 3 Girişli NARX Model M-file Dosyası

% Closed Loop Network

```
netc=closeloop(net);
netc.name = [net.name ' - Closed Loop'];
view(netc)
gensim(netc)
```

%Hata miktarının belirlendiği bölüm

```
[Xs,Xi,Ai,Ts] = preparets(netc,x22,{},y22);
yc = netc(Xs,Xi,Ai);
target=mapminmax('reverse',Ts,TS);
output1 = mapminmax('reverse',yc,TS);
error= cell2mat(target)-cell2mat(output1);
```

```
ploterrcorr(error)
numPts=length(error);
for i=1:numPts;
p(i)=error(i)^2;
end
s=1:length(error);
t=s;
```

%İstenilen çizimlerin elde edildiği bölüm

```
plotresponse(target,output1)
minumum=min(error)
maximum=max(error)
```

```
figure(5)
plot(t,error,'g');
hold
plot(t,cell2mat(target),'r');
```


EK-2.(Devam) 3 Girişli NARX Model M-file Dosyası

```

% plot(t,cell2mat(y22),'r');
hold on
%plot(t,output,'b');
plot(t,cell2mat(output1),'b');
hold on
plot(t,load,'k');
plot(t,ambient,'mx');
grid;
ylabel('SICAKLIK(C)');
xlabel('ZAMAN(Dakika)');
legend('hata','Ölçüm','Tahmin','Yük akımı','Çevre Sıcaklığı');
title(' NARX Yapay Sinir Ağ Modelini Kullanarak Sargı Sıcaklığı Tahmini');
W11=netc.IW{1,1}
b1=netc.b{1}
w12=netc.LW{1,2}
W21=netc.LW{2,1}
b21=netc.b{2}
rmse=sqrt(sum(p)/length(error))

```

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı : AŞKIN, Dildade

Uyruğu : T.C.

Doğum tarihi ve yeri : 27.07.1982 Elazığ

Medeni hali : Bekar

Telefon : 0 (312) 318 75 62

e-mail : dildadeaskin@gmail.com

Eğitim Derece

Eğitim Birimi

Mezuniyet tarihi

Lisans	Fırat Üniversitesi Elk.-Elektronik Müh.	2004
Lise	Elazığ Mehmet Akif Ersoy Süper Lisesi	2000

İş Deneyimi Yıl

Yer

Görev

2005-2006	Endost Otomasyon Sistemleri /Elazığ	Proje Mühendisi
2006-2007	Novawood Orman Ürünleri/Bolu	Üretim Mühendisi
2007-Devam ediyor	İller Bankası Genel Müdürlüğü/Ankara	Yazılım Geliştiricisi

Yabancı Dil

İngilizce(iyi derece),Arapça