

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**GALVANİZ SEKTÖRÜNDE BİR YAPAY SİNİR AĞI
UYGULAMASI**

YÜKSEK LİSANS TEZİ

End. Müh. Tuğçen HATİPOĞLU

Enstitü Anabilim Dalı : ENDÜSTRİ MÜHENDİSLİĞİ

Tez Danışmanı : Yrd. Doç. Dr. Semra BORAN

Ocak 2010

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

GALVANİZ SEKTÖRÜNDE BİR YAPAY SINIR AĞI
UYGULAMASI

YÜKSEK LİSANS TEZİ

End. Müh. Tuğçen HATİPOĞLU

Enstitü Anabilim Dalı : ENDÜSTRİ MÜHENDİSLİĞİ
Enstitü Bilim Dalı : ENDÜSTRİ MÜHENDİSLİĞİ

Bu tez 08/01/2010 tarihinde aşağıdaki jüri tarafından Oybirliği ile kabul edilmiştir.

Yrd. Doc. Dr. Semra Boran
Jüri Başkanı

Boran

Prof. Dr. Nilgün Fıçlalı
Üye

Nilgün

Y. Doc. Dr. Tarık Ç. Akar
Üye

Tarık Ç. Akar

ÖNSÖZ

“Galvaniz Sektöründe Bir Yapay Sinir Ağı Uygulaması” çalışmasında öncelikle, yaptığı katkılardan dolayı, saygıdeğer hocam, Sn. Yrd . Dç. Dr. Semra Boran’a, her konuda yardımlarını esirgemeyen Sn. Prof. Dr. Alpaslan Fıđlalı ve Sn. Prof. Dr. Nilgün Fıđlalı’ ya, sonsuz destek ve sevgilerini daima hissettiren aileme, ayrıca uygulama aşamasında ki desteklerinden dolayı Marmara Siegener Galvaniz Ltd. Şti. çalışanlarına, özellikle Genel Müdür Sn. Hüseyin Akduman’a ve sağladığı imkanlardan dolayı Tübitak’a teşekkürü bir borç bilirim.

İÇİNDEKİLER

ÖNSÖZ.....	ii
İÇİNDEKİLER	iii
SİMGELER VE KISALTMALAR LİSTESİ.....	vi
ŞEKİLLER LİSTESİ	vii
TABLolar LİSTESİ.....	ix
ÖZET.....	x
SUMMARY.....	xi
BÖLÜM 1.	
GİRİŞ.....	1
BÖLÜM 2.	
YAPAY SİNİR AĞLARI HAKKINDA GENEL BİLGİ.....	4
2.1. Yapay Sinir Ağlarının Tanımları.....	4
2.2. Yapay Sinir Ağlarının Tarihçesi.....	5
2.3. Yapay Sinir Ağlarının Özellikleri.....	8
2.4. Yapay Sinir Ağlarının Faydaları.....	10
2.5. Yapay Sinir Ağlarının Sınırları.....	13
2.6. Yapay Sinir Ağlarının Kullanım Amaçlarına Göre Sınıflandırılması.....	14
2.7. Yapay Sinir Ağlarının Farklı Sektörlerde Uygulandığı Alanlar.....	17
2.8. Yapay Sinir Ağlarının Normal Bilgisayarların Hesaplama Sistemlerinden Farkları.....	18
2.9. Yapay Zeka ve Sinir Ağları.....	19
2.10. Tanıtıcı Terminoloji ve Notasyonlar.....	24

BÖLÜM 3.

YAPAY SİNİR AĞLARININ YAPISI.....	25
3.1. . Biyolojik Sinir Ağı ve YSA Hücreleri.....	25
3.2. Yapay Sinir Hücrelerinin Matematiksel Modeli.....	27
3.2.1. Sinaptik ağırlıklar.....	27
3.2.2. Toplama fonksiyonu.....	29
3.2.3. Aktivasyon fonksiyonları.....	30
3.3. Yapay Sinir Ağları Katmanları.....	32
3.4. Yapay Sinir Ağlarında Öğrenme.....	33
3.5. Yapay Sinir Ağlarında Öğrenme Türleri.....	34
3.5.1. Danışmanlı öğrenme.....	34
3.5.2. Danışmansız öğrenme.....	35
3.5.3. Destekleyici öğrenme.....	35
3.6. Öğrenme Kuralları.....	36
3.6.1. Çevrim içi ve çevrim dışı öğrenme.....	36
3.6.2. Hebb kuralı.....	36
3.6.3. Hopfield kuralı.....	36
3.6.4. Delta kuralı.....	37
3.6.5. Kohonen kuralı.....	37
3.6.6. Dereceli azaltma.....	37
3.7. YSA'nın Oluşturulması.....	38
3.7.1. Eğitim ve test verilerinin toplanması.....	38
3.7.2. Ağ mimarisinin oluşturulması.....	39
3.7.3. Öğrenme parametrelerinin seçilmesi.....	40
3.7.4. Normalizasyon, ağın öğrenmesi ve ağın test edilmesi.....	40

BÖLÜM 4.

YAPAY SİNİR AĞLARINDA AĞ MİMARİLERİ.....	41
4.1. Tek Katmanlı Algılayıcılar.....	43
4.1.1. Basit algılayıcı modeli (Perceptron).....	45
4.1.2. ADALINE modeli.....	46
4.2. Çok Katmanlı Algılayıcılar.....	47
4.2.1. Genelleştirilmiş delta kuralı.....	49

4.3. Destekleyici Öğrenme Modeli.....	53
4.3.1. LVQ modeli.....	53
4.4. Öğretmensiz Öğrenme.....	54
4.4.1. Adaptif rezonans teori (ART) ağları.....	54
4.5. Geri Dönüşümlü Ağlar.....	60
4.5.1. Hopfield ağlar.....	60
4.5.2. Boltzman makinesi.....	62

BÖLÜM 5.

YAPAY SİNİR AĞI İLE KAPLAMA KALINLIĞININ BELİRLENMESİ	65
5.1. Uygulama Yapılan İşletmenin Tanımı.....	65
5.2. Proses Hakkında.....	66
5.3. Problemin Tanımı.....	69
5.4. Önerilen Yapay Sinir Ağı Esaslı Model	71
5.5. Kaplama Kalınlığına Etki Eden Faktörler.....	73
5.5.1. Veri setinin belirlenmesi.....	73
5.5.1.1. Parça özellikleri.....	73
5.5.1.2. Süreç özellikleri.....	78
5.5.1.3 Nihai ürün özellikleri.....	81
5.5.2. İhmal edilen faktörler.....	84
5.6. Verilerin Toplanması.....	85
5.7. YSA Mimarisinin Kurulması.....	86
5.8. Modelin Sonuçları.....	90

BÖLÜM 6.

SONUÇLAR.....	94
KAYNAKLAR.....	96
EKLER.....	99
ÖZGEÇMİŞ.....	105

SİMGELER VE KISALTMALAR LİSTESİ

A.N.N.	: Artificial Neural Network (Yapay Sinir Ağı)
A.I.	: Artificial Intelligence
A.R.T	: Adaptive Rezonans Theory (Adaptif Rezonans Teorisi)
ARIMA	: The Autoregressive Integrated Moving Average (Birleştirilmiş Otoregresif Hareketli Ortalama)
ÇKA	: Çok Katmanlı Algılayıcı
LVQ	: Linear Vector Quantization (Doğrusal Vektör Niceleme)
M.L.P	: Multilayer Perceptron (Çok Katmanlı Algılayıcı)
MAE	: Mean Absolute Error (Ortalama Mutlak Hata)
MAPE	: Mean Absolute Percentage Error (Ortalama Mutlak Yüzdesele Hata)
O.E.K.	: Ortalama Et Kalınlığı
RMSE	: Root Mean Square Errors(Ortalama Karesel Hata)
TKA	: Tek Katmanlı Algılayıcı
V.L.S.I.	: Very-large-scale integration (Çok büyük ölçekli entegrasyon)
Y.Z.	: Yapay Zeka
YSA	: Yapay Sinir Ağı
Zn	: Çinko

ŞEKİLLER LİSTESİ

Şekil 2.1.	Örüntü Sınıflandırma.....	14
Şekil 2.2.	Öbekleme/Kümeleme.....	14
Şekil 2.3.	Yaklaşık Fonksiyon Belirleme.....	15
Şekil 2.4.	Tahminleme/Öngörü.....	15
Şekil 2.5.	Optimizasyon.....	16
Şekil 2.6.	Çağrışimli Bellek.....	16
Şekil 2.7.	Kontrol Uygulamaları.....	17
Şekil 2.8.	Basit bir makine öğrenmesi.....	21
Şekil 3.1.	Biyolojik Sinir Hücresinin Yapısı.....	26
Şekil 3.2.	Basit bir yapay sinir hücresinin yapısı.....	26
Şekil 3.3.	n adet girdisi ve bir çıktısı olan bir nöronun matematiksel modeli.....	28
Şekil 3.4.	a) Eşik Fonksiyonu.....	30
	b)Parça-parça Doğrusal Fonksiyon.....	30
	c) Sigmoid fonksiyonu.....	30
Şekil 3.5.	Signum Fonksiyonu	31
Şekil 3.6.	Değişik α değerleri için (3.9) ile tanımlanan fonksiyonun görünümü.....	32
Şekil 3.7.	Katman sayısı 3 olan bir yapay sinir ağı modeli.....	33
Şekil 3.8.	Eğitimin durdurulması için uygun durdurma bölgesi.....	34
Şekil 3.9.	Danışmanlı Öğrenme.....	35
Şekil 3.10.	Danışmansız Öğrenme.....	35
Şekil 4.1.	Tek Katmanlı Algılayıcı.....	43
Şekil 4.2.	Ağırlıkların ve sınıf ayracı olan doğrunun geometrik gösterimi.....	44
Şekil 4.3.	Perseptron Yapısı.....	45

Şekil 4.4.	Adaline'nin Blok Diyagramı	46
Şekil 4.5.	Madaline Ağ Yapısı.....	47
Şekil 4.6.	Madaline Karar Uzayı Örneği.....	47
Şekil 4.7.	Çok Katmanlı İleri Beslemeli Ağ Yapısı.....	48
Şekil 4.8.	L adet katmandan oluşan bir çok katmanlı ağ örneği.....	49
Şekil 4.9.	a)İleri Besleme	52
	b)Geri Yayılım.....	52
Şekil 4.10.	ART Ağının Yapısı.....	56
Şekil 4.11.	ART 2 Ağı Yapısı.....	58
Şekil 4.12.	ART2 Ağında F ₁ Katmanı.....	59
Şekil 4.13.	Hopfield Ağı.....	60
Şekil 4.14.	j nöronu için sinyal akışı.....	61
Şekil 4.15.	Basit Boltzmann Makinesi Ağ Topolojik Yapısı.....	62
Şekil 4.16.	Çeşitli İşlemcilerde Boltzmann Makinesi T Değişkeni.....	63
Şekil 5.1.	Çinko Talep Eğrisi.....	66
Şekil 5.2.	Proses Akış Diyagramı.....	68
Şekil 5.3.	Çinko Stok ve Fiyat Eğrisi.....	70
Şekil 5.4.	Uygulama Adımları.....	72
Şekil 5.5.	Sıcaklık Kalınlık İlişkisi.....	79
Şekil 5.6.	Açılı Askılama.....	81
Şekil 5.7.	Silisyum Oranı Kaplama Kalınlığı İlişkisi.....	84
Şekil 5.8.	Kalınlık YSA Mimarisi.....	87
Şekil 5.9.	Kalite Derecesi için YSA Mimarisi.....	88
Şekil 5.10.	Kaplama kalınlığı için Ağ Özellikleri.....	89
Şekil 5.11.	Kaplama kalınlığı için Ağ Yapısı.....	89
Şekil 5.12.	Kalite derecesi için Ağ Yapısı.....	89
Şekil 5.13.	Gerçek değerlerle kaplama tahmin değerlerinin karşılaştırılması..	91
Şekil 5.14.	Gerçek değerlerle kalite tahmin değerlerinin karşılaştırılması.....	93

TABLULAR LİSTESİ

Tablo 2.1.	Yapay Sinir Ağlarının Tarihsel Gelişimi (Karakuzu, 1998).....	7
Tablo 3.1.	Biyolojik Sinir ile YSA'nın Karşılaştırılması.....	27
Tablo 3.2.	Toplama Fonksiyonu Örnekleri.....	29
Tablo 3.3.	Ağların Başarılı Oldukları Alanlar.....	39
Tablo 4.1.	YSA Türlerinin Sınıflandırılması.....	41
Tablo 5.1.	Kalite Hataları Ve Sebep Olan Faaliyet.....	82
Tablo 5.2.	Kalite Dereceleri.....	83
Tablo 5.3.	Yüzde Doğruluk Ölçüt Değerleri.....	91
Tablo 5.4.	Kaplama Kalınlığı İçin Örnek Değerleri.....	92
Tablo 5.5	Kalite İçin Örnek Değerleri.....	93

ÖZET

Anahtar kelimeler: Yapay Sinir Ağları, Tahminleme

Endüstriden ekonomiye, askeri alanlardan sağlık sektörüne kadar pek çok alanda Yapay Sinir Ağları (YSA) Modelleri kullanılmaktadır. İnsan beyninin öğrenme, sınıflandırma, genelleme vb bir çok özelliğini simüle ederek YSA, Yapay Zeka teknikleri arasında oldukça yaygın bir şekilde uygulanmaktadır. İşletmeler arasında artan rekabet nedeniyle müşterinin istediği kalitede ürün üretmek ve maliyetlerin düşürülmesi öncelikli hedeflerdendir. Galvaniz sektöründe temel hammadde girdisi olan Çinko(Zn), en önemli maliyet kalemini oluşturmaktadır. Dolayısıyla sarf edilecek çinko miktarının tahmin edilmesi ve kalitenin sürekliliğinin sağlanması gerekmektedir. Bu çalışmada galvaniz sektöründe faaliyet gösteren bir firmada Yapay Sinir Ağı(YSA) yardımıyla kaplama kalınlığı ve yüzey kalitesi tahmin edilmeye çalışılmıştır. Kaplama kalınlığı ve yüzey kalitesine etki eden malzeme ve süreç parametreleri uzman kişilerle beyin fırtınası yöntemiyle belirlenmiştir. Hem kalite açısından hem de maliyetler açısından en uygun değerin belirlenmesine çalışılmıştır. YSA sonuçları gerçek veriler ile karşılaştırıldığında %84 kalınlık tahmin performansının elde edildiği gözlemlenmiştir. Ayrıca tahminlenen değerlerin gerçek verilerle uygunluğunu test etmek açısından hem kaplama kalınlığı hem de yüzey kalitesi için hipotez testi uygulanmış; her iki parametre için de modelden elde edilen değerlerle gerçek değerlerin ortalaması arasında istatistiksel olarak anlamlı bir fark olmadığı görülmüştür.

Çalışmanın 2. bölümünde YSA teorisine genel bir giriş yapılmış, 3.bölümde YSA yapısı açıklanmış, 4.bölümde YSA mimarileri sınıflandırmaları verilmiş ve son bölüm de galvaniz sektöründe kalite ve kaplama kalınlığının tahminine yönelik bir model kurulmuş ve test verileriyle sonuçlar karşılaştırılarak yorumlanmıştır.

AN APPLICATION TO ARTIFICIAL NEURAL NETWORKS IN GALVANIZATION SECTOR

SUMMARY

Key Words: Artificial Neural Networks, Forecasting

From industry to economy and from military to health a lot of sectors use ANN models. Simulating the features of human brain such as learning, classification, generalization etc, ANN has been widely used among the artificial intelligence techniques. Since the competition level among the companies is increasing day by day, meeting customer demands with qualified products and cost reduction are primary goals of each company. Zinc, the main raw material in galvanization sector, is the most important cost item. So it is a must to forecast the amount of zinc to be spent and to maintain the quality at a certain level. In this study it is tried to forecast the amount of zinc consumption and surface quality using the ANN method. The material and process parameters are determined by specialists using brain storming method. The purpose is find the optimum value for both cost and quality sides. When compared the ANN values (desired values) with the real data, we observed %84 surface thickness forecasting perform. And for testing the convenience of values hypothesis tests are done; and the results showed that there is no significance between the desired and real outputs statically.

In the second section of the study is made an introduction to ANN, in the 3th section is explained the Structure of ANN, in the 4th section the ANN topologies are classified, and the final section a model for forecasting the quality and the coating thickness is developed and the results are evaluated with regarding to the desired and real values.

BÖLÜM 1. GİRİŞ

İşletmeler de güvenilir maliyet verilerine ulaşmak, öncelikle yöneticilerin sağlıklı kararlar verebilmeleri için bilgi gereksinimlerini karşılamak amacını taşır. Bu temel amacın dışında doğru verilerin elde edilmesi kısa dönemde ve uzun dönemde pek çok getiri sağlar. Yapılan yatırım sonucunda istenen oranda kar elde edilmesi, teklif fiyatlarının belirlenmesi, işletme de başarının değerlendirilmesi, maliyet kontrolü vb. çalışmalar bu getiriler arasında sayılabilir. Böylece her bir ürün için planlanan başarının sağlanıp sağlanmadığı, teklif fiyatlarından piyasa durumuna göre ne kadar indirim yapılabileceği belirsizlikten kurtarılmış olur.

Sipariş maliyet yöntemi farklı malzeme ve işçilik giderlerini ve farklı üretim yöntemlerini gerektiren birden çok ürünün üretildiği işletmelerde uygulanır. Uygulamanın gerçekleştirildiği işletmede bu yöntem kullanılmakta ve direkt malzeme giderlerinin doğru hesaplanmasına yönelik verilerin sağlanması çalışmanın temelini oluşturmaktadır. Bu süreç işletmede ki ilgili bilgilerin ham veri olarak toplanmasından başlayıp, yöneticileri nihai işlenmiş verilerin sunulmasıyla sona erer. Çalışmada hedef üretim maliyetlerinden olan direkt çinko maliyetinin hesaplanması için gerekli kaplama kalınlığı bilgisinin tahmin edilmesidir. Bu maliyet üretim hacmi ile aynı yönde değişim gösterir yani üretim miktarının bir fonksiyonudur. Maliyet fonksiyonlarının tahmininde iş ölçümü yaklaşımı, en düşük ve en yüksek noktalar yöntemi, basit ya da çoklu regresyon yöntemleri kullanılırken, son dönemde yapay sinir ağları modeli de bu yöntemler arasına katılmıştır. Çoklu regresyon yöntemi ile yapılmış birçok tahmin çalışması vardır ancak bu yöntemde bazı koşullar sağlanmazsa sağlıklı maliyet öngörüsü yapılamaz. Bu koşullardan bazıları bağımlı ve bağımsız değişkenler arasında ekonomik mantığı olan bir ilişkinin varlığı, bağımsız değişkenin bağımlı değişken de gözlemlenen değişmelerin önemli bir bölümünü açıklıyor olması, doğrusallık varsayımı, hata terimlerinin bağımsızlığı ve normal dağılıdır. Bu varsayımlar pratikte sağlanmıyorsa ve belirlenen probleme

uyumuyorsa bu yöntemi kullanmak yersiz olacaktır. Ancak yapay sinir ağları yönteminin bu dezavantajları bulunmamakta, değişkenler arasında ki belirsiz ilişkileri çözüp, güvenilir bir şekilde analiz ederek yorumlamaktadır.

Literatürde üretim alanında tahminleme amacıyla YSA modeli kullanılan pek çok çalışmaya rastlamak mümkündür.

Zhang ve Fuh (1998) ürün maliyetlerinin tasarım aşaması boyunca etkin bir şekilde kontrol edilmesine odaklanmıştır. Bu da üretimin proses planları tam olarak netleşmeden ürünün maliyetinin tahminini gerektirir. Bu makalede geri yayımlı yapay sinir ağı kullanarak maliyet tahmini amaçlanmış ve yalnızca tasarım bilgisinden yola çıkılarak ürün maliyetinin tahmini için bir prototip geliştirilmiştir. Ürün tasarımında maliyete ilişkin bütün unsurlar belirlenerek, bu maliyete ilişkin unsurlar arasındaki korelasyon ve ürünün nihai maliyeti geri yayımlı sinir ağı eğitilerek belirlenmiştir. Test örnekleri kullanarak sistemin performansı da çalışmada verilmiştir (Zhang ve Fuh, 1998). Kermanshahi ve Iwamiya (2002) Japonya'da 2020 yılına kadar olan elektrik yükünün tahmin edilmesi için 10 faktör ele almıştır. (yerli ürünler, nüfus, hissedar sayısı, hava koşulları, CO2 miktarı, endüstri üretim indeksi, benzin fiyatları, enerji tüketimi ve elektrik fiyatları). Yapay sinir ağı yaklaşımını kullanarak elektrik yükünü tahmin etmişlerdir (Kermanshahi ve Iwamiya, 2002). Benzer bir çalışmada yeni tipte fren diski üretmeye başlayacak olan bir firmada üretim maliyetlerinin tahminlenmesi için yapay sinir ağları teknikleri kullanılmış ve yapay sinir ağları teorisinin geçerliliğini göstermiştir (Cavalieri ve diğerleri, 2004). Qing Wang'ın makalesinde yapay sinir ağı kullanarak bir maliyet modeli geliştirmiştir. (Wang, 2007). Günaydın ve Doğan (2004) inşaat sektöründe maliyet tahminlemede yapay sinir ağları yönteminden faydalanmışlar ve çalışma sonucunda % 93 başarıya ulaşmışlardır (Günaydın ve Doğan, 2004). Pendharkar (2006) kaynak kod dökümantasyonunu etkileyen faktörleri yapay sinir ağı tahminleme modeli ve lineer regresyon modeliyle araştırmıştır. Doğrusal olmayan değişkenlerin çoklu girdileri ve çoklu çıktıları arasında ölçek ekonomisi var olduğu durumlarda yapay sinir ağlarının daha iyi performans gösterdiği görülmüştür (Pendharkar, 2006). Bir diğer uygulama alanı ise İspanya'da ki elektrik üretim piyasasında enerji fiyatlarının tahmini için Box–Jenkins, ARIMA ve ANN modeli

kullanılmasıdır. Bu makalede ANN modelinde hem çok katmanlı algılayıcı ve hem de A.R.T yapıları kullanılmıştır (Pino ve diğerleri, 2007). Caputo ve Pelagagge (2008) 'nin araştırmalarında komplike ve büyük ölçekli basınçlı kazan üretim maliyetlerinin tahminlenmesi için YSA ile parametrik yöntemler karşılaştırılmıştır. Kazanın ölçülerindeki değişkenliğinin ve konfigürasyonun çok olması, önceki siparişlere benzer özellikteki siparişlere nadir rastlanması imalat maliyetlerinin tahminini zorlaştırmaktadır. Parametrik yöntemlerle bulunan hata tahmini %12 iken, YSA yaklaşımı ile bulunan hata yüzdesi %9 olarak bulunmuştur. YSA, parametrik yaklaşıma göre daha iyi sonuçlar vermiştir (Caputo ve Pelagagge, 2008). Artan rekabet koşulları, şirketleri metal levha sektöründe kısa sürede doğru maliyet tahmini yapacak yeni araçlar bulmaya zorlamıştır. Verlinden ve diğerlerinin (2008) çalışmasında regresyon teknikleri ile yapay sinir ağları teknikleri karşılaştırılmış, gözlemlenen sonuçlar YSA'nın daha iyi sonuçlar verdiğini göstermiştir (Verlinden ve diğerleri, 2008). Çinko kaplama ile ilgili Rešković ve Glavaš bir çalışma yapmış ve YSA yöntemini tercih etmişlerdir. Girdi faktörleri olarak ise çinko havuz sıcaklığı, bekleme süresi ve et kalınlığını almışlardır. (Rešković ve Glavaš, 2009)

BÖLÜM 2. YAPAY SİNİR AĞLARI HAKKINDA GENEL BİLGİ

2.1 Yapay Sinir Ağları Tanımları

Yapay sinir ağları (YSA)üzerine genel kabul görmüş tek bir tanım yapmak yerine çeşitli kapsamlarda farklı yazarlar tarafından yapılmış bazı tanımlamalar şu şekildedir.

Yapay sinir ağları, insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme, yeni bilgiler oluşturabilme ve keşfedebilme gibi yetenekleri, herhangi bir yardım almadan otomatik olarak gerçekleştirmek amacı ile geliştirilen bilgisayar sistemleridir.(Öztemel, 2006)

Yapay sinir ağı, basit işlem hücrelerinden oluşan, bilgileri depolama ve kullanabilme yeteneğine sahip yoğun paralellikte dağılmış yapıdaki bir işlemcidir. Bu işlemci iki yönden beyin ile benzer özellik gösterir.

- 1) Bilgi, öğrenme yoluyla çevreden elde edilir.
- 2) Bilgi depolamak için, sinaptik ağırlıklar olarak ta bilinen nöronlar arasındaki bağlantılar kullanılır.(Haykin,1999)

Yapay sinir ağı, biyolojik sinir hücreleri ile ortak performans özelliklerine sahip bir bilgi işleme sistemidir.(Fausett,1994)

Canlı organizmalarda bulunan biyolojik sinir yapısından esinlenerek yapılan modellerdir.(Nabiyev,2005)

Yapay Sinir Ağları, basit biyolojik sinir sisteminin çalışma şeklini simüle etmek için tasarlanan programlardır. Simüle edilen sinir hücreleri (nöronlar) içerirler ve bu nöronlar çeşitli şekillerde birbirlerine bağlanarak ağı oluştururlar. Bu ağlar öğrenme, hafızaya alma ve veriler arasındaki ilişkiyi ortaya çıkarma kapasitesine sahiptirler. Diğer bir ifadeyle, YSA'lar, normalde bir insanın düşünme ve gözlemlemeye yönelik doğal yeteneklerini gerektiren problemlere çözüm üretmektedir.(Yurtoğlu, 2005)

2.2 Yapay Sinir Ağlarının Tarihçesi

Yapay sinir ağları kavramı, beynin çalışma ilkelerinin sayısal bilgisayarlar üzerinde taklit edilmesi fikri ile ortaya çıkmış bir ve ilk çalışmalar beyni oluşturan biyolojik hücrelerin, ya da literatürdeki ismiyle nöronların matematiksel olarak modellenmesi üzerinde yoğunlaşmıştır. Bu çalışmaların ortaya çıkardığı bulgular, her bir nöronun komşu nöronlardan bazı bilgiler aldığı ve bu bilgilerin biyolojik nöron dinamiğinin öngördüğü biçimde bir çıktıya dönüştürüldüğü şeklinde idi. Bugün yapay sinir ağları olarak isimlendirilen alan, bir çok nöronun belirli biçimlerde bir araya getirilip bir işlevin gerçekleşmesi üzerinde ki yapısal olduğu kadar matematiksel ve felsefi sorunlara yanıt arayan bir bilim dalı olmuştur. (Efe,2000)

Bir nörobiyolojist olan Mcculloch ve matematikçi Walter Pitts 1943 yılında ilk sinir ağını tasarlamışlardır. Bu araştırmacılar basit sinir hücrelerini birleştirerek sinir sistemi modelini geliştirmişler ve Mcculloch-Pitts hücreleri üzerindeki ağırlıklar ile temel lojik fonksiyonları formülüze etmişlerdir. McGill üniversitesinde bir psikolog olan Donal Hebb, 1949 yılında yapay sinir ağları için ilk öğrenme kuralını tasarladı. Hebbian öğrenme kuralına göre bir hücre diğer bir hücreden bilgi alırsa ve her iki hücrede aktifse aralarındaki bağlantı kuvvetlendirilmelidir. Bu düşünce Kohonen tarafından geliştirilen matrisle yakın karakterdedir. Frank Rosenblatt ve Block, Minsky ve Papert ile birlikte 50li yıllarda algılayıcı diye adlandırılan yapay sinir ağını geliştirdi. Algılayıcı modeli tek katmanlı eğitilebilir ve tek çıkışa sahiptir. Algılayıcı öğrenme kuralı Hebb kuralına göre daha güçlüdür ve iteratif ağırlıkları kullanır. Bernard Widrow ve onun öğrencisi olan Marcian (Ted) Hoff 1960 yılında algılayıcı öğrenme kuralı ile benzer özelliklerde olan ADALINE (Adaptive Linear

Neuron) modelini ortaya attılar. Öğrenme kuralları arasındaki fark Adaline modelinde ağın genelleştirme yeteneğinin daha gelişmiş olmasıdır.

1970 li yıllar yapay sinir ağları literatüründe sessiz yıllar olarakta bilinir, çünkü bu dönemde konuya olan ilgi daha azalmış ve çok fazla sayıda çalışma yapılmamıştır. Teuvo Kohonen Çağrışimli bellek sinir ağları üzerine çalışmalar yaptı. 1982 yılında öbikleme üzerinde topolojik bir yapı kullanan kendi kendine öğrenme nitelikli haritalar çalışmasını yayınladı. Brown üniversitesinden James Anderson'da Kohonen gibi Çağrışimli bellek konusunda çalışmalar yaptı ve 1977 yılında Bir Kutu İçinde Zeka (Brain-State-in-a-Box) 'yı yayınladı. Stephen Grossberg ve Gail Carpenter birlikte 1985 yılında Adaptif Rezonans Teorisini (ART) geliştirdiler.(Fausett,1994)

1970'lerin sonlarına doğru Fukushima görsel şekil ve örüntü tanıma amaçlı geliştirdiği neocognitron modelini tanıttı. Bu model önceleri öğretmensiz öğrenme yapan bir model olacak şekilde geliştirilmesine rağmen daha sonraları öğretmenli öğrenme yapacak hale getirilmiştir. Bu çalışmaların neticesinde daha çok mühendislik uygulamaları görülmeye başlandı. Neocognitron modelinde ara katmanlar kullanılarak öğrenme konusuna değiniyordu. 1982 ve 1984 yıllarında Hopfield tarafından yayınlanan çalışmalar ile yapay sinir ağlarının genelleştirilebileceği ve özellikle geleneksel bilgisayar programlama ile çözülmesi zor olan problemlere çözüm üretebileceğini gösterdi. Gezgin satıcı problemini çözmesi bunun en güzel örneğiydi. Çalışmasını mühendislerin kolaylıkla anlayabileceği şekilde sunduğundan yapay sinir ağlarına ilgi yeniden kurulmaya başlandı. Çalışmaların neticesi Hinton ve arkadaşlarının geliştirdikleri Boltzman makinesinin doğmasına yol açıyordu. Aynı zamanlarda Rummelhart ve arkadaşları paralel programlama konularındaki çalışmalarını sonlandırıyor ve iki ciltlik bir eser ortaya koyuyordu. Bu eserlerinden çok katmanlı algılayıcı modelini temellerini atıyorlar ve daha sonra bu modeli geliştiriyorlardı. Çok katmanlı algılayıcıların bulunması yapay sinir ağlarının tarihsel gelişimi bakımından çok önemli bir adım oluyordu. Bu çalışmalardan sonra yapay sinir ağlarına olan ilgi yeniden ateşlendi. Çünkü tek katmanlı algılayıcının çözemediği XOR problemi çok katmanlı algılayıcıların bulunması ile çözülmüş ve yapay sinir ağlarının çalışmadığını söyleyen bütün tezler çürütülmüştü. Çok katmanlı algılayıcı sadece XOR problemini

çözmekle kalmamış aynı zamanda Hopfield ve Boltzman makinelerinin sınırlamalarını da çözmüştü. Bu da dikkatleri daha çok bu ağlar üzerine çekiyordu. 1988'de Broomhead ve Lowe Radyal Tabanlı fonksiyonlar modelini geliştirdiler. Bu ağın çok katmanlı algılayıcılara alternatif olarak geliştirildiğini belirttiler. Özellikle filtreleme problemlerine oldukça başarılı sonuçlar ürettiler. Daha sonra Specht bu ağların daha gelişmiş şekli olan Probabilistik Ağlar (PNN) ve Genel Regresyon Ağları (GRNN) geliştirdi. (Öztemel, 2006)

Yukarıda anlatılmaya çalışılan yapay sinir ağları mimarilerinin kısa tarihçesi Tablo 2.1 'de görülmektedir.

Tablo 2.1 Yapay Sinir Ağlarının Tarihsel Gelişimi (Karakuzu, 1998)

Yıl	Ağ Mimarisi	Bulan Bilim Adamı
1942	McCulloch-Pitts Hücresi	McCulloch-Pitts
1957	Algılayıcı (Perceptron)	Rosenblatt
1960	Madaline	Widrow
1969	Cerebellatron	Albus
1974	Geri yayılım (Backpropagation)	Werbos,Parker, Rumelhart
1977	Bir kutu içinde zeka	Anderson
1978	Neocognitron	Fukushima
1978	Adaptif Rezonans Teorisi	Carpenter, Grossberg
1980	Öz düzenlemeli harita	Kohonen
1982	Hopfield	Hopfield
1985	İki yönlü birleşik hafıza	Kosko
1985	Boltzman Makinesi	Hinton, Seinowsky, Szu
1986	Sayıcıyayılım (Counterpropagation)	Hecht-Nielsen
1988	Hücresel sinir ağı	Chua, Yang

2.3 Yapay Sinir Ağlarının Özellikleri

Sinir ağları kavramının temel özelliklerinden ilki sistem paralelliği ve toplamsal işlevin yapısal olarak dağılımıdır. Diğer bir deyişle bir çok nöron eşzamanlı çalışır ve karmaşık bir işlev çok sayıda küçük nöron aktivitesinin bir araya gelmesinden oluşur. Bu da zaman içerisinde herhangi bir nöronun işlev dışı kalması durumunda ağ başarımının dikkate değer ölçüde etkilenmeyeceği anlamına gelir. İkinci özellik ise genelleme yeteneği, diğer bir deyişle ağ yapısının eğitim esnasında kullanılan nümerik bilgilerden eşleştirmeyi betimleyen kaba özellikleri çıkarsaması ve böylelikle eğitim sırasında kullanılmayan girdiler için de anlamlı yanıtlar üretebilmesidir.

Bir başka özellik ise ağ fonksiyonunun nonlineer oluşudur. Yapı üzerinde dağılmış belli tipteki nonlineer alt birimler özellikle, istenen eşleştirmenin denetim ya da tanılama işlemlerinde olduğu gibi nonlineer olması durumunda işlevin doğru biçimde yerine getirebilmesini matematiksel olarak olası kılar. Burada, işlevin doğru biçimde gerçekleştirilebilmesi için yapısal bir esneklik gerekliliği vurgulanmalıdır. Yani ağ parametreleri, başarıyı arttıracak ya da maliyeti azaltacak şekilde değiştirilebilmelidir. (Efe,2000)

Yapay sinir ağlarında bilgi ağın bağlantılarının değerleri ile ölçülmekte ve bağlantılarda saklanmaktadır. Diğer programlarda olduğu gibi veriler bir veri tabanında veya programın içinde gömülü değildir. Bilgiler ağın üzerinde saklı olup ortaya çıkartılması ve yorumlanması zordur.

Yapay sinir ağlarının güvenle çalıştırılabilmesi için önce eğitilmeleri ve performanslarının test edilmesi gerekmektedir. Yapay sinir ağlarının eğitilmesi demek, mevcut örneklerin tek tek ağa gösterilmesi ve ağın kendi mekanizmalarını çalıştırarak örnekteki olaylar arasındaki ilişkileri belirlemesidir. Her ağı eğitmek için elde bulunan örnekler iki ayrı sete bölünürler. Birincisi ağı eğitmek için (eğitim seti) diğeri ise ağın performansını sınamak için (test seti) kullanılır. Her ağ önce eğitim seti ile eğitilir. Ağ bütün örneklere doğru cevaplar vermeye başlayınca eğitim işi

tamamlanmış kabul edilir. Daha sonra ağı hiç görmediği test setindeki örnekler ağı gösterilerek ağı verdiđi cevaplara bakılır.

Yapay sinir ağlarının örnekler ile kendisine gösterilen yeni durumlara adapte olması ve sürekli yeni olayları öğrenebilmesi mümkündür.

Yapay sinir ağları kendileri eğitildikten sonra eksik bilgiler ile çalışabilir ve gelen yeni örneklerde eksik bilgiler olmasına rağmen sonuç üretebilirler. Ayrıca yapay sinir ağlarının eksik bilgiler ile çalışması performanslarının düşeceği anlamına gelmez. Performansın düşmesi eksik olan bilginin önemine bağlıdır. Hangi bilginin önemli olduğunu ağı kendisi eğitim sırasında öğrenmektedir. Kullanıcıların bu konuda bir fikri yoktur. Ağı performansı düşük olunca kayıp olan bilginin önemli olduğu kararla varılır. Eğer ağı performansı düşmez ise eksik olan bilginin önemli olmadığı anlaşılır.

Yapay sinir ağlarının eksik bilgilerle çalışabilme yetenekleri hatalara karşı toleranslı olmalarını sağlamaktadır. Ağı bazı hücrelerinin bozulması ve çalışamaz duruma düşmesi halinde ağı çalışmaya devam eder.

Yapay sinir ağlarının belirsiz bilgileri işleyebilme yetenekleri vardır. Olayları öğrendikten sonra belirsizlikler altında ağlar öğrendikleri olayları ile ilgili ilişkileri kurarak kararlar verebilirler.

Bir ağı zaman içerisinde yavaş yavaş ve zarif bir şekilde bozulur. Bu eksik olan bilgiden veya hücrelerin bozulmasından kaynaklanır. Ağlar, herhangi bir problem ortaya çıktığında hemen anında bozulmazlar.

Son özellikleri ise sadece nümerik bilgiler ile çalışmalarıdır. Sembolik ifadeler ile gösterilen bilgilerin nümerik gösterime çevrilmeleri gerekmektedir. (Öztemel,2006)

2.4 Yapay Sinir Ağlarının Faydaları

Nöral ağlar hesaplama gücünü ilk olarak yoğun paralel dağıtılmış yapısından ve ikinci olarak ta öğrenme ve genelleştirme yeteneğinden alır; genelleştirme nöral ağın öğrenme sırasında rastlanmayan girişlere uygun çıkışlar üretmesini tanımlar. Bu iki bilgi nöral ağların karışık problemleri çözmesini mümkün kılar. Pratikte, nöral ağlar sadece kendileri çalışarak çözüm üretmezler. Bunun yanı sıra mühendislik yaklaşımli tutarlı bir sistemle bütünleştirilmeleri gerekir. Açık bir şekilde, ilgili karmaşık bir problem bağlı bir dizi küçük göreve ayrılır ve nöral ağlar doğasında olan yetenekleriyle uyuşan alt görevlere atanırlar.

YSA'nin genel olarak faydaları şu şekildedir:

1.Doğrusal olmayan yapı: Nöron basit bir doğrusal olmayan işlemcidir. Sonuç olarak, nöronların birleşiminden oluşan bir nöral ağda doğrusal değildir. Doğrusal olmayan yapı, özellikle eğer altında yatan giriş sinyalinin oluşmasından sorumlu fiziksel mekanizma da doğrusal değilse, oldukça önemli bir özelliktir.

2.Giriş-Çıkış Haritalamak: Denetlenmiş öğrenim olarak bilinen yaygın bir öğrenme paradigması nöral ağların sinaptik ağırlığını bir dizi etiketlenmiş eğitim örnekleri ve ya görev örnekleri uygulayarak değiştirmeyi içerir. Her örnek bir giriş sinyali ve buna karşılık bir cevap içerir. Ağa diziden rassal alınan bir örnek gösterilir ve ağın sinaptik ağırlıklar, beklenen yanıt ve gerçek yanıt arasında ki farkı en aza indirmek için modifiye edilir. Ağın eğitimi, sinaptik ağırlıklarda başka önemli değişiklik olmadığı, ağın sabit bir duruma ulaştığı ana kadar dizideki bir çok örnek için tekrarlanır; bir önce uygulanan eğitim örnekleri eğitim seansı sırasından yeniden fakat başka bir sırayla uygulanabilir. Böylece ağ problem için giriş-çıkış haritası oluşturarak örneklerden öğrenir.

3.Uyarlanabilirlik: Nöral ağların sinaptik ağırlıklarını yakın çevredeki değişikliklere ayak uydurmasını sağlayan kapasitesi vardır. Özellikle, belirli bir çevrede işlem yapması için eğitilen nöral ağ kolaylıkla çevresel durumları işletmedeki küçük

değişikliklerle uğraşması için geri getirilebilir. Dahası sabit olmayan bir çevrede çalışırken, bir nöral ağ gerçek zamanda sinaptik ağırlığını değiştirmek için dizayn edilebilir. Ağın uyarlanabilirlik kapasitesiyle birleştirilen, desen sınıflandırması, sinyal iletimi, ve kontrol uygulamaları için olan nöral ağın doğal mimarisi onu uyarlanabilir örüntü sınıflandırması uyarlanabilir sinyal iletimi ve uyarlanabilir kontrolde kullanmak için ideal bir aygıt haline getirmiştir. Genel bir kural olarak uyarlanabilir sistemin sabit olduğunu varsayarak sistemi ne kadar düzgün dizayn edilmiş bir halde yaparsak sistem sabit olmayan bir çevrede çalışması gerektiğinde performansı da o kadar sağlam olur. Ama uyarlanabilirliğin her zaman sağlamlığa yol açmadığı aslında bazen tam tersine yol açtığı vurgulanmalıdır. Mesela kısa zaman aralıklı uyarlanabilir bir sistem hızla değişebilir ve böylece sistem performansın da şiddetli bir düşüşe yol açar. Uyarlanabilirliğin bütün yararlarını anlamak için sistemin ilk zaman aralıkları sistemin sahte karışıklıkları aldırması için yeterince uzun olmalıdır, ama çevredeki anlamlı değişikliklere yanıt verebilmek için yeterince kısa olmalıdır; burada anlatılan problem süreklilik-esneklik ikilemi olarak adlandırılır.

4.Açık Yanıt: Örüntü sınıflandırması durumunda bir nöral ağ sadece hangi desenin seçileceği bilgisini vermek için değil karar vermede güvenilirlik sağlamak için dizayn edilir. Bu son bilgi belirsiz desenleri geri çevirmede kullanılabilir, eğer çoğalırlarsa o zaman ağın sınıflandırma performansını geliştirmek gerekir.

5.Bilgi içeriği: Bilgi nöral ağın aktivasyon durumuyla ve yapısıyla gösterilir. Ağdaki her nöron ağdaki diğer nöronların global aktivitesiyle güçlü bir şekilde etkilenir. Sonuç olarak bilgi içeriği nöral ağ tarafından doğal bir şekilde idare edilir.

6.Hata Toleransı: Donanım şekline getirilmiş nöral bir ağ ters işlem durumları altında performansın hafifçe alçaltılması eğilimiyle doğuştan hata toleranslıdır. Mesela eğer bir nöron ya da bağlantı noktaları hasar görürse depolanmış bir desenin geri getirişi kalite olarak zayıflar. Yine de, ağdaki bilginin dağıtılmış doğasına bağlı olarak hasar, ağın bütün yanıtının ciddi bir şekilde alçaltılmadan önce çok büyük olmalıdır. Böylece prensipte bir nöral ağ performans olarak büyük bir hatanın yerine hafif bir düşüş gösterir.

7.VLSI Uygulaması: Nöral ağın yoğun paralel doğası belirli görevlerin hesaplanmasını hızlı bir hale getirir. Bu aynı özellik nöral bir ağı VLSI teknolojisi kullanarak uygulamaya ideal bir şekilde uygun hale getirir. VLSI 'nın belirli bir avantajı oldukça hiyerarşik bir yolla tamamen karmaşık davranış için bir araç sağlamasıdır ve bu bir nöral ağını desen hatırlama, sinyal iletimi ve kontrol içeren gerçek zaman uygulamaları için bir araç olarak kullanılmasını sağlar.

8.Analiz ve Dizayn Birleşmesi: Temel olarak, nöral ağlar evrenselliği bilgi ileticisi olarak kullanılır. Bunu nöral ağ uygulamalarını içeren her alanda aynı sistemin kullanıldığı için söylenir. Bu özellik kendini değişik yollarla açığa koyar:

a. Nöronlar, bir ya da başka biçimde bütün nöral ağlara ortak bir şekilde içerik olarak sunulurlar.

b. Bu ortaklık teorileri paylaşma ve nöral ağların değişik uygulamalarında algoritmaları öğrenme imkanı verir.

c. Modüler ağlar modüllerin bağlantı yeri olmadan bütünleşmesi yoluyla yapılabilirler.

9.Nörobiyolojik Benzerlik: Nöral ağın dizaynı beyne benzerlikle motive edilir, bu hata-toleranslı iletimin sadece fiziksel olarak mümkün olmasının değil aynı zamanda hızlı ve güçlü olmasının yaşayan bir kanıtıdır. (Haykin,1994)

2.5 Yapay Sinir Ağlarının Sınırları

Genellikle YSA'nın aşağıdaki dezavantajları gösterilir.

a.YSA yapısına uygun olarak yerel çözümlere takılabilir. Uygun ağ yapısının belirlenmesi genellikle deneme yanılma yoluyla gerçekleştirildiğinden bu YSA'nın dezavantajı olarak görülmektedir.

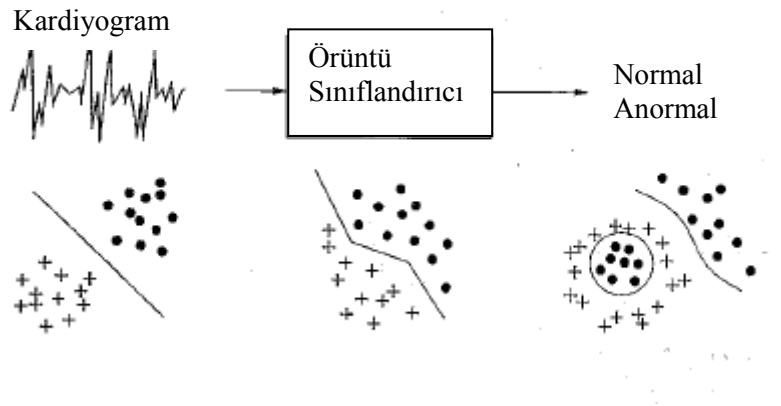
b.YSA'nın birçoğunda öğrenme katsayısının, gerekli katman ve katmanlardaki hücre sayılarının belirlenmesinde kesin bir kural olmamaktadır. Gizli katmandaki nöron sayısı, bir tanıma işleminin doğruluğunu ve eğitim hızını etkilemektedir. Örneğin karmaşık örüntüler, gizli katmanda nöron sayısı az olduğunda bulunamamaktadır. Fakat sayının çok büyük olması hesaplama yükünü korkunç şekilde artırmaktadır.

c.YSA'nın eğitilmesinde örnekler önem taşımakta ve örneklerin seçiminde genel bir kural olmamaktadır. Örneğin karakter tanımda Times New Roman fontu örnekleriyle eğitilen bir sistem Comic Sans MS fontlarını tanımayabilir.

d.Bilgiler ağa "gömülü" olmasından dolayı yorumlanması ve çözümün elde edilmesinde YSA'nın davranışının takibi zordur.(Nabiyev, 2005)


2.6 Yapay Sinir Ağlarının Kullanım Amaçlarına Göre Sınıflandırılması

Örüntü sınıflandırmasının görevi, daha önceden belirlenmiş sınıflara öznitelik vektörüyle gösterilen bir giriş deseni (bir konuşma dalga biçimi ya da el yazısı sembolü gibi) tahsis etmektir. Yaygın uygulamalar karakter tanıma, konuşma tanıma, Elektroensefalografi (EEG) dalga biçimi sınıflandırması, kan hücresi sınıflandırması ve baskılı devre levhası sınıflandırmasını içerir.




Şekil 2.1 Örüntü Sınıflandırma

Denetlenmeyen sınıflandırma olarakta bilinen kümelemede bilinen sınıf etiketli eğitim verisi yoktur. Bir kümeleme algoritması desenler arasındaki benzerliği ortaya çıkarır ve kümeye benzer desenler yerleştirir. Yaygın kümeleme uygulamaları veri madenciliği, veri sıkıştırması, araştırmacı veri analizi içerir.




Şekil 2.2 Öbikleme/Kümeleme

Bir dizi n etiketli desenin bilinmeyen bir fonksiyondan oluştuğunu düşünün. İşlev yaklaşımının görevi bilinmeyen fonksiyona bir tahminde bulunmaktır. Çeşitli mühendis ve modelleme problemleri yaklaşık fonksiyon belirleme yaklaşımını gerektirir.




Şekil 2.3 Yaklaşık Fonksiyon Belirleme

Bir dizi n örneği bir zaman dizisinde verildiğinde amaç, örneği gelecek bir zamanda tahmin etmektir. Tahmin/Öngörü bilim ve mühendislikte karar vermede önemli etkisi vardır. Hisse piyasası tahmini ve hava durumu tahmini tahmin/öngörü tekniklerinin tipik birer örnekleridir.




Şekil 2.4 Tahminleme/Öngörü

Matematik, istatistik, mühendislik, bilim, tıp ve ekonomideki geniş çapta görülen problemler optimizasyon problemleri olarak ortaya çıkabilir. Bir optimizasyon algoritmasının amacı hedef işlevin yükseltilmesi yada küçültülmesi gibi bir dizi sınıtlara tatmin edici çözüm bulmaktır. Gezgin Satıcı Problemi (TSP), klasik örneklerindedir.



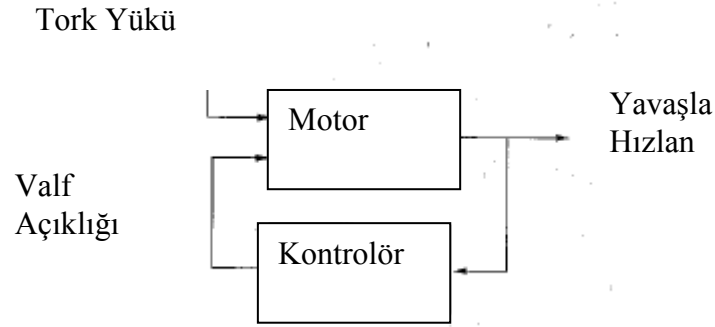
Şekil 2.5 Optimizasyon (Gezgin Satıcı Problemi örneği için)

Von Neumann hesaplama modelinde, hafızaya giriş sadece kendi yönünden giriş yapabilir ve bu hafızanın içeriğinden bağımsızdır. Dahası eğer yönü hesaplamada küçük bir hata yapılırsa bile tamamen değişik bir madde elde edilir. Birleşmeli bellek veya çağrışimli belleğe, adından da anlaşıldığı gibi, içeriğiyle ulaşılabilir. Hafızadaki içerik kısmi girişle veya bozuk içerikle bile geri alınabilir. Birleşmeli hafıza, multimedya bilgi veritabanı kurmada son derece kullanışlıdır.



Şekil 2.6 Çağrışimli bellek

Model-ilişkili uyarlanabilir kontrolde amaç, sistemin referans model tarafından belirlenen bir yörünge izleyebilsin diye bir kontrol girişi oluşturmaktır. Motor yavaş-hız kontrolü bir örnektir (Şekil 2.7). ANN kullanarak bir biyolojik sinirsel sistem modellemek biyolojik işlevleri anlamamızı sağlar. Art ağları, bilgisayar donanım teknolojisi (VLSI ve optik gibi) bu modellemeyi mümkün kılmıştır.



Şekil 2.7 Kontrol Uygulamaları

ANN'nin eksiksiz bir incelemesi nöropsikoloji, bilişsel bilim/psikoloji, fizik(istatistik mekanik), kontrol teorisi, bilgisayar bilimi, yapay zeka, istatistik/matematik, desen hatırlama, bilgisayar vizyonu, paralel ilerleme, ve donanım bilgisi gerektirir. Bu bilgi dallarındaki yeni gelişmeler alanı destekler. Diğer bir taraftan ANN'ler ayrıca bu bilgi dallarına yeni aletler ve işaretler biçiminde enerji sağlar. Bu bilgi dalları arasındaki iletişim desteklenmelidir. (Jain, 1996)

2.7 Yapay Sinir Ağlarının Farklı Sektörlerde Uygulandığı Alanlar

Yapay sinir ağlarının kullanım alanı oldukça geniş olup, pek çok sektörde farklı amaçlarda uygulanarak başarılı sonuçlar elde edilmektedir. YSA'ların gerçek hayattaki yaygın uygulama alanlarına şu örnekler verilebilir (Altuğ, 1994):

- 1.Kalite kontrol
- 2.Finansal öngörü
- 3.Ekonomik öngörü
- 4.Kredi derecelendirme
- 5.Konuşma ve yapı tanımlama
- 6.İşlem modelleme ve yönetimi
- 7.Laboratuvar araştırmaları
- 8.İflas tahmini
- 9.Petrol ve gaz arama
- 10.Denetim

- 11.Sistem modelleme
- 12.Ses tanıma
- 13.El yazısı tanıma/parmak izi tanıma
- 14.Elektrik işaret tanıma
- 15.Meteorolojik yorumlama
- 16.Otomatik araç denetimi
- 17.Fizyolojik işaretleri(kalp fonksiyonları gibi) izleme, tanıma ve yorumlama
- 18.Zaman serilerinin yorumlanması ve gelecek döneminin tahmin edilmesi

2.8 Yapay Sinir Ağlarının Normal Bilgisayarların Hesaplama Sistemlerinden Farkları

Yapay sinir ağları geleneksel işlemcilerin hesaplamalarından farklı şekilde işlem yaparlar. Bir bilgisayarın işlemcisi (CPU) belirli bir algoritma çerçevesinde kendisine verilen görevi adım adım-lineer bir şekilde yaparken, her yapay sinir ağı büyük bir problemin sadece kendine ait olan küçük bir parçasını doğrusal olmayan bir şekilde işler ve bir sonuç elde eder. Bu sonucu, bir sonraki ağa verir. İşlerken kullandığı denklem birçok denklemin bir araya gelmesinden oluşur. Kullanılan denklemler genelde optimizasyonda ve grafiksel modellerde gözlenen tarzdadır. Bazı fonksiyonların göreceli olarak aldığı girdiye bağlı olmaması da bir miktar paralel hesaplama sağlamaktadır.

Öğrenme çevreyi gözlemleyerek, bir f fonksiyonundan f^* bulmayı sağlar. f^* , f fonksiyonunun optimize edilmiş halidir. Yani yeni üretilen çözüm yolu problemi en kısa sürede çözer. Kabul edilebilir zaman aralığında tam optimize olamayanlarda ise bu süreyi kısaltmak için mükemmele yakın bir sonuç bulunur. Bunun için bazı yöntemler vardır. Mesela ateşleme kuralı (firing rule). Bu kuralın işleyişle ilgili bir örnek vermek gerekirse, öğrenilen 3 bilgi olsun ve yeni bir bilgi alınsın. Yeni alınan bu bilgi öğrenilmiş bir bilgiyse sonuç her zamanki gibi olur. Ancak öğrenilen kısma ait değilse, ondan ne kadar farklı bir bilgi olduğu kontrol edilir. Ona göre nasıl işlem yapılacağı belirlenir. Bu genelleme özelliği sayesinde benzer modellere benzer şekilde cevap verilmesi sağlanır. Model tanıma (pattern recognition) bu sayede sağlanır.

Ateşleme kuralı bir şekilde normal bilgisayarlarda da uygulanabilmektedir. Ancak yapay ağ sistemleri bundan çok daha karmaşık ilişkilere sahiptir. Daha üst seviyeli işlem birimlerinde girilen bilgiler 0-1 şeklinde değil, ağırlıklıdır. Sadece girilen bilginin türü değil ağırlığı da dikkate alınır. Eşik değer (treshold value) burada devreye girer. Eğer eşik değer üzerinde bir girdi alınırsa cevap verilir, yoksa verilmez. Ayrıca her verilen cevaptan sonra sistemin ağırlığı tekrar ayarlanarak yeni gelen bilgi için daha farklı bir işlem uygulanabilir. (Odtü Bilgisayar Topluluğu Online Elektronik Dergisi, 2008)

2.9 Yapay Zeka ve Sinir Ağları

Yapay zeka (AI) insanlar tarafından yapıldığında açık bir şekilde kavrama gerektiren görevlerin makineler tarafından yapılması için paradigma ve algoritmaların gelişmesidir. Ayrıca bu ifadede “zeka” yerine “kavrama kelimesini bilerek kullanılmıştır böylece amaç AI'nin üstesinden geldiği görevleri problem çözmeye birlikte kavrama ve dil ile birlikte bilinçli süreci içererek genişletmektir.

Bir AI sistemi 3 şeyi yapabilmelidir:

- a) Bilgi depolamak;
- b) Depolanan bilgiyi problemleri çözmek için uygulamak;
- c) Deneyim sayesinde yeni bilgi kazanmak.

Bir AI sistemin 3 anahtar bileşeni vardır: Temsil, muhakeme ve öğrenim.

1.Temsil: AI'nin muhtemelen en ayırt edici özelliği olup hem ilgili bölgedeki problem hakkındaki genel bilgiyi hem de problemi çözmeye de gerekli olan bilgiyi göstermek için sembol yapılarının dilinin etkili bir şekilde kullanımınıdır. Semboller genellikle bilinen terimlerle formüle edilir, buda AI'nin temsilini bir insan kullanıcı tarafından anlaşılmasını kolay hale getirir. Aslında, AI'nin sembolik açıklığı bunu insan-makine iletişimi için uygun bir hale getirir.

“Bilgi” diğerk bir veri terimidir. Değişmez yada prosedür biçiminde olabilir. Değişmez bir temsilde, bilgi gerçekleri yönetmek için kullanılan küçük bir dizi genel prosedürle birlikte gerçeklerin istatistiki bir koleksiyonu olarak sunulur. Değişmez temsillerin karakteristik bir özelliğı AI sistemi içersinde, kullanımlarından bağımsız olarak, insanların gözlerinde kendi anlamlarına sahip olmaktır. Diğerk bir taraftan prosedür temsiline, bilgi, bilginin anlamını ortaya çıkaran uygulanabilir bir koda dahil edilir. İki bilgi türü de ilgili problem alanlarında gereklidir.

2.Muhakeme : En temel biçimde, sonuç problem çözüme kapasitesidir. Bir sistem için bir muhakeme sistemi olarak yeterli olmak için belirli koşulları karşılamalıdır:


- a.Sistem geniş çapta problemleri ve problem türlerini çözebilmelidir.
- b.Sistem belirli ve belirsiz bilgiler verebilmelidir.
- c.Sistem bir probleme bir çözüm elde edildiğinde veya problem üstünde daha fazla çalışma sonlandırılması gerektiğinde probleme hangi işlemin uygulanacağını belirlemek için bir kontrol mekanizmasına sahip olmalıdır.

Problem çözmek bir araştırma problemi gibi görülebilir. “Araştırma” ile uğraşmanın yaygın bir yolu kuralları, veriyi ve kontrolü kullanmaktır. Kurallar veri üstünde çalışır ve kontrol kurallar üstünde çalışır. Mesela, bütün şehirlerin sadece bir kere ziyaret edildiğı bir şehirden diğerkine gitmenin en kısa yolunu bulmanın gerekli olduğu “gezgin satıcı problemini” düşünün. Bu problemde veriler olası turlardan türetilir ve bir grafikte gösterilir, kurallar bir şehirden diğerkine gitmenin yollarını tanımlar ve kontrol hangi kuralların ne zaman uygulanacağına karar verir.

Pratikte karşılaşılan bir çok durumda eldeki bilgi ya eksiktir ya da kesin değildir. Bu gibi durumlarda olası sonuç prosedürleri kullanılır ve böylece AI sistemleri problemin belirsizliğini hesaba katar.

3.Öğrenme: Şekil 2.8’de gösterilen basit bir makine öğrenimi modelinde çevre öğrenme elemanına bazı bilgiler sağlar, öğrenme elemanı sonra bu bilgiyi bilgi tabanında gelişme sağlamak için kullanır ve son olarak performans elemanı bilgi tabanını görevini yerine getirmek için kullanır. Makinaya çevre tarafından sağlanan

bilgi genelde hatalıdır ve sonuç olarak öğrenme elemanının ilerde kayıp detayları nasıl dolduracağını bilmemesi ve detayları göz ardı etmesi önemli değildir. Bu yüzden makine tahmin ederek daha sonra performans elemanından geri besleme olarak çalışır. Geri besleme mekanizması makinenin hipotezini değerlendirmesini ve gerekli olduğunda onları gözden geçirmesini sağlar.



Şekil 2.8. Basit bir makine öğrenmesi

Makine öğrenimi iki çeşit bilgi iletimi içerebilir; endüktif ve dedüktif. Endüktif bilgi iletiminde genel desenler ve kurallar ham veri ve tecrübeden elde edilir. Dedüktif bilgi iletiminde genel kurallar belirli gerçekleri belirlemek için kullanılır. Benzerlik-tabanlı öğrenme tümevarım kullanır ama bir önermenin kanıtı bilinen aksiyom ve diğer önermelerde olduğu gibi dedüktiftir. Açıklama-tabanlı öğrenme her ikisini de içerir.

Bilgi tabanlarının önemi ve öğrenmede karşılaşılan zorluklar, bilgi tabanlarını değerlendirmek için çeşitli metotların gelişmesine yol açmıştır. Özellikle, verilen bir alanda uzmanlar varsa genelde uzmanların tecrübelerini elde etmek taklit etmekten ve uzmanlığı artıran tecrübeyi yönlendirmekten daha kolaydır. Bu aslında uzman sistemlerin ötesinde bir fikirdir.

Sembolik AI makinelerini tanıdıktan sonra onları kavram modelleri olarak sınır ağlarıyla karşılaştırabilmek için, 3 alt bölümü takip ederiz; açıklama seviyesi, İletim stili ve temsili yapı.

1.Açıklama Seviyesi: Klasik bir AI'de vurgu muhtemelen sembolik temsiller üstündedir çünkü onlar bir kavramı ifade eder. Normalde, temsiller belirsizdir: belirsiz özellikler ve analog olmayan imgeler. Kavrama bakış açısından AI'nin

zihinsel sunumların varlığını farz ettiğini ve kavramayı sembolik sunumların ardışık süreci olarak modellediği kesindir.

Sinir ağları için yapılan varsayımlar bilişsel süreçlerin tatmin edici bir açıklamasını teşkil ettiği için klasik AI'lerden tamamen farklıdır. Nöral ağlarda önem paralel dağıtılmış iletme modellerinin gelişimine verilmiştir. Bu modeller, bilgi iletiminin her biri ağdaki diğer nöronlara uyarıcı ve kısıtlayıcı sinyaller gönderen büyük sayıda nöronların etkileşimleri yoluyla oluştuğunu varsayar. Dahası nöral ağlar bilişsel fenomenin nörobiyolojik açıklamasına büyük önem verir.

2. İletme Stili: Klasik bir AI'da, iletim normal bir bilgisayar programındaki gibi ardışıktır. Daha önceden belirlenmemiş bir sıra olmasa bile (mesela uzman bir sistemin kuralları) işlemler adım adım yapılır. Muhtemelen ardışık iletim fikri Von Neumann makinesinin yapısındaki gibi, doğal dil ve mantıksal sonucun ardışık doğasından gelir. AI'nin Von Neumann makinesinden hemen sonra ortaya çıktığı unutulmamalıdır.

Diğer bir taraftan, paralel iletim sinir ağlarının göze çarpan bir özelliğidir. Aslında, paralellik nöral ağlarda sadece bilgi iletimi için önemli değildir, aynı zamanda onların esnekliğinin de kaynağıdır. Dahası paralellik devasa olabilir ve bu nöral ağlara kayda değer bir sağlamlık verir. Ölçümün bir çok nörona dağılmasıyla, eğer ağdaki bazı nöronların durumları beklenen değerlerinden sapsa da bu çok önemli değildir. Belirsiz ya da eksik girişler yine de onaylanacak, arızalı bir ağ tatmin edici bir şekilde çalışacaktır ve öğrenmenin mükemmel olmasına gerek yoktur; ağın performansı belirli bir sınıra kadar hafifçe düşecektir. Ağ, her özelliğin bir çok nörona yayıldığı durumda "kaba kodlama" özelliğiyle daha da sağlam hale getirilir. Böylece paralel dağıtılmış iletim, ayırık sembolik AI'nin esnemeyen yapısı ve kırılabilirliğinin tersine sürekli bir sistemin esnekliğine yaklaşır.

Paralelliğin diğer bir sonucu içeriksel bilginin otomatik iletimidir. Bilgi bildirimsel ifadelerle gösterilmez, ama sinir ağının yapısı ve aktivasyon durumuyla gösterilir. Her sinir ağı diğer nöronların global aktivitesinden etkilenir ve bunun sonucunda içerik otomatik bir şekilde işlem görür.

Kısaca, ardışık bilgi iletimi klasik AI'yı destekler, paralel bilgi iletimi nöral ağları destekler. Buna rağmen sembolik AI sistemleri paralel olarak ta uygulanır. Mesela AI de kullanımı önemli bir hale gelen LISP dili bağlantı makinesi olarak bilinen devasa paralel bir bilgisayarda uygulanmıştır. Aynı şekilde ardışık iletimin nöral mimaride uygulanmaması için bir sebep yoktur, aslında nöral ağlar programlarda ardışık olarak simüle edilir.

3. Temsili Yapı: Klasik bir AI modelinde sembolik temsillerin dilsel (linguistik) bir yapısı olduğunu görürüz. Doğal dilin ifadesi gibi klasik AI'nin ifadeleri genelde karmaşıktır ve sembollerle sistematik bir düzen içinde inşa edilmiştir. Sınırlı sayıda sembollerle verilmiş olup yeni anlamlı ifadeler, sembolik ifadelerin tümlene özelliğiyle, sentetik yapı ve semantik arasındaki analogi ile oluşturulmuştur.

Özetle sembolik AI'yı dil algoritmalarının ve veri sunumlarının yukarıdan-aşağıya şekilde yönlendirilmesi olarak tanımlayabiliriz. Diğer bir taraftan nöral ağları doğal öğrenme yetenekli olarak tanımlayabiliriz ve genelde aşağıdan yukarıya şekilde çalışırlar. Bilişsel görevlerin uygulaması için sadece AI ya da nöral ağlara bağlı olarak sonuç aramaktansa yapısal bağlantılı modeller inşa etmek daha uygun bir yaklaşım olur. Bu şekilde nöral ağlar tarafından, sunum, sonuç çıkarma ve evrenselle birlikte sunulan uyarlanabilirlik, sağlamlık, ve benzerlik gibi özellikleri birleştirebiliriz. Böyle melez bir sistemin başarılı olması için her yolun en iyi çalıştığı alanları değerlendirmemiz gerekir. Klasik AI teknikleri en iyi doğal dil iletimi, planlama, veya açık sonuçla uyum sağlar. Nöral Ağlar ise daha düşük algısal iletim, desen eşleştirme ve ilişkili hafızalarda uyum sağlar. Böylece, bu iki değişik metodu birleştirerek iki yönteminde yararlarını birleştirmiş olur ve ikisinin de eksik yönlerini azaltmış oluruz. (Haykin, 1994)

2.10 Tanıtıcı Terminoloji ve Notasyonlar

Belirgin kavramların kısaca tanımları aşağıdaki gibidir. (Schalkoff, 1997)

Uyarlanabilir sistem: Performansı istenilen seviyeye uyarlayabilen veya belirsiz işlemsel çevrelere göre ayarlanabilen sistem

Algoritma: Bir amaca yada çözüme erişmek için bir metot ya da prosedür.

Mimari: Donanım veya program organizasyonu

Sınıflandırma: Bir kategoriye dahil etme kabiliyeti

Özellik: Bir nesne yada durumu karakterize eden faktör

Bulanık mantık: Gerçek değerlerin sınırlı olmadığı bir mantık uzantısı

Genelleme: Daha çok örnek alabilmek; özelleştirmenin zıttı

Deneyimsel: Göz kararı bir yoldur ama problemi çözmesi garanti değildir.

Ağ: Paralel İşlemcilerin birleşimi

Topoloji: Bir ağın yapısı

Eğitim: Öğrenme

İşlemci: ANN'nin en küçük yapısı; bölgesel bir haritalama uygulur.

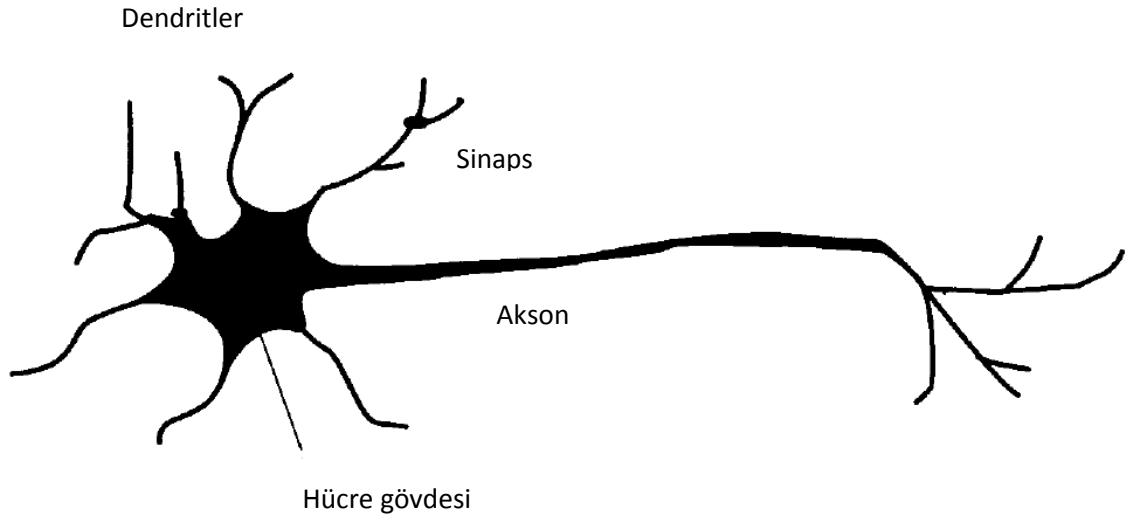
VLSI: Çok büyük ölçek entegrasyonu, genelde iletimi ve ya hafıza kapasitesini artırır.

BÖLÜM 3. YAPAY SİNİR AĞLARININ YAPISI


3.1 Biyolojik Sinir Ağı ve YSA Hücreleri

Bütün sinirsel olayların temeli, insan vücudunun çeşitli bölgelerinde bulunan ve temelde merkezi sinir sisteminde kümelenmiş ve nöron olarak adlandırılan sinir hücreleridir. Nöronlar kendilerinden iki ya da daha fazla sinir uzantısı çıkabilen özel hücrelerdir. Nöronların sinir uzantılarından dendrit olarak tanımlananlar, yakın ya da uzak diğer nöronlardan bilgi alabilen özel yapıları sinir liflerini oluşturur. Nörondan çıkan ve akson adını alan temel bir sinir lifi ise, sinir hücresinden çıkan mesajları taşımakla görevlidir. Dendritler bir nöronun algı ağı, akson ise, o hücrenin motor iletim kanalı olarak düşünülebilir. Özel algı organlarından uyarım alarak bunu ilgili merkezlere ulaştıran nöronlar genellikle en basit yapıya sahip nöronlardır. Bunların dendrit ve akson sayıları tek olabilir. Duyu nöronları dışındaki sinir hücrelerinin çoğunda bir akson ve çok sayıda dendrit bulunur.(Erkan,2003)

Başka nöronlardan gelen sinyalleri alan dendritler ile sinir hücrelerinin ürettiği çıkış sinyallerini taşıyan aksonlar arasındaki bağlantıyı sağlayan boşluklara sinaps denilir. İnsan beyni yaklaşık 10^{11} adet nöron ve 60 trilyon bağlantı içermektedir. İnsan beyninin yaklaşık enerji verimliliği işlem başına saniyede yaklaşık 10^{-16} Joule iken, kullanılan en iyi bilgisayarlarda işlem başına saniyede 10^{-6} Joule harcanmaktadır. Şekil 3.1 ve Şekil 3.2'de basit birer biyolojik hücrenin ve yapay sinir ağı hücresinin yapısı görülmektedir.(Veelenturf, 1995)



Şekil 3.1 Biyolojik Sinir Hücresinin Yapısı (Veelenturf, 1995)



Şekil 3.2 Basit bir yapay sinir hücresinin yapısı

Tablo 3.1' de Sinir sistemi ile YSA'nın birbiriyle eşleşen yanları gösterilmektedir.

Tablo 3.1: Biyolojik Sinir ile YSA'nın Karşılaştırılması (Elmas, 2003)

BİYOLOJİK SİNİR AĞI	YAPAY SİNİR AĞI
Sinir Sistemi	Sinirsel Hesaplama Sistemi
Sinir	Düğüm
Sinaps	Sinirler Arası Bağlantı Ağırlıkları
Dentrit	Toplama İşlevi
Hücre Gövdesi	Etkinlik İşlevi
Akson	Sinir Çıkışı


YSA'lar, ağırlıklandırılmış şekilde birbirlerine bağlanmış birçok işlem biriminden oluşan matematiksel sistemlerdir. Her bir işlem birimi, aslında başlı başına “etkinlik işlevi” olarak anılan bir denklemdir. Her bir birim; diğer nöronlardan sinyalleri alır, bunları birleştirir, dönüştürür ve sayısal bir sonuç ortaya çıkarır. Genelde, işlem birimleri kabaca gerçek nöronlara karşılık gelirler ve bir ağ içinde birbirlerine bağlanırlar; bu yapı da sinir ağlarını oluşturur.

3.2 Yapay Sinir Hücrelerinin Matematiksel Modeli

Nöronlar YSA'nı oluşturan basit yapılu işlemcilerdir. Nöronu matematiksel olarak 3 kısımda inceleyebiliriz. Bunlardan birincisi sinaptik ağırlıklar, ikincisi toplama fonksiyonu ve üçüncüsü de aktivasyon fonksiyonudur.

3.2.1 Sinaptik ağırlıklar

Şekil 3.3' den adet girişi ve tek çıkışı olan bir nöronun matematiksel modeli verilmiştir.



Şekil 3.3 n adet girdisi ve bir çıktısı olan bir nöronun matematiksel modeli(Patan,2008)

Bütün sinir ağları modellerinde $u_1, u_2, u_3, \dots, u_n$ değerleri girişleri, $w_1, w_2, w_3, \dots, w_n$ değerleri sinaptik ağırlıkları ve y değeri ise çıkış değerini ifade etmektedir.

$$y = f\{\sum_i^N w_i \cdot x_i\} \quad (3.1)$$

Sinir ağı çıkışı ikili biçimde ifade edileceği zaman y değeri belirli bir eşik değerinden geçirilerek, eşğin üstünde ise 1, altında ise 0 değeri üretilir.

$$y = \begin{cases} 1, & \sum x_i \cdot w_i \geq b \\ 0, & \sum x_i \cdot w_i < b \end{cases} \quad (3.2)$$

Ağırlıkların işareti ağ için önemlilik derecesini ifade etmez. Burada, uyarma sinapsisi için $w_i=+1$, engelleme sinapsisi için $w_i=-1$ ve nöronu ateşlemek için gerekli olan eşik seviye değeri ise b olmaktadır. Bu model ayrık ağ içindeki bütün nöronların eşzamanlı çalışmaları varsayılmaktadır. Modelde ağırlıklar ve nöronların eşik seviyeleri sabit olmakta ve sinyal akışı dışında, ağ içinde yer alan nöronlar birbirini etkilememektedir. Bundan dolayı ilgili model, yapay nöron konusunda bir başlangıç noktası olarak kabul edilir. (Vahiyev, 2005)

YSA uyarlanabilir olma özellikleri sayesinde eğitildikleri durum dışında bir örnek ile karşılaştıklarında sinaptik ağırlıklarını değiştirerek benzerliklerini arttırabilirler.

3.2.2 Toplama fonksiyonu

Her problem türü için uygun olan toplama fonksiyonu farklıdır ve kullanılabilir genel bir formül yoktur. Prosesteki her bir eleman ayrı toplama fonksiyonuna da sahip olabilir. En yaygın olarak kullanılan ağırlıklı toplamı bulmaktır. Burada her gelen girdi değeri kendi ağırlığı ile çarpılarak toplanır. Böylece ağa giren net girdi bulunmuş olur. Formülizasyonu şu şekildedir.

$$NET = \sum_i^N G_i \cdot A_i \quad (3.3)$$

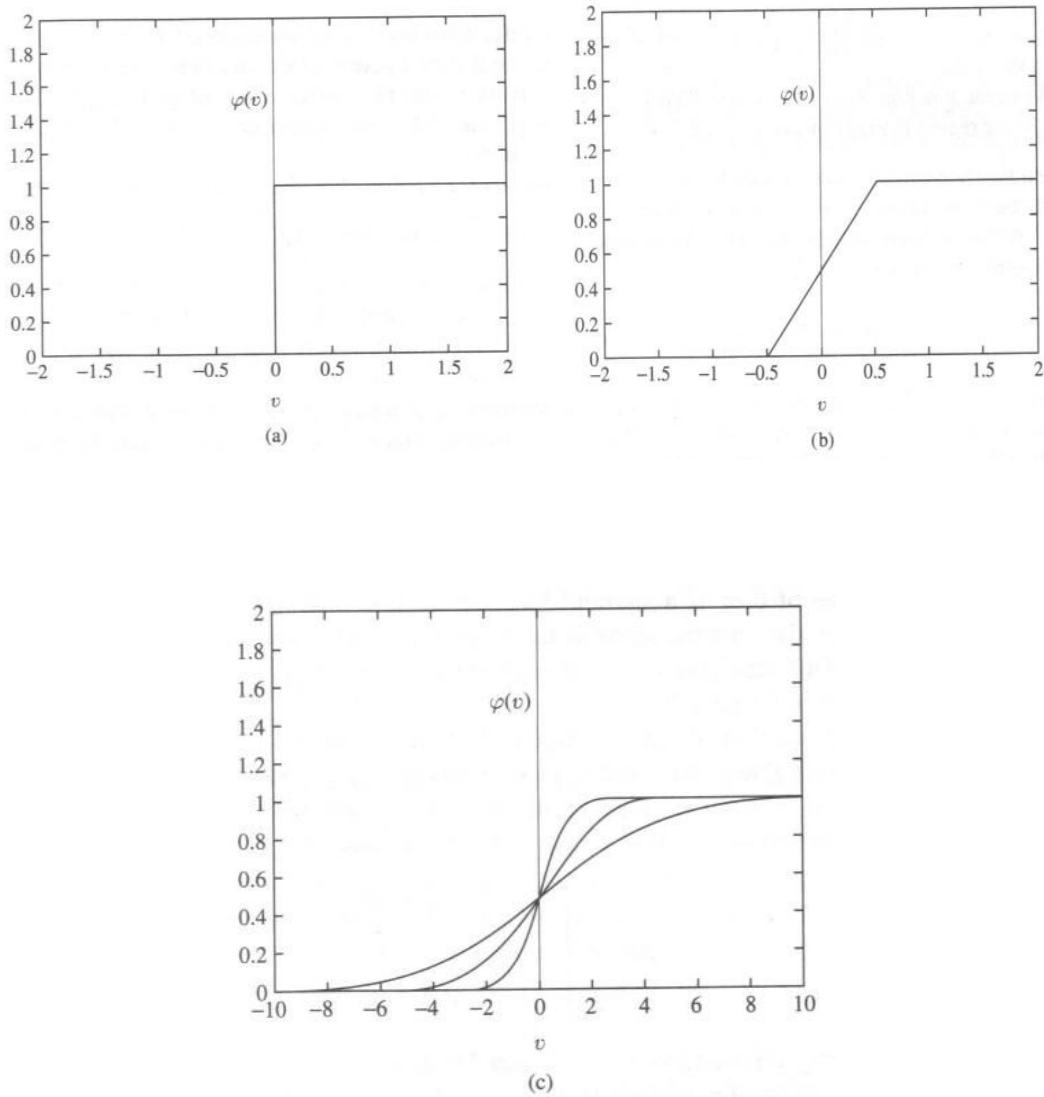
Bunun dışında kullanılabilir bazı toplama fonksiyonu örnekleri Tablo 3.2 ' de verilmiştir. (Öztemel, 2006)

Tablo 3.2 Toplama Fonksiyonu Örnekleri

Net giriş	Açıklama
Çarpım Net girdi = $\prod_i G_i \cdot A_i$	Ağırlık değerleri girdiler ile çarpılır ve daha sonra bulunan değerler birbirleri ile çarpılarak net girdi hesaplanır.
Maksimum Net girdi = Max (G _i ,A _i) , i=1.....N	N adet girdi içinden ağırlıklar ile çarpıldıktan sonra en büyüğü yapay sinir hücresinin net girdisi olarak kabul edilir.
Minimum Net girdi = Min (G _i ,A _i) , i=1.....N	N adet girdi içinden ağırlıklar ile çarpıldıktan sonra en küçüğü yapay sinir hücresinin net girdisi olarak kabul edilir.
Çoğunluk Net girdi = $\sum_i sgn(G_i \cdot A_i)$	N adet girdi içinden ağırlıklar ile çarpıldıktan sonra pozitif ve negatif olanların sayısı bulunur. Büyük olan sayı hücrenin net girdisi olarak kabul edilir.
Kümülatif Toplam Net girdi= Net(eski)+ $\sum(G_i \cdot A_i)$	Hücreye gelen bilgiler ağırlıklı olarak toplanır ve daha önce gelen bilgilere eklenerek hücrenin net girdisi bulunur.

3.2.3 Aktivasyon fonksiyonları

Hücreye gelen net girdilerin işlendiği ve hücrelerin bu girdilere karşılık üretecekleri çıktılarının belirlendiği kısımdır. Toplama fonksiyonuna benzer şekilde her problem için farklı aktivasyon fonksiyonları daha iyi sonuç üretebilir. Ayrıca bütün proses elemanları için aynı aktivasyon fonksiyonunun kullanılma zorunluluğu yoktur. Proses elemanlarından bazıları için aynı, bazıları içinse farklı aktivasyon fonksiyonları kullanılabilir. En uygun aktivasyon fonksiyonunun seçimi için mevcut bir kabul olmamakla beraber, tasarımcının deneme yanılma yöntemi sonucu vereceği karar önemlidir.



Şekil 3.4 a) Eşik Fonksiyonu b) Parça-parça Doğrusal Fonksiyon c) Sigmoid fonksiyonu

Eşik Fonksiyonu Şekil 3.4 a için bağıntı;

$$f(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (3.4)$$

Şekil 3.4 b için;

$$f(x) = \begin{cases} 1, & x \geq 0,5 \\ x, & -0,5 < x < 0,5 \\ 0, & x \leq -0,5 \end{cases} \quad (3.5)$$


Şekil 3.4 c için;

$$f(x) = \frac{1}{1+e^{-ax}} \quad (3.6)$$

şeklindedir.

Yukarıdaki fonksiyonlar dışında signum fonksiyonunun formülasyonu aşağıdaki gibidir.(Şekil 3.5)

$$f(x) = \text{sgn}(x) = \begin{cases} +1, & x > 0 \\ -1, & x < 0 \end{cases} \quad (3.7)$$



Şekil 3.5. Signum Fonksiyonu

Son olarak da hiperbolik tanjant fonksiyonu için denklemler şu şekilde ifade edilir.


$$f(x) = \frac{e^x + e^{-x}}{e^x - e^{-x}} \quad (3.8)$$

Uygulamalarda nöron cevabının, girdilerin sürekli bir fonksiyonu olmasını gerektiren durumlarda sigmoid tipi ya da hiperbolik tanjant tipi denklemlerinde verilen aktivasyon fonksiyonları tercih edilmektedir.

Aktivasyon fonksiyonunun parametrik olması, sinaptik ağırlıkların kazandırdığı esnekliğin ötesinde, değişik eşleştirmelerin yapılabilmesini mümkün kılan bir başka esneklik sağlar. Bu amaçla, hiperbolik tanjant tipi aktivasyonu şu şekilde düzenlenebilir:

$$f(x) = \frac{e^{\alpha x} + e^{-\alpha x}}{e^{\alpha x} - e^{-\alpha x}} = \tan h(\alpha x) \quad (3.9)$$

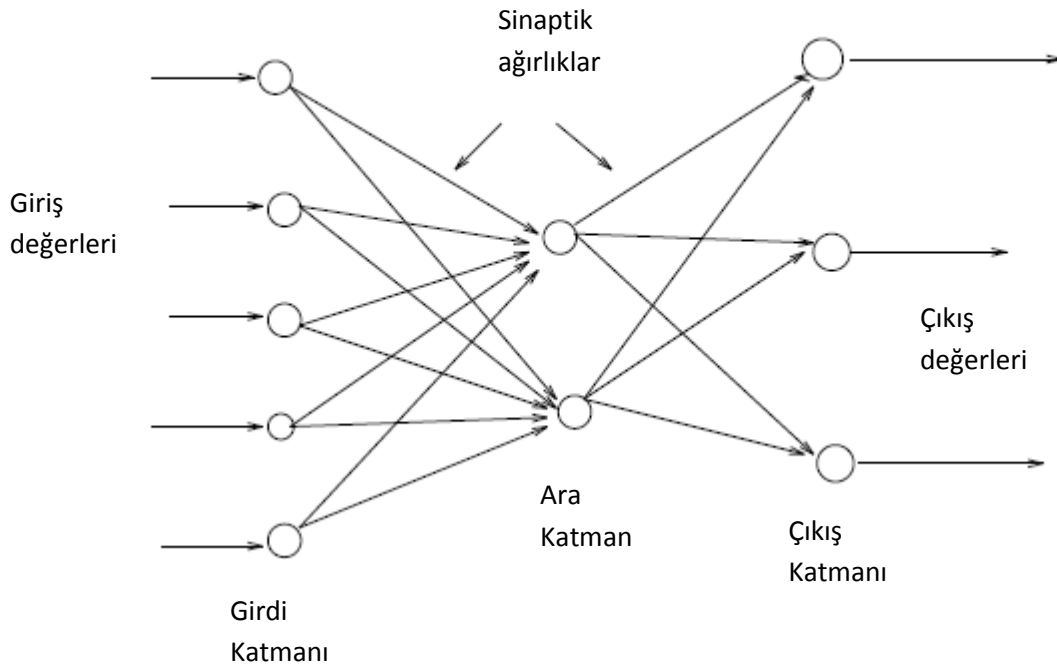
Bu parametrenin değiştirilmesi ile aktivasyon fonksiyonunun şekli değiştirilebilir.



Şekil 3.6 Değişik α değerleri için (3.9) ile tanımlanan fonksiyonun görünümü(Efe, 2000)

3.3 Yapay Sinir Ağları Katmanları

YSA girdi katmanı, ara katman ve çıktı katmanı olmak üzere üç katmandan oluşur. Girdi katmanının görevi gelen bilgilerin ara katmana transferinin sağlanmasıdır. Girdi katmanından sonra ağda yer alan katman ara katmandır. Bu katman bir veya birden çok sayıda olabilir. Bu sayı problemin karmaşıklığına göre değişmektedir. Sistem ne kadar komplike ise katman sayısı o kadar arttırılabilir. Gelen bilgilerin işlenmesi burada gerçekleşir. Son katman olan çıktı katmanı ise ara katmandan gelen bilgilerin işlenip bu bilgilere karşılık cevapların üretildiği katmandır. Her katmanda yer alan nöronlar birbirlerine paralel bir yapıda dizilirler.



Şekil 3.7 Katman sayısı 3 olan bir yapay sinir ağı modeli (Fyfe,1996)

3.4 Yapay Sinir Ağlarında Öğrenme

Yapay sinir ağlarında, ağın öğrenmesinin ilk aşaması ağın eğitilmesidir. Kullanılan başlangıç ağırlık değerleri rassal olarak atanır. Daha sonra üretilen çıktılar ile eğitim setinde yer alan gerçekleşen sonuçlar karşılaştırılır. Bu ikisi arasındaki farkın minimum olması arzulanan durumdur. Bu farkın derecesine göre sistem belirli sayıda iterasyon yaparak her seferinde bu değeri minimize edecek şekilde ağırlık katsayılarını değiştirir. Ağ en iyi sonucu elde ettikten sonra ağın eğitimi işlemi bitmiş olup, sıra ağın test edilmesi işlemine gelmiştir. Son iterasyon ile aynı ağırlık değerleri kullanılarak seçilen test seti örnekleri ağa sunulur ve ürettiği tahmin değerleri ile gerçek değerler karşılaştırılır. Bu karşılaştırmanın sonucu bize ağ performansını verecektir. Ağın performansının yüksek olması ağın genelleştirebilme yeteneğinden kaynaklanır. Böylelikle ağ hiç görmediği bir örnek için, doğru karşılıkları üretebilmektedir. Ancak dikkat edilmesi gereken en önemli nokta ağın ezberlememesidir. Ağ genelleme yeteneği kazandığı anda eğitime son verilmelidir ki eğitim çiftleri için ezberleme gerçekleşmesin. Bu durum Şekil 3.8 de gösterilmektedir.



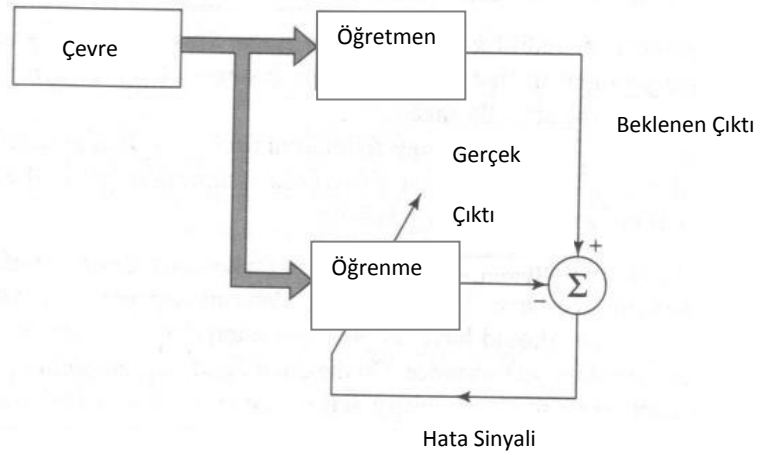
Şekil 3.8 Eğitimin durdurulması için uygun durdurma bölgesi

3.5. Yapay Sinir Ağlarında Öğrenme Türleri

Literatürde kimi kaynaklarda öğrenme danışmanlı ve danışmansız olarak ikiye, kimi kaynaklarda ise danışmanlı, danışmansız ve destekleyici öğrenme olarak 3'e ayrılmıştır. (Fyfe, 1996)

3.5.1 Danışmanlı öğrenme


Bu tipte öğrenmede, ağa girdi değerleriyle birlikte elde edilen çıktı değerleri de verilir. Ağın her bir girdi değeri için ürettiği tahmin değerleri ve gerçekleşen değerler kıyaslanarak ağırlıklar hesaplanır. Bu işlem ilerleyen her iterasyonda sistem doğru cevaplar üretmeye başlayıncaya kadar devam eder. Öğretmenli öğrenme olarak da bilinir. Sistem girdiler ile çıktılar arasındaki haritalama yeteneği sayesinde ilişkileri öğrenip derecelendirmektedir. Çok katmanlı algılayıcı (Multilayer Perceptron) örnek olarak gösterilebilir.



Şekil 3.9 Danışmanlı Öğrenme (Haykin, 1994)

3.5.2 Danışmansız öğrenme

Bu tipte öğrenmede ağa yalnızca girdi verileri sunulur. Ağın kendi kendine öğrenmesi girdi verilerinin yapısına bağlıdır. Yani herhangi bir danışman(öğretmen) yoktur. Sistem ilişkileri kendi kendine öğrendikten sonra çıktıların yorumunun kullanıcı tarafından yapılması gereklidir. Çünkü sisteme sunulan ve üretilen çıktı ile karşılaştırılması beklenen gerçek değerler ağa verilmemiştir.



Şekil 3.10 Danışmansız Öğrenme(Haykin, 1994)

3.5.3 Destekleyici öğrenme

Yukarıda anlatılan 2 öğrenme tipinin arasında kalan bir öğrenme yöntemidir. Danışmanlı öğrenmede olduğu gibi bir öğretmen mevcuttur. Sisteme öğretmen tarafından girdi verileri sağlanır ancak çıktı değerleri yerine sadece doğru ya da yanlış cevap ürettiği söylenir. Eğer ürettiği cevaplar yanlış ise ağırlıklarda bazı

ayarlamalar yapılarak devam edilir. LVQ ağırları bu öğrenme türüne örnek olarak verilebilir. Bunun dışında Hinton ve Sejnowski'nin geliştirdiği Boltzman öğrenme kuralı da bu tipte öğrenmeye verilebilecek örnekler arasındadır.

3.6. Öğrenme Kuralları

3.6.1 Çevrim içi ve çevrim dışı öğrenme

Çevrim içi öğrenen sistemler çalışırken öğrenmeye devam eden sistemlerdir. ART ve Kohonen öğrenme kuralları çevrimiçi öğrenme kurallarının örneklerindedir.

Bazı sistemlerde ise önce eğitim gerçekleşir. Sistemde öğrenme sağlandıktan sonra kullanılmaya başlanmakta ve bundan sonra öğrenme durmaktadır. Sistemde değişen koşullar olduğu zaman bu sistemin kullanımına son verilmekte ve çevrimdışı tekrar eğitim gerekmektedir ve sistemin güncellenmiş hali devreye alınmaktadır. İleride anlatılacak olan delta kuralı da çevrim dışı öğrenme kuralı prensibiyle çalışmaktadır.

3.6.2 Hebb kuralı

Hebb'in öğrenme kuralı bilinen öğrenme kuralları içerisinde en eski ve ünlü olanıdır. Bu kural ismini bir nöropsikolog olan Donald Hebb'ten alır. Bu kural "The Organization of Behaviour" kitabında şu şekilde tanımlanır:

Eğer A hücresi B hücrelerini uyarmaya yetecek kadar yakınsa ve B hücrelerinin aktifleştirilmesinde tekrarlı ve sürekli olarak yer alıyorsa, A hücrelerinin etkinliği arttırılacak şekilde bir veya her iki hücrede de değişiklikler yapılır. Bu kural diğer öğrenme kurallarının da birçoğunun temelini oluşturur. (Graupe,2007)

3.6.3 Hopfield kuralı

Yapısı Hebb kuralına benzeyen bir kuraldır. Elemanlar arasındaki bağlantıların ne derece kuvvetlendirilmesi ya da zayıflatılması gerektiği ile ilgilenir. Şayet girdi değerleri ve çıktı değerleri aktiflerse, ağırlıklar öğrenme katsayısı kadar

kuvvetlendirilir. Ya da tam tersi durumda girdi deęerleri ve çıktı deęerleri pasiflerse, aęırlıklar öğrenme katsayısı kadar zayıflatılır. Öğrenme katsayısı ise kullanıcı tarafından belirlenen sabit ve pozitif işaretli bir deęerdir.

3.6.4 Delta kuralı

Delta kuralı Hebb kuralından türetilmiş kurallardan birisidir. Literatürde Widrow-Hoff ya da En Küçük Kareler Öğrenme Kuralı olarak ta geçer. Danışmanlı öğrenen sistemlerde kullanılabilir.

Tahminlenen çıktı deęerleriyle gerçekte elde edilen çıktı deęerleri arasındaki farklar hesaplanır ve bu farkların karelerinin ortalamasını azaltmak amacı ile çalışır. Kullanılan fonksiyonun türevlenebilir bir fonksiyon olması önemlidir, böylece bulduğumuz hata deęeri transfer fonksiyonunun türevi ile dönüştürülerek hatanın geriye doğru yayılması sağlanmış olur. Bu öğrenme kuralını kullanan aęlar Geri Yayılım Aęları olup, geriye doğru yayılma son katmandan ilk katmana kadar ilerler. Burada eğitim setindeki veriler aęa sıralı bir yapıda deęil rassal şekilde verilmelidir ki aęın öğrenmesi gerçekleşebilsin.

3.6.5 Kohonen kuralı

Kohonen kuralı kazanan her şeyi alır (winner-take-all) şeklinde tanımlanabilir. Aędaki hücreler aęırlıklarını deęiştirmek için bir nevi yarış halindedirler. Üretilen çıktılar içerisinde en büyüğe sahip olan kazanan hücredir ve dięer hücrelere göre üstünlük sağlamıştır. Bu kurala göre hem kazanan hücre hem de komşuları olan dięer hücrelerin aęırlıklarının güncellemesine izin verilir.

3.6.6 Dereceli azaltma

Dereceli azaltma kuralında da delta kuralına benzer şekilde hatanın deęiştirilmesi için transfer fonksiyonunun türevi alınır. μ öğrenme oranıdır ve bir sabitle çarpılarak aęırlık deęişimi sağlanır.

$$w_{i(n+1)} = w_{i(n)} + \Delta w_{i(n)} \quad (3.10)$$

$$\Delta w_{i(n)} = -\mu \frac{\partial \epsilon^d}{\partial w_i} \quad (3.11)$$

Bütün örnekler için bu işlemler tekrarlanır.

3.7. YSA'nın Oluşturulması

Genel olarak bir YSA oluşturmanın adımlarını şu şekilde sınıflandırabiliriz.

- 1.Eğitim ve test verilerinin toplanması
- 2.Ağ mimarisinin oluşturulması
- 3.Öğrenme parametrelerinin seçilmesi
- 4.Örneklerin normalizasyonu ağa sunularak öğrenmenin gerçekleşmesi ve gerekli hesaplamaların yapılması.

3.7.1 Eğitim ve test verilerinin toplanması:

Eğitim verileri ağın öğrenmesini sağlaması açısından çok önemlidir. Toplanan ilk örnekten itibaren, her bir iterasyon sonrasında bütün eğitim setindeki veriler ağa sunulur. Ağ eğitildikten sonra ağa daha önce karşılaşmadığı test seti gösterilir ve üretilen sonuçlar ile gerçek sonuçlar karşılaştırılır. Böylelikle ağın başarısını gösterecek olan performansı ölçülür.

Bu noktada ağ tasarımcısının rolü de çok büyüktür. Ağa verilen örnekler iyi belirlenmeli ve eldeki problemi temsil etme yeteneği yüksek olmalıdır. Ağa sunulan örnekler çok uç noktalardan ya da sadece belirli bir bölgeden alınmamalıdır. Ağ kullanımında başarısız sonuçlar üretiyorsa, problem uzayı ağa iyi sunulamamıştır. Bu nedenle ağın yetersiz kaldığı örneklerin belirlenip, ağa gösterilip ağın yeniden eğitilmesi gerekir. Sonuçta ağın performansının arttığı gözlemlenecektir.

Dikkat edilmesi gereken bir diğer nokta ise verilerin ağa sayısal olarak sunulma zorunluluğudur. Bu ise ağ performansında çok etkili bir faktördür. Öğrenmenin gerçekleşmemesi durumunda örnek verileri sayısal değerlere çevirmekte

kullandığımız yöntemleri değiştirmek de faydalı olabilir. Gerçek hayat problemini temsilen oluşturduğumuz benzetim modelinin tasarımındaki hatalarda ağ performansını doğrudan etkilemektedir. Yani yanlış parametreleri göz önünde bulundurarak toplanan örneklerin de performansa katkısı olumsuz yönde olabilir.

Son olarak öğrenmede kullanılacak örneklerin sayısı performansta etkili kriterler arasında sayılabilir. Eğitim ve test çiftleri için hatanın minimum olduğu noktada eğitime son verilmelidir. Böylece öğrenme sağlanır. Ancak ezberleme süreci başlamadan eğitim durdurulur.

3.7.2 Ağ mimarisinin oluşturulması:

Problemin türüne göre hangi ağ yapısının kullanılacağına karar verilir.

Tablo 3.3 Ağların başarılı oldukları alanlar

Kullanım Amacı	Ağ Türü	Ağın Kullanımı
Tahmin	<ul style="list-style-type: none"> • ÇKA 	Ağın girdilerinde bir çıktı değerinin tahmin edilmesi
Sınıflandırma	<ul style="list-style-type: none"> • LVQ • ART • Counterpropagation • Olasılık Sinir Ağları (PNN) 	Girdilerin hangi sınıfa ait olduklarının belirlenmesi
Veri İlişkilendirme	<ul style="list-style-type: none"> • Hopfield • Boltzmann Machine • Bidirectional Associative Memory (BAM) 	Girdilerin içindeki hatalı bilgilerin bulunması ve eksik bilgilerin tamamlanması

Görüldüğü gibi her ağın iyi olduğu kullanım alanları vardır.(Tablo 3.3) Bu alanları belirleyerek uygulamalar geliştirmek başarılı sonuçları elde etmeye neden olur. Bazı durumlarda yanlış ağ seçimi yüzünden haftalarca ağını eğitemeyen ve yapay sinir ağlarının becerisinin bazı olaylar için yetersiz olduğunu iddia edenler görülmektedir.

Bu doğru bir yaklaşım değildir. Doğru ağ, doğru örnek seti ve doğru bir öğrenme algoritmasının çözemeyeceği problem yok denecek kadar azdır. (Öztemel, 2006)

Kullanılacak ağ yapısının kararı verildikten sonra ise ağda kullanılacak olan katman sayısı belirlenmelidir. Girdilerin uygulandığı katmana giriş katmanı, çıkışların alındığı katmana çıkış katmanı denir ve bu katmanlara fiziksel dünyadan erişilebilir. Giriş ve çıkış katmanlarının arasında gizli katmanlar bulunur ki bu katmanlardaki nöronlar, nonlinear davranışları dolayısıyla, sinir ağının toplam davranışındaki nonlineerliğin kaynağını teşkil ederler. Giriş ve çıkış katmanlarındaki nöron sayıları ele alınan problemin gereklerine göre belirlenir ancak gizli katmandaki (veya katmanlardaki) nöron sayısının optimallik anlamında doğru sayısını veren herhangi bir analitik yöntem şu ana kadar geliştirilmemiştir. Dolayısıyla gizli katman sayısındaki ve bu katmanların nöron sayılarındaki belirsizlikleri aşabilmenin tek yolu deneme yanılma yöntemidir. (Efe, 2000)

3.7.3 Öğrenme parametrelerinin seçilmesi:

Toplama ve aktivasyon fonksiyonlarının belirlenmesidir. Aktivasyon fonksiyonları lineer fonksiyon, eşik değer fonksiyon, sinus fonksiyonu, sigmoid ya da hiperbolik tanjant fonksiyonu olabilir. Uygulamalarda nöron cevabının, girdilerin sürekli bir fonksiyonu olmasını gerektiren durumlarda sigmoid veya hiperbolik tanjant tipi fonksiyonlar kullanılırken, ikili karar mekanizması gerektiren durumlarda sert geçişli aktivasyon fonksiyonları tercih edilmektedir. (Efe, 2000)

3.7.4 Normalizasyon, ağı öğrenmesi ve ağı test edilmesi

Verilerin ağa sunulmadan normalize edilmesi aşırı salınımların engellenerek, ağ performansının artırılması için gereklidir. Bir sonraki aşama başlangıç ağırlık değerlerinin atanmasıdır. İlk değerler rastgele atanır, sonrasında ise ağ topolojisine göre ağırlıklar güncellenir. Örnekler sırasıyla ya da rassal bir şekilde ağa gösterilmeye başlanır ve ağı öğrenmesi tamamlandıktan sonra ağ test edilir.

BÖLÜM 4.YAPAY SİNİR AĞLARINDA AĞ MİMARİLERİ

Ağ mimarileri iletişim yönüne, ağdaki katman sayısına, öğrenme türlerine veya kurallarına göre sınıflandırılabilirler. Çok bilinen YSA mimarilerinin bir sınıflandırma örneği Tablo 4.1’de görülmektedir.

Tablo 4.1 YSA Türlerinin Sınıflandırılması (Bayır, 2006)


A. Danışmanlı
1. İleri Beslemeli
i. Doğrusal
– Hebb
– Algılayıcı
– Adaptif Doğrusal Eleman
– Yüksek Dereceli Ağlar
– Fonksiyonel Bağlantı (Functional Link)
ii. Çok Katmanlı Algılayıcı
– Geri Yayılım
– Kademeli (Cascade) Korelasyon
– Hızlı Yayılım
– Esnek Yayılım (Resilient Propagation, RPROP)
iii. RBF Ağları
– Dikey En Küçük Kareler (Orthogonal Least Squares)
iv. CMAC: Beyincik (Cerebellar) Model Artikülasyon Kontrolörü
v. Sadece Sınıflandırma
– Doğrusal Vektör Niceleme (LVQ)
– Olasılık Tabanlı (PBNN)
vi. Sadece Regresyon
– Genel Regresyon Yapay Sinir Ağı (GNN)
2. Geri Beslemeli
i. Çift Yönlü İlişkili Hafıza (BAM)
ii. Boltzman Makinesi
iii. Yinelemeli Zaman Serileri

Tablo 4.1 YSA Türlerinin Sınıflandırılması (Devam)

<ul style="list-style-type: none"> – Zaman Boyunca Geri Yayılım – Elman – Sonlu Dürtü Yanıtı (Finite Impulse Response, FIR) – Gerçek Zamanlı Yinelemeli Ağ – Yinelemeli Geri Yayılım – Zaman Gecikmeli Sinir Ağı (TDNN)
<p>3. Yarışmacı</p> <ul style="list-style-type: none"> i. ARTMAP ii. Fuzzy ARTMAP iii. Gaussian ARTMAP iv. Karşı Yayılım v. Neocognitron
<p>B. Danışmansız</p>
<p>1. Yarışmacı</p> <ul style="list-style-type: none"> i. Vektör Niceleme <ul style="list-style-type: none"> – Grossberg – Kohonen – Vicdani (Conscience) ii. Self-Organizing Map <ul style="list-style-type: none"> – Kohonen – Yerel Doğrusal (Local Linear) iii. Adaptive resonance theory <ul style="list-style-type: none"> – ART 1 – ART 2, ART 2-A – ART 3 – Fuzzy ART iv. Diferansiyel Yarışmacı Öğrenme (DCL)
<p>2. Boyut Düşürme</p> <ul style="list-style-type: none"> i. Hebb ii. Oja iii. Sanger iv. Diferansiyel Hebb
<p>3. Kendinden İlişkili</p> <ul style="list-style-type: none"> i. Doğrusal Kendinden İlişkili ii. Kutudaki Beyin Durumu (Brain State in a Box) iii. Hopfield

4.1 Tek Katmanlı Algılayıcılar

Tek katmanlı yapay sinir ağı bağlantı ağırlıklarının olduğu tek bir katmana sahiptir. Şekil 4.1' de görülen tek katmanlı ağda olduğu gibi girdi işlemcileri tamamen çıktı işlemcilerine bağlıdır. Bu girdi işlemcilerinin diğer girdi işlemcileriyle aynı şekilde çıktı işlemcilerinin de diğer çıktı işlemcileriyle bağlantısı bulunmamaktadır. Hopfield ağ yapısında ise tam tersi bir durum söz konusudur yani bütün proses işlemcileri hem girdi hem de çıktı işlemcileridir. (Fausett, 1994)



Şekil 4.1 Tek Katmanlı Algılayıcı

Basit bir tek katmanlı algılayıcı için formülizasyon şu şekildedir:

$$\zeta = f(\sum_{i=1}^m w_i \cdot x_i + \theta) \quad (4.1)$$

Bu denklemde y çıktı değerini, x_i girdi değerini, w_i bağlantıların ağırlıklarını, θ eşik değerini, f ise aktivasyon fonksiyonunu ifade eder.

Aktivasyon fonksiyonunun eşik değer fonksiyonu olarak seçildiği durumda çıktı +1 ya da -1 değerlerini alır.

$$f(g) = \begin{cases} +1, & \zeta > 0 \\ -1, & \zeta \leq 0 \end{cases} \quad (4.2)$$

Çıktı değerleri 1 veya 0 olarak da gösterilebilir. O halde denklem aşağıdaki şekli alır.

$$f(g) = \begin{cases} +1, & \zeta > 0 \\ 0, & \zeta \leq 0 \end{cases} \quad (4.3)$$

Bu durumda girdi uzayı ikiye bölünmüştür. Toplam girdi değeri pozitif olduğunda çıktı değeri +1 aksi durumda ise -1 olacaktır.


$$w_1x_1 + w_2x_2 + \theta = 0 \quad (4.4)$$

4.4 bağıntısından x_1 ve x_2 değişkenleri çekilirse;

$$x_1 = -\frac{w_2}{w_1}x_2 - \frac{\theta}{w_1} \quad (4.5)$$

$$x_2 = -\frac{w_1}{w_2}x_1 - \frac{\theta}{w_2}$$

Bu doğru denkleminin geometrik gösterimi ise Şekil 4.2'de gösterilmiştir.



Şekil 4.2 Ağırlıkların ve sınıf ayraç olan doğrunun geometrik gösterimi

$$w_{i(t+1)} = w_{i(t)} + \Delta w_{i(t)} \quad (4.6)$$


Burada her iterasyon da değişen ağırlıklar aslında doğrunun eğiminin değişimidir. İterasyon t 'deki eşik değeri şöyle gösterilir.

$$\theta_{(t+1)} = \theta_{(t)} + \Delta\theta_{(t)} \quad (4.7)$$

Bu tipteki TKA sadece doğrusal olan problemlerin çözümü için uygundur. Doğrusal olmayan problemler için çözüm üretme yeteneği yoktur.

4.1.1 Basit algılayıcı modeli (Perceptron)

Perseptron birden fazla girdi değişkeni ve bir tek çıktı değişkeninden oluşan tek katmanlı algılayıcı modelidir.




Şekil 4.3 Perseptron Yapısı (Smagt, 1996)

Perseptron kuralının çok basit bir yapısı vardır ve şu şekilde 4 adım ile ifade edilebilir:

1. Bağlantılar için rassal başlangıç değerleri atanır,
2. Eğitim setinden bir x girdi vektörü seçilir,
3. Eğer $y \neq d(x)$ (perseptron yanlış cevap verir) ise, $\Delta w_i = d(x)x_i$ denklemi kullanılarak bütün ağırlıklar değiştirilir,
4. İkinci adıma geri dönlür. (Kröse&Smaght,1996)

4.1.2. ADALINE modeli

Adaline modeli 1959 yılında Widrow ve Hoff tarafından geliştirilmiş bir modeldir. Adını Adaptif Lineer Element'in kısaltılmış şekline alır. Basit Algılayıcı Modeline (Perseptron) benzemektedir. Tek farkları öğrenme kurallarından kaynaklanmaktadır. Öğrenme kuralı Delta kuralıdır ve beklenen çıktı ile gerçekleşen çıktı arasındaki hatanın minimum olması üzerine ağırlıklarını değiştirerek çalışır.




Şekil 4.4 Adaline'nin Blok Diyagramı

$$net_i = \sum_{i=1}^p w_i \cdot x_i + \theta \quad (4.8)$$


$$y = \begin{cases} +1, & y \geq 0 \\ -1, & y < 0 \end{cases} \quad (4.9)$$

Eğer birden fazla Adaline ağı bir araya gelirse oluşan ağa Madaline ağı denir.

Öğrenme kuralları Adaline ile aynıdır. Şekil 4.5'te Madaline ağ yapısı gösterilmiştir.



Şekil 4.5 Madaline Ağ Yapısı




Şekil 4.6 Madaline Karar Uzağı Örneđi

4.2 Çok Katmanlı Algılayıcılar

Doğrusal olmayan problemleri çözebilmek için çok katmanlı algılayıcılara ihtiyaç duyarız. 1970'li yıllarda sessiz bir dönem yaşadığını söyleyebileceğimiz YSA çalışmaları Rumelhart ve arkadaşlarının ÇKA modelini geliştirerek XOR problemini çözmeleriyle yeniden hız kazanmıştır. Bu model geriye yayılım modeli olarak da bilinir.

Modelde Adaline modelinde kullanılan Delta öğrenme kuralının doğrusal olmayan yapılar için geliştirilmiş bir hali olan Genelleştirilmiş Delta Kuralı kullanılır. Bu kuralın temeli En Küçük Kareler Yöntemine (LMS) dayanmaktadır. Hem girdi değerleri hem de çıktı değerleri ağa sunularak ağ eğitildiğinden danışmanlı öğrenme gerçekleşir. Doğrusal olmayan gerçek hayat problemlerinin neredeyse hepsine çözüm üretebildiğinden çok geniş bir uygulama alanına sahiptir. ÇKA'larda girdi ve çıktı katmanının yanı sıra bir ya da daha fazla sayıda saklı (ara) katman bulunur.



Şekil 4.7 Çok Katmanlı İleri Beslemeli Ağ Yapısı


Şekilde girdi katmanı dışarıdan gelen girdilerin alındığı ve ara katmana gönderildiği kısımdır. Herhangi bir bilgi işleme bu katmanda mevcut değildir. Geri yayılım ağlarında birden fazla sayıda girdi olabilir ancak her bir işlemcinin tek bir girdisi ve çıktısı vardır. Bu çıktı ara katmandaki her işlemciye gönderilir. Girdi katmanındaki işlemci(bağımsız değişken) sayısı problemin türüne göre değişkenlik gösterir.

Ara katman, girdi katmanından gelen bilgilerin işlenilip daha sonraki katmana gönderildiği kısımdır. ÇKA'da birden fazla sayıda ara katman bulunabilir. Her bir problem türü için ara katman ve bu katmandaki işlemci sayısına denem yanılma yöntemiyle karar verilir.

Çıktı katmanı ara katmandan gelen bilgilerin işlenip dış dünyaya gönderildiği bölümdür. Çıktı katmanı sayısı tektir. Çıktı katmanındaki işlemci sayısı (bağımlı değişken) problemin türüne bağlıdır .

4.2.1. Genelleştirilmiş delta kuralı

Delta kuralının en küçük kareler yöntemi ile genelleştirilmiş halidir. Ağa verilen girdiler ileriye doğru işlenerek ağın çıktısının üretilmesi ile beklenen çıktılar ile üretilen çıktılar arasındaki farkın azaltılması için geriye doğru ağırlıkların değiştirilmesinden ibarettir.



Şekil 4.8 L adet katmandan oluşan bir çok katmanlı ağ örneği

Girdi katmanında bilgi işleme olmadığından ara (saklı) katmana gönderilen çıktı değeri aynıdır. Aktivasyon fonksiyonu toplam girdinin türevlenebilir bir fonksiyonudur ve şu formül ile hesaplanır. (4.10)

$$y_k^p = F(S_k^p) \quad (4.10)$$

$$S_k^p = \sum_j w_{jk} \cdot y_j^p + \theta_k \quad (4.11)$$

S_k^p değeri net girdiyi, w_{jk} ağırlık değerini, θ_k ise eşik değerini ifade eder.

Delta kuralına göre doğru genelleme yapılabilmesi için değişim katsayısı aşağıdaki şekilde (4.12) olmalıdır.

$$\Delta_p w_{jk} = -\gamma \frac{\partial E^p}{\partial w_{jk}} \quad (4.12)$$

E^p p örneği için toplam hatayı temsil etmektedir.

$$E^p = \frac{1}{2} \sum_{o=1}^{N_o} (d_o^p - y_o^p)^2 \quad (4.13)$$

Yukarıdaki denklemde d_o^p p örneğinde o ünitesi için beklenen çıktı değeridir.

$E = \sum_p E^p$ dersek ;

$$\frac{\partial E^p}{\partial w_{jk}} = \frac{\partial E^p}{\partial s_k^p} \cdot \frac{\partial s_k^p}{\partial w_{jk}} \quad (4.14)$$

Denklemdaki 2. faktör $\frac{\partial s_k^p}{\partial w_{jk}} = y_j^p$ 'dir.

$\delta_k^p = -\frac{\partial E^p}{\partial s_k^p}$ olarak tanımladığımızda delta kuralının güncellenmiş haline eşit olan hata yüzeyindeki dereceli azalma denklemini elde ederiz. Ağırlık değiştirmeleri ise $\Delta_p w_{jk} = \gamma_k^p y_j^p$ denklemi ile gerçekleştirilir.

Ağdaki her bir k birimi için δ_k^p değeri olmalıdır. Buradaki δ değerini hesaplamak için ağ boyunca hata sinyalleri geriye doğru yayılmalıdır.

$$\delta_k^p = -\frac{\partial E^p}{\partial s_k^p} = \frac{\partial E^p}{\partial y_k^p} \cdot \frac{\partial y_k^p}{\partial s_k^p} \quad (4.15)$$

4.15 numaralı denklemde $\frac{\partial y_k^p}{\partial s_k^p} = F'(s_k^p)$ 'dir.

Ağın ağırlıklarını değiştirmek için 2 durum söz konusudur.

a. Ara katman ile çıktı katmanı arasında ki ağırlıkların değiştirilmesi

b. Ara katmanlar arası veya ara katman, girdi katmanı arasında ki ağırlıkların değiştirilmesi (Öztemel, 2006)

Öncelikle k ünitesinin ağın çıktı katmanı olduğunu $k=0$ olduğunu varsayalım. Bu durumda, E^p delta kuralının çıktısıyla aynı sonucu verir.

$$\frac{\partial E^p}{\partial y_o^p} = -(d_o^p - y_o^p) \quad (4.16)$$

Eşitlik 4.15'da yerine konulursa o biriminin her bir çıktısı için elde edilen denklem

$$\delta_o^p = (d_o^p - y_o^p) F'_0(s_o^p) \text{ olur.}$$

Şimdi ise k katmanının çıktı katmanı değil de ara katman olduğunu düşünerek k=h için hata ölçümünü ara katmanlardan çıktı katmanına doğru net girdilerin bir fonksiyonu olarak yazalım.

$$E^p = E^p(S_1^p, S_2^p, \dots, S_j^p \dots) \quad (4.17)$$


$$\begin{aligned} \frac{\partial E^p}{\partial y_h^p} &= \sum_{o=1}^{N_o} \frac{\partial E^p}{\partial S_o^p} \cdot \frac{\partial S_o^p}{\partial y_h^p} \\ &= \sum_{o=1}^{N_o} \frac{\partial E^p}{\partial S_o^p} \cdot \frac{\partial}{\partial y_h^p} \sum_{o=1}^{N_o} w_{ko} y_j^p \end{aligned} \quad (4.18)$$

$$\begin{aligned} &= \sum_{o=1}^{N_o} \frac{\partial E^p}{\partial S_o^p} w_{ho} \\ &= - \sum_{o=1}^{N_o} \delta_o^p w_{ho} \end{aligned} \quad (4.19)$$

$$\delta_h^p = F'(S_h^p) \sum_{o=1}^{N_o} \delta_o^p w_{ho} \quad (4.20)$$

Doğrusal olmayan ileri beslemeli bir ağ için genelleştirilmiş delta kuralı bu şekildedir. Matematiksel olarak nasıl türetildiği açıklanan bu eşitliklerin gerçek anlamları da çok açıktır. Örnek ağa sunulur, aktivasyon değerleri ağın çıktılarına yayılırlar ve gerçek ağ çıktıları ile beklenen çıktı değerleri karşılaştırılır, bu sürecin sonu ise her bir çıktı birimi için hesaplanan hata ile sonuçlanır. Bu hata değerine e_o dersek; amaç bu değerini sıfıra yakınsamasıdır. Bunu sağlamak için de ağırlıklar $\Delta w_{ho} = (d_o - y_o)y_h$ olarak hesaplanır. Bu işlem tek başına yeterli olmamaktadır çünkü girdi katmanından ara katmana olan ağırlıklar bu şekilde değiştirilemez. Bu sebeple tekrar delta kuralına başvurulur. Bu durumda ara (saklı-hidden) katmanlar için δ değeri yoktur, saklı katman için bu değerini hesaplanmasını formülize edersek $\delta_h = \sum_o \delta_o w_{ho}$ olur.

Genelleştirilmiş delta kuralı uygulaması iki aşama içerir. Birinci aşama boyunca x değerleri ağa sunulur ve her çıktı ünitesi için y_o^p değerini üretmek üzere yayılır. Daha sonra δ_h^p hesaplanır. İkinci aşama bu hata değerinin ağ üzerinde geriye doğru yayılmasını ve yaklaşık ağırlık değişikliklerinin hesaplanmasını kapsamaktadır.



Şekil 4.9 a)İleri Besleme b)Geri Yayılım (Kamruzzaman, 2006)

Sigmoid fonksiyonu ile ağırlık ayarlamalarının yapılması üç adımda özetlenebilir:

- 1- Hata sinyali δ , bunu girdi olarak alan k işlemcisi ve hatayı gönderen j işlemcisi arasındaki bağlantı $\Delta w_{jk} = \gamma \delta_k^p y_j^p$ 'dir.
- 2- Eğer işlemci çıktı elemanıysa hata sinyali $\delta_o^p = (d_o^p - y_o^p) F'(s_o^p)$ 'dir.
F'i sigmoid fonksiyonu olarak belirtmiştik.

$$y^p = F(s^p) = \frac{1}{1 + e^{-s^p}} \quad (4.21)$$

4.21 eşitliğinin türevi ise aşağıdaki gibi hesaplanır.

$$F'(S^p) = \frac{\partial}{\partial s^p} \frac{1}{1 + e^{-s^p}} \quad (4.22)$$

$$F'(S^p) = \frac{1}{(1 + e^{-s^p})^2} (-e^{-s^p}) \quad (4.23)$$

$$F'(S^p) = \frac{1}{(1 + e^{-s^p})} \frac{(-e^{-s^p})}{(1 + e^{-s^p})} \quad (4.24)$$

$$= y^p (1 - y^p) \quad (4.25)$$

- 3- Çıktı işlemcisi için hata sinyali ise $\delta_o^p = (d_o^p - y_o^p) y_o^p (1 - y_o^p)$ olur.

Gizli katmandaki hata sinyali ise $\delta_h^p = y_h^p (1 - y_h^p) \sum_{o=1}^{N_o} \delta_o^p w_{ho}$ 'dir.

4.3 Destekleyici Öğrenme Modeli

Danışmanlı öğrenme modellerinde ağa girdi değerlerinin yanı sıra üretilen çıktılarının da neler olacağı veriliyordu. Ancak bu modelde sadece öğretmen tarafından üretilen çıktının doğru ya da yanlış olduğu söylenir.

4.3.1 LVQ modeli

Genellikle sınıflandırma problemlerinin çözümünde kullanılan bu model 1984 yılında Kohonen tarafından geliştirilmiştir. Çıktılardan yalnız bir tanesi 1 değerini alırken diğerleri ise 0 değerini alır. Ağa sadece ürettiği çıktının doğru olup olmadığı söylenir. Girdi vektörüne en yakın vektör kazanan vektördür ve bu vektörün ağırlıkları değiştirilir.

Proses elemanları girdi vektörleri ile referans vektörleri arasında ki Öklid mesafesine göre birbirleri ile yarışmaktadırlar. Proses elemanlarından referans vektörü girdi vektörüne en yakın eleman kazanmaktadır. Referans vektörler $\{\mu_i \mid i=1,2,\dots,a\}$ ile girdi vektörleri x ile $\{x_j \mid j=1,2,\dots,a\}$ gösterilsin. İterasyon değerimize t dersek aşağıdaki 3 adım sırasıyla izlenir:

1. Her bir girdi değeri için (x_j) referans vektörler (μ_i) ile aralarındaki uzaklık hesaplanır ve en yakın olan vektör μ_c yarışmayı kazanır.
2. Eğer kazanan eleman doğru sınıfın üyesi ise $\mu_{c(t+1)} = \mu_{c(t)} + \alpha(t) [x_j - \mu_{c(t)}]$ olur. Burada α öğrenme katsayısıdır. Böylelikle μ_c referans vektörü x_j girdi vektörüne yaklaştırılmış olur.
- 3- Diğer koşulda, yeni x_j değeri yanlış sınıf içerisinde ise $\mu_{c(t+1)} = \mu_{c(t)} - \alpha(t) [x_j - \mu_{c(t)}]$ olur. Böylece ağırlık vektörü girdi vektöründen uzaklaştırılmış olur. Bütün girdi bileşenleri için bu adımlar tekrarlanır.

Öğrenme katsayısıyla ilgili dikkat edilmesi gereken bir nokta vardır. $0 < \alpha(t) < 1$ aralığındadır ve k iterasyonda monoton olarak azaltılmalıdır.

LVQ2 Ağı: LVQ ağı ile bulunan çözümün iyileştirilmesi için Kohonen tarafından geliştirilmiş bir modeldir. LVQ2 ağının LVQ ağından farkı eğitim esnasında x_j girdi vektörüne en yakın 2 referans vektörün ağırlığının değiştirilmesidir. Böylece x_j vektörü bu 2 referans vektörün arasındaki bir yerde kalmaktadır. Ağırlık vektörlerinin değiştirilmesi ise şu şekilde formülize edilir:

m_i ve m_j referans vektörlerini, α öğrenme katsayısını, x girdi vektörlerini, t ise iterasyon sayısını gösterebilir.

$$m_i(t+1) = m_i(t) - \alpha(t) [x(t) - m_i(t)] \quad (4.26)$$

$$m_j(t+1) = m_j(t) + \alpha(t) [x(t) - m_j(t)] \quad (4.27)$$

x_0 girdi vektörünün 2 ağırlık vektörü arasında olup olmadığını anlamak için aşağıdaki 2 denkleme bakılır.

$$\min(d_i/d_j, d_j/d_i) > S \quad (4.28)$$

$$S = (1-w)/(1+w) \quad (4.29)$$

Bu denklemler sağlanıyorsa girdi vektörü belirlenen aralıktadır.

d_i m_i vektörünün, d_j ise m_j vektörünün girdi vektörüne olan mesafesidir.

4.4. Öğretmensiz Öğrenme

Ağın herhangi bir öğretmene başvurmadan, örneklerden kendisinin bilgileri türettiği ağ tipidir.

4.4.1. Adaptif rezonans teori (ART) ağları

ART ağları temelde sınıflandırma problemlerinin çözümü için Grosberg tarafından geliştirilmiştir. Öğretmensiz öğrenen ağ tipi örneklerindedir. Çok katmanlı algılayıcılardan temel farklılıkları şunlardır:

a. ART ağları gerçek zamanlı olarak oldukça hızlı ve kararlı bir şekilde öğrenme yeteneklerine sahiptirler. Bu yetenek birçok ağda yoktur. ART ağları bu özellikleri ile gerçek zamanlı öğrenebilen bilgisayarların oluşmasına yardımcı olmaktadır.

b. Gerçek zamanda ortam genel olarak durağan değildir. Olayların oluşumu her an beklenmedik olaylar ile değişebilmektedir. Bununda ötesinde gerçek zamanlı olaylar sürekli devam etmektedir. ART ağları bu durağan olmayan dünyada sınırsız karmaşıklık altında çalışabilme yeteneğine sahiptirler. Diğer ağların çoğu ise durağan olarak çevrimdışı (off-line) öğrenip çalışırlar. Esneklikleri yoktur. Ortama uyum sağlamaları çok sınırlıdır.

c. ART ağları beklenen çıktıları bir öğretmenden almak yerine kendi kendine öğrenmeye çalışır.

d. ART ağları ağa sunulan farklı nitelikteki ve değişik durumlardaki örnekler karşısında kendi kendilerine kararlı (stabil) bir yapı oluşturabilirler. Ağa sunulan, yeni bir girdi geldiği zaman ya bilinen sınıfların kodlarına (sınıflarına) ulaşabilecek şekilde ağda iyileşmeler yapılır ya da yeni kod (sınıf) oluşturulur. Bu ağın büyümesine de neden olabilir ve ağın bütün kapasitesini kullanana kadar devam eder.

e. ART ağları çevredeki olayları sürekli öğrenmeye devam eder. Uzun dönemli hafızada bulunan ağırlıklar sürekli olarak gelen girdi değerlerine göre değişmeye devam ederler.


f. ART ağları girdi değerlerini otomatik olarak normalize ederler. Çok fazla ve oldukça düşük orandaki gürültülerin girdi işaretindeki etkileri ortadan kaldırılmış olur.

g. ART ağlarında hem aşağıdan yukarı hem de yukarıdan aşağıya ağırlık değerleri vardır. Özellikle yukarıdan aşağıya ağırlıklar sınıfları temsil etmektedirler. Bunları ağ kendisi girdilerine bağlı olarak otomatik olarak belirlemektedir. Bu ağırlıklar aynı sınıftan olan bütün örneklerin ortak yönlerini içermektedir. Bu ağırlıklardan oluşan örüntülere kritik özellik örüntüleri denmektedir. Yukarıdan aşağıya ağırlıklar ağın öğrendiği beklentileri (beklenen girdi temsilcileri) göstermektedir. Bu değerler aşağıdan yukarı gelen bilgiler ile karşılaştırılarak eşleme yapılır. Aşağıdan yukarı gelen bilgiler ile karşılaştırma kısa zamanlı hafızada (KDH) oluşmaktadır. Aşağıdan yukarı ve yukarıdan aşağı ilişkiler bir ART ağında kapalı çevrimi tamamlamaktadır.

h. Bu kapalı çevrimden dolayı yukarıdan aşağı ağırlıklar KDH'da yapılan karşılaştırma ile kazanç faktörünü kullanarak aynı kategoride olmayan girdilerin o

kategoriye girmesini önlemektir. Böylece kategoriye gösteren ağırlıkların gerçek zamanlı gelen farklı bir girdiden etkilenmeleri önlenmektedir. Böyle bir kontrol yapılmaması gelen her girdi değerinin ağırlıkları değiştirerek önceden öğrenilen bilgilerin kayıp olmasına neden olacaktır. ART bu özelliği ile sürekli öğrenmeyi desteklemekte ve önceden öğrenilenler ancak aynı gruptaki başka örneklerin yeni özellikleri olunca değiştirilmektedir. Bu özellik ise yakın eşleme (approximate match) olarak bilinmektedir.

i.ART ağlarının yakın eşleme özelliğinden dolayı hem hızlı hem de yavaş öğrenebilme yetenekleri vardır. Hızlı öğrenme Uzun Dönemli Hafıza (UDH) bir denemede yeni bir dengenin (equilibrium) oluşturulması ile gerçekleştirilir. Yavaş öğrenme ile bir dengenin oluşması için birden çok denemenin yapılması durumu kastedilmektedir. Halbuki çok katmanlı algılayıcılar gibi ağlarda osilasyonları önlemek için özellikle yavaş öğrenme zorunluluğu vardır. (Öztemel, 2006)



Şekil 4.10 ART Ağının Yapısı

Bir ART ağının algoritmasını şu şekilde açıklayabiliriz:

1-Ağdaki başlangıç değerlerin atanması

$$t_{ij}^0 = 1 \quad \forall i, j \quad (4.30)$$

$$b_{ij}^0 = \frac{1}{1+n} \quad (4.31)$$

Bu denklemlerde t_{ij}^0 F_B 'den F_A 'ya doğru olan ağırlıkları, b_{ij} F_B 'den F_A 'ya olan ağırlıkları, n ise F_A katmanındaki proses eleman sayısını göstermektedir.

2-Ağa girdi setinden bir örnek sunulur.

$$i=(i_1, i_2, \dots, i_d)$$

3- F_A katmanından F_B katmanına doğru ağırlıkları ifade eden b_{ij} değeri kullanılarak F_B katmanındaki çıktılar hesaplanması;

$$net_i^{FB} = \sum_j b_{ij} \cdot i_j \quad (4.32)$$

4-Maksimum çıktıya sahip olan kazanan proses elemanının seçilmesi,

$$u_j^{FBwin} = \max\{u_k^{FB}\} \quad (4.33)$$

5- $\|i\| = \sum |i_j|$, $net_i^{FA} = t_{ij} u_j^{FBwin}$, p =benzerlik katsayısı olmak üzere eğer aşağıdaki denklem sağlanırsa iki vektör birbirinin benzeridir denilir.

$$\sum_i net_i^{FA} > p \|i\| \quad (4.34)$$

Yukarıdaki eşitlik gerçekleştiğinde ağırlıklar şu şekildedir.


$$t_{ij} = \alpha_1 m_{(j)} [-\beta_1 t_{ij} + f_{(ii)}] \quad (4.35)$$

$$b_{ji} = \alpha_2 m_{(j)} [-\beta_2 b_{ji} + f_{(ii)}] \quad (4.36)$$

$$m(j) = \begin{cases} 1, & v_j = v_j^{FBwin} \\ 0, & \text{aksi halde} \end{cases} \quad (4.37)$$

Eğer 4.34 ile ifade edilen denklem sağlanamazsa, adım 4'ten itibaren bir kazanan buluncaya ya da hiçbir şey kalmayana kadar tekrar edilir.


ART2 Ağı: ART1 ağı ikili (binary) girdi değerleri ile çalışırken, ART2 ağı onun gelişmiş hali olup sürekli girdi değerleri ile çalışmak için tasarlanmıştır.



Şekil 4.11 ART2 Ağı Yapısı(Fausett, 1994)

ART1 ve ART2 modelleri arasındaki en önemli yapısal fark ART2 ağına F_1 katmanında 3 alt sistemin bulunmasıdır.(Şekil 4.12) Bunlar;

- 1.Aşağıdan yukarı girdi değerlerini okuyan alt sistem
- 2.Yukarıdan aşağıya girdileri okuyan alt sistem
- 3.Bu ikisini birbirleri ile eşleştiren alt sistem



Şekil 4.12 ART2 Ağında F₁ Katmanı (Fausett, 1994)


ART2 ağının en önemli sorunlarından birisi birçok parametreyi kullanıcının belirlemesinin gerekmesidir. Bunlar ise ancak uzun denemeler ve deneyimler sonucunda doğru olarak belirlenebilmektedir.

4.5. Geri Dönüşümlü Ağlar

Çıktıların geri dönüşümünün olduğu yeni bir katmandaki çıktının tekrar sisteme girdi olarak sağlanabildiği ağlara verilen isimdir.


4.5.1. Hopfield ağlar

Hopfield ağ McCulloch and Pitts'teki hücre modelini kullanır ve tek katmanlı geri dönüşümlü bir ağıdır. Hopfield ağları kesikli ve sürekli olmak üzere ikiye ayrılırlar. 4 hücreli bir Hopfield ağ modeli şekil Şekil 4.13 (Haykin, 1994) 'de gösterilmiştir.



Şekil 4.13 Hopfield Ağı

Kesikli bir Hopfield ağının algoritmasını şöyle ifade edebiliriz. Her hücrenin tanımlı 2 durumu vardır. Birincisi aktif olduğu durum $s_i=+1$, ikincisi ise pasif olduğu $s_i=-1$ durumdur.



Şekil 4.14 j nöronu için sinyal akışı (Haykin, 1994)

Şekil 4.14'teki değişkenlere göre algoritmanın formülasyonu aşağıdaki gibidir.

$$v_j = \sum_{i=1}^N w_{ji} s_i - \theta_j \quad (4.38)$$

θ_j eşik değerini ifade eder.

$$s_j = \text{sgn}[v_j] \quad (4.39)$$

$$s_j = \begin{cases} +1, & v_j > 0 \\ -1, & v_j < 0 \end{cases} \quad (4.40)$$

Fakat $v_j=0$ ise, j hücresi bir önceki durumunda sabit kalır.

Bundan sonra tanımlanan 2 aşama vardır. 1.si ağırlıkların depolanması, 2.si ise bilgilerin çağırılması safhasıdır.

İlk safhada ağırlıkların öğrenilmesi

$$w_{ij} = \frac{1}{N} \sum_{\mu=1}^p \xi_{\mu,j} \xi_{\mu,i} \quad j \neq k \quad (4.41)$$

$$w_{ij} = 0 \quad \text{aksi halde} \quad (4.42)$$

$\xi_{\mu,i}$ i. Bileşenin değerini, p ise örnek sayısını gösterir. Daha sonra bu ağırlıklar durağan hale gelir. 2.aşamada ağırlıklara tanımadığı bir örnek sunulur ve algoritmanın devamında kullanılan denklem aşağıdaki şekildedir.

$$y_j = \text{sgn}(\sum_{i=1}^N w_{ji} y_i - \theta_j) \quad j = 1, 2, \dots, N \quad (4.43)$$

Ağın durağan hale gelmesini sağlayan enerji fonksiyonu ise

$$E = -\frac{1}{2} \sum_{i=1}^N \sum_{j=1, i \neq j}^N W_{ji} S_i S_j \quad (4.44)$$

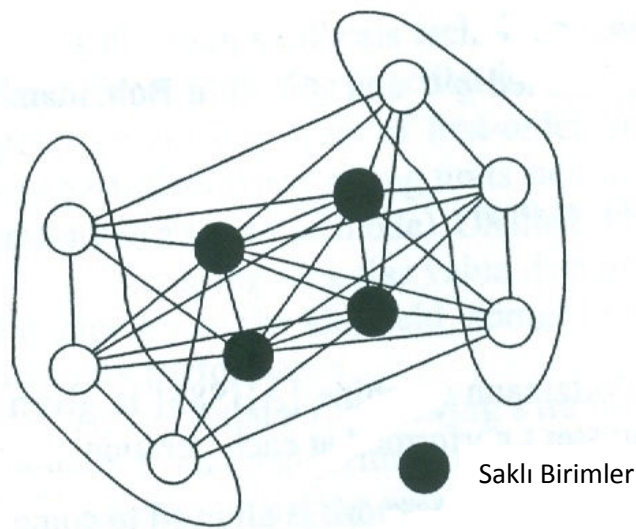
Ve enerji değişimi şu şekildedir.

$$\Delta E = -\Delta S_j \sum_{i=1, i \neq j}^N W_{ji} S_i \quad (4.45)$$


Sürekli ağların kesikli ağlardan tek farkı signum fonksiyonunun değil, sigmoid fonksiyonunun kullanılmasıdır.

4.5.2 Boltzman makinesi

Bir Boltzmann makinesi İşlemcilerin durum geçişlerini karakterize etmesi için rastgele bir yanıt fonksiyonu uyguladığı için Hopfield ağının genellemesidir. Ek olarak, saklı birimler içerir. Saklı birimler sadece görünür birimleri içeren ağlarda mümkün olmayan içsel temsillere izin verir. Şekil 4.15'te basit bir BM gösterilmiştir. Boltzmann birimleri rastgele bir güncelleme bir özelliğindedir (-1,1). Boltzmann birimlerinin sigmoid aktivasyon fonksiyonu arasındaki analogi şekil 4.16'da gösterilmiştir.



Şekil 4.15 Basit Boltzmann Makinesi Ağ Topolojik Yapısı



Şekil 4.16 Çeşitli işlemcilerde Boltzmann makinesi T değişkeni

Enerji Formülasyonu ve Güncelleme:

Rastgele bir işlemci seçilir. Bu durumda çıktı;

$$P(o_j \rightarrow -o_j) = \frac{1}{1 + e^{-\frac{\Delta E_j}{T}}} \quad (4.46)$$

ΔE bu geçiş sonucundaki enerji değişimidir. Bir Boltzmann ağıнын enerji işlevi Hopfield birimlerin de kullanılanlarla benzerdir;

$$E = -\frac{1}{2} \sum_i \sum_j w_{ij} o_i o_j = -\frac{1}{2} O^T W O \quad (4.47)$$

$W_{ii}=0$. Denklem 3.47 in $T \rightarrow 0$ 'a fonksiyonel olarak yaklaşır.

Denklem 4.47' i kullanarak o_j den $-o_j$ ye enerji değişimi (4.48) olarak gösterilebilir.

$$\Delta E_j = -2o_j net_j \quad (4.48)$$

Bu nedenle, denklem 4.46 aşağıdaki hali alır.

$$P(o_j \rightarrow -o_j) = \frac{1}{1 + e^{-\frac{2o_j \Delta net_j}{T}}} \quad (4.49)$$

(4.46) denklemini kullanarak $o_j = -1$ ve $P(o_j \rightarrow 1) = \frac{1}{\left(1 + e^{-\frac{2net_j}{T}}\right)}$ ile verilir. Aynı

durum $o_j \rightarrow -1$ içinde gösterilebilir. (Schalkoff, 1997)

BÖLÜM 5. YAPAY SİNİR AĞI İLE KAPLAMA KALINLIĞININ VE KALİTE DERECESİNİN BELİRLENMESİ

Bu bölümde, çalışma kapsamında incelenecek olan problem tanımlanmakta ve neden çözümde YSA modeline ihtiyaç duyulduğu açıklanmaktadır. Ürün kalitesinden ödün vermeden galvanizleme prosesinin en büyük maliyet kalemini oluşturan çinkonun kaplama kalınlığının tahminine yönelik bir model kurulmuş ve elde edilen değerler sonuç kısmında yorumlanmıştır.

5.1 Uygulama Yapılan İşletmenin Tanımı

2004 yılının Ağustos ayında İzmit'te kurulan Marmara Galvaniz , Sıcak Daldırma Galvaniz (SDG) sektöründe hizmet vermektedir.SDG demir ve çelik ürünlerin paslanmaya karşı korunmasını sağlayan bir metalik kaplama yöntemidir.Bu yöntem dünyada 250 yıldır uygulanan ve bilinen en ekonomik ve uzun ömürlü kaplama yöntemi sayılabilir. Tesiste 7.5 x 1.5 x 2.20 m ebatlarında bir USA menşeli ve yüksek teknolojlili bir galvanizleme ocağı vardır.Su anda sadece fason galvanizleme yapılmaktadır.Firma Yıllık 22.000 ton çelik galvanizleme kapasitesine sahiptir.Şirketin ürün yelpazesini oluşturan ürünler ve SDG'nin kullanım alanları sektörlere göre aşağıda listelenmiştir:

Enerji Sektöründe; -Enerji Nakil Hatları, Aydınlatma direkleri, Travers, potans, şaseler,İzolator demirleri,Topraklama elemanları,Paratoner,Enerji Santralleri (Doğalgaz, Rüzgar, vs) çelik elemanları,Trafo Binaları.

Tarım Sektöründe; -Sulama aparatları (Boru vs),Sera konstrüksiyonları, Tarım Aletleri,Tarım makinaları

Otomotiv Sektöründe; -Otomobil aksamaları, Şase, benzin borusu, Stepne, basamak, zincir, Takoz,Tır Şaseleri, Kasalar, branda elemanları,Demiryolları iletim hatları,Vagon sanayi

Diğer sektörlerde ; -Karayolları İşaret levhaları, Yönlendirme tabelaları,Şehir Mobilyaları (Park Bahçe konstrüksiyonları, duraklar, reklam ilan tabelaları)Oyun Parkları, Lunaparklar,Evsel İnşaat elemanları (Balkon Korkuluğu, merdiven, çit vs),Boylar, Kazan,Tank, termosifon kazanları,Çöp Konteynırları ,Havaalanı, Liman İşletmeleri İskele yapıları, Kıyı otelleri çelik yapıları, Su sporları, Dağcılık Malzemeleridir.


Bütün bunlardan ayrıca gündelik yaşamda kullanılan ve tasarımı Sıcak Daldırma Galvanize uygun her türlü çelik malzeme galvanizlenebilir. Başlıca tabaka, şerit boru, tüp, tel, tel halat, yapısal şekiller ve çok sayıda madeni eşyalardır.

(<http://www.marmaragalvaniz.com>)

5.2 Proses Hakkında

SDG basit anlamda tasarımı ve kimyasal kompozisyonu galvanizlemeye uygun demir ve çelik ürünlerinin ergimiş çinko banyosuna daldırılmasıyla oluşan difüzyon sonucu meydana gelen metalik tepkimeyle oluşan kaplama yöntemidir. Bu kaplama yöntemine olan talep her yıl biraz daha artmaktadır (Şekil 5.1).

Talep (ton)



Şekil 5.1 Çinko Talep Eğrisi (ilzsg istatistikleri)

Galvanizleme prosesinin adımları özet olarak şu şekilde açıklanabilir.

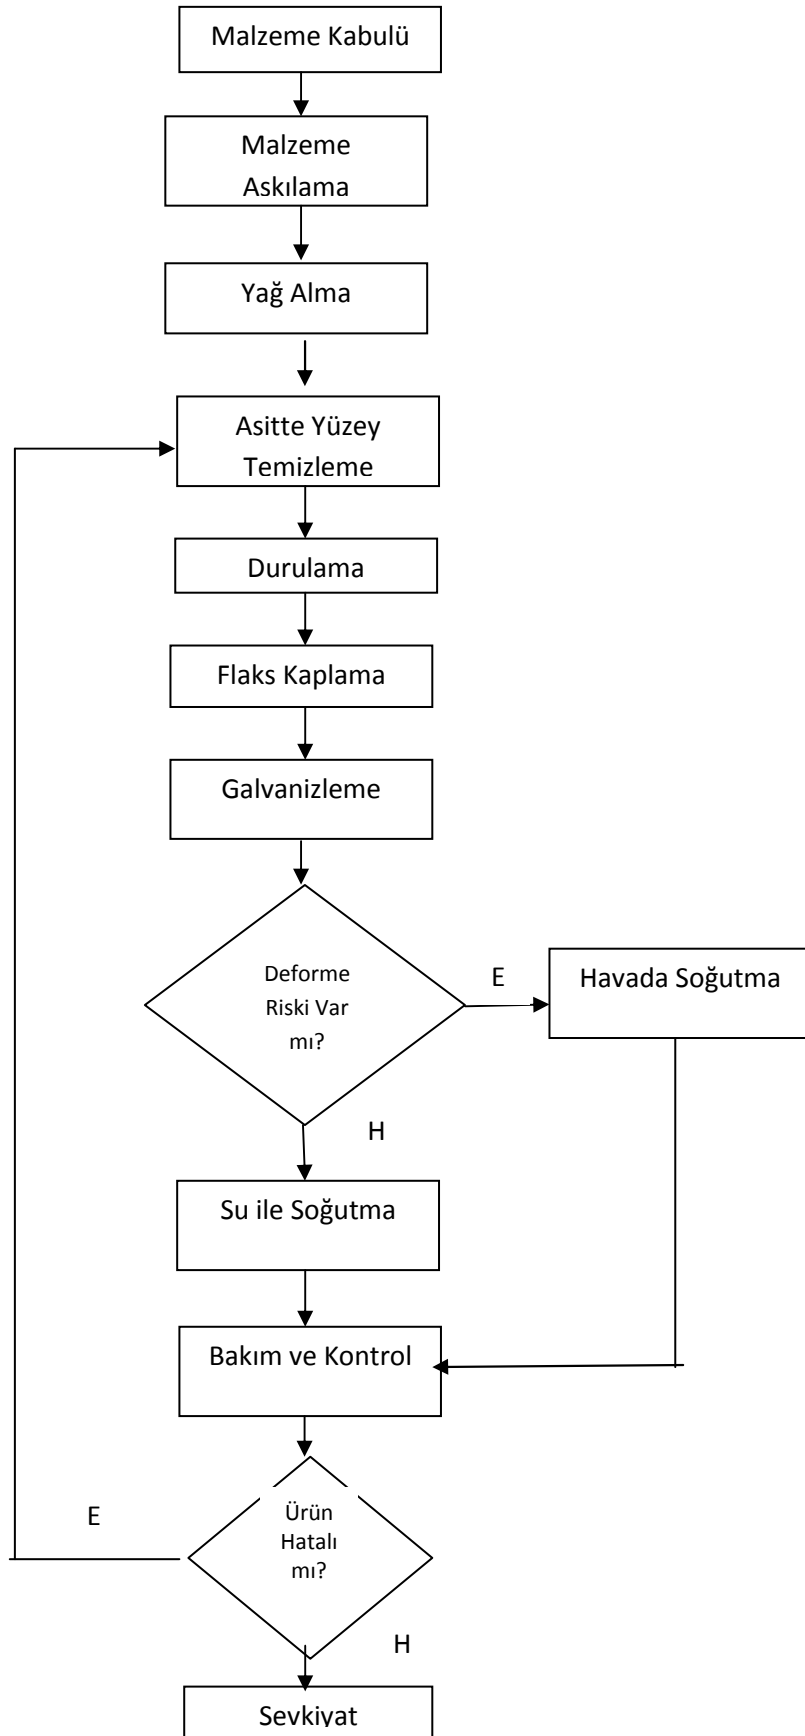
a-İlk olarak galvanizlemeye uygun olan ya da galvanizleme öncesi hazırlık işlemine tabi tutulan ürünler dik, yatay veya açılı olmak üzere 3 tipte askılanabilir.

b-Askılanan ürünler üzerlerindeki kirlilik, yağ ve kimyasal artıkların temizlenmesi için alkali havuzuna daldırılır. Banyoda tutma süresi ortalama olarak 3-7 dakikadır ve bu süre malzeme yüzeyinin temizliğine bağlı olarak değişir.

c-Yağ alma havuzlarında ürünlerin sadece yüzeyindeki kolay lekeler temizlenir, ancak ürünlerdeki pası temizlemek için asit havuzlarında işlem görmeleri gereklidir. Bu yüzden %18'lik konsantrasyona sahip HCL asit banyolarına daldırılarak malzeme üzerindeki pas temizleninceye kadar bekletilir. Ürün yüzeyinde pas olmasa bile yüzeyin galvaniz için aktifleşmesi için asit banyolarında tutulur.

d-Asit banyosundan çıkan ürünler su banyosuna daldırılarak durulanır ve ergimiş çinkonun ürün yüzeyine yapışması için 50-70 °C sıcaklıkta %30 NH₄Cl-Zn C₁₂'den oluşan flaks banyosuna daldırılır.

e-Son olarak ise yüzeyi temizlenmiş ve flaks kaplanmış ürünler 445-465 °C sıcaklıkta "Ocak" denilen ergimiş çinko banyosuna daldırılarak kaplanır. Galvaniz ocağından çıkarılan deforme olabilecek ürünler havada soğutulur, diğer ürünler su banyosunda soğutulur. Proses sonucu galvaniz kaplanan ürünlerin kaplama kalınlıkları dijital mikrometre ile ölçülür. Ölçüm sonuçlarına göre kaplama hataları olan ürünler tamir edilir veya yeniden işlenir. Varsa çinko akıntıları bir eğe yardımıyla temizlenir. (Şekil 5.2)




Şekil 5.2 Proses Akış Diyagramı

5.3 Problemin Tanımı

Uygulamanın gerçekleştiği işletmede siparişe göre üretim yapılmaktadır. İşletme elektrik sektörünün ihtiyacı olan demir çelik enstrümanlarını (Travers, potans, şase, topraklama elemanları, aydınlatma ve ENH direkleri)müşterilerine sunmaktadır. Ancak maliyetlendirme sisteminde ki problemler sebebiyle müşteriye fiyat teklifi sunarken sıkıntı yaşanmaktaydı. Fiyatlandırma politikasında geçmiş verilerde göz önünde bulundurularak Ortalama Et Kalınlığı (OEK)'na göre teklif verilmekteydi. Fakat kaplamayı etkileyen tek faktör OEK değildir, bunun dışında proses ve ürün kaynaklı başka etkenler de bulunmaktadır. Aynı et kalınlığına sahip parçaların kalınlıkları her zaman aynı sonucu vermez.

Özellikle 2009 döneminde yaşanan ekonomik kriz, kronik enflasyon, sermaye maliyetlerinin yükselmesi, ölçek sorunları sanayide küçük ve orta büyüklükteki işletmelerin istikrarlı şekilde büyümesinin önündeki en büyük engellerdendir. Ağustos 2006-2007 yılları arasında çinko maliyeti ciddi bir artış göstermiş daha sonra 2008 yılında çinko fiyatları düşmüştür. Fakat 2009 Ocak ayından beri tekrar çinko maliyetlerinin yükselmeye başlaması önlem olarak işletmenin bu konuda bir çalışmaya yönelmesine neden olmuştur.(Şekil 5.3)İşletmede büyümenin sağlanması ve hedeflenen karlılığa ulaşmak için maliyetin kabul edilebilir bir tahmininin yapılması ve ekonomik koşullara göre hedeflenen kar yüzdesinin maliyetlere yansıtılması kaçınılmaz bir gereklilik arz eder. Uygulanması gereken fiyat belirleme sisteminde kaplama kalınlığına etkisi olan bütün faktörlerin göz önünde bulundurulduğu bir sistem sağlıklı sonuçlar elde etmek açısından önemlidir.



Şekil 5.3 Çinko Stok ve Fiyat Eğrisi

Kaplama kalınlığını doğru tahmin etmek sadece maliyet verilerine faydalı olmayacak bunun dışında standart dışı kaplama oranının da azalmasını sağlayacaktır. Bazı müşteriler ürünlerinin kullanacakları ortamda korozyona daha fazla dayanıklı olması açısından istedikleri minimum kaplama kalınlığını siparişlerde belirtmektedirler. Kaplama kalınlığını tahmin eden bir sistem sayesinde, elimizdeki girdi değerlerinin bu kalınlığa ulaşıp ulaşılamayacağı cevabı da belirsiz olmaktan kurtulacaktır. Böyle özel durumlarda müşteri memnuniyetini sağlamak için de kaplama kalınlıklarının tahmini gereklidir.

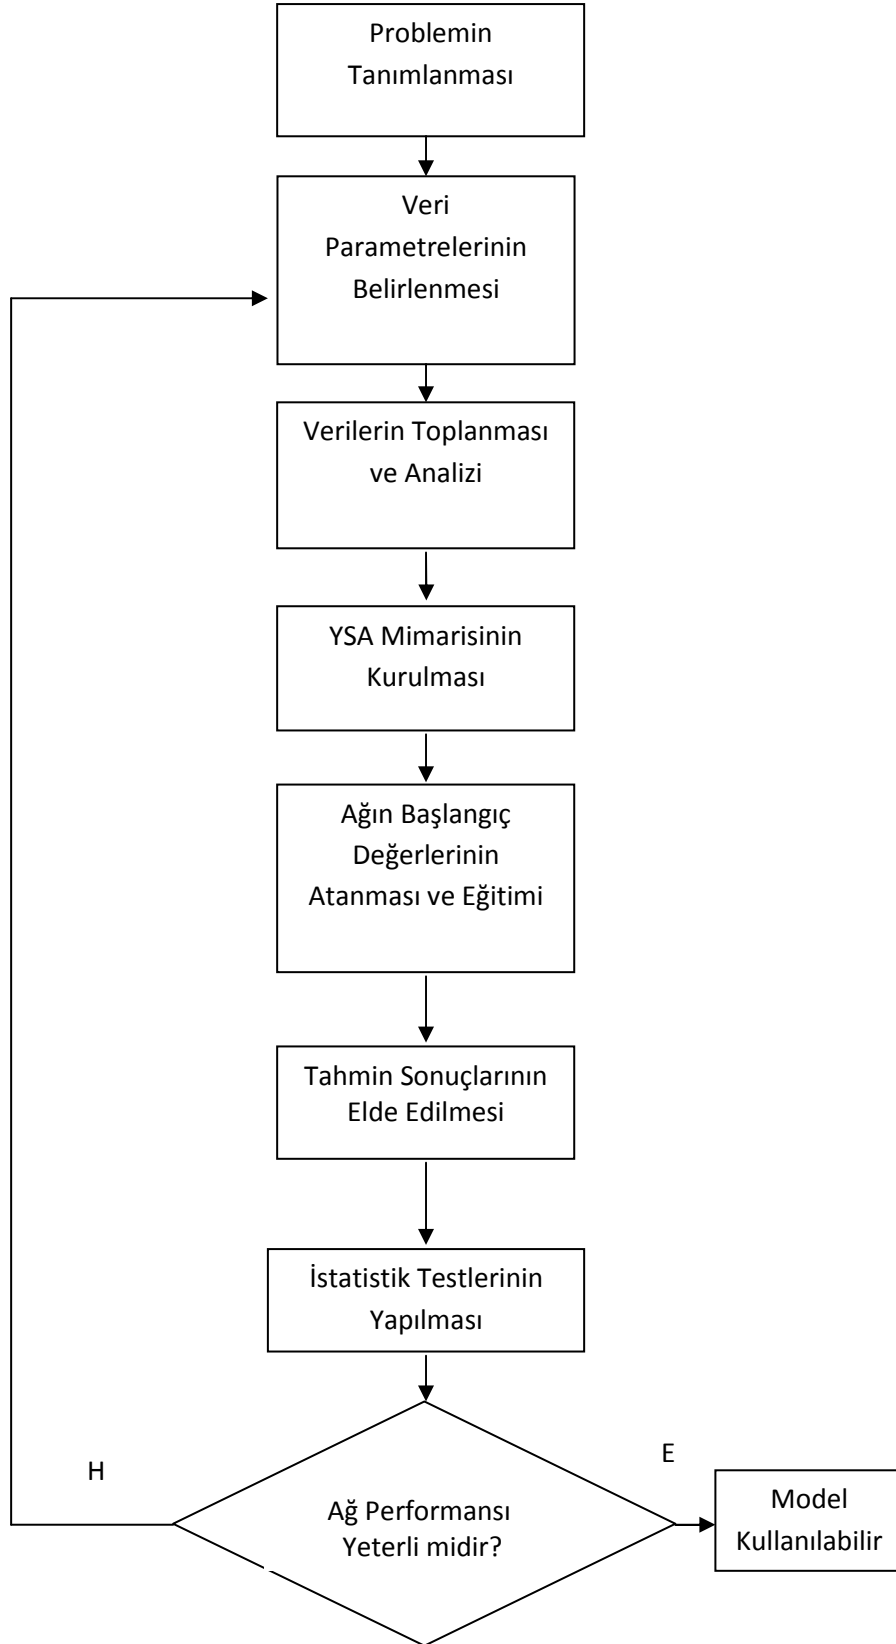
Bu çalışmada yukarıda açıklanan sebeplerden ötürü kaplama kalınlığını tahmin etmeye yönelik bir model kurulmuştur. Bunu yaparken elde edilen verilerinin sonucunda ürünün hangi kalite derecesinde elde edileceğinin de cevabı aranmıştır ve sistemde kullanılan diğer bir model de aynı verilerle ürünün hangi kalite derecesinde çıkacağını tahmin etmek amacıyla taşınmaktadır. Özetle çalışmanın amaçlarını şu şekilde gruplandırabiliriz:

- a.Fiyat tekliflerini sadece OEK 'dan ziyade, kaplama kalınlıkları tahmin değerlerini kullanarak oluşturmak.
- b.Yöneticilerin sağlıklı yatırım kararları verebilmeleri için gerekli bilgi gereksinimini sağlamak
- c.Standart dışı kaplama oranlarını azaltmak
- d.Ürün kalite derecesini tahmin etmek

5.4. Önerilen Yapay Sinir Ağı Esaslı Model

Çalışmada YSA yöntem olarak tercih edilmiştir. Bunun en önemli sebebi YSA'ların genelleştirme yeteneklerinin bulunmasıdır. İşletme çok geniş bir ürün yelpazesine sahiptir ve her ürün için ayrı bir model kurulması imkânsızdır. Çünkü gerekli verilerin toplanması hem zahmetli olacaktır hem de daha sonra aynı ürünün siparişinin gelmemesi durumu söz konusudur. Bu nedenle gelen herhangi bir çelik malzemenin kaplama kalınlığını verecek bir sisteme ihtiyaç duyarız. YSA tanımadığı örnekler için de çözüm üretebilme yeteneğine sahiptirler ve bu nedenle bu yöntem tercih edilmiştir. Bunun dışında tahminleme çalışmalarındaki yüksek başarısı, veriler arasında ki karmaşık ilişkilere cevap verebilmesi, kullanım kolaylığı ve hızı da bu yöntemin kullanılmasının diğer sebepleridir. Bu çalışmada ürünün kaplama kalınlığı ve kalite derecesini tahminleyen bir model kurulmak istenmekte ve bu modelin kurulması sırasında izlenen adımlar şu şekildedir.(Şekil 5.4)

- 1) Problemin tanımlanması
- 2) Kaplama Kalınlığına ve ürün Kalitesine etki eden faktörlerin belirlenmesi
- 3) Verilerin toplanması ve analizi
- 4) YSA mimarisinin kurulması
- 5) Ağın başlangıç değerlerinin atanması ve eğitimi
- 6) Tahmin sonuçlarının elde edilmesi
- 7) Ağ performansını hesaplamak için istatistik testlerinin yapılması



Şekil 5.4 Uygulama Adımları

5.5 Kaplama Kalınlığına Etki Eden Faktörler

5.5.1 Veri setinin belirlenmesi

Bu çalışmada kullanılan ve ürün kaplama kalınlığı ile ürün kalitesine etki eden parametreler işletme yetkilileri ve öğretim görevlilerinin katıldığı toplantıda beyin fırtınası yöntemiyle belirlenmiştir. Bunları genel olarak 3 ana başlık altında sınıflandırabiliriz.

- 1)İşlenecek olan parçaların özellikleri
- 2)Proses özellikleri
- 3)Nihai ürün özellikleri

Parça özellikleri ile ilgili olan parametreler OEK(Ortalama et kalınlığı), parça geometrisi ve yüzey durumudur. Banyo tipi,sıcaklığı, banyolarda bekleme süreleri, banyo bileşimleri, çinko havuzunun kirlilik derecesi ve askılama açısı ise proses özellikleri sınıfındaki parametrelerdir.Son gruptaki nihai ürün özellikleri ise kaplama kalınlığı ve fiziksel kalite derecesi olarak belirlenmiştir.

5.5.1.1 Parça özellikleri

Parça özelliklerinden kaynaklanan parametreler şunlardır:

- a)Ortalama Et Kalınlığı
- b)Parça Geometrisi
- c)Parçanın Durumu

Bu parametrelerin anlamları ve kurulacak yapay sinir ağı modeline etkisi sırasıyla açıklanmıştır.

a)Ortalama et kalınlığı:

Ortalama et kalınlığı çinko sarfiyatını doğrudan etkileyen faktörlerden ilkidir. Ortalama et kalınlığı artıkça diğer bütün parametrelerin sabit tutulması durumunda kaplama kalınlığı artarken,% Zn sarfiyatı düşmektedir. Ortalama et kalınlığı azaldıkça ise kaplama kalınlığı azalır ve %Zn sarfiyatı artar. Ancak bu artış ve azalışlar sabit bir oranda olmayıp çeliğin cinsine göre değişmektedir.

b)Parça geometrisi

Bu parametrede ölçülmeye çalışılan faktör parçanın sıcak daldırma galvaniz için uygunluk derecesidir. Parça geometrisi toplanan bütün verilerde aynı uzman kişi tarafından 1-10 skalasında takdir edilmiştir. Böylece farklı kişilerin farklı değerlendirmeler yaparak çalışmanın objektifliğini etkilemesinin önüne geçilmiştir. Parça geometrisi değerlendirirken dikkate alınması gereken alt başlıklar havuza dalış sayısı, patlama riski, parçanın havuz da yüzme durumu ve süzülme kolaylığıdır ve açıklamaları aşağıda yer almıştır:

a)Havuza dalış sayısı: Küçük hacimli sac malzemeler, boyu çok uzun olmayan borular gibi kimi parçalar havuza tek dalış ile kaplanabilirken hacmi çok büyük profiller gibi kimi malzemeler ise çifte dalış gerektirmektedir. Bu ise hem operatörün işini zorlaştırmakta hem de malzemenin askıda geçirdiği süreyi iki katına çıkarmaktadır.

b)Patlama riski olan malzemeler: Bu madde sıralanan parametreler içinde en önemliler arasındadır. Doğrudan geometriyle alakası yok gibi görünse de galvaniz sektöründe parçanın geometrisinden kaynaklanan sebepler iş güvenliği açısından tehlike yaratmaktadır. Örneğin birbirine kaynak ile birleştirilmiş 2 sac malzemeyi ele alalım. Birleşim yerlerinde boşluk olması durumunda havuza dalış esnasında patlama riski çok yüksektir. Bu şekilde kapalı hacimli parçalarda kaza riskini sıfırlamak için muhakkak çapraz konumlu “akar delik” denilen delikler açılmalıdır. Bu sayede hava tahliyesi ve çinko akışı sağlanabilir. Alınması gereken diğer bir

önlem olarak da vincin havuza dalış hızının ayarlanmasıdır. Bu gruptaki parçaların dalışı esnasında vinç minimum hızına ayarlanmalıdır.

c)Parçanın havuz içinde yüzme durumu: Diğer bir zorluk ise radyatör gibi dar hacimli ve yoğunluğu düşük olan, havuza daldırıldığında batmak yerine yüzme eğiliminde olan parçalarda görülmektedir. B maddesindeki durumun aksine burada deformasyonu önlemek için yapılması gereken vincin hızlı hareket ettirilerek havuza dalış yapılmasıdır. İhtiyaç duyulması halinde parçanın yüzmesinin önüne geçebilmek için daha ağır malzemeler ile birlikte askılanabilir, askılanan parçaların havuzda kalış sürelerinin yakın olması ve hacimlerinin havuza tek seferde sığabilecek büyüklükte olması yeterlidir. Yüzme dışında değerlendirme de dikkat edilmesi gereken diğer bir hususta genişletilmiş metallerdeki çarpılma, burulma riskidir.

d) Süzülme kolaylığı: Çinko havuzundan çıkan parça askıda bir süre bekletilerek çinkonun akışı, süzülmesi beklenir. Ek işlem (eğe ile çinko akıntılarının temizlenmesi) gerektiren süzülmenin zor gerçekleştiği parçaların geometrisini karmaşık yapıyı sayabiliriz.

Bu dört faktörün de birlikte değerlendirilmesi sonucu ölçekte 1 numara en basit geometriye sahip ürünü gösterirken, 10 numara ile geometrisi en karmaşık olan ürün ifade edilmektedir.

Bu skalada:

1-3: Düzgün yüzeye sahip, açık ve küçük hacimli, hafif, tek parçalı, girinti çıkıntısı olmayan, hazırlık süresi sıfır ya da çok düşük olan, hiçbir şekilde zarar verilemeyecek parçalardır. Örnek olarak şase, ızgara, profil, tek sac parçalar, kolon, çöp konteynırı, köşebent, kazan vb parçaları gösterebiliriz.

4-7: Üzerinde akar delik bulunmayan ancak kısa sürede ve kolaylıkla delik açılacak, orta hacimde ve ağırlıkta, çok fazla dikkat gerektirmeyen patlamadan ziyade sadece çarpma ve burulma riskine göre askılanması gereken parçalardır. Örnek: filtre, korkuluk, boru, metal kasa, beton kalıbı vb.

8-10: Büyük hacimli ve ağır, düzensiz yapılı, patlama riski yüksek olan, hazırlık süresi oldukça uzun, çok fazla dikkat gerektiren, üzerinde akar delik açılması zor olan ve uzun süren parçalardır. Bu parçalara radyatörleri, kaynakla birleştirilmiş sac malzemeleri ve kapalı büyük hacimli parçaları örnek verebiliriz.

Bu parametredeki farklılıklar nihai ürün kalitesini direkt olarak etkilediğinden ve eğer arzulanan kalite elde edilemezse yeniden işlemeye gerek duyulacağından ve bu da çinko sarfını arttıracığından modelde yer almıştır.

c)Parçanın durumu

Parçanın durumuyla alakalı sonuca etki eden faktör sayısı ikidir.

- 1)Parçanın kirlilik derecesi
- 2)Parçanın pürüzlülük derecesi

Parçanın kirlilik derecesi

Müşteriden gelen ürünün kalitesini temsil eden iki faktörden ilkidir. Yağ alma ve asit havuzlarında ürün temizlenir. Havuzlarda kalış süreleri parçaların kirlilik durumuna göre değişir. Kirli parçaların havuzda kalış süreleri daha fazladır. Bu parametre ile parçanın pürüzlülük derecelerinin sözel ifadeleri modeli kurabilmek için sayısal değerlere dönüştürülmüştür. Parçanın kirlilik durumu üzerindeki leke, pas, yağ, gres, zank miktarına göre derecelendirilir. 1-3 skalası parçanın kirlilik durumunu temsil etmek için yeterli görülmüştür.

1: Yüzeyi temiz görünen parçalar, bu parçalar yağ alma ve asit havuzuna daldırılıp bekletilmeden çıkarılan parçalardır.

2: Yağlı, çapaklı, lekeli, orta derecede kirli saydığımız parçalardır. Bu parçalar yağ alma havuzuna dalıp çıktıktan sonra temizlenmiş olurlar. Çünkü üzerinde pas gibi malzemenin yüzeyini ciddi anlamda kirletmiş etkiler bulunmamaktadır.

3: Zanklı, paslı, boyalı, malzemenin yüzeyinin kimyası zarar görmüş parçalardır. Yağ alma havuzundan çıktıktan sonra hala parçalar kirli sayılırlar. Temiz hale geldikleri yer asit banyolarıdır. Ancak dikkat edilmesi gereken bir konuda deformasyondur. Asitte kalma süresi arttıkça malzemenin deformasyonu da artacak

ve ürün kalitesi olumsuz yönde etkilenecektir. Bu yüzden havuzda malzemenin temizlendiği ve deformasyona uğramadığı optimum süre çok önemlidir.

Bu faktörün etkisi sadece nihai ürünün kalitesine değildir, bunun dışında eğer iyi temizlenmeden malzeme çinko havuzuna daldırılırsa havuzun da kompozisyonunu bozmakta ve çinko havuzunun da kirlenmesini hızlandırmaktadır. Sonuçta havuza sonrasında temiz bir ürün bile daldırılırsa bozulan havuz içeriği nedeniyle yüzeyi temizlenmemiş ürünler elde ederiz ve çinko havuzu temizlenene kadar kısır bir döngü oluşur.

Parçanın pürüzlülük derecesi

Malzeme yüzeyindeki pasın neden olduğu girinti çıkıntı durumunun derecesidir. Yüzey pürüzlülüğü asit havuzunda giderilmeye çalışılan bir faktördür. Ancak parçanın asitte deforme olmaması için havuz içerisinde sadece belirli bir süre tutulabilir. Bu nedenle bazı malzemeler asit havuzundan çıktıktan sonra bile pürüzlü kalabilir. Bu parametre de nihai ürünün kalitesini etkiler. Yüzeydeki pürüzlülük arttıkça çinko parçaya daha kolay tutunabileceğinden % Zn sarfiyatı da artacaktır. Derecelendirme için kirlilik parametresi ile aynı olan 1-3 skalası yeterli görülmüştür.

1: Hiç pürüzsüz yüzeyler

2: Pürüzlü ancak asit havuzunda bu problemin giderilebileceği yüzeyler

3: Çok pürüzlü, paslı parçalar. Bu probleme malzemenin kendi yapısının sebep olabileceği gibi imalat sırasında oluşan hadde bozuklukları, çizilmeler vb. de sebep olabilir.

Yüzey durumunun derecelendirilmesi işleminin malzeme kabulünden hemen sonra yapılması sağlıklı olmayacağından flaks banyosunun hemen ardından formun doldurulması istenmiştir. Çünkü çıplak gözle yüzeyinin kusursuz olduğunu düşündüğümüz bir parçanın asit havuzundan çıktığında aslında kusurlu olan yapısı ortaya çıkabilir. Gerçekten yüzeyi pürüzsüz olan bir parça da asit ya da flaks havuzunda deforme olup yüzeyi bozulabilir ve çinko sarfi artar. Aksi durum da

mümkündür. Yani çok pürüzlü bir parça asit havuzu çıkışında pürüzsüzlük kazanabilir.

5.5.1.2 Süreç özellikleri

Bu parametrede ölçülen değerleri banyonun sabit aralıklarda tutulması istenen içerikleri(pH, bome, demir oranı) , banyo sıcaklıkları, banyoda kalış süreleri ve askılanma açısı oluşturmaktadır. Banyo ile ilgili istenen değerler banyo tipleri alt başlıklarının içinde anlatılacaktır.

Yağ banyosu

Ürünün askılanma işleminden sonra ilk girdiği havuz yağ havuzudur. Veri takip formlarına bu banyonun pH'ı ve sıcaklığı kalite kontrol sorumlusu tarafından diğer havuzların kimyasal özellikleri ile birlikte not edilmiştir. PH'ın belirli aralıkları aşması ürün kalitesini olumsuz etkileyeceğinden takip açısından önemlidir. Yağ havuzunda kontrol altında tutulması istenen diğer bir etken de havuzda bekleme süresidir. Parça kirliliği arttıkça yağ havuzunda bekleme süresi de artar. Diğer havuzlardaki bekleme süreleri gibi bu süre de yapılan zaman etüdü çalışmasıyla belirlenmiştir.

Asit banyosu


Asit banyosunda kimyasal açıdan en önemli olan faktör bome (yoğunluk) değeri ve sıcaklıktır. Asitte bekleme süresi ise malzeme pürüzlülüğü derecesinin bir fonksiyonu olarak düşünülebilir ve bu değere göre değişkenlik gösterir.

Flaks banyosu

Diğer banyolardan pH ve sıcaklık dışında farkı ölçülen demir oranıdır. Bu oran belirli bir aralıkta sabit tutulmalıdır. Ancak ölçme işlemi kalite kontrol için ekstra bir yük oluşturduğundan haftada 2 kere ölçülüp değerlerin 3 gün için geçerli kabul edilmesi uygun görülmüştür.

Çinko banyosu

Çinko banyosunda dikkate alınan değerler sıcaklık, bekleme süresi ve havuz kirliliğidir.



Şekil 5.5 Sıcaklık Kalınlık İlişkisi

Havuzun kirliliğini etkileyecek faktörler tespit edilip bunlar üzerinden ocak kirliliği tahmin edilmiştir. Ocak bileşiminin kalitesini bozan en etkili faktör drostur. Dros ocağın dibinde biriken, istenmeyen kalıntılar anlamına gelir. Çinko havuzuna parçanın dalmasıyla dipte biriken dros havuz yüzeyine doğru harekete geçer ve parçanı üzerine yapışarak, malzeme yüzeyini bozar.

Çinko havuzunun temizliği havuzun tamamen boşaltılıp, yeniden doldurulması şeklinde gerçekleşmez. Bu çinkonun yüksek maliyetinden dolayı sadece üretimin tamamen durduğu fabrikanın tekrardan tasarlanması gereken bir durumda ya da kazanda sızdırma gibi ciddi bir problem tespit edildiği takdirde kabul edilebilir. Kriz öncesi haftada iki kez Pazartesi ve Çarşamba günleri havuz temizleniyorken bu çalışmanın yürütüldüğü esnada azalan iş yoğunluğu sebebiyle sadece Pazar günleri

havuzun temizlenmesi yeterlidir. Temizlik işlemi azalan hacim kadar çinko ilavesi ve dipteki drosun temizlenmesidir.

Değerlendirme havuzun temizlenmesinden sonra geçen her bir gün için kirlilik değerinin bir arttırılması şeklinde yapılmıştır.

1: Pazar ve Pazartesi günleri

2: Salı günü

3: Çarşamba günü

4: Perşembe günü

5: Cuma ve Cumartesi günleri


Bunun dışında havuz bileşimine ayda bir defaya mahsus kalay, alüminyum ilave edilir. Ayrıca belirli günlerde atılan temizleyici kimyasallar bazı günler için yukarıdaki derecelendirmeden farklı değerler atanmasına sebep olabilir. Örneğin Perşembe günü havuza 4 kirlilik derecesi atanması gerekirken, o gün havuzun bileşiminde yapılan bir katkıdan dolayı 1 değeri anabilir. Bu derecelendirme de objektiflik sağlanması açısından bütün veriler için aynı uzmanın görüşünden faydalanılmıştır.

Askılama açısı

Askılama ürün üzerine delik açılarak ya da mapa kaynatılarak yapılır. Ürünler ağırlık merkezine göre 3 tipe askılanabilir. Aksi takdirde ürün kendi ağırlığından dolayı deforme olabilir. Askılama tipinde etkili olan diğer faktörler de havuz boyutları ve süzülme kolaylığıdır.

a) Dik askılama: Parçalar askıya dik şekilde askılanırlar. Çinko akışının en kolay olduğu askılama tipidir. Havuzdan çıkan parça üzerinden çinko kolaylıkla ve kısa sürede süzülür. Bu nedenle bu tipte askılama modelde 1 değeri ile ifade edilir.

b) Açılı askılama: Parçalar askıyla belirli bir α açısı yapacak şekilde askılanırlar. Modelde süzülme kolaylığına bakılarak 2 değeri ile ifade edilir.



Şekil 5.6 Açılı Askılama

c)Yan askılama: Parçalar askıya paralel şekilde askılanır. Süzülmenin en zor olduğu ve en fazla zaman aldığı göz önünde bulundurularak modelden 3 değeri ile temsil edilmiştir.

5.5.1.3 Nihai ürün özellikleri

Kaplama işleminden sonra kurulan model ile tahmin edilmeye çalışılan faktör ürün kalite derecesinden hiçbir ödün vermeden kaplama kalınlığıdır.

Kaplama kalınlığı

Kaplama kalınlığının bağlı olduğu faktörler ortalama et kalınlığı, parçanın kütlesi, çeliğin kimyasal kompozisyonu, çinko banyosu sıcaklığı ve yüzey pürüzlülüğüdür. OEK arttıkça kaplama kalınlığı da artar ancak yüzde çinko sarfiyatı düşer. Ocak sıcaklığı arttıkça belirli bir noktaya ulaşıncaya kadar kaplama kalınlığı da artar, daha sonra düşüşe geçer. Son olarakta malzeme pürüzlülüğü arttıkça çinko tutunması kolaylaşacağından kaplama kalınlığı da artacaktır. Eğer müşteriden kaplama kalınlığının artırılması isteniyorsa ürün yüzeyi kumlama ile pürüzlendirilebilir.

Kaplama kalınlığı malzeme kesit kalınlığına göre değerlendirilir. Kaplama kalınlık değerleri “TS 914 EN ISO 1461 Demir ve Çelikten yapılmış malzemeler üzerine sıcak daldırılmalı galvaniz kaplamalar-özellikler ve deney metotları” standardında verilmiştir. Bu standartta kaplama kalınlığı için istenen minimum miktarlar belirlidir.

Ancak maksimum miktarlar için bir standart yoktur, her mikron ekstra bir maliyet demektir ve bu nedenle minimuma yakın değerler elde etmek amaçtır.

Kalite derecesi

Kalite derecesi ocak çıkışından hemen sonra değerlendirilmiştir. Geniş ve kıvrımlı malzemelerin köşelerinde biriken kalıntılar, galvaniz üzerindeki gözle görülebilen dalgalanmalar galvanizin kalitesinin düşük olduğu anlamına gelir. Üründe proses esnasında oluşabilecek kalite hataları ve prosesin hangi aşamasından kaynaklandığı aşağıdaki tabloda gösterilmiştir.

Tablo 5.1. Kalite Hataları ve Sebep Olan Faaliyet

Kalite Hatası	Proseste Hataya Sebep olan Faaliyet
Askılama Hatası	Askılama
Asitte Yüzey Temizleme Hatası	Asit Banyosu
Dalış Hatası	Çinko Banyosu
Malzemeye Dros Yapışması	Çinko Banyosu
Malzemede Çinko Kalıntısı	Çinko Banyosu
Kaplama Bozukluğu Hatası	Çinko Banyosu
Aşırı Küllü Malzeme	Çinko Banyosu
Malzemede Aşırı Çapak/Dökülme	Asit Banyosu
Standart Dışı Kaplama	Çinko Banyosu
Malzemede Görünüm Bozukluğu	Asit Banyosu/Çinko Banyosu
Kaplama Dökülmesi	Çinko Banyosu
Yağ Alma Spek Dışı(pH,sıcaklık)	Yağ Banyosu
Asit Spek Dışı(bome,sıcaklık)	Asit Banyosu
Durulama Spek Dışı(pH)	Durulama Banyosu
Flaks Spek Dışı(pH, sıcaklık,bome)	Flaks Banyosu

Yukarıdaki tabloda verilen hataları göz önünde bulundurarak uzman kişiden ürünün kalite derecesini 1-5 skalasında derecelendirilmesi istenmiştir.

Tablo 5.2 Kalite Dereceleri

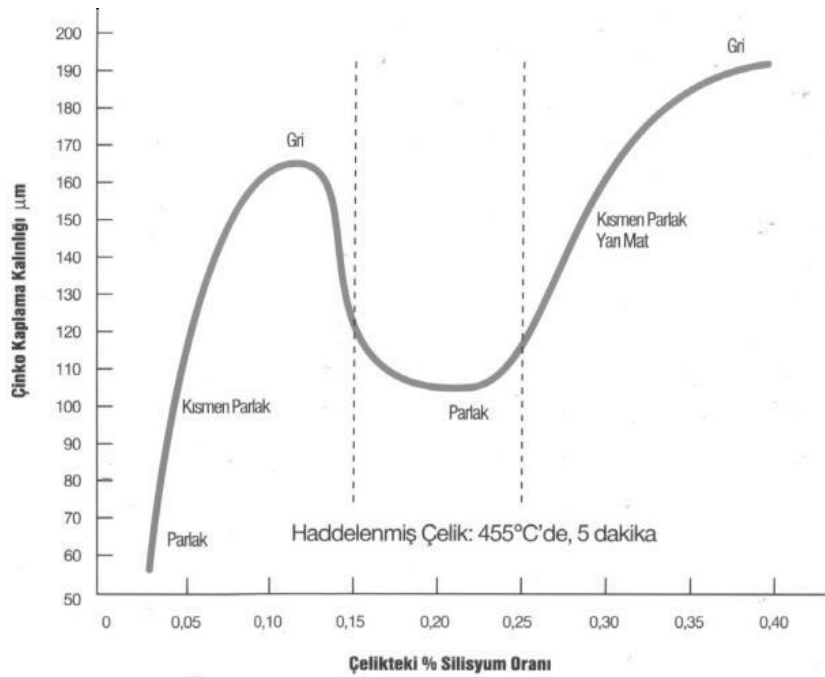
Kalite Derecesi	Tanımı
1	Çok kaliteli, hiçbir uygunsuzluğu bulunmayan ürünlerdir.
2	Çıplak gözle bakıldığında hiçbir hatası olmayan, ancak yapılan hassas ölçümler sonucu hataları olan ürünlerdir. Örnek: Galvanizde fark edilmeyen dalgalanmalar
3	Orta kalitedeki, tekrar çinko ocağına girmeden elle yapılan birkaç işlem sonrasında 2.gruba dahil edebileceğimiz ürünlerdir. Örnek: Parçada çapak, çinko kalıntısı
4	Yeniden işleme gerektirmeden müşteri onayı alındıktan sonra müşteriye gönderilebilecek ürünlerdir. Örnek: Malzemede görünüm bozukluğu
5	Kalite şartlarını sağlamayan, üzerindeki galvanizin sıyrılıp tekrardan işlenmesi zorunlu olan ürünlerdir. Örnek: Standart dışı kaplama

5.5.2. İhmal edilen faktörler

Veri setinin açıklandığı bölümlerdeki beyin fırtınası yöntemiyle belirlenen parametreler dışında, kaplama kalınlığına etki eden ancak ihmal edilen birkaç faktör daha vardır. Modele bu parametrelerin dahil edilmeme sebepleri:

- Gerekli teknik ekipman eksikliğinden ötürü hatasız ölçümlemenin imkansızlığı,
- Ölçümlemeyi yapacak kalifiye personel yetersizliğinden sürekliliğin sağlanamayacak olması,
- Nitelik olarak sayısallaştırılmasının çok karmaşık olduğu parametreler,
- Firma tarafından ihtiyaç duyulmadığından bazı bilgilerin düzenli kaydının bulunmaması

İhmal edilen parametrelerden ilki kullanılan çeliğin özellikleridir. Çeliğin türünün ne olduğu her ne kadar biliniyor olsa da tedarikçilerinin farklı olması, çeliğin muhafaza edildikleri ortamın çeliğin yapısına etkisi ve Silisyum yüzdesi gibi kimyasal farklılıkları bu parametrenin tahminini zorlaştırmaktadır. Konuyla ilgili veriye ulaşılamayacağından önemli olan bu faktör ihmal edilmek zorunda kalmıştır.



Şekil 5.7 Silisyum Oranı Kaplama Kalınlığı İlişkisi

Bunun dışında modelde yer alması gereken diğer bir faktör kütlelerdir. Normal şartlar altında kütle tartılabilir ancak her bir sala tek türde sabit bir ürün askılanmamaktadır. Bazen malzemelerin yüzme riskine karşın o anda siparişi olan ve daha ağır malzemeler aynı sala askılanabilir. Bu da sal kütlelerinin her proses için değişmesine neden olur. Artı ürün yelpazesinin çeşitliliği ortak bir değerlendirme birimi (çap, kesit, kütle, hacim, alan) bulmayı zorlaştırmaktadır. Farklı uzman görüşler farklı birimlerin modelde kullanılmasını savunabilir, farklı kişisel algılar da modelde yer almamıştır.

Prosesle alakalı ihmal edilen diğer parametreler havuza dalış hızı, vinç devirleri, galvanizleme şartları, imalat yöntemleri ve makine verimleridir. Örneklemin dezavantajlarından birisi de verilerin düzenlenmesinde yaşanabilecek yanlılıklardır. Ancak mevcut hata toleransları içinde firma yetkilileri tarafından bu parametrelerin ihmal edilmesinde bir sakınca görülmemiştir.

5.6 Verilerin Toplanması

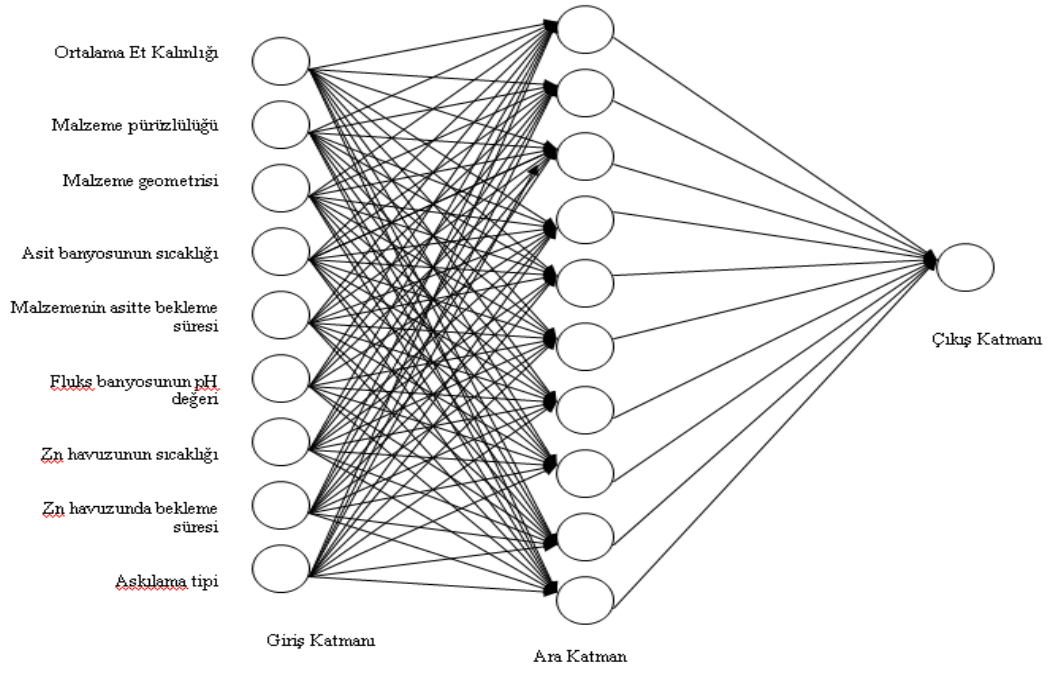
Kaplama kalınlığı 45 ile 288 mikron arasında değişen farklı numunelerden veriler 24 Ocak 2009/16 Nisan 2009 tarihleri arasında rassal zaman aralıklarında işletmeye gidilerek işletme şefi ile birlikte sistematik şekilde toplanmıştır. Bu verileri toplamak üzere işletmede yeni bir veri takip formu oluşturulmuştur. Oluşturulan form örneği Ek A1'de görülebilir. Toplamda doldurulan form sayısı 230'dur. Verileri en genel şekilde 2 grupta toplayabiliriz: sayısal ve sözel veriler. Sayısal olan veriler direk ölçüm yoluyla elde ettiğimiz nicel değerlerdir. Sayısal veri grubu OEK, banyo sıcaklığı, banyolarda bekleme süreleri, banyo bileşimleri(pH, demir oranı, bome değeri) ve kaplama kalınlığıdır. Sözel veriler ise uzman görüş yardımıyla sınıflara ayrılmış ve her grubu temsil eden bir sayısal değer belirlenerek bu verilerin nicel hale gelmesi sağlanmıştır. Her vardiyada aynı uzman tarafından veriler yorumlanarak çalışmada objektif bir değerlendirme sağlanmıştır. Bu veriler ise fiziksel kalite derecesi, parça geometrisi ve yüzey durumu, çinko havuzunun kirlilik derecesi, askılama açısıdır. Eğitim için kullanılan veriler ise Ek A2'de yer almıştır.

5.7 YSA Mimarisinin Kurulması

Modelde deęişken sayısının çok olması, deęişkenlerin birbirleriyle olan ilişkileri, bu ilişkilerin hangi dağılıma ve fonksiyona uygunluk gösterdiği gibi sebepler çoklu doğrusal regresyon modelinin sağlıklı sonuçlar vermesine engel teşkil ettiğinden çözümde YSA yöntemi kullanılmıştır. Uygulamada kullanılan bağımsız deęişkenler OEK, askılama tipi, parça geometrisi, kirlilik derecesi, pürüzlülük derecesi, yağ banyosunun sıcaklığı, pH'ı ve süresi, asit banyosunun sıcaklığı, bomesi (gr/lt) ve süresi, flaksın sıcaklığı, pH'ı, bomesi, demir oranı(gr/lt) ve süresi, çinko banyosu sıcaklığı, süresi ve havuz kirlilik derecesidir. Toplanan dięer beş veri türü ise tamamlayıcı bilgi niteliğindeki ölçüm numarası, tarih, parti numarası, müşteri firma ve malzeme cinsi olup sayısal modelde yer almamıştır.

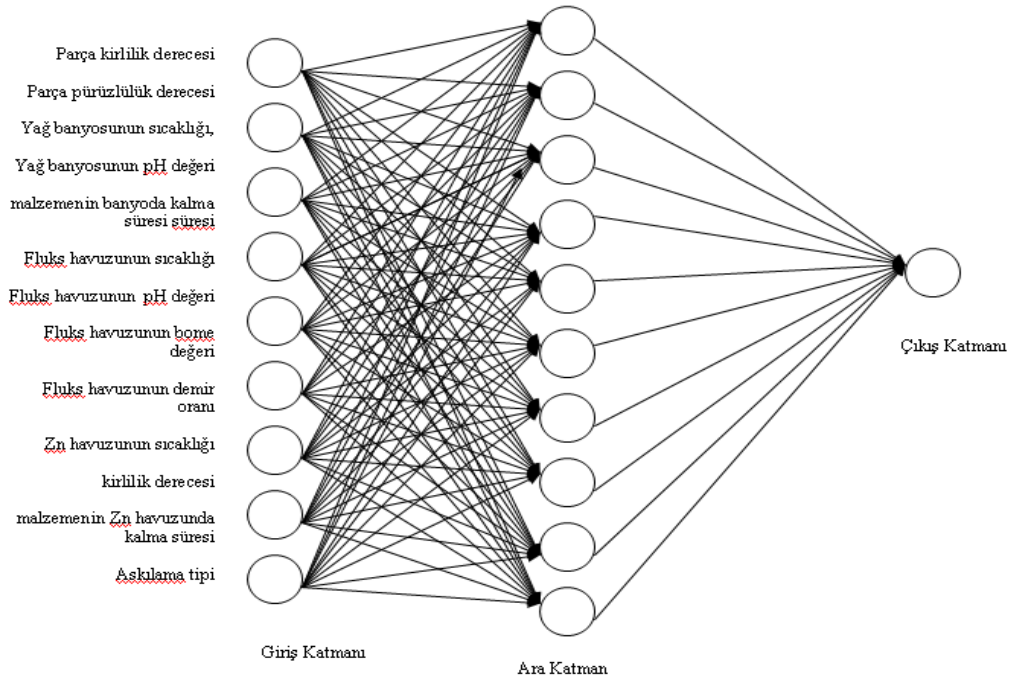
Modelleme yapısı geri yayılım ileri beslemeli (Back- Propagation) yapay sinir ağıdır. Bu ağı tercih edilme sebebi kullanımının kolay olması, üretimde tahmin çalışmalarında en çok kullanılan model olması ve doğrusal olmayan modellerdeki yüksek tahmin başarısıdır. Modelde MATLAB R2007b paket programı kullanılmıştır.

Verilerin program tarafından işleme girmeden önce normalizasyonu gerçekleştirilmiş, veriler [0,1] aralığına indirgenmiştir. Daha sonra verilerin eğitimi ve testi için veriler ikiye bölünmüştür. 230 verinin 43'ü test verisi olarak belirlenmiştir. Uygulamada ki bağımlı deęişkenler ürünün kaplama kalınlığı ve kalite derecesidir. 2 ayrı çıktı deęişkeni için 2 ayrı model kurulmuştur ve ağ mimarileri şekilde gösterilmiştir.



Şekil 5.8 Kalınlık YSA Mimarisi

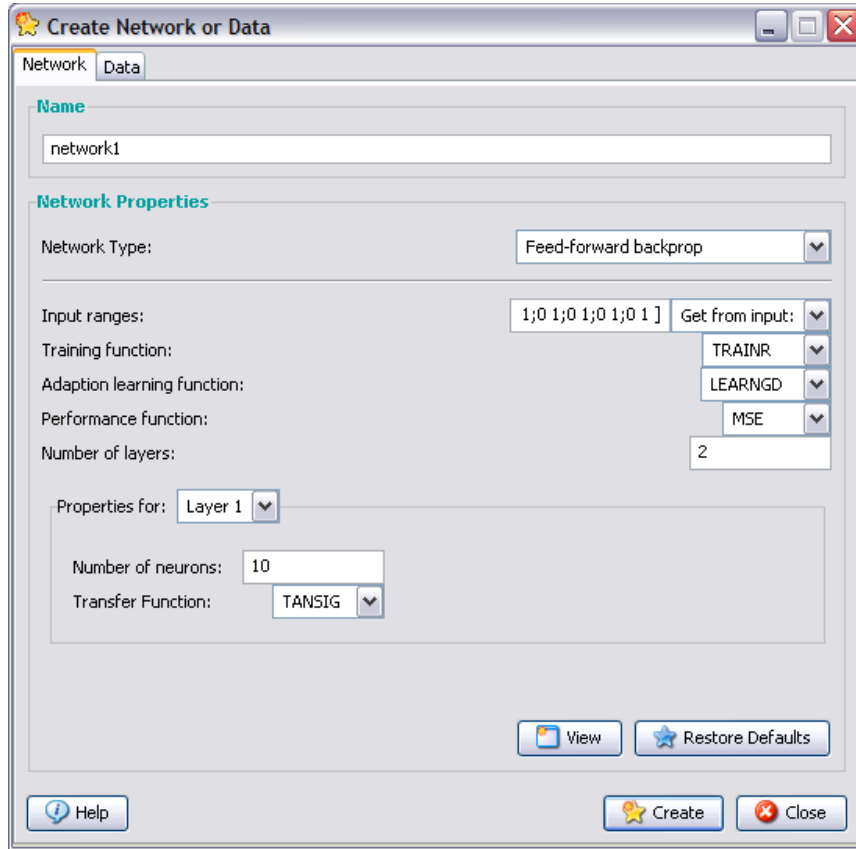
Kaplama kalınlığı için kurulan model 9 girdi değişkenli, tek ara katmanı olan, tek çıktıya sahip ileri beslemeli geri yayılım ağıdır. Ara katmandaki işlemci eleman sayısı 10'dur ve çeşitli denemeler sonrasında bu rakamda karar kılınmıştır.



Şekil. 5.9.Kalite Derecesi için YSA Mimarisi


Kalite derecesi için kurulan model 13 girdi değişkenli, tek ara katmanı olan, tek çıktıya sahip ileri beslemeli geri yayılım ağıdır. Ara katmandaki işlemci eleman sayısı 10'dur .

Toplama fonksiyonu her iki modelde de işlemci elemanların birleştirme fonksiyonu , ara katmanda ki ve çıktı katmanında ki transfer fonksiyonları hiperbolik tanjant ve performans fonksiyonu da Ortalama Hata Kareleri(Mean Squared Errors, MSE) olarak belirlenmiştir.




Şekil 5.10 Kaplama kalınlığı için Ağ Özellikleri

Modelde kullanılacak fonksiyonlarda seçildikten sonra yapılacak işlem modelin eğitilmiştir. Bunun için başlangıç ağırlık değerleri program tarafından rassal olarak atanmıştır. Eğitim için 100 iterasyon kullanılmıştır.



Şekil 5.11 Kaplama kalınlığı için Ağ Yapısı



Şekil 5.12 Kalite derecesi için Ağ Yapısı

5.8 Modelin Sonuçları

Tahmin edilen değerlerin gerçekleşen değerlere ne kadar yaklaştığını ölçmek için, aralarındaki sapma $e(t) = x(t) - f(t)$ şeklinde hesaplanır. Ortalama Hata ise aşağıdaki formülle ifade edilir.

$$ME = \frac{1}{n} \sum e(t) \quad (6.1)$$

Ayrıca kullanılacak diğer kavramlar Ortalama Hata Kareleri (MSE), Ortalama Hata Kareleri Kökü (RMSE) ve Ortalama Mutlak Hata (MAE) dir.

$$MSE = \frac{1}{n} \sum [e(t)]^2 \quad (6.2)$$

$$RMSE = \sqrt{\frac{1}{n} \sum [e(t)]^2} \quad (6.3)$$

$$MAE = \frac{1}{n} \sum |e(t)| \quad (6.4)$$

Kullanılabilecek diğer bir ölçütte hata yüzdesi $p(t) = e(t) / x(t)$ 'dir. Ortalama Yüzde Hata (MPE), Ortalama Yüzde Hata Kareleri (MSPE), Ortalama Yüzde Hata Kareleri Kökü (RMSPE) ve Ortalama Mutlak Yüzde Hata (MAPE) formülleri ise şu şekilde hesaplanır :

$$MPE = \frac{1}{n} \sum p(t) \quad (6.5)$$

$$MSPE = \frac{1}{n} \sum [p(t)]^2 \quad (6.6)$$

$$RMSPE = \sqrt{\frac{1}{n} \sum [p(t)]^2} \quad (6.7)$$


$$MAPE = \frac{1}{n} \sum |p(t)| \quad (6.8)$$

Kurduğumuz modeller için hesaplanan yüzde doğruluk ölçütleri tablosu aşağıdaki şekildedir.

Tablo 5.3 Yüzde Doğruluk Ölçüt Değerleri

	MPE	MSPE	RMSPE	MAPE
Kaplama Kalınlığı Modeli	-0,0827	0,059544	0,244017	0,170922
Kalite Derecesi Modeli	-0,0982	0,122816	0,350451	0,225295

Alınan örneklerin her biri için gerçek ve tahmin değerleri arasındaki sapma grafik üzerinde gözlemlenebilmektedir.



Şekil 5.13 Gerçek değerlerle tahmin değerlerinin karşılaştırılması

Tahmin değerleri ve gerçek veriler arasındaki bu fark, hipotez testi yapılarak yorumlanmıştır. Kaplama kalınlığı için örnek değerleri Tablo 5.4’de verilmiştir.

Tablo 5.4. Kaplama Kalınlığı için örnek değerleri

	Ortalama değer	Standart sapma
Gerçek değerler	85,458	40,16832
Tahmin değerleri	84,81288	23,61217

Kaplama için test istatistiğinin hesaplaması;


$$H_0 = \mu_1 - \mu_2 = 0 \quad (6.9)$$

$$H_a = \mu_1 - \mu_2 \neq 0$$

$$\text{Test İstatistiği} \quad z = \frac{\bar{x}_1 - \bar{x}_2 - (\mu_1 - \mu_2)}{\sqrt{\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}}} \quad (6.10)$$

$$z = 0,097902$$

%95 Güven aralığında H_0 kabul edilir. Bu durum, istatistiksel anlamda gerçek verilerin ve tahmin verilerinin arasında anlamlı bir fark olmadığını, her iki örnek grubunun aynı yığından geldiğini; dolayısıyla tahmin verilerinin gerçek verileri temsil edebilecek yeterlilikte olduğunu göstermektedir.



Şekil 5.14 Gerçek değerlerle tahmin değerlerinin karşılaştırılması

Kaliteye ilişkin değerler Tablo 5.5’de verilmiştir.

Tablo 5.5 Kalite için örnek değerleri

	Ortalama değer	Standart sapma
Gerçek değerler	2,03473	0,75
Tahmin değerleri	2,02	0,39

Kalite için test istatistiğinin hesaplaması;

$$z = 0,12$$

%95 Güven aralığında H_0 kabul edilir. İstatistiksel olarak Kalite yüzeyi için için gerçek verilerle tahminlenen veriler arasında anlamlı bir fark yoktur.

BÖLÜM 6. SONUÇLAR

Yapay sinir ağları yöntemi günümüzde pek çok alanda uygulanmakta ve tahmin modellerinde de başarılı sonuçlar elde edilmektedir. Galvaniz sektöründe de daha önceden bu yöntem kullanılarak yapılan bir tahminleme çalışması bulunmaması, kullanımının kolay olması, esnekliği, hızlı ve başarılı sonuçlar elde etme yeteneğinden dolayı çalışmada bu yöntem tercih edilmiştir.

Proje öncesinde işletmede kaplama kalınlıklarının tahminine yönelik herhangi bir çalışma bulunmamaktaydı, kalınlıklar tamamen geçmiş tecrübelerle dayalı bölüm şefinin insiyatifinde sezgisel olarak tahmin edilmekteydi. Bu da üretim esnasında yetkili bir kişi olmadığında, çalışmaların aksamasına, işlerin kişi odaklı yürümesine neden olmaktadır. Amaç işletmenin ihtiyacı çinko kaplama kalınlıklarında bir standartlaşma sağlanması ve girdiler sisteme işlendiğinde sonucu tahmin eden bir sistem oluşturulmasıydı. Aynı zamanda bu girdiler ile hangi kalite derecesinde ürün elde edileceği de önemli bir faktördü. Belirlenen model havuzda bekleyiş süreleri ve diğer faktörlere ait belirsizliği ortadan kaldırmak adına önemli bir adımdır. Çalışma sonucunda ortalama mutlak yüzdesel hata değeri hesaplanmıştır ve buna göre kaplama kalınlığı için kurulan YSA modelinin yüzde on yedi hata ile diğer bir deyişle yüzde seksen üç performansla çalıştığı tespit edilmiştir. Bu modelin kalınlık ve kalite tahminlemeye dönük kullanılabilir bir model olduğu hipotez testleriyle desteklenmiştir. Çalışmaların daha da geliştirilip bir arayüz halinde şirketin kullanımına sunulması da mümkündür.

Sistem performansı daha da iyileştirilebilir. Ancak bunun için geliştirilmesi gereken ortam koşulları da bulunmaktadır. Bu bağlamda mevcut sistem için önerileri şu şekilde listeleyebiliriz:

- a) ISO 1461 standardında belirlenen ortalama et kalınlıklarına göre verilerin sınıflandırılıp modelin çalıştırılması

- b) Farklı örnek sayısının arttırılması
- c) Bulanık mantık yardımıyla modelde geliřtirmelere gidilmesi
- d) Modelde ihmal edilen parametrelerin modelde kullanılması için gerekli ölçüm ekipmanlarının temin edilmesi
- e) Metalurji ve kimya alanından mühendis desteęi sağlanması

KAYNAKLAR

ALTUĞ, S., İstanbul Menkul Kıymetler Borsası'nda Yapay Sinir Ağları Kullanılarak Fiyat Öngörüsü, Yüksek Lisans Tezi, Bilkent Üniversitesi Fen Bilimleri Enstitüsü, Sf.53, 1994.

BAYIR, F., Yapay Sinir Ağları ve Tahmin Modellemesi Üzerine Bir Uygulama, Yüksek Lisans Tezi, İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, Sf.43, 2006.

CAPUTO , A.C., PELAGAGGE, P.M., Parametric and neural methods for cost estimation of process vessels, Int. J. Production Economics, 112, pp. 934–954, 2008.

CAVALIERI,S., MACCARRONE,P., PINTO,R., Parametric vs. neural networkmodels for the estimation of production costs: A case study in the automotive industry, Int. J. Production Economics, 91, pp.165-177, 2004

EFE, Ö., KAYNAK, O., Yapay Sinir Ağları ve Uygulamaları, Boğaziçi Üniversitesi, İstanbul, 2000.

ELMAS, Ç., Yapay Sinir Ağları, Seçkin Kitabevi, Ankara, 2003.

ERKAN, N., Verimlilik, Sağlık ve Güvenlik İçin İnsan Faktör Mühendisliği Ergonomi, MPM Yayınları No:373, Ankara, 2003.

FAUSETT, L., Fundamentals of Neural Networks Architectures, Algorithms, and Applications, Prentice-Hall, New Jersey, 1994.

FYFE, C., Artificial Neural Networks, The University of Paisley, 1996.

GRAUPE, D., Principles of Artificial Neural Networks, World Scientific, Singapore, 2007.

GUNAYDIN ,H.M., DOGAN ,S.Z., A neural network approach for early cost estimation of structural systems of buildings, International Journal of Project Management, 22, pp. 595–602, 2004.

HAGAN, M.T., DEMUTH H.B., BEALE M., Neural Network Design, PWS, 1996.

- HAYKIN, S., *Neural Network a Comprehensive Foundation*, MacMillan College Publishing, New Jersey, 1994.
- JAIN, A.K., MAO, J., MOHIUDDIN, K.M., *Artificial Neural Networks: A Tutorial*, IEE, pp. 31-44 1996.
- KAMRUZZAMAN, J., BEGG, R.K., SARKER, R.A., *Artificial Neural Networks in Finance and Manufacturing*, Idea Group, 2006.
- KARAKUZU, C., *Yapay Sinir Ağları ile Bir Kontrol Uygulaması, Yüksek Lisans Tezi, Kocaeli Üniversitesi Fen Bilimleri Enstitüsü, Sf.4, Kocaeli, 1998.*
- KERMANSHAHİ, B., IWAMIYA, H., *Up to year 2020 load forecasting using neural nets, Electrical power and energy systems, 24 , pp. 789-797, 2002.*
- KRÖSE, B., SMAGT, P., *An Introduction To Neural Networks*, The University of Amsterdam, Amsterdam, 1996.
- NABIYEV, V., *Yapay Zeka Problemler-Yöntemler-Algoritma*, Seçkin Yayıncılık, Ankara, 2005.
- RESKOVIC S., GLAVAS Z., *The Application Of An Artificial Neural Network For Determining The Influence Of The Parameters For The Deposition Of A Zinc Coating On Steel Tubes, Material In Tehnologije, 43, 4, pp 201-205, 2009*
- ÖZTEMEL, E., *Yapay Sinir Ağları*, Papatya Yayıncılık, İstanbul, 2003.
- ÖZTÜRKCAN, M., *İstatistik*, Kocaeli Üniversitesi Yayınları, 2002.
- PARAG C. PENDHARKAR, *Scale economies and production function estimation for object-oriented software component and source code documentation size, European Journal of Operational Research, 172, pp. 1040–1050, 2006.*
- PİNO, R., PARRENO, J., GOMEZ, A., Priore, P., *Forecasting next-day price of electricity in the Spanish energy market using artificial neural Networks, Engineering Applications of Artificial Intelligence, Vol.21, pp. 53-62, 2008.*
- SCHALKOFF, R.J., *Artificial Neural Networks*, McGraw-Hill International Editions, Singapore, 1997.
- SCHULZ, W.D., THIELE, M., *Feuerverzinken von Stückgut Die Schichtbildung in Theorie und Praxis, Erste Auflage, 2007*
- VEELENURF, L.P.J., *Analysis and Applications of Artificial Neural Networks*, Prentice Hall, NJ, 1995.

VERLINDEN, B., Duflou, J.R., Collin, P., Cattrysse, D., Cost estimation for sheet metal parts using multiple regression and artificial neural networks: A case study, *Int. J. Production Economics*, 111, pp. 484–492, 2008

WANG, Q., Artificial neural networks as cost engineering methods in a collaborative manufacturing environment , *Int. J. Production Economics*, vol.109, pp. 53-64, 2007.

YURTOĞLU, H., Yapay Sinir Ağları Metodolojisi ile Öngörü Modellemesi: Bazı Makroekonomik Değişkenler için Türkiye Örneği, Yayın No: Dpt:2683, Uzmanlık Tezi, Sf. 4, Şubat 2005.

ZHANG, Y.F., Fuh, J.Y.H., A Neural Network Approach For Early Cost Estimation Of Packaging Products , *Computers ind. Engng*, Vol.34, No.2, pp. 433-450, 1998

<http://www.ilzsg.org/static/stocksandprices.aspx>, Erişim Tarihi: 25.06.2009.

<http://e-bergi.com/2008/Subat/Yapay-Sinir-Aglari>, Erişim Tarihi: 25.06.2009.

EK A.1

MARMARA - SIEGENER GALVANİZ LTD.

Yapay Sinir Ağları Veri Formu

Ölçüm Tarihi:

Parti No:

Firma Adı:

Malzeme Cinsi:

PARÇA ÖZELLİKLERİ

1) OEK (Ortalama Et Kalınlığı):

2) Parça geometrisi

1	2	3	4	5
6	7	8	9	10

3) Yüzey Durumu

Kirlilik	1	2	3
Pürüz	1	2	3

PROSES ÖZELLİKLERİ

1) Banyo özellikleri

Banyo Tipi	Banyo Sic	Bekl. Sür.	Banyo bileşimi
Yağ			pH:
Asit			Bome:
Flaks			pH:
			Bome:
			Demir Oranı:

Zn (Ocak)		
-----------	--	--

2) Zn havuzunun temizlik derecesi

1 2 3 4 5

--	--	--	--	--

3) Askılama Açısı

	Yan Askılama
	Dik Askılama
	Açılı Askılama

SONUÇ ÖZELLİKLERİ

1) Kaplama Kalınlığı

--

2) Kalite derecesi

1 2 3 4 5

--	--	--	--	--

EK A.2 Eğitim Veri Seti (Normalize edilmiş)

OEK	Parça Geo.	Pürüz	Asit sic.	Asit Bekleme	Flaks pH	Zn sic.	Zn. Bekleme	A sku	Kalınlık
0,10625	0,5	0,333333	0,625	0,125	0,888889	0,984444	0,147058824	1	0,200347
0,125	0,3	0,333333	1	0,083333	0,888889	0,973333	0,176470588	0,333	0,249653
0,1875	0,6	0,333333	0,75	0,125	1	0,977778	0,147058824	1	0,323958
0,21875	0,3	0,333333	0,675	0,125	1	0,977778	0,117647059	0,667	0,242014
0,09375	0,5	0,333333	0,5	0,116667	1	0,98	0,176470588	0,667	0,207986
0,25	0,4	1	0,45	0,5	1	0,988889	0,176470588	1	0,832639
0,3125	0,4	0,666667	0,45	0,375	1	0,977778	0,235294118	1	0,541667
0,625	1	0,666667	0,45	0,458333	1	0,977778	1	1	0,652778
0,1875	0,3	1	0,475	0,416667	1	0,982222	0,176470588	0,333	0,217708
0,5	0,1	0,333333	0,55	0,316667	1	0,984444	0,176470588	0,333	0,584375
0,1875	0,4	1	0,5	0,416667	0,888889	0,988889	0,294117647	1	0,459028
0,3125	0,4	1	0,5	0,416667	0,888889	0,988889	0,294117647	1	0,476042
0,375	0,2	0,333333	0,5	0,25	0,888889	0,988889	0,882352941	0,333	0,30625
0,375	0,5	1	0,55	0,166667	0,888889	0,988889	0,352941176	1	0,589931
0,3125	0,2	0,333333	0,4	0,208333	1	0,977778	0,588235294	0,333	0,255903
0,5	0,4	0,333333	0,5	0,166667	1	0,977778	0,588235294	0,333	0,290278
0,34375	0,1	1	0,4	0,166667	0,888889	0,977778	0,588235294	1	0,697917
0,125	0,4	0,333333	0,55	0,125	0,888889	0,977778	0,588235294	1	0,207292
0,125	0,3	1	0,525	0,166667	0,777778	0,977778	0,588235294	1	0,232639
0,5	0,4	0,333333	0,9	0,25	0,777778	0,977778	0,588235294	1	0,464236
0,21875	0,4	1	0,525	0,208333	0,777778	0,977778	0,588235294	0,333	0,273958
0,625	0,5	0,333333	0,575	0,25	0,888889	0,977778	0,588235294	1	0,589931
0,075	0,7	0,666667	0,4	0,125	0,888889	0,977778	0,588235294	1	0,244444
0,375	0,5	0,666667	0,4	0,5	0,888889	1	0,588235294	1	0,480556
0,1875	0,2	0,666667	0,525	0,75	0,888889	1	0,235294118	0,333	0,580208
0,1875	0,1	0,333333	0,55	0,25	0,888889	1	0,882352941	0,333	0,293056
0,25	0,4	0,333333	0,525	0,291667	0,888889	1	0,294117647	0,333	0,370486
0,3125	0,4	0,333333	0,525	0,5	0,777778	0,991111	0,294117647	1	0,798958
0,25	0,1	0,333333	0,525	0,25	0,777778	0,986667	0,294117647	0,333	0,509722
0,125	0,1	1	0,45	0,166667	0,777778	0,984444	0,176470588	1	0,229167
0,075	0,6	0,333333	0,9	0,333333	0,777778	0,984444	0,235294118	1	0,281944
0,125	0,3	0,333333	0,45	0,166667	0,777778	0,982222	0,176470588	1	0,2125
0,125	0,6	0,333333	0,625	0,15	0,888889	0,977778	0,294117647	1	0,239236
0,125	0,2	0,333333	0,5	0,158333	0,888889	0,977778	0,294117647	1	0,246181
0,15625	0,5	0,666667	0,5	0,158333	0,888889	0,977778	0,176470588	1	0,269097
0,375	0,1	0,333333	0,5	0,158333	0,888889	0,988889	0,294117647	0,333	0,328472
0,15625	0,8	0,333333	0,625	0,158333	0,888889	0,988889	0,235294118	1	0,388542
0,625	0,8	0,666667	0,45	0,333333	0,777778	0,988889	0,882352941	1	0,509028
0,1875	0,6	0,666667	0,55	0,25	0,777778	0,982222	0,588235294	1	0,482639
0,1875	0,5	0,333333	0,55	0,333333	0,777778	0,977778	0,588235294	1	0,267014
0,1875	0,6	0,333333	0,55	0,208333	0,777778	0,977778	0,588235294	0,333	0,370486
0,25	0,2	0,666667	0,45	0,208333	0,777778	1	0,588235294	0,333	0,303819
0,9375	0,2	1	0,625	0,333333	0,666667	1	0,294117647	0,333	0,271875
0,1875	0,2	1	0,625	0,333333	0,666667	1	0,294117647	0,333	0,593403
0,075	0,7	0,333333	0,625	0,125	0,666667	0,977778	0,588235294	1	0,220139
0,125	0,6	0,333333	0,55	0,208333	0,666667	0,988889	0,588235294	1	0,216319
0,075	0,8	0,333333	0,625	0,125	0,666667	0,977778	0,588235294	1	0,23125
0,25	0,2	1	0,625	0,166667	0,666667	0,977778	0,588235294	1	0,505903

OEK	Parça Geo.	Pürüz	Asit s.c.	Asit Bekleme	Flaks pH	Zn s.c.	Zn. Bekleme	A s k ı	Kalınlık
0,1875	0,8	1	0,55	0,25	0,666667	1	0,588235294	1	0,320833
0,625	0,8	1	0,55	0,25	0,666667	1	0,588235294	1	0,809375
0,625	0,4	0,333333	0,55	0,208333	0,666667	1	0,294117647	0,333	0,508333
0,3125	0,4	0,666667	0,625	0,208333	0,666667	1	0,588235294	1	0,355556
0,375	0,2	0,666667	0,5	0,333333	1	0,988889	0,235294118	1	0,411111
0,25	0,1	0,333333	0,5	0,166667	1	0,984444	0,470588235	1	0,309375
0,125	0,3	0,333333	0,4	0,166667	1	0,977778	0,176470588	1	0,2375
0,125	0,4	0,333333	0,5	0,125	1	0,977778	0,588235294	0,333	0,28125
0,25	0,3	0,666667	0,725	0,333333	0,777778	0,988889	0,176470588	1	0,305556
0,28125	0,3	0,333333	0,825	0,166667	0,777778	0,977778	0,176470588	1	0,285069
0,125	0,5	0,333333	0,825	0,183333	0,888889	0,995556	0,176470588	1	0,259375
0,125	0,1	0,666667	0,725	0,333333	0,888889	0,982222	0,176470588	1	0,929514
0,3125	0,8	1	0,825	0,416667	0,888889	0,988889	0,176470588	1	0,277083
0,25	0,1	0,333333	0,825	0,166667	0,888889	0,977778	0,117647059	0,333	0,303819
0,1875	0,2	0,333333	0,5	0,208333	0,888889	0,984444	0,235294118	0,333	0,567014
0,125	0,3	0,666667	0,625	0,208333	0,777778	0,982222	0,117647059	0,333	0,178125
0,25	0,5	1	0,625	0,208333	0,777778	0,98	0,294117647	1	0,297569
0,125	0,5	0,333333	0,625	0,125	0,777778	0,977778	0,294117647	1	0,285069
0,3125	0,2	0,666667	0,825	0,208333	0,888889	0,986667	0,294117647	1	0,413889
0,3125	0,2	0,666667	0,825	0,25	0,888889	0,986667	0,294117647	1	0,413889
0,3125	0,2	0,666667	0,825	0,125	0,888889	0,982222	0,176470588	1	0,413889
0,3125	0,2	0,666667	0,825	0,125	0,888889	0,984444	0,235294118	1	0,413889
0,125	0,5	0,333333	0,575	0,166667	0,888889	0,986667	0,176470588	1	0,213194
0,125	0,5	0,333333	0,7	0,166667	0,888889	0,988889	0,176470588	1	0,213194
0,125	0,5	0,333333	0,475	0,166667	0,888889	0,984444	0,176470588	1	0,213194
0,125	0,5	0,333333	0,675	0,166667	0,888889	0,982222	0,176470588	1	0,213194
0,125	0,5	0,333333	0,575	0,166667	0,888889	0,982222	0,176470588	1	0,213194
0,125	0,5	0,666667	0,7	0,125	0,888889	0,977778	0,117647059	1	0,373611
0,125	0,5	0,666667	0,475	0,166667	0,888889	0,977778	0,117647059	1	0,373611
0,125	0,1	0,333333	0,575	0,15	0,888889	0,977778	0,294117647	0,333	0,223611
0,1875	0,1	0,333333	0,7	0,166667	0,888889	0,977778	0,176470588	0,333	0,300347
0,15625	0,6	0,333333	0,575	0,208333	0,888889	0,977778	0,235294118	0,333	0,223611
0,10625	0,5	1	0,675	0,166667	0,888889	0,977778	0,235294118	1	0,285764
0,3125	0,1	0,333333	0,475	0,333333	0,888889	0,977778	0,235294118	1	0,277778
0,075	0,7	0,333333	0,5	0,166667	0,888889	0,977778	0,235294118	1	0,304514
0,075	0,7	0,333333	0,45	0,166667	0,888889	0,975556	0,235294118	1	0,416667
0,075	0,8	0,333333	0,475	0,166667	0,888889	0,977778	0,235294118	1	0,228472
0,25	0,3	1	0,5	0,208333	0,888889	0,977778	0,176470588	0,333	0,457292
0,9375	0,1	0,333333	0,475	0,25	0,888889	0,977778	0,176470588	0,333	0,501389
0,3125	0,1	0,333333	0,45	0,208333	0,888889	0,977778	0,176470588	0,333	0,479861
0,4375	0,5	0,666667	0,5	0,25	0,888889	0,977778	0,176470588	1	0,519444
0,625	0,6	0,333333	0,425	0,25	0,888889	0,977778	0,588235294	1	0,916667
0,3125	0,4	0,333333	0,525	0,125	0,888889	0,977778	0,411764706	1	0,307292
0,09375	0,5	0,333333	0,775	0,083333	0,888889	0,977778	0,176470588	0,333	0,260069
0,125	0,5	0,333333	0,425	0,25	0,888889	0,982222	0,294117647	1	0,222917
0,09375	0,5	0,333333	0,425	0,083333	0,888889	0,977778	0,235294118	1	0,254514
0,075	0,8	0,333333	0,525	0,166667	0,888889	0,977778	0,235294118	1	0,219444
0,075	0,8	0,333333	0,5	0,166667	0,888889	0,977778	0,294117647	1	0,197917
0,625	0,8	0,666667	0,575	0,25	0,888889	1	0,588235294	1	0,392361
0,09375	0,5	0,333333	0,75	0,083333	0,888889	0,977778	0,176470588	0,333	0,198611

OEK	Parça Geo.	Pürüz	Asit sıc.	Asit Bekleme	Flaks pH	Zn sıc.	Zn. Bekleme	A s k ı	Kalınlık
0,25	0,3	0,333333	0,475	0,25	0,888889	0,977778	0,294117647	1	0,423611
0,625	0,8	0,666667	0,425	0,25	0,888889	0,995556	0,588235294	1	0,390972
0,1875	0,1	0,333333	0,425	0,333333	0,888889	0,977778	0,941176471	0,333	0,290625
0,075	0,7	0,333333	0,45	0,166667	0,888889	0,977778	0,235294118	1	0,260417
0,075	0,8	0,333333	0,45	0,166667	0,888889	0,977778	0,235294118	1	0,25625
0,1875	0,2	0,666667	0,45	0,208333	0,888889	1	0,294117647	0,333	0,25625
0,125	0,6	0,333333	0,45	0,166667	0,888889	1	0,470588235	0,333	0,218056
0,1875	0,2	0,333333	0,45	0,208333	0,888889	1	0,588235294	1	0,256597
0,125	0,1	0,666667	0,45	0,125	0,888889	0,982222	0,588235294	0,333	0,279514
0,1875	0,1	0,333333	0,45	0,166667	0,888889	0,982222	0,588235294	0,333	0,249306
0,125	0,3	1	0,575	0,333333	0,888889	0,977778	0,235294118	0,333	0,190972
0,09375	0,5	0,333333	0,45	0,208333	0,888889	0,977778	0,176470588	1	0,15625
0,1875	0,2	0,333333	0,5	0,166667	0,888889	0,977778	0,588235294	1	0,290278
0,1875	0,6	0,333333	0,5	0,208333	0,888889	0,977778	0,588235294	0,333	0,361111
0,075	0,1	0,333333	0,5	0,058333	0,888889	0,977778	0,588235294	0,333	0,219444
0,75	0,3	0,666667	0,5	0,166667	0,888889	0,977778	0,588235294	1	0,479167
0,25	0,4	0,333333	0,5	0,208333	0,888889	0,977778	0,588235294	1	0,303472
0,1375	0,2	0,666667	0,5	0,166667	0,888889	0,977778	0,588235294	1	0,21875
0,09375	0,5	0,333333	0,5	0,125	0,888889	0,977778	0,588235294	0,333	0,263889
0,125	0,2	0,333333	0,55	0,125	0,888889	0,977778	0,117647059	1	0,221528
0,4375	0,4	0,333333	0,5	0,208333	0,888889	0,977778	0,294117647	1	0,472222
0,15625	0,4	0,333333	0,5	0,125	0,888889	0,977778	0,117647059	0,333	0,342014
0,125	0,1	0,333333	0,55	0,125	0,888889	0,977778	0,176470588	1	0,240625
0,075	0,3	0,333333	0,475	0,333333	0,888889	0,977778	0,235294118	1	0,381944
0,1875	0,3	0,333333	0,475	0,25	0,888889	0,988889	0,176470588	0,333	0,291667
0,625	0,8	0,333333	0,475	0,25	0,888889	0,988889	0,588235294	1	0,336806
0,075	0,8	0,333333	0,475	0,125	0,888889	0,977778	0,588235294	1	0,229167
0,3125	0,1	1	0,475	0,208333	0,888889	0,977778	0,588235294	0,333	0,305556
0,25	0,5	0,666667	0,475	0,25	0,888889	0,977778	0,588235294	1	0,430556
0,09375	0,1	0,333333	0,475	0,25	0,888889	0,977778	0,235294118	1	0,21875
0,125	0,1	0,333333	0,475	0,208333	0,888889	0,977778	0,470588235	1	0,253472
0,25	0,1	0,666667	0,475	0,125	0,888889	0,977778	0,176470588	0,333	0,510417
0,375	0,2	0,333333	0,475	0,375	0,888889	0,977778	0,411764706	1	0,569444
0,125	0,7	0,666667	0,475	0,208333	0,888889	0,977778	0,588235294	0,333	0,295139
0,15625	0,4	0,333333	0,475	0,208333	0,888889	1	0,588235294	1	0,298611
0,375	0,3	1	0,65	0,25	0,888889	0,977778	0,588235294	1	0,986111
0,125	0,1	0,333333	0,475	0,291667	0,888889	1	0,588235294	1	0,222222
0,3125	0,1	0,666667	0,475	0,208333	0,888889	1	0,294117647	0,333	0,381944
0,5	0,6	0,333333	0,475	0,25	0,888889	0,977778	0,588235294	1	0,315972
0,125	0,4	0,333333	0,5	0,166667	0,777778	0,977778	0,176470588	0,333	0,269792
0,15625	0,5	0,333333	0,475	0,25	0,777778	0,977778	0,411764706	1	0,280208
0,075	0,8	0,333333	0,45	0,166667	0,777778	0,977778	0,235294118	1	0,311806
0,075	0,4	0,333333	0,475	0,25	0,777778	0,988889	0,176470588	1	0,2125
0,375	0,1	0,333333	0,475	0,166667	0,777778	0,988889	0,294117647	0,333	0,416319
0,1875	0,2	0,333333	0,45	0,208333	0,777778	0,986667	0,529411765	0,333	0,284722
0,075	0,5	0,333333	0,45	0,125	0,777778	0,988889	0,117647059	0,333	0,221528
0,075	0,7	0,333333	0,5	0,166667	0,777778	0,977778	0,176470588	1	0,2625
0,25	0,4	1	0,675	0,25	0,777778	0,982222	0,588235294	1	0,704861
0,3125	0,2	0,666667	0,675	0,208333	0,777778	0,982222	0,588235294	0,333	0,310764
0,3125	0,2	0,333333	0,675	0,208333	0,777778	0,982222	0,588235294	0,333	0,284722

OEK	Parça Geo.	Pürüz	Asit sıc.	Asit Bekleme	Flaks pH	Zn sıc.	Zn. Bekleme	A s k ₁	Kalınlık
0,25	0,1	0,333333	0,55	0,208333	0,777778	0,982222	0,588235294	0,333	0,272222
0,375	0,3	0,333333	0,675	0,25	0,777778	0,982222	0,588235294	1	0,730556
0,375	0,1	0,333333	0,55	0,208333	0,777778	0,982222	0,588235294	0,333	0,314236
0,15625	0,2	0,333333	0,7	0,25	0,777778	0,977778	0,588235294	1	0,267708
0,3125	0,2	0,333333	0,7	0,208333	0,777778	0,982222	0,588235294	1	0,3125
0,125	0,2	0,333333	0,7	0,166667	0,777778	0,977778	0,588235294	0,333	0,241319
0,9375	0,1	0,666667	0,7	0,208333	0,777778	0,977778	0,588235294	0,333	0,560069
0,875	0,1	0,333333	0,7	0,25	0,777778	0,982222	0,588235294	0,333	0,542708
0,075	0,5	0,333333	0,625	0,166667	0,777778	0,977778	0,588235294	0,333	0,207292
0,375	0,1	0,666667	0,625	0,25	0,777778	0,988889	0,411764706	0,333	0,323611
0,075	0,7	0,333333	0,7	0,25	0,777778	0,977778	0,235294118	1	0,275694
0,075	0,7	0,333333	0,7	0,25	0,777778	0,977778	0,176470588	1	0,275694
0,1875	0,1	0,333333	0,7	0,208333	0,777778	0,984444	0,411764706	1	0,263542
0,1875	0,4	0,666667	0,625	0,333333	0,777778	0,977778	0,235294118	0,333	0,350694
0,075	0,8	0,333333	0,7	0,208333	0,777778	0,977778	0,235294118	1	0,273611
0,125	0,2	0,333333	0,7	0,166667	0,777778	0,977778	0,352941176	0,333	0,216319
0,075	0,8	0,333333	0,7	0,208333	0,777778	0,977778	0,176470588	1	0,21875
0,075	0,8	0,333333	0,7	0,25	0,777778	0,977778	0,235294118	1	0,21875
0,075	0,7	0,333333	0,7	0,291667	0,777778	0,98	0,235294118	1	0,239931
0,4375	0,2	0,333333	0,725	1	0,777778	0,988889	0,705882353	0,333	0,457986
0,125	0,2	0,333333	0,725	0,166667	0,777778	0,977778	0,294117647	0,333	0,271528
0,625	0,1	0,333333	0,7	0,5	0,777778	0,993333	0,176470588	0,333	0,451389
0,3125	0,4	0,333333	0,7	0,208333	0,777778	0,982222	0,588235294	1	1
0,625	0,3	0,333333	0,725	0,208333	0,777778	0,977778	0,588235294	1	0,878472
0,1875	0,2	0,333333	0,7	0,166667	0,777778	0,977778	0,588235294	0,333	0,402778
0,3125	0,1	0,666667	0,7	0,208333	0,777778	0,977778	0,588235294	0,333	0,46875
0,375	0,3	0,666667	0,7	0,25	0,777778	0,982222	0,588235294	1	0,625
0,15625	0,4	0,333333	0,725	0,166667	0,777778	0,982222	0,411764706	1	0,625
0,25	0,2	0,333333	0,725	0,125	0,777778	0,98	0,235294118	0,333	0,364583
0,15625	0,4	0,333333	0,725	0,166667	0,777778	0,984444	0,470588235	1	0,625
0,5	0,3	0,666667	0,725	0,125	0,777778	0,984444	0,352941176	1	0,861111
0,625	0,2	0,666667	0,575	0,208333	0,777778	0,98	0,470588235	1	0,395833
0,625	0,2	0,666667	0,725	0,166667	0,777778	0,98	0,411764706	1	0,395833
0,15625	0,4	0,333333	0,725	0,208333	0,777778	0,977778	0,411764706	1	0,241319
0,625	0,2	0,666667	0,725	0,166667	0,777778	0,977778	0,470588235	1	0,395833
0,15625	0,4	0,333333	0,475	0,333333	0,777778	0,984444	0,176470588	0,333	0,225694
0,15625	0,4	0,333333	0,725	0,166667	0,777778	0,984444	0,176470588	0,333	0,225694
0,25	0,2	0,333333	0,725	0,125	0,777778	0,977778	0,176470588	0,333	0,364583
0,5	0,3	0,666667	0,725	0,166667	0,777778	0,984444	0,235294118	1	0,861111

ÖZGEÇMİŞ

Tuğçen Hatipođlu, 16.08.1985'de Eskişehir' de doğdu. İlkokulu Denizli'de, orta eğitimini Necatibey İlköğretim Okulunda ve lise eğitimini Kocaeli Anadolu Lisesi'nde tamamladı. 2007 yılında Kocaeli Üniversitesi, Endüstri Mühendisliği Bölümünden mezun oldu. 2007 yılında Kocaeli Üniversitesi Endüstri Mühendisliği bölümünde yüksek lisansa başladı. 2009 Ocak ayından beri Sakarya Üniversitesi Endüstri Mühendisliği bölümünde Araştırma Görevlisi olarak görev yapmaktadır.