

**YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

128568

**YAPAY SİNİR AĞI KULLANILARAK TORNALAMADA
KESİCİ TAKIM AŞINMASI TAHMİNİ**

Makina Mühendisi Ulvi GÜNDÜZÖZ

**T.C. YÜKSEKÖĞRETİM KURULUŞ
DOKÜmantasyon Merkezi**

**F.B.E Makina Mühendisliği Anabilim Dalı İmal Usulleri Programında
Hazırlanan**

YÜKSEK LİSANS TEZİ

Tez Danışmanı

: Prof. Dr. Erhan ALTAN (YTÜ)

Doç. Dr. Mesut Özgürer
Doç. Dr. Hüseyin Şönmez

İSTANBUL, 2002

128568

İÇİNDEKİLER

	Sayfa
SİMGE LİSTESİ	iv
KISALTMA LİSTESİ.....	v
ŞEKİL LİSTESİ	vi
ÇİZELGE LİSTESİ.....	viii
ÖNSÖZ.....	ix
ÖZET.....	x
ABSTRACT	xi
1. GİRİŞ.....	1
2. GENEL OLARAK YAPAY SİNİR AĞLARI.....	3
2.1 Yapay Sinir Ağı Nedir?	3
2.1.1 Beyin, Bilgisayar Karşılaştırması.....	3
2.1.2 Biyolojik Sinir Hücresinin Yapısı	4
2.1.3 Biyolojik Nörondan Yapay Sinir Ağına Geçiş	5
2.2 Yapay Sinir Ağı Uygulamalarının Avantajları.....	6
2.3 Yapay Sinir Hücre Modeli	7
2.4 Transfer (Aktivasyon) Fonksiyonları	8
2.5 Ağ Yapıları	9
2.5.1 Bağlantı Geometrileri	10
2.5.2 Bellek.....	10
2.6 Öğrenme İşlemleri	11
2.6.1 Hata Düzeltme Öğrenme Metodu.....	12
2.6.2 Hebb Öğrenme Metodu	14
2.6.3 Yarışmacı (Competitive) Öğrenme Metodu.....	14
2.6.4 Boltzmann Öğrenme Metodu	15
2.6.5 Öğreticili Öğrenme (Supervised training).....	15
2.6.6 Destekli Öğrenme (Reinforcement Learning)	16
2.6.7 Kendini Düzenlemeyle (Öğreticisiz) Öğrenme (Self Organization Training).....	17
2.7 Çok Katmanlı İdrak (Multi-Layer Perceptrons).....	17
2.7.1 Hatanın Geriye Yayılması ile öğrenme metodu (Error Back-propagation Algorithm)	18
2.7.2 Hatanın Geriye Yayılması Algoritmasının Matematiksel Çıkarımı.....	18
2.7.2.1 Çıkış Katmanına Ait İşlem Elemanın Ağırlık Değişim Formülasyonu	19
2.7.2.2 Gizli Katmana Ait İşlem Elemanın Ağırlık Değişim Formülasyonu	20
2.7.3 Genelleştirilmiş Formülasyon	22
3. TALAŞLI İMALATTA YAPAY SİNİR AĞININ KULANIMI ÜZERİNE GELİŞTİRİLEN BELLİ BAŞLI ÇALIŞMALAR	24
3.1 Yapay Sinir Ağı Yardımıyla Kesme Şartlarının Modellenmesi.....	24

3.2	Yapay Sinir Ağı Yardımıyla Takım Aşınma Takibi	35
3.3	Yapay Sinir Ağı Yardımıyla Kesme Kuvvetinin Tahmini.....	69
3.4	Yapay Sinir Ağı Yardımıyla Yüzey Kalitesi Takibi	74
4.	YAPAY SİNİR AĞIYLA KESİCİ TAKIM AŞINMASI TAHMİN MODELİNİN OLUŞTURULMASI	87
4.1	Aşınma Geometrisi.....	87
4.2	Tornalama Veri Seçimi	88
4.3	Gizli Katman Sayısına göre Uygun Konfigürasyonun Seçimi.....	91
4.4	Ağırlıkların ve Eşik Değerlerin Başlangıç Seçimleri	92
4.5	Momentum ve Öğrenme Hızı Değerlerinin Seçimi	93
4.6	Eğitim Setinin Her Bir Çevrimde Rasgele Sırayla Yapay Sinir Ağına Verilmesi	93
4.7	Normalizasyon Yapay Sinir Ağının Öğrenmesine Etkisi.....	93
4.8	İrdeleme Seti Kullanımı	94
4.9	Farklı Eğitim Seti Kullanımıyla Genellemenin Araştırılması.....	94
5.	SONUÇLAR	95
	KAYNAKLAR.....	101
	ÖZGEÇMİŞ	103

SİMGELİSTESİ

a	Yapay sinir ağı işlem elemanı aktivasyonu
d	Yapay sinir ağı hedeflenen sistem çıkış değeri
Dc	Kesme derinliği
e	Yapay sinir ağı sistem çıkış hatası
E	Yapay sinir ağı sistem çıkış hata kareleri toplamı
f	İlerleme
F	Kesme kuvveti
J	Yapay sinir ağı hata maliyet fonksiyonu
KB	Kesici takım krater aşınması genişliği
KT	Kesici takım krater aşınması derinliği
Ra	Yüzey pürüzlülüğü
S	Kesme hızı
SV	Kesici takım serbest yüzey aşınması eni
u	Yapay sinir ağı giriş verisi
VB	Kesici takım serbest yüzey aşınması yüksekliği
w	Yapay sinir ağı işlem elemanı ağırlığı
x	Yapay sinir ağı işlem elemanı çıkış değeri
y	Yapay sinir ağı sistem çıkış değeri
Δw	Yapay sinir ağı işlem elemanı ağırlık değişimi
α	Yapay sinir ağı öğrenme momentumu
δ	Yapay sinir ağı işlem elemanı lokal gradyanı
ε	Yapay sinir ağı anlık sistem çıkış hata kareleri toplamı
η	Yapay sinir ağı öğrenme hızı
θ	Yapay sinir ağı işlem elemanı eşik değeri

KISALTMA LİSTESİ

AC	Adaptive Control
ACC	Adaptive Control of Constraints
ACO	Adaptive Control with Optimization
ADALINE	Adaptive Lineer Element
ASME	American Society of Mechanical Engineers
BP	Back Propagation
IEEE	Institute of Electrical and Electronics Engineers
LMS	Least Mean Square
MLP	Multi-Layer Perceptrons
MRR	Material Removal Rate
TWR	Tool wear rate
RMS	Root mean square
VLSI	Very Large Scale Integrated circuits
YSA	Yapay Sinir Ağı

ŞEKİL LİSTESİ

Şekil 2.1	Sinir hücresi yapısı.....	4
Şekil 2.2	Yapay nöron modeli.....	7
Şekil 2.3	Transfer (Aktivasyon) fonksiyonları.....	8
Şekil 2.4	Öğrenme işlemlerinin genel sınıflandırılması.....	11
Şekil 2.5	Hata fonksiyonuna göre tanımlanan hata yüzeyi	13
Şekil 3.1	Öğrenme hata değişimi, öğrenim set sayısı=30, ağ yapısı 3-4-4 (Dornfeld, 1989)	28
Şekil 3.2	Ağın öğrenme performansı (Dornfeld, 1989)	29
Şekil 3.3	Giriş parametrelerinin değişimi (Dornfeld, 1989)	31
Şekil 3.4	Çıkış parametrelerinin değişimi (Dornfeld,1989).....	32
Şekil 3.5	Hata değişimi (Dornfeld,1989)	33
Şekil 3.6	Kesme hızını tahmin etmek için oluşturulan (4-10-10-1) yapısındaki yapay sinir ağı (Y.H.Lee vd., 1999).....	34
Şekil 3.7	Sistem kuruluşu (Teshima vd.,1993)	35
Şekil 3.8	Renkli görünüm verisinin oluşturulması (Teshima vd.,1993)	36
Şekil 3.9	Yapay sinir ağının yapısal modeli (Teshima vd.,1993)	37
Şekil 3.10	Öğrenme çevrimi ve hata kareleri toplamı arasındaki ilişki (Teshima vd.,1993)..	39
Şekil 3.11	Yapay sinir ağı ve deney sonuçlarının karşılaştırılması (Teshima vd.,1993)	40
Şekil3.12	Yüksek hız düşük ilerlemeye işleme zamanıyla aşınmanın artışı ve kuvvet bileşenlerindeki değişim (Santanu vd., 1996)	44
Şekil3.13	Yüksek hız düşük ilerlemeye işleme zamanıyla kuvvet oranlarındaki değişim (Santanu vd., 1996).....	45
Şekil 3.14	Eğitimde gizli işlem elemanı sayısının RMS hataya etkisi (Santanu vd., 1996) ...	46
Şekil 3.15	Modellerin değişik uygulamalardaki hata karşılaştırmaları (Santanu vd., 1996) ..	46
Şekil 3.16	Direkt olarak ölçülen aşınma miktarları ve değişik ağ modellerinin tahminleri (Santanu vd., 1996)	47
Şekil 3.17	Değişik ağ modellerinin aşınma tahmin doğruluk dereceleri (Santanu vd., 1996)	48
Şekil 3.18	İş parçası geometrisi (S.C.Lin ve R.J.Lin, 1996)	48
Şekil 3.19	Freze çakı geometrisi, frezeleme işleminin geometrisi ve deney düzeneği (S.C.Lin ve R.J.Lin, 1996)	50
Şekil 3.20	Öğrenim hatasının değişimi, ağ yapısı:6-24-12-1 (S.C.Lin ve R.J.Lin, 1996)	51
Şekil 3.21	Öğrenim hatasının değişimi, ağ yapısı:6-18-9-1 (S.C.Lin ve R.J.Lin, 1996)	51
Şekil 3.22	Öğrenim hatasının değişimi, ağ yapısı:6-12-6-1 (S.C.Lin ve R.J.Lin, 1996)	52
Şekil 3.23	Optik fiberin çalışma prensibi (Choudhury vd., 1999)	54
Şekil 3.24	Zamana bağlı sensor çıkış sinyali (Choudhury vd., 1999).....	55
Şekil 3.25	Yapay sinir ağının öğreniminde hata değişimi (Choudhury vd., 1999).....	56
Şekil 3.26	Eğitim seti için tahmin edilen ve ölçülen aşınma değerlerinin oransal karşılaştırılması (Choudhury vd., 1999).....	56
Şekil 3.27	Test seti için tahmin edilen ve ölçülen aşınma değerlerinin oransal karşılaştırılması (Choudhury vd., 1999).....	57
Şekil 3.28	Tahmin edilen ve ölçülen aşınma değerlerinin grafik karşılaştırması (Choudhury vd., 1999)	57
Şekil 3.29	Bir adım ötesini tahmin eden yapay sinir ağı modeli (J.H. Lee ve S.J. Lee, 1999)	58
Şekil 3.30	Deney düzeneği (J.H. Lee ve S.J. Lee, 1999)	59
Şekil 3.31	Test 1, 5 ve 9 için öğrenme sonuçları (J.H. Lee ve S.J. Lee, 1999).....	60
Şekil 3.32	Test 2 ve 3 için tahmin sonuçları (J.H. Lee ve S.J. Lee, 1999).....	61
Şekil 3.33	Test 4 ve 6 için tahmin sonuçları (J.H. Lee ve S.J. Lee, 1999).....	61
Şekil 3.34	Test 7 ve 8 için tahmin sonuçları (J.H. Lee ve S.J. Lee, 1999).....	62
Şekil 3.35	Genel aşınma tahmin hataları (J.H. Lee ve S.J. Lee, 1999)	62
Şekil 3.36	Yapay sinir ağının eğitim sonuçları (Altıntaş ve Liu, 1999).....	64
Şekil 3.37	Yapay sinir ağının test sonuçları (Altıntaş ve Liu, 1999)	64

Şekil 3.38 Yapay sinir ağının aktif test sonuçları (Altıntaş ve Liu, 1999)	65
Şekil 3.39 Çok eksenli frezelemede dolaylı kesme kuvveti tahmini için tasarlanan yapay sinir ağ konfigürasyonu (Kim vd., 1999)	69
Şekil 3.40 Eğitim sürecinde yapay sinir ağının hata kareleri toplamı değişimi (Kim vd., 1999)	70
Şekil 3.41 Kesme kuvveti y-ekseni bileşeninin tahmininde yapay sinir ağı performansı (Kim vd., 1999)	70
Şekil 3.42 Kesme kuvveti x-ekseni bileşeninin tahmininde yapay sinir ağı performansı (Kim vd., 1999)	70
Şekil 3.43 Farklı kesme koşullarında yapay sinir ağı kesme kuvveti tahmin performansı (Kim vd., 1999)	71
Şekil 3.44 Talaş açısının farklı hızlarda kesme kuvetine etkisi (Raj vd., 2000)	73
Şekil 3.45 Kesme açısının (ϕ) kesme kuvetine etkisi (Raj vd., 2000)	73
Şekil 3.46 Eğim açısının (λ) kesme kuvvet bileşenlerine etkisi (Raj vd., 2000)	74
Şekil 3.47 Takım uç yarıçapının kesme kuvvet bileşenlerine etkisi (Raj vd., 2000)	74
Şekil 3.48 Deney düzeneği (Tsai vd., 1999)	75
Şekil 3.49 Yapay sinir ağının tahmin doğruluğu (Silindir profil verileri) (Suneel ve Pande, 2000).....	80
Şekil 3.50 Silindir tornalamada profil sapma karşılaştırması (Suneel ve Pande, 2000)	81
Şekil 3.51 Yapay sinir ağının tahmin doğruluğu (Eğimli profil verileri) (Suneel ve Pande, 2000)	82
Şekil 3.52 Eğim tornalamada profil sapma karşılaştırması (Suneel ve Pande, 2000).....	82
Şekil 3.53 Yapay sinir ağının tahmin doğruluğu (Konveks kavis profil verileri) (Suneel ve Pande, 2000).....	83
Şekil 3.54 Yapay sinir ağının tahmin doğruluğu (Konkav kavis profil verileri) (Suneel ve Pande, 2000).....	83
Şekil 3.55 Konveks kavis tornalamada profil sapma karşılaştırması (Suneel ve Pande, 2000).....	84
Şekil 3.56 Konkav kavis tornalamada profil sapma karşılaştırması (Suneel ve Pande, 2000).....	84
Şekil 3.57 Yapay sinir ağının tahmin doğruluğu (Birleşik profil verileri) (Suneel ve Pande, 2000).....	85
Şekil 3.58 Birleşik geometri tornalamada profil sapma karşılaştırması (Suneel ve Pande, 2000).....	85
Şekil 4.1 Takım Aşınma Geometrisi	87
Şekil 4.2 Yapay sinir ağ modellemesinde kullanılan genel algoritma	92
Şekil 5.1 Yapay sinir ağlarının çıkış değer karşılaştırmaları	97

ÇİZELGE LİSTESİ

Çizelge 3.1 Ağ optimum giriş değer tahmin performansı (Dornfeld, 1989).....	30
Çizelge 3.2 Ağ ve sensor çıkış değer karşılaştırması (Dornfeld, 1989).....	30
Çizelge 3.3 Yapay sinir ağı için eğitim ve kontrol verileri (Y.H.Lee vd., 1999).....	33
Çizelge 3.4 Yapay sinir ağı test sonuçları (Y.H.Lee vd., 1999).....	34
Çizelge 3.5 Deney kesme şartları ve sonuçları (Teshima vd., 1993)	38
Çizelge 3.6 Sistem çıkış örnekleri (Teshima vd., 1993)	40
Çizelge 3.7 Giriş veri sayısının ağın verimliliğine etkisi (Dornfeld, 1990).....	42
Çizelge 3.8 Gizli katman işlem elemanı sayısının ağın verimliliğine etkisi (Dornfeld, 1990).....	42
Çizelge 3.9 Değişen kesme derinliklerinde ağın performansı (Dornfeld, 1990)	43
Çizelge 3.10 Değişen ilerlemelerde ağın performansı (Dornfeld, 1990)	43
Çizelge 3.11 Değişen kesme hızlarında ağın performansı (Dornfeld, 1990)	43
Çizelge 3.12 Değişik sensor kombinasyonlarında ağın performansı (Dornfeld, 1990)	43
Çizelge 3.13 Deney seviyeleri (Uygulamalar) (Santanu vd., 1996)	44
Çizelge 3.14 Kullanılan yapay sinir ağı modelleri (Santanu vd., 1996)	45
Çizelge 3.15 Ekstra doğrulama testlerinde kullanılan kesme parametreleri (S.C.Lin ve R.J.Lin, 1996)	52
Çizelge 3.16 Ölçülen ve tahmin edilen aşınma değerlerinin karşılaştırılması (S.C.Lin ve R.J.Lin, 1996)	53
Çizelge 3.17 Eğitim setinde kullanılan deney verileri (Choudhury vd., 1999).....	55
Çizelge 3.18 Test setinde kullanılan deney verileri (Choudhury vd., 1999).....	55
Çizelge 3.19 Veri toplamak için kullanılan kesme şartları (Altıntaş ve Liu, 1999).....	63
Çizelge 3.20 Yapay sinir ağıının çapraz tez sonuçları (Dimla ve Lister, 2000).....	66
Çizelge 3.21 Yüzdelik olarak sınıflandırma başarısı (Dimla ve Lister, 2000).....	67
Çizelge 3.22 Verilen kesme hızı, ilerleme ve kesme derinliği, deneylerde bulunan ve yapay sinir aıyla tahmin edilen kesme kuvveti bileşenleri (Raj vd., 2000)	72
Çizelge 3.23 Deney şartları (Tsai vd., 1999).....	76
Çizelge 3.24 Yapay sinir ağı model özeti; değişik yapılar ile eğitim test setindeki ortalama hataları (Tsai vd., 1999)	77
Çizelge 3.25 Yapay sinir ağı ile istatistiksel metod sonuç karşılaştırması (Tsai vd., 1999) ...	78
Çizelge 3.26 Performans testi sonuçları (Tsai vd., 1999)	78
Çizelge 3.27 Parça geometrileri ve işleme koşulları (Suneel ve Pande, 2000).....	79
Çizelge 3.28 Profil sapmalarının karşılaştırılması(Suneel ve Pande, 2000)	86
Çizelge 4.1 Tornalamada toplanan veriler	89
Çizelge 5.1 Tek gizli katmanlı ağ performansları (3000 Set çevrimine göre)	95
Çizelge 5.2 İki gizli katmanlı ağ performansları (2000 Set çevrimine göre)	96
Çizelge 5.3 Yapısı 7-8-1 olan ağında momentum denemeleri ($\eta=0,5$).....	98
Çizelge 5.4 Yapısı 7-8-1 olan ağıda öğrenme hızı denemeleri ($\alpha=0,3$).....	98
Çizelge 5.5 İki katmanlı ağ yapılarında öğrenme hızı denemeleri.....	99
Çizelge 5.6 İki katmanlı ağ yapılarında momentum denemeleri ($\eta=0,5$)	99

ÖNSÖZ

Bu çalışmanın yapılmasında ve tezin hazırlanmasında eşine az rastlanır bir uyum içerisinde çalıştığım danışmanım Sayın Prof. Dr. Erhan Altan Bey'e teşekkür ederim. Ayrıca eğitim hayatım boyunca bana yalnız maddi değil manevi desteklerini de limitsiz sunan aileme ve özellikle annem Gülsen Gündüzöz'e, teknik yardımlarından istifade ettiğim özverili, nadide; arkadaşlarım Elekt.Elektron.Yük.Müh Fatih İsmail Selçuk Bey'e, İnş.Müh. Mehmet Başerdem Bey'e, Mak.Müh. Mesut Özer Bey'e, Murat Başerdem Bey'e, Elekt.Elektron.Müh Oğuzhan Yüçeturk Bey'e, Elekt.Elektron.Yük.Müh Selçuk Özer Bey'e, Mak.Müh. Yunus Lüleci Bey'e teşekkür ederim.

ÖZET

Yapay sinir ağları mühendislik uygulamalarında gittikçe geniş bir kullanım alanı bulmaktadır. Son on senede talaşlı imalatta en önemli, üzerinde en çok çalışılan konulardan biri olan kesici takım aşınma takibinde de yapay sinir ağları kullanılmış ve başarılı sonuçlar elde edilmiştir.

Bu çalışmada da tornalama işleminde verilen proses parametrelerine karşılık kesici takım serbest yüzey aşınmasının tahmini sınıflandırılmasına yönelik C++ programlama dilinde yazılan bir yapay sinir ağ modeli üzerinde çalışılmıştır. Yapay sinir ağına verilen ve istenen giriş-çıkış veri seti Purushothaman, ve Srinivasa'nın 1994 ve 1998 yıllarında üzerinde çalışıkları deney sonuçlarından alınmıştır. Model oluşturulmadan önce geniş kapsamlı bir literatür araştırmasıyla takip edilecek yöntem belirlenmiştir.

Modelde gizli katman ve gizli işlem elemanı sayılarına göre uygun konfigürasyonun belirlenmesinden önce araştırılan ilk konu yapay sinir ağının giriş-çıkış veri değerleri içinden eğitim setinin seçimidir. Yapay sinir ağının işlem elmanları ağırlık ve eşik değerlerinin çevrimler başlamadan optimum rasgele başlangıç seçim aralığı araştırılmıştır. Momentum ve öğrenme hızı değerlerini optimize etmek için seçilen konfigürasyonlar test edilmiştir. Eğitim setinin belli bir sırayla değil her bir çevrimde rasgele bir sırayla yapay sinir ağına verilmesi de denenmiştir. Geometrik ve aritmetik ortalamalara göre farklı iki normalizasyon tekniği test edilmiştir. Performansın artırılıp artırılamadığını görebilmek için irdeleme seti de kullanılmıştır. Son olarak farklı eğitim seti belirlenmesiyle yapay sinir ağının genelleme kabiliyeti araştırılmıştır. C++ programlama dilinde yazılmış denemelerde kullanılan program tez danışmanından ya da çalışmayı hazırlayandan temin edilebilir.

Anahtar Kelimeler: Yapay sinir ağları, kesici takım aşınma tahmini.

ABSTRACT

Artificial neural networks have been used in a wider range of engineering applications year by year. Last decade artificial neural networks have been applied to monitoring cutting tool condition, which is one of most important and much studied subjects in machining, and successful results have been found.

At this study also to estimate classification of cutting tool flank wear against process parameters of turning, an artificial neural network model in C++ programming language was built. Input-output set given to the artificial neural network was taken from the study of Purushothaman, and Srinivasa's experiment results in 1994 and 1998. Before building the model, a comprehensive literature search had been made to select the appropriate method.

The first topic was training set selection from input-output values before choosing appropriate configuration according to the number of hidden layers and hidden process elements. Optimum random initiation range of artificial neural network elements' weight and threshold values was searched. Selected models were tested to optimize learning rate and momentum values. Entering randomly sorted training set to artificial neural network for every training epoch was also tried. Two different normalization technique based upon geometric and arithmetic means were tested. Evaluation set was used to observe whether there was a performance increase. Lastly different training set was chosen to search generalization capability of artificial neural network. C++ program used in trials can be obtained from thesis instructor or student.

Keywords: Artificial neural networks, cutting tool wear estimation.

1. GİRİŞ

Makina imalat sistemlerinde gittikçe artan bir hızda robotlaşmaya ve otomasyona geçilmektedir. Teknoloji gelişikçe üretim hızları artmakta eskiden gerçekleştirilmesi, imal edilmesi tahmin edilemeyecek boyutlarda büyük işler kısa sürelerde bitirilebilmektedir. Temponun bu kadar yükselmesinin sebebi şüphesiz insanların teknolojiyi etkin olarak kullanmalarıyla genişleyen pazar ve artan taleptir. Sonuç olarak arkası gelmeyecekmiş gibi görünen bir performans yarışı içerisinde olduğumuzu söyleyebiliriz. İmalat mühendisliğindeki araştırmalar daima çitäyi biraz daha yukarılara çıkarabilmek üzerine kuruludur.

İmalat sistemlerinde talaşlı imalatin yeri çok büyüktür. Kullandığımız pek çok makina elemanı, otomobillerimizde motor aksamının ve hareketi iletten parçaların neredeyse tamamı ve daha bir sürü ekipman imal aşamalarında talaşlı imalatin az ya da çok kullanılmasıyla üretilmişlerdir. Bu nedenle hedeflenen yüksek performanslı üretim sistemlerinde talaşlı imalatin da gözönünde bulundurulmaması düşünülemez. Talaşlı imalatta üretimi hızlandırma araştırmaları çok boyutlu olarak sürdürülmektedir. Yayınlanan, seneler geçtikçe işleme kapasiteleri artan bilgisayar nümerik kontrollü tezgahlar, eskiden hayal dahi edilemeyen kesme hızlarında çalışan, yüksek sıcaklık ve aşınma dayanımına sahip üstelik daha kaliteli yüzeyleri netice veren yeni kesici takım malzemeleri hep teknik araştırmaların sonucu ortaya çıkmaktadır.

Talaşlı imalatta başdöndürücü aşamalar kaydedilmiş olsa da henüz etkin bir şekilde çözümlenmemiş bir problem vardır; takım aşınma takibi. Kesici takımın yanında müdahale edilebilecek şekilde aşınma durumunun belirlenmesi, olası bir kırılma ile işlenen parçanın zarar görmemesi açısından çok önemlidir. Özellikle uçak sanayii gibi boyut ve yüzey toleranslarının çok dar aralıklarda tutulduğu imalat alanlarında kesici takımın kırılmadan, körelmeden işleyişini sürekli takip etmek gereklidir. Bu gibi sektörlerde kesici takımın kaynaklanabilecek hatalar büyük parça kayıp maliyetlerine neden olabilmektedir. İmalat mühendisleri bu tip durumlarla karşılaşmamak için emniyet faktörünü çok büyük tutarak kesici takım kataloglarındaki ve imalat el kitaplarındaki önerilen optimum kesme şartlarından büyük ödünlere verebilmektedirler. Sonuçta parça zayıf miktarını azaltmak isterken üretim maliyetlerinde imalat zaman kayıplarından kaynaklanan bir yükselme açığa çıkmaktadır.

Kesici takımın karşılayabileceği optimum kesme hızı, kesme derinliği ve ilerleme gibi kesme parametrelerinde kullanılabilmesi için erken bir kırılma, aşınma uyarı sisteminin oluşturulabilmesi ve bu sistemin çok büyük maliyetler yüklemeden, imalatı aksatmayacak az

bir ekipmanla gerçekleştirilebilmesi pratikte henüz ulaşılamamış bir konudur. Şimdiye kadar araştırmacılarca önerilen birçok model ne yazık ki sanayide geniş bir uygulama alanına kavuşamamıştır. Araştırmacıların üzerinde hemfikir oldukları ortak tek konu doğal olarak imalat esnasında sensor verilerinin kullanımıdır. En çok tartışılan husus ise hangi sensorun en etkin bir biçimde takım aşınmasına paralel değerler ürettiği ve sensor verilerinin nasıl bir matematik model üzerinden işlenerek kesin sonuçlara ulaşılabileceğidir. Problemin ana nedeni sensor verileri ile aşınma değerleri arasında doğrusal olmayan bir ilişkinin bulunması ve her kesici takım, iş parçası malzeme değişiminde ilişkinin değişmesidir. Bunu kısaca aradaki etkileşimin kolayca formülize edilememesi olarak görebiliriz.

Yapay sinir ağlarının 1943'ten bu yana geliştirilmesi takım aşınma takibi gibi aralarında birebir doğrusal bir ilişki bulunamayan veri gruplarını barındıran pekçok bilimsel problemden bir umut ışığı olmuştur. Yapay sinir ağlarının kullanımı, isminden de anlaşılabilceği gibi insan ve hayvan sinir sistemlerindeki sinir hücrelerinin birbirleriyle kurdukları ilişkiler ve bilgiyi işleme metodlarına dayandırılmak istenmiştir. Kullandığımız teknolojiyle henüz emekleme aşamasına dahi gelenememiş, normalde hesapları günler alan pek çok kabiliyet için insanda ve hayvanlar aleminde mükemmel örneklerin bulunması etkin bir kontrol sisteminin ve adaptasyonun sinir sistemlerindeki varlığını kanıtlar. İşte yapay sinir ağları bu mükemmelîe ulaşabilmek için doğrusal olmayan, formülize etmekte güçlük çekilen parametre eşleşmelerini veren, öğrenme kapasitesine sahip modeller olarak düşünülmüştür.

Yapay sinir ağlarında özellikle hataya dayalı eğitim algoritmalarından delta kuralının geliştirilmesi ardı ardına pek çok talaşlı imalat uygulamasının da yapılmasını sağlamıştır. Yapay sinir ağlarının temelde çok basit prensiplere dayanması ve pratik yönleri bu çalışmaları kamçılıyan hususlardır. Yapay sinir ağları ile takım aşınma tahmini üzerine yapılan çalışmalar oldukça başarılı bulunmuştur.

2. GENEL OLARAK YAPAY SINİR AĞLARI

2.1 Yapay Sinir Ağı Nedir?

Beynin çalışma prensiplerine benzeyen bilgisayar modellerinin oluşturulması çabaları neticede nöral hesaplama çalışmalarını meydana getirmiştir. Yapay sinir ağı (YSA) insan beynindekine benzer şekilde birçok nöronun ya da yapay olarak basit işlemcilerin birbirlerine değişik etki seviyeleriyle bağlanmasıyla oluşan karmaşık bir sistemdir. Mühendislik uygulamalarında YSA'nın geniş çaplı kullanılmasının en önemli nedeni, klasik tekniklerle çözümü zor problemler için etkin bir alternatif oluşturmasıdır.

Yapay sinir ağları yeni bir bilgi işleme tekniği olarak düşünülebilir. Okuyucunun bilgi seviyesine ve çok kompleks bir matematik yeterlilik gerektirmese de matematik altyapısına göre YSA için bir sürü farklı tanım vardır. Basitçe YSA insan sinir sisteminin bilgisayar modellemesidir.

Genellikle YSA insan beynine benzer bir yapıda olduğu için mekanikten ziyade insansı bir yapı gösterir fakat, YSA teknolojisindeki ana amaç insanların bir benzerini yapmak değil, insan beyninin gerçeklestirebildiği bazı farklı kabiliyetleri bilgisayar sistemleri kullanımıyla taklit etmektir.

2.1.1 Beyin, Bilgisayar Karşılaştırması

Yapay sinir ağları dijital bilgisayarlardan tamamen farklı bir bilgi işleme tekniğine sahip beyinden esinlenerek geliştirilmeye başlamıştır. Silikon mikroçipler beyindeki nöronlardan 5-6 kat daha hızlıdır. Mikroçiplerde işlemler nanosaniyelerde (10^{-9} s) gerçekleşirken nöronlarda ancak milisaniyelerden (10^{-3} s) söz edilir. Beyni oluşturan bu nöronların bu yavaşlıklarına rağmen, çok yüksek sayıarda nörona ve bunlar arasındaki güçlü bağlantılarla sahip olmakla beyin net sonuç olarak kat be kat daha verimli bir yapıdadır.

Beyin çok kompleks, doğrusal olmayan ve paralel bir bilgi işleme sistemidir. Tanıma, algılama ve motor kontrol gibi bazı özel işlemleri gerçeklestirebilmekte nöronlarını kendi kendine organize etme özelliğine sahip olduğu için bu gün en hızlı bilgisayar sistemlerinden bile daha hızlı çalışabilmektedir. Mikroçiplerin, bilgisayar işlemcilerinin ise hiçbir zaman yapılarını adapte etme ve insan gibi öğrenme kabiliyetleri yoktur. Aradaki fark yapısal ve işlevsel değişikliklerden ileri gelmektedir.

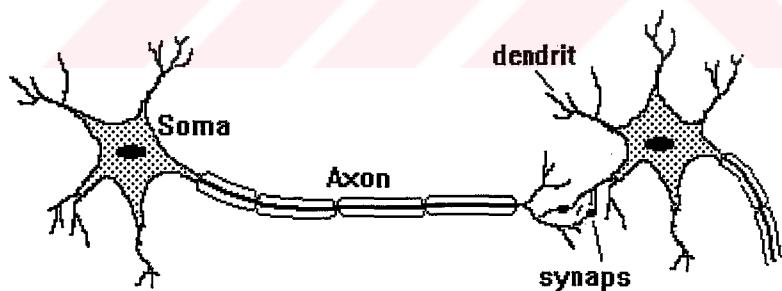
İnsanın görme sistemi, aradaki farkı gösteren en iyi örneklerden biridir. Görme sistemimiz

bize sürekli çevremizin "temsilini" çıkarmakta daha da önemli temas halinde bulunduklarımız hakkında bizi sürekli bilgilendirmektedir. Daha derine inecek olursak beynimiz rutin olarak, alışık olmadığımız bir ortamda alışık olduğumuz yüzleri tanımak gibi algısal tanıma aşamalarını 100-200 milisaniyelerde gerçekleştirip durmaktadır. Kompleksliği bundan çok daha düşük görevler muazzam bilgisayar sistemlerinde günler alabilemektedir.

Bilgisayar-beyin karşılaşmasında aradaki farkın en belirgin olduğu bir başka örnek de yarasanın radar (sonar) sistemidir. Bu sistem uçan sinek gibi bir hedefin ne kadar uzaklıkta bulunduğuunu vermesinin yanında hedefin bağıl hızı, değişik görünümleri, açısı ve yüksekliği bilgilerini de yarasanın kullanımına sunar. Sistemin başarısı büyük radarları ve ses mühendislerini gıpta ettirecek kadar büyüktür.

2.1.2 Biyolojik Sinir Hücresinin Yapısı

Nöron soma adı verilen kabaca küresel bir hücre gövdesi, dentrit adı verilen çalı gibi kıvrımlı uzantılar ve nöronu diğerlerine bağlayan somadan çıkan sinir lifleri ya da diğer adıyla aksonlardan oluşur. Dentritler hücreye gelen girişleri toplarlar. Giriş sinyalleri hücrede toplanarak çıkış darbesi üretilip üretilmeyeceğine karar verilir. Eğer bir aksiyon gerçekleştirilecekse üretilen çıkış darbesi aksonlar tarafından taşınarak diğer nöronlarla olan bağlantılara veya terminal organlara iletilir. (Haykin S. (1994))



Şekil 2.1 Sinir hücresi yapısı

Aksonun sonundaki çıkış düğümleri, sinaps adı verilen ve sinyallerin bir nörondan diğerine iletimini sağlayan özelleşmiş yapılarda konumlanmıştır. Genellikle sinapslar bir nöronun aksonu ile bir diğerinin dentriti arasında yer alır. Nöronlar büyük miktarlardaki giriş verilerini sinaptik bağlantıları üzerinden alır. Gönderilen sinyallerle sinaptik bağlantıdaki elektriksel kutuplaşmanın eşik miktarını geçecek kadar düşmesi sinaps ötesinin ateşlenmesini sağlar. Alınan sinyal miktarı ve hızı toplam kutuplaşma düşüşünün nöronun aksonu boyunca cevap darbesi üretmesi için yeterli olup olmadığını tayin eder.

Genelde sinir sistemindeki sinyal iletiminin topyekun aktif ya da aktif olmama şeklinde dijital bir karakterde olduğu sonucunu çıkarma yanlışına çokça düşülmüştür, fakat aslında nöron sinyalinin yoğunluğu darbe frekanslarıyla kodlanmıştır.

2.1.3 Biyolojik Nörondan Yapay Sinir Ağına Geçiş

Acaba insan ya da yarasa beyni bize çok kompleks gelen işleri nasıl rahatça gerçekleştiriyor? Daha doğuştaki büyük bir yapıya ve bizim "tecrübe" olarak adlandırdığımıza ulaşabilmek için kendi kurallarını oluşturabilme yeteneğine sahiptir. Gerçekten tecrübe, yıllar boyunca kazanılmaktadır ama doğumdan hemen sonraki ilk iki yıl çok kritiktir. Bu erken süreçte beyinde saniyede 1 milyon sinaps kurulur. Nöron gelişimi beynin plastik yapılanması ile eşanlamlıdır; beynin plastiklik özelliği sinir sisteminin çevreye uyumuna imkan verir. Bir çocuk beyninde plastiklik, iki mekanizma ile sağlanır; nöronlar arasında yeni sinaptik bağlantılar kurulması ve halihazırda sinapsların geliştirilmesi.

İnsan beynindeki plastiklik özelliği nöronların bilgi işleme fonksiyonları için gerekli gibi görünmektedir. Genel olarak yapay sinir ağları beynin bilgi işleme tekniğini kullanan bir model olarak tasarlandığı için yapay sinir ağlarında da bu olgunun kullanılması gereklidir. Yapay sinir ağları elektronik elemanların kullanımı ile ya da bilgisayarda oluşturulan yazılımlarla kurulur.

YSA alışılıkla bilgisayar hesaplama uygulamalarından oldukça farklıdır. En başta YSA paralel çalışma prensibinden dolayı, bilgiyi işleme ve çözüm üretme proseslerini aynı anda gerçekleştirir. Bunun yanında YSA'nın istatistiksel olarak uygun örnek giriş seti ve beklenen sonuçlar verildiğinde öğrenme özelliği vardır. YSA öğrenir, fakat bazen yeni ortamlara uyum sağlayabilmek için daha önce öğrendiklerini unutma yeteneğine de sahiptir. Alışılıkla bilgisayar sistemleri ise sadece programlanmış komutları çalıştırırlar.

Yapay sinir ağları doğal meyli tecrübe ile edinilen bilgiyi saklamaya ve kullanıma hazır hale getirmeye dayanan, güçlü paralel dağılmış bir işlemcidir. Beyne iki yönyle benzerlik gösterir;

- Bilgi bir öğrenme sürecinden sonra edinilir.
- Sinirler arasındaki sinaptik ağırlıklar olarak ifade edebileceğimiz bağlantı kuvvetleri bilginin saklanmasında kullanılır.

Pascal gibi alışılıkla yapısal bir programlama dilini kullanarak program yapan bir programcı başlamadan önce giriş verilerini ve gerekli çıkış verilerini üretmemek için bunlarla ne yapılacağını bilir. Bütün yapacağı, giriş ile çıkış verileri arasında kurulacak bağlantıyı

aşama aşama oluşturmaktır. Bilgi tabanlı programlama tekniklerinde giriş ve çıkış verileri arasındaki ilişki belli kurallarla düzenlenmiştir. YSA bu ilişkiye örnek giriş ve çıkış verilerine bakarak kurar. Buna göre talimatların yazılmasına, algoritmanın oluşturulmasına veya kuralların bulunmasına gerek yoktur. Bu şekilde verilerin nasıl işlenebileceğini belirleme yeteneğine kendini düzenleme yeteneğinin aşamaları adaptasyon ve öğrenmedir.

Yapay zeka da (Artificial intelligence) pek çok fantastik yönler barındırsa da şekil tanıma ve eşleştirme gibi proseslerdeki bulanık ve kesin olmayan girişlerde YSA kadar randımanlı çalışmaz.

2.2 Yapay Sinir Ağı Uygulamalarının Avantajları

Şimdiye kadar anlatılanlara göre yapay sinir ağı hesaplama gücünü iki önemli özelliğinden alır; güçlü paralel dağılmış yapısı ve öğrenip, genelleme yapabilme. Genelleme daha önce öğrenme sürecinde karşılaşmayan verilere uygun mantıklı çıkışlar üretebilmek olarak tanımlanabilir. Bu önemli iki özellik sayesindedir ki yapay sinir ağları çözüm üretmekte yönlendirilemeyen kompleks problem uygulamalarında kullanılabilir. (Haykin S. (1994))

Yapay sinir Ağlarının kullanımı şu faydaları ve kabiliyetleri verir;

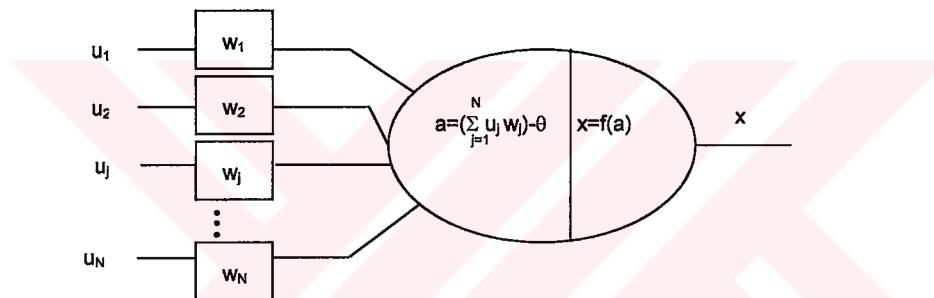
- 1) Doğrusal (Lineer) olmama: Ses verileri gibi doğasında doğrusallık (linearity) olmayan giriş verilerinde bu özellik çok daha önemlidir.
- 2) Giriş-çıkış verilerini eşleştirme: Ağ gösterilen örneklerden giriş-çıkış eşleştirmelerini (haritalandırma) yaparak öğrenir.
- 3) Adapte olabilme: Çevre şartlarındaki değişimlere göre ağ sinaptik ağırlıklarını ayarlayarak adapte olabilme kapasitesine sahiptir. Bu özellikten yeterince yararlanılması için temel zaman aralıklarının çok küçük değişimleri gözardı edecek kadar uzun ve anlamlı çevre değişimlerine tepki verecek kadar da kısa seçilmesi gereklidir.
- 4) Kanıt dayalı çıkış verme: Örnek sınıflandırma konusunda yapay sinir ağı hangi özel örneğin seçileceğini vermesinin yanında, seçimin güvenilirliği hakkında da bilgilendirebilecek şekilde tasarlanabilir.
- 5) Genelden bilgi sağlama: Ağdaki her bir nöron ağını diğer nöronlarındaki genel bir aktiviteden etkilenir.
- 6) Hata toleransı: Yapay sinir ağları, başka hesaplama yöntemleri gibi ufak hatalardan etkilenmemektedir. Hata toleransı fiziksel ve mantıksal olarak fazladır. Alışlageldik bilgisayar hesaplama sistemlerinde donanımın bir bölümünün zarar görmesi bütün sistemin çökmesine neden olabilir. YSA' da ise işlem elemanlarının az da olsa zarar görmesi sistemin bütününe etkiler, performans düşer ama sistem hiçbir zaman durma noktasına gelmez. YSA sistemlerinin hata toleranslı olmasının nedeni bilginin tek bir

yerde saklanmayıp, sisteme dağıtilmasıdır.

- 7) VLSI uygulanabilirlik: Yapay sinir ağları çok büyük ölçekli entegre devreleri (VLSI= Very Large Scale Integrated circuits) uygulamaları yapılabilir.
- 8) Analiz ve tasarım Birliği: Bütün yapay sinir ağları uygulamalarında hep aynı gösterim kullanılır.
- 9) Nörobiyolojik benzerlik: Hızlı, güçlü, hata toleranslı, paralel bir bilgi işleme birimi olarak beyin yapay sinir ağlarının tasarımını motive eden fiziksel bir kanıttır.

2.3 Yapay Sinir Hücre Modeli

Bir nörondan diğerine sinapslardan sinyal gönderimi sinyali alan hücre gövdesinin elektrik potansiyelinin yükseltilmesi ya da düşürülmesi yoluyla olur. Eğer bu potansiyel eşik değere ulaşırsa nöron ateşlenir. McCulloch ve Pitts tarafından 1943'te önerilen yapay nöron modelinin dayandığı esas da bu özelliktir.



Şekil 2.2 Yapay nöron modeli

Şekil 2.2'de verilen yapay nöron modelinin u_1, u_2, \dots, u_N ile belirtilen N tane giriş verisi vardır. Giriş verisini iletten her bir çizgi verileri sırasıyla w_1, w_2, \dots, w_N ağırlıklarına bağlar. Modeldeki ağırlıklar biyolojik nörondaki sinaptik bağlantılarla karşılık gelir. Yapay nörondaki eşik değeri θ (bias) ile gösterilir. Formüldeki aktivasyon şöyle gösterilir;

$$a = \left(\sum_{j=1}^N u_j w_j \right) + \theta \quad (2.1)$$

Eşik değeri sanal bir giriş değeri olarak gösterilip $u_0 = +1$ ve $w_0 = \theta$ olarak tanımlanırsa aktivasyon formülü;

$$a = \sum_{j=0}^N u_j w_j \text{ olur.} \quad (2.2)$$

Nöronun çıkış değeri, biyolojik nöronun ateşleme frekansına benzer şekilde bir aktivasyon fonksiyonudur;

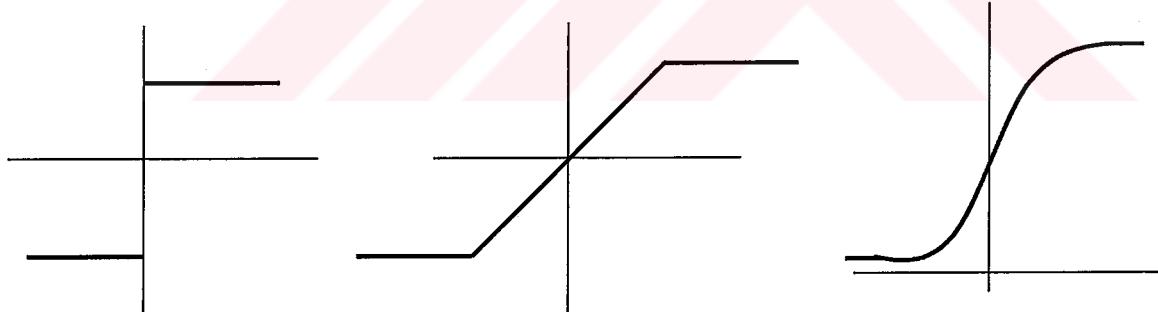
$$x=f(a) \quad (2.3)$$

Eşik birimi nöron modeli, girişleri toplayan ve sadece girişin toplamı iç eşik değerini aştığında bir çıkış üreten işlem elemanıdır. Bir eşik birimi sinapslerdeki sinyalleri alır. Bazı sinyaller diğerlerinden daha kuvvetlidir, çünkü ağırlıkları diğerlerinininkinden daha büyütür. Eğer toplam sinyal gücü eşik değeri geçecek kadar büyükse, diğer nöronları ve dentritleri uyarın akson boyunca bir sinyal gönderir aksi takdirde YSA işlem elemanı çıkış vermez. YSA bu basit ünitelerin birbirlerine bağlanarak bir ağa dönüştürülmesi ile meydana getirilir.

2.4 Transfer (Aktivasyon) Fonksiyonları

Transfer (aktivasyon) fonksiyonları, muhtemel sonsuz alan girişli işlem elemanlarını önceden belirlenmiş sınırla çıkış olarak düzenler. Dört tane yaygın transfer fonksiyonu vardır. Bunlar, basamak, rampa, doğrusal ve sigmoid fonksiyonlardır. Kendisinin ve türevinin sürekli olması nedeniyle kullanılmaya en elverişli doğrusal olmayan transfer fonksiyonu sigmoid fonksiyondur;

$$f(a) = 1/(1+e^{-a}) \quad (2.4)$$



Şekil 2.3 Transfer (Aktivasyon) fonksiyonları (Soldan sağa basmak, rampa, sigmoid)

Transfer fonksiyonu herhangi bir anda çıkış ile giriş arasındaki ilişkiyi belirler. Kendi ağırlıklarıyla çarpılıp toplamları alınan girişleri işlem elemanı transfer fonksiyonu ile çıkışa dönüştürür. Transfer fonksiyonunun ana görevi girişlerin alan sınırlandırmasını yapmaktadır. Eğer girişlerin derecelendirilmesi uygun sınırlarda yapılrsa çıkışlar da ayırdedilebilir anlamda üretilirler. Aksi takdirde çıkışlar ya tepe noktalarda birikme yapar ve küçük değişimlere konsantre olunduğundan genel eğilim anlaşılması zor, ya da tam tersi şekilde genel çıkış eğilimini görebilmek için sınırlar yetmeyebilir. (Haykin S. (1994))

Hesaplamalara başlamadan önceki ağırlıklar seçilen algoritmaya göre gelişigüzel belirlenir. Öğrenme algoritması daha sonra bu ağırlıkların değiştirilmesini sağlayacaktır. Farklı öğrenme algoritmalarının farklı hedefleri vardır. Ağırlıklar ayrı sınıfların benzer giriş örneklerine göre kümelenmek için değiştirilebilirler.

2.5 Ağ Yapıları

Bazen sadece bir tane yapay nöron bazı mantık fonksiyonlarının (boolean functions) üstesinden gelemez. Böyle problemlerin halledilebilmesi için bazı nöronların çıkış verileri diğerlerinin giriş verisi olarak kullanılır. Bu şekilde birbirine bağlanan nöronlarla bir ağ oluşturulur.

Her işlem elemanı istenildiği sayıda giriş bağlantısı ve tek bir çıkış bağlantısı alabilir. Bu tek çıkış bağlantısı kopyalanarak birçok diğer elemana dağıtılabılır. İşlem elemanları yerel (lokal) bellek taşıyabilirler. Her işlem elemanın bir transfer fonksiyonu vardır. YSA bir takım alt kümelere ayrılabilir. Bu alt kümelerdeki elemanların transfer fonksiyonları aynıdır. Bu küçük grulplara katman (layer) adı verilir. Ağ, katmanların hiyerarşik bir biçimde bağlanmasıından oluşmuştur. Transfer fonksiyonu ve yerel bellek elemanı, bir öğrenme kuralıyla giriş-çıkış sinyali arasındaki bağıntıya göre ayarlanır.

Yapay sinir Ağını eğitmede kullanılan öğrenme algoritmaları ile ağ yapısı arasında çok yakın bir ilişki vardır. Bu nedenle yapay sinir ağının tasarımda kullanılan algoritmadan önce ağın yapısı belirtilir.

Üç çeşit temel ağ vardır:

- 1) Tek katmanlı ileri beslemeli ağ: Katmanlanmış ağın en basit olarıdır. Giriş katmanı olarak sadece tersine olmamak koşulu ile çıkış katmanına yönelen kaynak noktaları vardır.
- 2) Çok katmanlı ileri beslemeli ağ (feedforward): Eğer herhangi bir işlem elemanın çıkışı aynı katmandaki veya önceki katmanlardaki bir başka işlem elemanın giriş olmuyorsa YSA, İleri beslemeli ağ (feedforward network) olarak tanımlanır. Her bir katmandaki hücreler sadece bir önceki katmanın hücreleriyle beslenirler. Direkt olarak giriş sinyallerini alan katmana giriş katmanı, YSA'nın çıkışını üreten katmana da çıkış katmanı denir. Bu iki katman arasında kalan katmanlara gizli katmanlar adı verilir. Çok katmanlı ileri beslemeli Ağ bir ya da daha fazla gizli katmana sahiptir. Gizli katman sayısının artırılması yüksek dereceden istatistik bilginin açılımına imkan verir. Eğer her bir katmandaki bütün işlem elemanları bir sonraki katmanın bütün işlem elemanlarına bağlılığı ise ağ tümüyle bağlı denir.
- 3) Kaskat (Yinelenen) bağlılı ağ : İleri beslemeli ağdan en az bir adet geri besleme bağlantısı içermesi yönüyle ayrılır. Örnek olarak bir kaskat bağlılı ağ, her bir işlem elemanı diğer işlem elemanlarının giriş verisi olacak şekilde geri besleme yapan tek

katmanlı bir ağ olabilir.

2.5.1 Bağlantı Geometrileri

Yapay sinir ağlarında öğrenme işlemi, ağırlık uzayındaki, işlem elemanlarının ağırlıkları değiştirilerek sağlanır.

1'den N'e kadar elemanı bulunan bir işlem elemanları kümesinin bağlantıları NxN boyutlu bir matris biçiminde gösterilebilir. Buna göre i.nöronun aktivasyonu;

$$a_j = \left(\sum_{j=1}^N w_{ji} x_i \right) + \theta_j \text{ olur.} \quad (2.5)$$

Burada i işlem elemanından j işlem elemanına giden sinyalin sinaptik ağırlığı w_{ji} i . nöronundan j . nörona x_j çıkışının ağırlığıdır.

Burada x_j her bir nöronun çıkışı olarak tanımlanır;

$$x_j = f_j(a_j) \quad (2.6)$$

Vektörel (Matris) gösterimle;

$$X = F(W^T X + \theta) \text{ olarak gösterilir.} \quad (2.7)$$

T Ağırlık matrisinin devrik olduğunu göstermektedir. Ağırlık matrisinin diagonal verileri sıfırdır, çünkü bir nöron kendi kendini besleyemez. Eğer ağırlık matrisinde diagonun altındaki rakamlar sıfırsa ağ ileri beslemeli bir ağdır.

En fazla N^2 sayıda bağıntı olabilir. Bağlantılar çeşitli geometrik bölgeler arasında demetler halinde düşünülebilir. Bu bağlantı demetlerinin uyması gereken kurallar şunlardır;

- 1) Bağlantı demetini oluşturan işlem elemanları aynı bölgeden çıkmalıdır.
- 2) Bağlantı demetinin sinyalleri aynı matematiksel tipten olmalıdır.
- 3) Bağlantı demetinin sinyalleri aynı sınıftan olmalıdır.
- 4) Bağlantı demetinin bir seçim fonksiyonu olmalıdır. Şöyle ki;

$$T \rightarrow 2^S$$

T : Hedef bölgesi

S : Kaynak bölgesi

2.5.2 Bellek

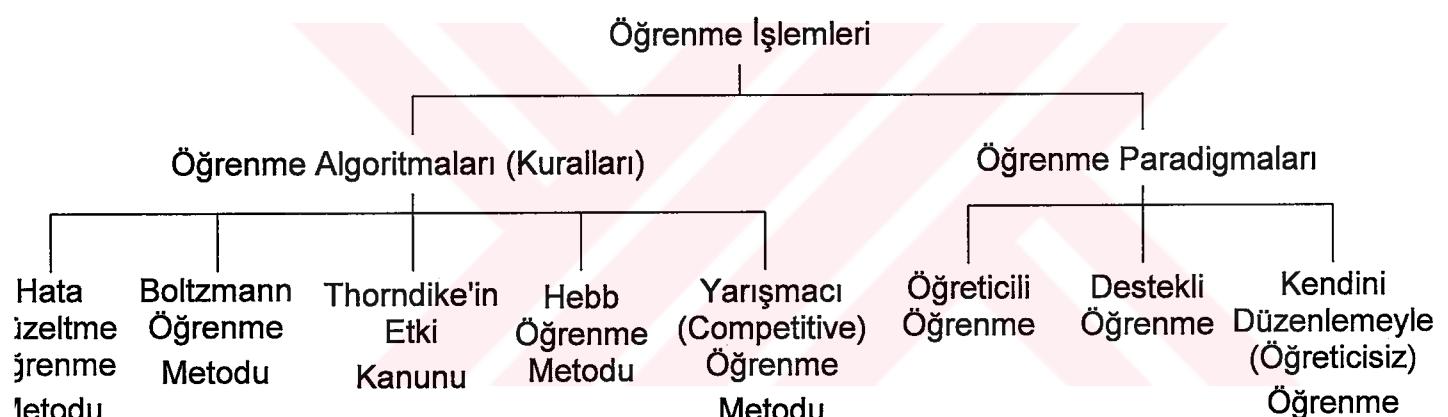
Bağlantı ağırlıkları YSA bellek biçimleridir. YSA belleğinin yapısı; eksik gürültülü ve tam seçilemeyen bir giriş uygulandığı zaman bile mantıklı çıkış üretmeye uygundur. (Genelleme)

Alışlageldik bilgisayar hesaplama sistemlerinde bilgi özel bellek kısımlarında saklanır ve bilgi ile saklandığı adres arasında herhangi bir ilişki yoktur. YSA' da ise bilgi YSA' nın bütününe dağıtılmıştır.

YSA' daki bellek aynı zamanda birleştirilmiştir. Bunu insan öğrenmesinin matematiksel modellemesi olarak tanımlayabiliriz. İnsan beyninin direkt adresleme yapmaktadır, bilgi haritalarının çıkarmak, bilgiyi giriş uyarıları ile karşılaştırmak ve hafızanın içeriğine yerleştirmek kabiliyetleri vardır. Öğretmenlerin öğrencilerinin okunamayan el yazlarını kolayca okumaları bu durumu gösteren bir örnektir. Birleştirilmiş hafızanın iki önemli avantajı vardır;

- Çok büyük miktarlarda kompleks örnekleri saklayabilir.
- Saklanmış örnekleri baz alarak yeni örnekleri sınıflayabilir.

2.6 Öğrenme İşlemleri



Şekil 2.4 Öğrenme işlemlerinin genel sınıflandırılması

Yapay sinir ağının pek çok ilginç özelliğinin yanında ona birincil derecede önemini veren yönü ağır çevresinden öğrenme kabiliyeti ve öğrenerek performansını geliştirmesidir. Bilgilerin belirli kurallarla birbirlerine bağlılığı klasik hesaplama sistemlerinin tersine, YSA kendisine gösterilen örnekten öğrenerek, kendi kurallarını oluşturabilmektedir. Yapay sinir ağı deneme yanlışları ile sinaptik ağırlıklarda ve eşik değerlerinde bir takım ayarlamalar yaparak öğrenir. (Haykin S. (1994))

Yapay Sinir Ağında öğrenmeyi şöyle tanımlayabiliriz:

Öğrenme, Yapay Sinir Ağının içine yerleştirildiği ortamdan aldığı sürekli uyarılar neticesinde serbest parametrelerini adapte ettiği bir prosesidir. Öğrenmenin tipi parametrelerin değiştiriliş

şekline göre belirlenir.

Öğrenme algoritması, öğrenme probleminin çözümüne yönelik önceden belirlenmiş kurallar bütünüdür. Temelde öğrenme algoritmaları Δw_{kj} sinaptik ağırlık değişiminin formüle ediliş farklılıklarıyla birbirlerinden ayırlırlar. Göz önüne alınacak diğer bir faktör ise yapay sinir ağının (öğrenme makinesi) çevresiyle etkileşim yoludur. Bu son hususta yapay sinir ağının işlediği çevre modelini bize belirten "Öğrenme Paradigmasından" bahsedebiliriz.

Bugün bir sürü öğrenme metodu bulunmasına rağmen bunların pek çoğu en eski, en çok bilinen Hebb öğrenme metoduna dayanır. İki tip araştırma sürdürmektedir; bazı araştırmacılar biyolojik öğrenmenin modellenmesi üzerine çalışmaktadır, diğer bir kısmı ise kendi doğanın öğrenme tekniği anlayışlarına göre bazı adaptasyonları uygulamaya çalışmaktadır. Öğrenmenin oldukça kompleks bir olgu olduğu ve öğrenme konusunda henüz bir çok bilinmeyenin bulunduğu bir gerçekdir. Öğrenme işlemlerinin sınıflandırılması Şekil 2.4'de gösterilmiştir. Bütün öğrenme metotları bu sınıflandırmadaki ana metotların farklı yaklaşımlarından türemişlerdir.

2.6.1 Hata Düzeltme Öğrenme Metodu

Bu çokça kullanılan öğrenme metoduna göre bağlantılar arasındaki güç ağırlıkları, istenen ve üretilen çıkış verileri arasındaki minimuma indirilmesi gereken fark (delta) kadar ayarlanır. Bu metod Widrow ve Hoff'un kendi ADALINE (Adaptive Lineer Element) modellerinde kullandıkları için Widrow-Hoff metodu olarak, ya da ortalama hata karesi minimuma indirilmeye çalışıldığı için en düşük ortalama hata karesi anlamında Least Mean Square (LMS) öğrenme metodu olarak da isimlendirilmektedir.

Gradyan iniş kuralı (Gradient descent rule) delta öğrenme metodunda kullanılır. Bu kuralda hatanın minimize edilmesi için ağırlıklar hata fonksiyonunun ağırlıklara göre türevleri oranında değiştirilirler. Bu kuralın dezavantajı kararlı noktaya çok geç ulaşılabilmesidir.

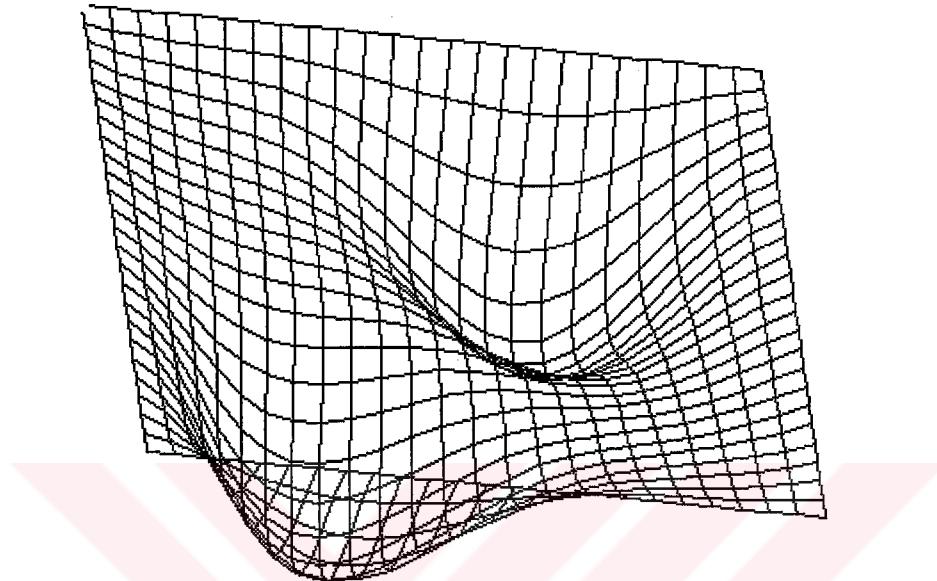
n anında k nöronundan istenen ya da hedeflenen sistem cevabı $d_k(n)$ ve bu nöronundan gerçekte elde edilen sistem cevabı $y_k(n)$ olduğunu düşünelim. Buna göre hata sinyalini hedeflenen sistem cevabı $d_k(n)$ ve gerçekte ortaya çıkan $y_k(n)$ arasındaki fark olarak düşünebiliriz;

$$e_k(n) = d_k(n) - y_k(n) \quad (2.8)$$

Hata düzeltme öğrenme metodunun en büyük amacı hata sinyaline ($e_k(n)$) dayalı maliyet fonksiyonunu minimize etmektir. Maliyet fonksiyonu için genelde kullanılan kriter hata

kareleri toplamının ortalaması anlamına gelen ortalama hata karesi kriteridir;

$$J = E \left(\frac{1}{2} \sum_k e_k^2(n) \right) \quad (2.9)$$



Şekil 2.5 Hata fonksiyonuna göre tanımlanan hata yüzeyi

Burada E istatistiksel bekleni faktörür. J maliyet fonksiyonunun ağ parametrelerine göre minimize edilmesine Gradyan iniş metodu (Gradient descent rule) denir. fonksiyonun istatistiksel yönünden kaynaklanan hesaplama zorluklarını aşabilmek için anlık hata kareleri toplamı değeri şu şekilde tanımlanır;

$$\epsilon(n) = \frac{1}{2} \sum_k e_k^2(n) \quad (2.10)$$

Buna göre hata düzeltme kuralında (delta kuralı.) w_{kj} 'de n anında yapılan $\Delta w_{kj}(n)$ ağırlık ayarlaması şu şekilde verilir;

$$\Delta w_{kj} = \eta e_k(n) x_j(n) \quad (2.11)$$

Burada η öğrenme hızını belirten pozitif bir sabittir. Eğer η küçük alınırsa öğrenme işlemi çok hassas devam edecek fakat çok uzun zaman alacaktır. η büyük alınırsa da öğrenme hızı artacaktır, fakat öğrenme işleminin hedeften sapması ve buna bağlı olarak sistemin düzensiz hale gelmesi tehlikesi vardır. Bu nedenlerle η değerinin seçimi önemlidir.

2.6.2 Hebb Öğrenme Metodu

Nöropsikolojist Donald Hebb 1949 yılında "The organization of behaviour (Davranış organizasyonu)" isimli kitabında bu kuralı tanıtmıştır. En eski ve en çok tanınan bu kurala göre eğer bir işlem elemanı başka bir işlem elemanından giriş sinyali alıyorsa ve ikisi de oldukça aktiflerse bu işlem elemanları arasındaki ağırlık güçlendirilmelidir.

Tam tanım şu şekildedir;

A hücresinin aksonu B hücresini uyaracak kadar yakınındaysa ve sürekli, ısrarlı bir şekilde bu hücrenin ateşlemesinde pay alıyorsa, A'ın B'yi ateşlemedeki verimliliğinin yükselmesini sağlayacak şekilde bu hücrelerden birinde ya da ikisinde de bir büyümeye işlemi veya metabolizmaya ait bir değişim oluşur.

Yapay sinir ağına uyarlanmış şekliyle bu tanım iki maddeli bir kural şecline dönüşür;

- 1) Eğer sinaptik bir bağlantının iki tarafında yer alan iki işlem elemanı aynı anda aktive oluyorlarsa bu sinapsın gücü seçicili bir şekilde artar.
- 2) Eğer sinaptik bir bağlantının iki tarafında yer alan iki işlem elemanı farklı zamanlarda aktive oluyorlarsa bu sinapsın gücü seçicili bir şekilde azalır ya da iptal edilir.

Matematiksel olarak Hebb Öğrenme Metodu şu şekilde modellenir;

$$\Delta w_{kj}(n) = F(y_k(n), x_j(n)) \quad (2.12)$$

Burada Δw_{kj} ağırlık değişiminin sinaps öncesi (x_j) ve sinaps sonrası (y_k) sinyal aktivitelerinin bir fonksiyonu ($F()$) olduğu gösterilmiştir.

2.6.3 Yarışmacı (Competitive) Öğrenme Metodu

Yarışmacı öğrenme metodunda isminden de anlaşılabileceği gibi çıkış işlem elemanları aktif (tetiklenmiş) işlem elemanı olabilmek için kendi aralarında yarışırlar ve en uygun çıkış verisini üreten kazanan olur. Her bir anda sadece bir işlem elemanı aktif olabilir. Öğreticisiz bir öğrenme metodudur. Bu işlem elemanın komşu işlem elemanlarını canlandırma, rakip işlem elemanlarını da engelleme yeteneği vardır. Gerçekten, kazanan işlem elemanı giriş veri örneğine en uyumlu olandır. Sadece kazanan çıkış verisi üretebilir ve sadece kazanan ve komşuları ağırlıklarını ayarlama hakkına sahiptirler. Bu arada komşuların sayıları eğitim periyodu sırasında değişebilir. Genellikle başta komşu işlem elemanı miktarı yüksek verilmişken bu zamanla azalır.

Yarışmacı Öğrenme metodunun üç ana unsuru vardır;

- 1) Sadece rastlantısal ağırlık dağılımları yönüyle farklı olan ve buna bağlı verilen sistem girişlerine farklı çıkışlar üreten bir işlem elemanları seti
- 2) Her bir işlem elemanın gücüne konulan bir limit
- 3) İşlem elemanlarının bir kısım giriş verisine doğru sistem cevabını verebilmek için birbirleriyle yarışmalarına imkan tanıyacak bir mekanizma. Bu mekanizmaya göre kazanan tümünü alır prensibiyle herhangi bir anda sadece bir işlem elemanı aktif olmalıdır.

2.6.4 Boltzmann Öğrenme Metodu

L. Boltzmann'in anısına bu şekilde isimlendirilen bu metod termodinamik ve bilgi-teorik konularından çıkarılmıştır. Bir Boltzmann makinesinde ağ yinelenen (kaskat) bir yapıya sahip olup, +1 ile gösterilen açık (on) konumunda ya da -1 ile gösterilen kapalı (off) konumunda ikili (binary) sistemde çalışan işlem elemanlarına sahiptir. Bu makine Enerji fonksiyonu (E) ile tanımlanır:

$$E = -\frac{1}{2} \sum_{i,j} w_{ji} s_j s_i \quad (2.13)$$

$i \neq j$

burada s_i i işlem elemanın halini, w_{ji} ise i işlem elemanından j işlem elemanına bağlanan sinaptik ağırlığı göstermektedir. Makine bazı öğrenme aşamalarında j gibi rasgele bir işlem elemanın seçimi ve bu j işlem elemanın T sıcaklığında s_j halinden $-s_j$ haline hareket etmesi olasılılığı ile işler:

$$\Delta w(s_j \rightarrow -s_j) = 1/(1+\exp(\Delta E_j/T)) \quad (2.14)$$

Burada ΔE_j hareketten kaynaklanan makinenin enerji fonksiyonundaki değişimdir. T gerçek fiziksel sıcaklığı değil sözde sıcaklığı ifade eder. Bu kural sürekli olarak uygulanırsa makine termal dengeye kavuşur. Bu termal denge durumunda hesaplanan korelasyonlardan Δw_{ji} bulunur.

2.6.5 Öğreticili Öğrenme (Supervised training)

Öğreticili ya da aktif öğrenmede gereklili olan dışarıdan bir öğreticinin bulunmasıdır. YSA'ının eğitilmesi için ağırlıklar sabitleninceye kadar çeşitli giriş verileriyle her birine ait istenilen çıkış veri seti yani öğreticide bulunan çevre bilgisi mümkün mertebe eksiksiz yapay sinir ağına aktarılmalıdır. Aksi takdirde YSA eğitilmediği için kullanıma hazır değildir. Ağırlıkların

sabitlendiği duruma ulaşıldığında öğretici ağdan ayrılır ve bundan sonra ağ öğreticisiz şekilde çevresiyle etkileşimde bulunur. Bu tekniğe göre eğitilen YSA karar verme, bilgiyi ezberleme vs. gibi işlerde kullanılabilir.

Öğrenme, ağırlıkların değiştirilerek bir sonraki deneme-yanılma çevrimlerinde üretilen ve istenilen çıkış verileri arasındaki karşılaştırmalarla sağlanır. Genellikle öğrenme prosedürünün amacı istenilen ve üretilen çıkış arasındaki hata farkını en aza indirmektir.

Sistemin performans ölçüsü olarak beklenen ortalama hata kareleri toplamı serbest parametrelerin bir fonksiyonu olarak tanımlanır. Bu fonksiyon, koordinatları serbest parametreler olan ve Şekil 2.5'de gösterilen çok boyutlu hata-performans yüzeyi ya da basitçe hata yüzeyi ile somut olarak canlandırılabilir. Gerçek hata yüzeyi bütün mümkün giriş-çıkış örneklerinin ortalama yüzeyidir. Öğreticinin nezaretinde sisteme verilen herhangi bir operasyon hata yüzeyinde bir nokta olarak gösterilir. Sistem performansının geliştirilmesi ve buna bağlı olarak öğrenmenin gerçekleşebilmesi için operasyon noktası lokal ya da global minimum hata noktasına doğru aşağı yönlendirilmelidir. Hata yüzeyindeki herhangi bir noktanın gradyanı en dik inişi gösteren bir vektördür. (Gradient steepest descent rule)

Öğreticili öğrenmenin örnekleri her yerde görülen en az ortalama kare (LMS : Least Mean Square) algoritması ve bunun genelleştirilmiş hali olan geriye yayınım (BP:Back Propagation) algoritmasıdır. Birincisi tek işlem elemanlı YSA'da uygulanmasına karşın ikincisi çok katmanlı aralarında bağlı çok işlem elemanlı YSA'da uygulanır.

Öğreticili öğrenmenin tek dezavantajı ağır eğitimde kullanılan giriş-çıkış setinin içermediği özel durumlar için öğreticisiz yeni stratejileri geliştirememesidir.

2.6.6 Destekli Öğrenme (Reinforcement Learning)

Bu tip eğitim metodunda performans sistemin dışından değil içinden notlandırılır. Dışarıdan bir öğretici müdahale etmeden giriş verilerinin genel eğilimi ve düzenliliğine göre ayarlamalar yapılır. YSA'ının tek gereksinimi kendini nasıl düzenleyeceğini bilgisidir. Çevreden destek olarak alınan sadece bir parça bilgidir, öğrenme sistemi bazı uygun noktalardaki bilgiyi edinebilmek için değişimlerde bulunup sonuçlarını gözlemlemelidir.

Destekli öğrenme on-line giriş-çıkış haritalamasının, deneme yanılmaya skaler performans indeksi anlamındaki destek sinyalinin maksimize edilmesi yoluyla yapılmalıdır. Thorndike'in

klasik etki kanunu (Thorndike, 1911) şu şekildedir;

Eşit şartlar altında aynı ortamı ortaya çıkan bir sürü tepki içerisinde, hayvanın isteklerine eşlik eden ya da yakından takip eden tepki aynı ortam yeniden oluştuğunda çok büyük ihtimalle meydana gelecek şekilde ortamla doğrudan ilişkilenir; hayvana rahatsızlık veren tepkinin ise ortam yeniden oluştuğunda çok düşük ihtimalle meydana gelecek şekilde ortamla ilişkisi zayıflar. Tatmin yükseldikçe ilişkinin sağlamlığı, rahatsızlık yükseldikçe de ilişkinin zayıflığı artar.

Bu kanunu Y.S.A'da destekli öğrenme olarak yeniden tanımlayıp önermemiz gerekirse;

Eğer öğrenme sistemi tarafından gerçekleştirilen bir işlemi tatmin edici bir oluşum hali takip ediyorsa sistemin eğilimi bu özel işlemin üretimini kuvvetlendirmek yönündedir. Buna karşılık tersi bir durumda sistemin eğilimi bu özel işlemin üretimini zayıflatmak yönündedir.

Öğreticili öğrenme sisteminde performans ölçüsü ortalama hata karesi gibi bilinen bir hata kriterine göre hedeflenen giriş-çıkış seti tarafından tanımlanır. Bu nedenle bu sistem bilgilendirici bir geri beslemeli sistem olarak tanımlanabilir. Buna karşın destekli öğrenme sisteminde ise geliştirme performansı ve buna bağlı olarak öğrenme, sisteme değer girişiabilen herhangi bir ölçüye dayandırılabilir. Bu yönyle destekli öğrenme irdeleyici, değer biçici bir geri beslemeli sistem olarak düşünülebilir.

2.6.7 Kendini Düzenlemeyle (Öğretcisiz) Öğrenme (Self Organization Training).

Öğretcisiz öğrenmede ya da kendini düzenlemeyle öğrenmede sistemi takip etmek için dışarıdan bir öğretici ya da bir kritik yoktur. Başka bir deyişle ağ tarafından öğrenilmesi gereken fonksyonun özel örnekleri yoktur. Bunun yerine ağın öğrenmesi gerekenin gösteriminde aşamasız bir kalite ölçüsüyle sağlaması yapılır ve serbest parametreler bu ölçüye göre optimize edilir. Öğretcisiz öğrenmeyi gerçekleştirebilmek için yarışmacı (competitive) öğrenme algoritmasına ihtiyaç vardır.

2.7 Çok Katmanlı İdrak (Multi-Layer Perceptrons)

Çok katmanlı ileri beslemeli bir ağda bir takım duyumsal noktalardan oluşan giriş katmanı, işlem elemanlarından oluşan bir ya da daha fazla gizli katman ve gene işlem elemanlarından oluşan bir çıkış katmanı bulunur. Giriş sinyali, katmandan katmana ileri doğru yayılır. Bu yapay sinir ağlarına çok katmanlı idrak de (MLPs = Multi-Layer Perceptrons) denir.

Çok katmanlı idrakin üç ayırt edici özelliği vardır;

- 1) Her bir işlem elemanı modeli doğrusal olmayan (nonlinear) çıkışta etkilidir. Doğrusal olmama her noktada türevlenebilme açısından önemlidir. Doğrusal olmama gerekliliğini sağlayan en sık kullanım, lojistik fonksiyon tarafından oluşturulan sigmoidal doğrusal olmama durumudur;

$$y_j = 1/(1+\exp(-a_j)) \quad (2.15)$$

- 2) Gizli katmanlardaki işlem elemanları giriş örneklerinin anlamlı belirleyici niteliklerinin daha çok ortaya çıkmasını sağlayarak kompleks aşamaların öğrenilmesini sağlarlar.
- 3) Ağ sinapslarla belirlenen yüksek dereceden bir bağlantılılık gösterir.

2.7.1 Hatanın Geriye Yayılması ile öğrenme metodu (Error Back-propagation Algorithm)

Çok katmanlı idrakte hatanın geriye yayılması olarak bilinen öğreticili öğrenme algoritması bazı zor problemlerin çözümünde başarıyla kullanılır. Sistemin yaptığı hatalardan bir şeyle öğrenip istenen bulana kadar işleme devam etmesi olarak özetleyebileceğimiz yöntem hata düzeltme öğrenme tekniğine dayalıdır. (Haykin S. (1994))

Temel olarak hatanın geriye yayılması algoritmasının iki aşaması vardır; ileri ve geri. Birinci aşamada (ileri, forward) sisteme girilen giriş verisi ağıın duyum noktaları tarafından alınır ve katmandan katmana ileriye yayının ile her bir işlem elemanın çıkış verisini oluşturur. Birinci aşamada sinaptik ağırlıklar sabitlenmiştir. İkinci aşamada (geri, backward) ise her bir işlem elemanın istenen ve üretilen çıkış farkları geriye yayının yaptırılarak sinaptik ağırlıklar hata düzeltme kuralına göre ayarlanır. Her giriş verisinde bu işlemler tekrarlanır.

2.7.2 Hatanın Geriye Yayılması Algoritmasının Matematiksel Çıkarımı

Herhangi bir j işlem elemanına gelen toplam sinyalin, diğer bir deyişle net iç aktivasyonunun;

$$a_j = (\sum_{i=1}^N x_i w_{ji}) + \theta_j \quad (2.16)$$

olduğunu biliyoruz. Burada;

w_{ji} : i işlem elemanından j işlem elemanına giden sinyalin sinaptik ağırlığı,

θ_j : j eşik elemanın eşik değeri,

x_i : j işlem elemanına i işlem elemanından gelen giriş sinyalidir.

j işlem elemanın çıkışını aktivasyon fonksiyonu şu şekilde verir;

$$y_j = f_j(a_j) = 1/(1+\exp(-a_j)) \quad (2.17)$$

Ağa gösterilen n' inci örnek için j çıkış katmanı işlem elemanın hata sinyali şudur;

$$e_j(n) = d_j(n) - y_j(n) \quad (2.18)$$

Burada;

$d_j(n)$: n anında j işlem elemanından istenen ya da hedeflenen sistem cevabı

$y_j(n)$: n anında j işlem elemanından gerçekte elde edilen sistem cevabıdır.

Hatanın hesaplanabildiği görünebilen işlem elemanlarının; çıkış elemanlarının anlık hata kareleri toplamı;

$$\epsilon(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (2.19)$$

Burada C kümesi bütün çıkış katmanı işlem elemanlarını kapsar.

Geriye yayının (Back Propagation) algoritması $w_{ji}(n)$ ağırlığına anlık gradyan $\partial\epsilon(n)/\partial w_{ji}(n)$ ile orantılı bir $\Delta w_{ji}(n)$ ağırlık değişimi uygular;

$$\Delta w_{ji} = -\eta \partial\epsilon(n)/\partial w_{ji}(n) \text{ şeklindedir.} \quad (2.20)$$

Burada η öğrenme hızıdır.

Lokal gradyan olarak $\delta_j(n)$ de şu şekilde tanımlanır;

$$\delta_j(n) = -\partial\epsilon(n)/\partial a_j(n) \quad (2.21)$$

2.7.2.1 Çıkış Katmanına Ait İşlem Elemanın Ağırhık Değişim Formülasyonu

Zincir kuralına göre anlık gradyan $\partial\epsilon(n)/\partial w_{ji}(n)$ şöyledir;

$$\frac{\partial\epsilon(n)}{\partial w_{ji}(n)} = \frac{\partial\epsilon(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial w_{ji}(n)} \quad (2.22)$$

Burada $e_j(n)$ 'in hesaplanması 2.18, 2.17 ve 2.16'dan yapılabildiğinden zincir kuralına göre;

$$\frac{\partial e_j(n)}{\partial w_{ji}(n)} = \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial a_j(n)} \frac{\partial a_j(n)}{\partial w_{ji}(n)} \quad (2.23)$$

2.18'den;

$$\partial e_j(n) / \partial y_j(n) = -1 \quad (2.24)$$

2.17'den;

$$\partial y_j(n) / \partial a_j(n) = f(a_j(n)) \quad (2.25)$$

ve 2.16'dan;

$$\partial a_j(n) / \partial w_{ji}(n) = x_j(n) \text{ bulunur.} \quad (2.26)$$

2.24, 2.25 ve 2.26, 2.23'deki zincirde yerlerine konulursa;

$$\partial e_j(n) / \partial w_{ji}(n) = -f(a_j(n))x_j(n) \text{ olduğu görülür.} \quad (2.27)$$

2.19'a göre de;

$$\partial \epsilon(n) / \partial e_j(n) = e_j(n) \text{ bulunur.} \quad (2.28)$$

2.27 ve 2.28, 2.22'de yerine koyulursa;

$$\partial \epsilon(n) / \partial w_{ji}(n) = -e_j(n) f(a_j(n))x_j(n) \text{ bulunur.} \quad (2.29)$$

2.21'de ifade edilen lokal gradyan $\delta_j(n)$ 'i açarsak;

$$\delta_j(n) = -\partial \epsilon(n) / \partial a_j(n) = e_j(n) f(a_j(n)) \text{ bulunur.} \quad (2.30)$$

Buna göre 2.20'de tanımlanan $\Delta w_{ji}(n)$ ağırlık değişimini 2.29'dan ve 2.30'dan yararlanarak bulabiliriz;

$$\Delta w_{ji} = -\eta \delta_j(n) x_j(n) \quad (2.31)$$

2.7.2.2 Gizli Katmana Ait İşlem Elemanın Ağırlık Değişim Formülasyonu

Eğer j işlem elemanı gizli katmanda ise, $\epsilon(n)$ (ortalama anlık hata kareleri toplamı) çıkış katmanındaki işlem elemanlarından hesaplandığı için, lokal gradyan $\delta_j(n)$ hesabı değişir.

2.19'a göre k çıkış katmanındaki işlem elemanlarını göstermek üzere ortalama anlık hata kareleri toplamı;

$$\epsilon(n) = \frac{1}{2} \sum_k e_k^2(n) \quad (2.32)$$

Lokal gradyan $\delta_j(n)$ 2.21'den şu şekilde bulunur;

$$\delta_j(n) = -\frac{\partial \varepsilon(n)}{\partial a_j(n)} = -\frac{\partial \varepsilon(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial a_j(n)} = -\frac{\partial \varepsilon(n)}{\partial y_j(n)} f(a_j(n)) \quad (2.33)$$

$\partial \varepsilon(n)/\partial y_j(n)$, zincir kuralına göre şu şekilde bulunabilir;

$$\frac{\partial \varepsilon(n)}{\partial y_j(n)} = \sum \frac{\partial \varepsilon(n)}{\partial e_k(n)} \frac{\partial e_k(n)}{\partial a_k(n)} \frac{\partial a_k(n)}{\partial y_j(n)} \quad (2.34)$$

2.32'ye göre;

$$\frac{\partial \varepsilon(n)}{\partial e_k(n)} = e_k(n) \quad (2.35)$$

2.17 ve 2.18'e göre;

$$e_k(n) = d_k(n) - y_k(n) = d_k(n) - f(a_k(n)) \Rightarrow \frac{\partial e_k(n)}{\partial a_k(n)} = -f'(a_k(n)) \quad (2.36)$$

2.16'dan;

$$a_k(n) = \sum_{j=0}^q w_{kj}(n) y_j(n) \Rightarrow \frac{\partial a_k(n)}{\partial y_j(n)} = w_{kj}(n) \quad (2.37)$$

2.37, 2.36 ve 2.35'i, 2.34'deki zincirde yerlerine koyarsak;

$$\begin{aligned} \frac{\partial \varepsilon(n)}{\partial y_j(n)} &= - \sum_k e_k(n) f'(a_k(n)) w_{kj}(n) \\ &= - \sum_k \delta_k(n) w_{kj}(n) \end{aligned} \quad (2.38)$$

Bulunan bu hesaplama 2.33'te yerleştirilirse;

$$\delta_j = f'(a_j(n)) \sum_k \delta_k(n) w_{kj}(n) \quad (2.39)$$

şeklinde lokal gradyan hesaplanabilir.

2.7.2.3 Genelleştirilmiş Formülasyon

Yapılan ağırlık değişimini genel olarak şu şekilde özetleyebiliriz;

Lokal gradyan $\delta_j(n)$;

j çıkış katmanına ait bir işlem elemanı ise 2.30'dan

$$\begin{bmatrix} \text{Ağırlık} \\ \text{Düzelme} \\ \Delta w_{ji}(n) \end{bmatrix} = \begin{bmatrix} \text{Öğrenme} \\ \text{Hızı} \\ \eta \end{bmatrix} \cdot \begin{bmatrix} \text{Lokal} \\ \text{Gradyan} \\ \delta_j(n) \end{bmatrix} \cdot \begin{bmatrix} j \text{ işlem} \\ \text{elemanına} \\ \text{gelen giriş} \\ x_i(n) \end{bmatrix}$$

j gizli katmana ait bir işlem elemanı ise 2.39'dan hesaplanır.

Çok katmanlı idrakte δ 'nin hesaplanması işlem elemanına ait $f(\cdot)$ aktivasyon fonksiyonunun türevleme hesabını bilmeyi gerektirir. İşte bu türevlemeyi yapabilmek için bu fonksiyonun sürekli bir fonksiyon olmasına ihtiyaç vardır. Başka bir deyişle türevlenebilirlik bu fonksiyonun sağlama gereken yegane özellikir. Çok katmanlı idrakte sıkılıkla kullanılan, sürekli, türevlenebilir, doğrusal olmayan (nonlinear) örnek aktivasyon fonksiyonu sigmoid fonksiyondur;

$$y_j = f_j(a_j) = 1/(1+\exp(-a_j)) \quad -\infty < a_j < \infty \quad (2.40)$$

Sigmoid fonksiyonun pratik türevi;

$$f'(a_j(n)) = y_j(n)(1-y_j(n)) \text{ şeklindedir.} \quad (2.41)$$

Türev hesaplamalarında kolaylık için bu formül kullanılır.

Geriye yayının algoritması en dik iniş kuralı (Steepest descent rule) ile hesaplanan ağırlıklarla hedef fonksiyona bir yaklaşım sağlar. η küçük alındığı oranda, sinaptik ağırlıklar küçük miktarda değişecek ve ağırlıklar uzayındaki hedef fonksiyona daha hassas yaklaşım sağlanacaktır. Buna karşın η büyük alınırsa da öğrenme hızı artacaktır, fakat öğrenme işlemi sırasında değişen ağırlıklar hedeften sapıp sistemin düzensiz hale gelmesine neden olabilecektir. Öğrenme hızını yükseltirken düzensizlige düşmekten kurtulmanın en basit metodu momentum kullanımıdır;

$$\Delta w_{ji}(n) = \alpha \Delta w_{ji}(n-1) + \eta \delta_j(n) x_i(n) \quad (\text{Genelleştirilmiş Delta Kuralı}) \quad (2.42)$$

Burada α momentum sabiti olarak anılan sabit pozitif bir sayıdır.

Elimizde bir fonksiyon tarafından ilgilendirilen doğrusal olmayan (nonlinear) giriş-çıkış veri eşleştirmelerinin bulunduğu varsayıyalım;

$$d = g(x) \quad (2.43)$$

Burada x vektörü giriş verisini ve skaler d de çıkış verisini gösteriyor. Fonksiyon $g(\cdot)$ bilinmiyor. Bizden istenen verilen $(x_1, d_1), (x_2, d_2), \dots, (x_N, d_N)$ giriş-çıkış veri çiftleriyle doğrusal olmayan bu $g(\cdot)$ fonksiyonuna yaklaşan bir yapay sinir ağını tasarlamaktır. Bu yaklaşım problemi $i=1, 2, \dots, N$ olmak üzere x_i 'yi giriş vektörü ve d_i 'yi istenen sistem cevabı gibi düşünürsek, öğreticili öğrenme için mükemmel bir aday oluşturmaktadır.



3. TALAŞLI İMALATTA YAPAY SINİR AĞININ KULANIMI ÜZERİNE GELİŞTİRİLEN BELLİ BAŞLI ÇALIŞMALAR

Yapay sinir ağının talaşlı imalatta kullanılmasını öneren ilk çalışmalar 80'lerin sonunda ortaya çıkmıştır. 1986 yılında Rumelhart ve McClelland tarafından geliştirilen hatanın geriye yayınımı algoritmasında genelleştirilmiş delta kuralının ardından birbirleri arasındaki ilişki için tam olarak bir fonksiyon kurulamayan sistem parametrelerine sahip pek çok bilimsel konuda pratiğe yönelik yapay sinir ağı uygulamaları yapılmaya başlanmıştır. Bu çalışmaların öncüleri Rangwala ve Dornfeld (1987) ve Chryssolouris ve Gulliot (1990) tarafından gerçekleştirilenlerdir.

Dimla 1997 yılında yayınladığı literatür araştırmasında o zamana kadar yapılan yapay sinir ağı yardımıyla kesici takım durum takibi çalışmalarından 40 tanesini incelemeye almıştır. Bu çalışmaların 26'sında model olarak hatanın geriye yayınımı algoritması ile eğitilen çok katmanlı, ileri beslemeli yapay sinir ağı seçilmiştir. Her ne kadar o zamandan bu yana yapılan çalışmalar öğreticisiz yapay sinir ağı modellerine ve bulanık mantık (fuzzy logic) ortak kullanımına kayma eğilimi gösterse de hatanın geriye yayınımı algoritması ile eğitilen çok katmanlı ileri beslemeli ağ kullanımı güncelliğini korumaktadır. Hatta bu modelin referans olarak kabul edildiğini söyleyebiliriz.

3.1 Yapay Sinir Ağı Yardımıyla Kesme Şartlarının Modellenmesi

Dornfeld ve Rangwala'nın (1989) sistem modelleme üzerine yaptıkları ilk çalışmanın amacı yapay sinir ağlarının hesaplama kabiliyetinin kullanılmasıyla talaşlı imalat operasyonlarının öğrenilmesi ve optimizasyonudur. Örnek olarak tornalama işlemi seçilmiştir. Uygulamada yapay sinir ağı ilerleme, kesme derinliği ve kesme hızı gibi giriş parametrelerinin, kesme kuvveti, güç, sıcaklık ve iş parçası yüzey kalitesi gibi sonuç verileri üzerindeki etkisini değerlendirerek öğrenmektedir. Öğrenme aşamasından sonra gelen sentez aşamasında azami çalışma koşullarıyla sınırlandırılmış birim zamanda maksimum malzeme kaldırılması esasına göre kesici takımın işleme parametrelerinin tahmini yapılır.

Alışlageldik bilgisayar kontrollü tezgah sistemleri anlık ayarlamaların yapılabildiği bir bilgi akışına sahip olmadığından ilerleme, kesme hızı ve kesme derinliği gibi sistem parametrelerinin önceden belirlenip programlanması gibi bir dezavantajı taşırlar. Bu parametrelerin seçimi talaşlı imalat el kitaplarına ve programcının tecrübe ve bilgisine bağlıdır. Pek çok durumda seçilen işleme şartları makine titreşimleri ve kesici takım kırılma

olasılıkları karşısında oldukça korumaya yönelik bir şekilde alınır. Bu sebepten dolayı da proses verimliliğinde bir düşüş görülür çünkü korumaya yönelik operasyon parametreleri üretim hızı ya da malzeme kaldırma hızı gibi optimum işleme kriterlerine ulaşılabilmesinden sistemi alıkoyar. Bu duruma önerilebilecek bir çözüm sensor (müşir) sinyallerine dayalı olarak sistem parametrelerinin yanında izlenmesi ve ayarlanmasıdır. İmalat literatüründe bu tip kabiliyetlere sahip kontrol sistemleri adapteyle kontrol sistemleri (Adaptive Control (AC) Systems) olarak adlandırılır.

İnsansız imalat sistemlerinin başarısı büyük oranda uygun algılama ve bilgisayar temelli optimizasyon stratejilerine bağlıdır. Adapteyle kontrol sistemlerinden beklenen uygun proses özelliklerinin ölçümlerine dayalı olarak operasyon parametrelerinin yanında değişimlerini sağlayabilmektedir. Bu sistemler iki çeşittir; Kısıtlamaların adapteyle kontrolü (Adaptive Control of Constraints=ACC) ve optimizasyon temelli adapteyle kontrol (Adaptive Control with Optimization = ACO). ACC sistemleri kesme kuvveti veya tezgah gücü gibi önceden belirtilmiş değerlerin denetim altında tutularak ilerleme, kesme hızı gibi işleme parametrelerinin ayarlandığı geri beslemeli kontrol sistemleridir. Buradaki amaç kesme kuvveti veya harcanan güç gibi fiziksel kısıtlamaların belli üst sınırlar altında tutulması buna karşın işleme parametrelerinin alabilecekleri azami değerlere ayarlanmasıdır. ACO sistemleri ise önceden tanımlanan bir performans indeksinin optimizasyonunun yapılabilmesi için işleme parametrelerinin ayarlanması esasına dayanır. Talaşlı imalat için indeks malzeme kaldırma hızı (Material Removal Rate=MRR) ve kesici takım aşınma hızını (Tool wear rate=TWR) içerir. MRR ve TWR birbirleriyle ters orantılı kavramlar olduğu için indeksin yükseltilmesi bir optimizasyondur.

Akıllı imalat sistemleri tecrübe üzerinden öğrenebilme kapasitesine ve öğrenme sırasında edindiği bilgileri optimize etme kabiliyetine sahip olmalıdır. Nöral hesaplamanın talaşlı imalatta avantaj olabilecek kendine özgü özelikleri, çoklu parametre ilişkilerini göz önünde bulundurabilen ve hesaplama zamanını azaltan paralel hesaplama yapısına sahip olması, adreslemeyle değil içeriğiyle bilgiyi saklaması ve ulaşması, proses modellerine ihtiyaç duymaması, güçlü öğrenme kabiliyeti ve algılama sisteminin verilerine dayalı kendinden organize olabilme kabiliyetidir.

Dornfeld ve Rangwala'nın uygulamasında amaç ilerleme gibi kontrol parametrelerini ihtiva eden giriş verileri ile kesme kuvveti gibi ölçülebilen kesme şartlarını içeren çıkış verileri arasında eşleştirmenin yapılmıştır. Gizli katmandaki işlem elemanları lineer olmayan eşleştirmeler yapılabilmesinin garantisini oldukları için kullanılmaları zorunludur. Uygulamada

transfer (aktivasyon) fonksiyonu olarak kullanılan sigmoid fonksiyon biraz değiştirilerek aşağıdaki formata getirilmiştir;

$$F(\text{net}_{i,k}) = \theta_{i,k} / (1 + \exp(-\beta_{i,k} \cdot \text{net}_{i,k})) \quad (3.1)$$

Burada θ işlem elemanın maksimum çıkışını belirler. β ise sigmoid kavisin keskinliğini ve maksimum ve minimum çıkışları veren girişler arasındaki alanı belirler. β ve θ sıfırdan büyük sayılardır. Formatın değiştirilmesinin nedeni çıkış verilerinin 0 ve 1 aralığında normalize edilmek istenmemesi esas değerleriyle hesaplamada yer almalarıdır.

Bu öncü çalışmada ortalama hata fonksiyonunda global minimuma inilebilmesi için gizli katmandaki işlem elemanı sayısı seçiminin önemi üzerinde durulmuştur. Ağ yapısında yüksek sayıda gizli işlem elemanı tanımlanarak ya da az sayıda gizli işlem elemanıyla başlayıp global minimuma inebilmek mümkün olana kadar bu sayıyı kademe kademe artırarak bu seçim sağlanabilir. Çalışmadaki yaklaşım ikinci metottur.

Sentez aşamasındaki hedef, sonuç verilerinde belli kısıtlamalara bağlı kalınarak performans indeksini optimize edecek giriş değerlerine karar vermektedir. Ağın giriş verileri tornalama operasyonundaki ilerleme, kesme hızı ve kesme derinliği gibi parametrelerdir. Ağın öğrenme safhasında edindiği tecrübe dayanarak tahminde bulunacağı çıkış verileri ise kesme kuvveti, harcanan güç, sıcaklık ve yüzey kalitesi gibi kesme işlemi esnasında sensorlar tarafından ölçülen parametrelerdir. Giriş verilerindeki kısıtlamalar tezgah kapasitesiyle alakalı olabilir. Bazı çıkış verileri arzu edilen değerlerin mümkün olduğu kadar civarında tutulmak istenebilir. Örneğin düzgün gerçekleşen bir talaş kırılmasından emin olabilmek için akustik yayının sinyallerinin belli bir seviyede tutulmaya çalışılması gibi. Diğer çıkış verileri ise kesici takım kırılması ve aşırı takım aşınması gibi karşı faktörlerden korunmanın sağlanabilmesi için bir üst sınıra sahip olabilirler.

Teorikte tanımlanan peformans indeksi şu şekildedir;

$$H = \lambda_1 F + \lambda_2 G \quad (3.2)$$

Burada λ_1 ve λ_2 değerleri F ve G nin birbirlerine göre önemliliklerini belirtir. F bazı çıkış işlem elemanları için şöyle tanımlanır;

$$F = \frac{1}{2} \sum_{i=1}^m (d_i - y_i)^2 \quad (3.3)$$

Burada

y_i = i'nci işlem elemanınin gerçekte oluşan çıkış değeri

d_i = i'nci işlem elemanınin istenen çıkış değeri

G ise proses verimliliğini gösteren performans indeksidir. Bu çalışmada birim zamanda kaldırılan malzeme miktarının (MRR) negatif değeri G olarak seçilmiştir. MRR tornalama işleminde ilerleme, kesme derinliği ve kesme hızının çarpımına eşittir. Performans indeksinin kullanımındaki amaç H'ı minimuma indirecek z giriş değer takımını aşağıdaki kısıtlamalara bağlı kalarak bulmaktadır;

Giriş işlem elemanları için $z_{\min_i} \leq z_i \leq z_{\max_i}$

F'de tanımlanmayan çıkış işlem elemanları için $v_i = (d_i - y_i) \geq 0$

Yapay sinir ağının giriş değerleri olarak ilerleme, kesme hızı ve kesme derinliği belirlenmiştir. Kesme işleminin kalitesi kesme kuvveti, harcanan güç, kesici takım ucu sıcaklığı ve yüzey kalitesi gibi çıkış verilerini ölçen sensorlar tarafından görüntülenir. Çıkış verilerinin her biri kesici takım kırılması veya aşınması, iş parçası yanması, tezgah kapasitesi ve minimum kabul edilebilir iş parçası yüzey kalitesi gibi kriterler tarafından belirlenen üst limitler ile sınırlanır. Hedef öncelikle sistemin eğitim setinden gözlemlendiği giriş ve çıkış verileri arasında uygun eşleştirmeler yapmayı öğrenmesidir. Eğitilen sistem, daha sonra uygun limitler tarafından sınırlanırken birim zamanda maksimum malzeme kaldırılmaya yönelik giriş verilerine karar vermektedir. Çalışmada sensor çıkışları yerine teorik modellerin sonuçları kullanılmıştır.

Kesme kuvvetinin üst limiti takım kırılmasını önlemek için kesici takım malzemesinin mukavemetinden yola çıkılarak belirlenmiştir. Bunun yanında harcanan güç tezgah kapasitesinin sınırlarını aşamaz. Yüzey kalitesi tasarım gereklilikleriyle sınırlandırılmış, sıcaklığın ise kesici takımın sertliğini kaybettiği değerlerden daha aşağıda tutulması hedeflenmiştir. Bütün belirlenen üst limitlerde kesici takım aşınması da gözönünde bulundurulmuştur. Giriş verileri de ayrıca tezgah kapasitesine göre sınırlanmışlardır;

$0,05 \text{ mm/devir} \leq f \leq 0,50 \text{ mm/devir}$

$0,50 \text{ mm} \leq d \leq 5,0 \text{ mm}$

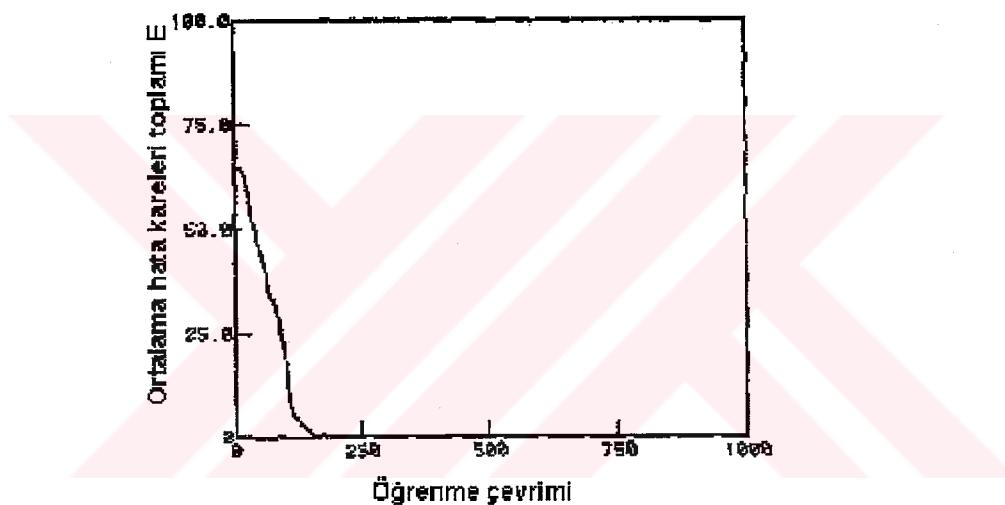
$0,50 \text{ m/s} \leq v \leq 5,0 \text{ m/s.}$

Çalışmada kullanılan performans indeksi ise şudur;

$$H = -fdv \quad (3.4)$$

İndekste sadece birim zamanda kaldırılan malzeme hacminin kullanılmasından da anlaşılacağı üzere bütün çıkış değerleri sadece üst limitleriyle sınırlanmıştır.

Teorik modellerde çıkış verilerinin hesaplanması için üç giriş verisinden her biri beş farklı değerde alınarak 125 farklı ($5 \times 5 \times 5$) giriş kombinasyonu oluşturulmuştur. Bu kombinasyonlar eğitim ve test için gerekli giriş-çıkış setlerini sağlar. Toplam 30 kombinasyon eğitim seti olarak kullanılmıştır. Sadece bir gizli katman kullanılmış ve bu katmandaki işlem elemanı sayısı başlangıçta düşük tutularak deneme yanılma ile öğrenme hatası sıfır yaklaştırılmışlığı yapıya kadar artırılmıştır.

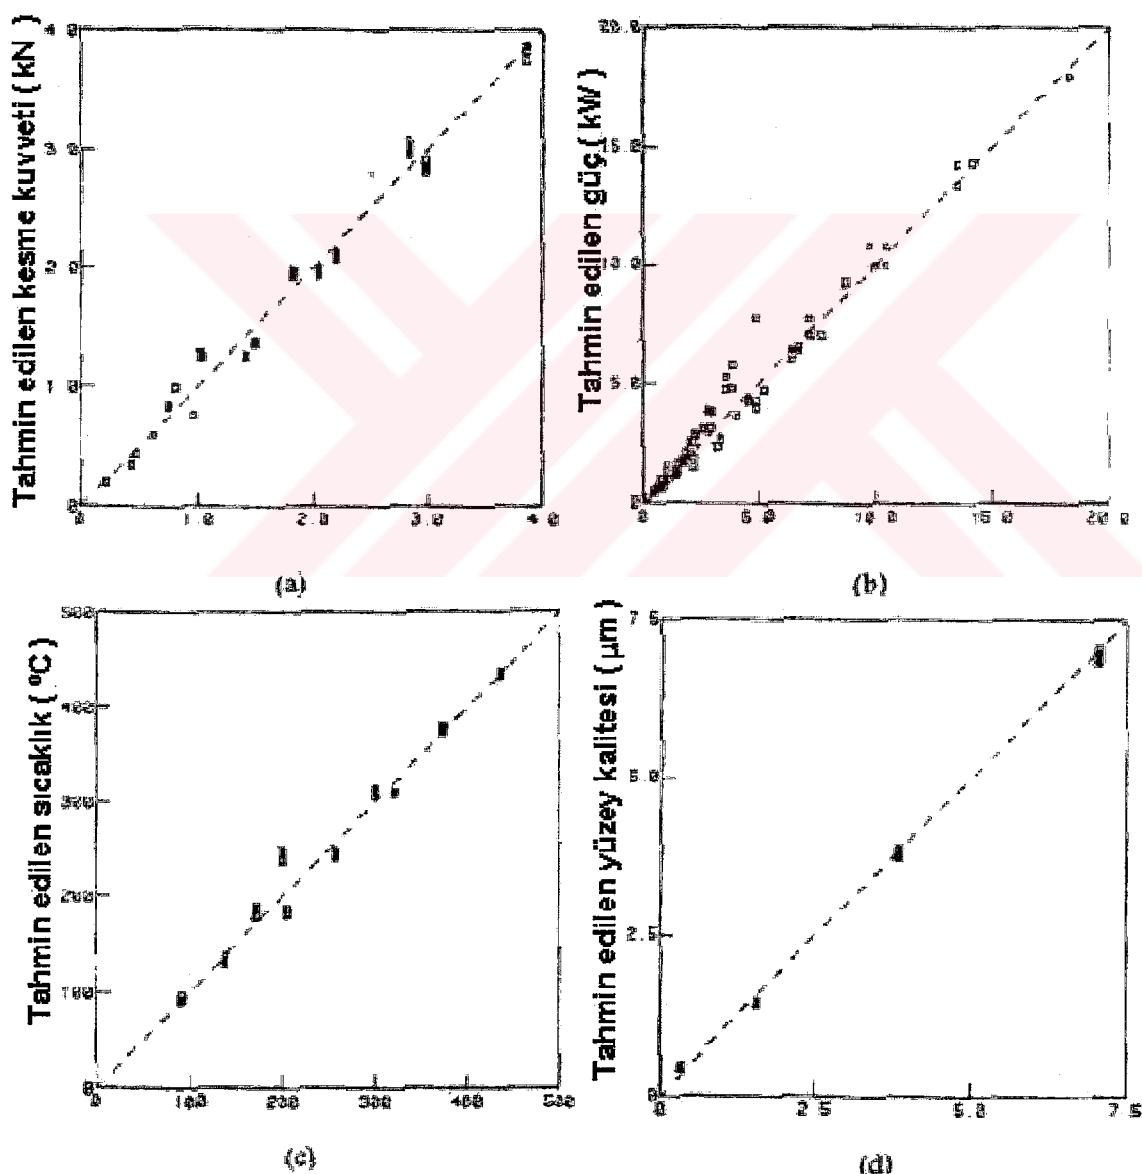


Şekil 3.1 Öğrenme hata değişimi, öğrenim set sayısı=30, ağ yapısı 3-4-4 (Dornfeld, 1989)

Öğrenme ve sentez için iki farklı yapay sinir ağı kullanılmıştır. Kümeleme ağıda bütün eğitim seti kullanıcı tarafından önceden belirlenmiş ve giriş veri alanının genelinden örneklemeye yapıldığı için ağıın, işleyişin genelini öğrendiği görülmüştür. Pek çok durumda ağıın genel bilgiye sahip olması gereklidir. Sistem sadece optimuma ulaşacağı imalat aşamalarında bilgiye ihtiyaç duyar. Ayrıca gerçek zamanlı uygulamalarda ağıın genel bilgiye ulaşması uygun olmayan zaman alıcı bir işlemdir. Bunu aşmak için önerilen ikinci ağ çeşidi arttırmalı ağıdır. Arttırmalı ağ rasgele seçilmiş öğrenme parametreleriyle işe başlar ve hemen ilk aşamada optimum giriş değerlerini tahmin eder. Gerçekte ağıın tahmin ettiği giriş değerlerine karşılık gelen sensorlarla ölçülen çıkış verileri ağı için bir öğrenme modeli oluşturur ve öğrenme parametreleri buna göre ayarlanır. Ağıın optimum giriş değer tahminleri bu şekilde çıkış değerleri gerçekte bulunanlarla eşitlenene kadar sürdürülür ve sonuça genel bilgiye

değil optimum bilgisine sahip bir ağ üretildiği düşünülebilir.

Kümeleme ağda giriş ve çıkış değerlerine paralel olarak giriş katmanının 3 ve çıkış katmanının 4 işlem elemanı sabit olarak öngörlür. Bütün simulasyonlarda yalnız bir adet gizli katman kullanılmıştır. Başlangıç olarak gizli katmanda iki adet işlem elemanı denenmiş. Bu yapıyla hata sıfır çekilemediği için gizli işlem elemanı sayısı artırılmıştır. Dört adet gizli işlem elemanı ile ağ öğrenmeye adapte olabilmiştir. Böylece bu çalışmadaki yapay sinir ağ yapısı 3-4-4 olarak seçilmiştir. Rasgele bir sayı üreticisi öğrenme parametrelerinin ilk değerlerini vermekte kullanılmıştır. Şekil 3.1'de gösterildiği üzere 300 deneme yanlış çevriminden sonra hata sıfır yaklaşmıştır.



Şekil3.2 Ağın öğrenme performansı a)Teorik kesme kuvveti (kN) b)Teorik güç (kW) c)Teorik sıcaklık (°C) d) teorik yüzey kalitesi (μm) (Dornfeld, 1989)

Test aşamasında dikey eksende ağıın yaptığı tahminler ile yatay eksende teorik modellerle hesaplanan olması gereken değerlerin karşılıklı olarak çizildiği grafikler Şekil 3.2'dedir. Bazı sapmalar bulunsa da ağıın performansı oldukça iyidir. Eğer gerekiyorsa sapmalar eğitim örneğinin ve gizli işlem elemanı sayılarının arttırımıyla azaltılabilir. Yüzey kalitesi ilişkisinin gayet iyi öğrenildiği gözden kaçmamaktadır. Bunun sebebi teorik modelde yüzey kalitesinin sadece bir değişkene; ilerlemeye bağlı olmasıdır. Bununla beraber öğrenme aşamasında ağıın yüzey kalitesine diğer faktörlerin etki etmediğini ve buna bağlı olarak kesme hızı ve kesme derinliği değişimlerine karşılık yüzey kalitesinde değişiklik yapılmadığını öğrenmesi özellikle zor bir süreçtir.

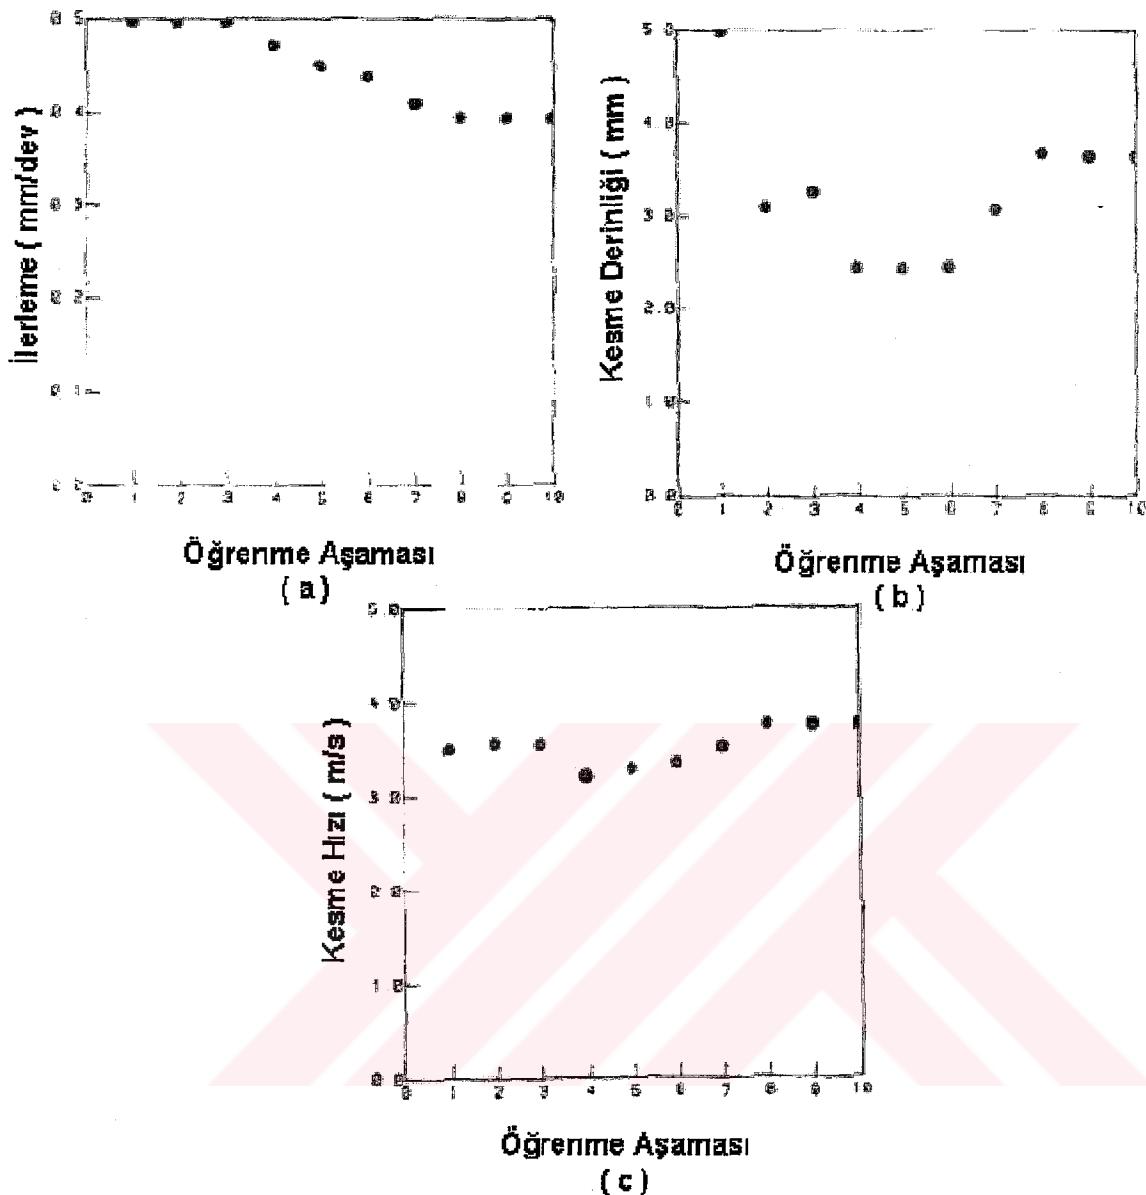
Çizelge 3.1 Ağ optimum giriş değer tahmin performansı (Dornfeld, 1989)

Durum	Maksimum Müsade Edilen Değerler				Optimum Değerler		
	Kuvvet (kN)	Güç (kW)	Sıcaklık (°C)	Yüz.Kalitesi (μm)	İlerleme (mm/dəvər)	Derinlik (mm)	Hız (m/s)
1	3.5	10.0	250	5.5	0.403	3.000	1.938
2	3.5	10.0	250	5.5	0.398	3.000	2.944
3	4.5	12.0	150	5.5	0.285	5.000	1.030
4	2.5	10.0	350	5.5	0.321	4.447	3.956
5	1.3	5.0	200	4.0	0.164	4.023	3.222
6	1.3	3.6	170	0.5	0.119	4.392	2.945
7	1.7	10.0	350	5.5	0.290	3.529	4.957

Sentez aşamasındaki çıkış verileri üst limitleri ve bunlara paralel optimum giriş değer tahminleri Çizelge 3.1'de gösterilmiştir. Çizelge 3.2'de ise tahmin edilen giriş değerlerine karşılık gelen çıkış değerleri ve bunların teorik modellerle hesaplanan gerçekte olmaları gereken değerler birlikte verilmiştir. Sonuçlar oldukça başarılıdır. Daha fazla yükselmesi halinde çıkış verilerinden birisinin üst limitini zorlayacak giriş verisi artırılmadan bırakılmıştır bu da ağıın prosesin inceliklerini kaptığını göstermektedir.

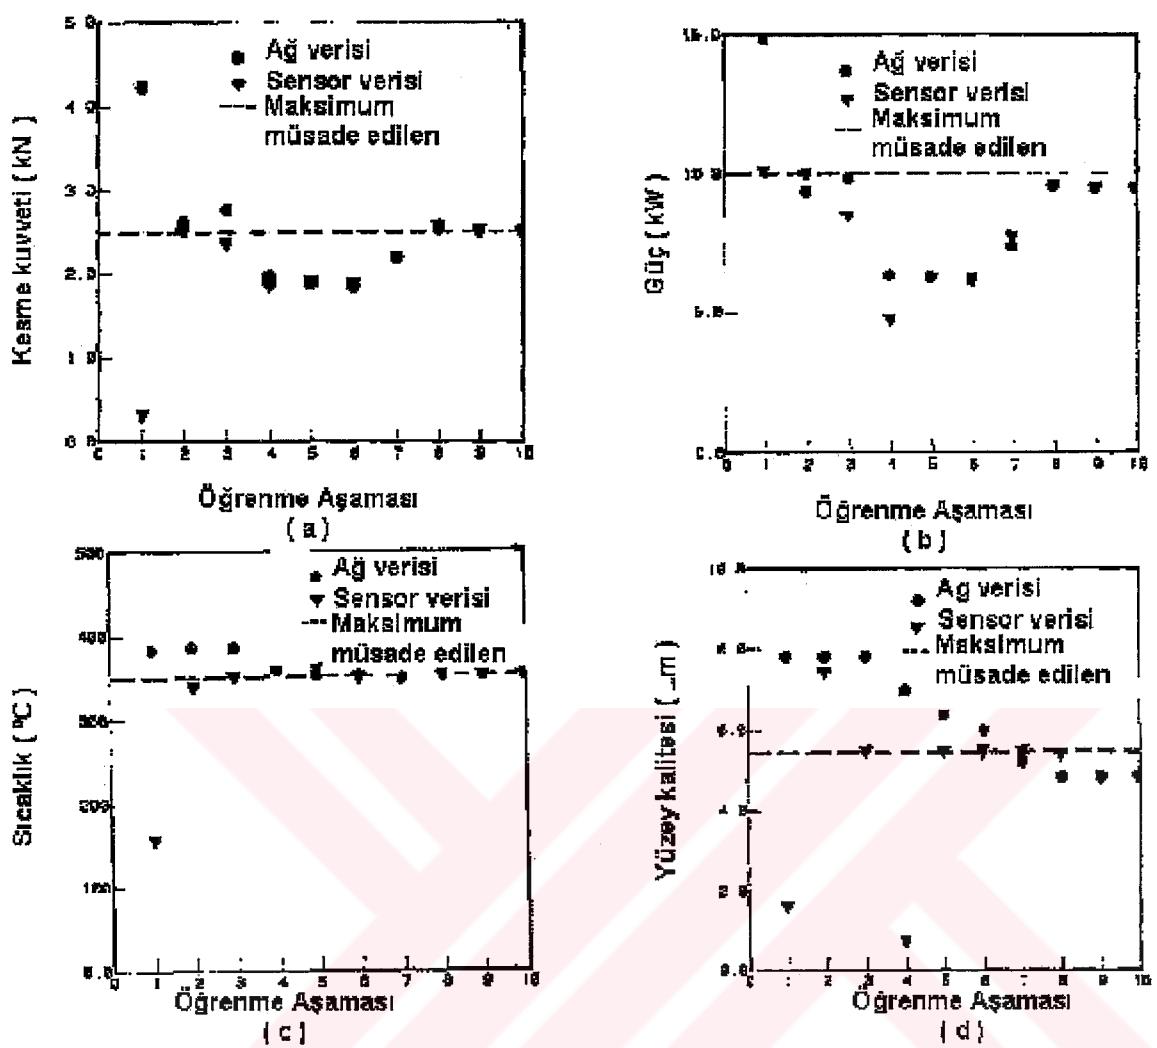
Çizelge 3.2 Ağ ve sensor çıkış değer karşılaştırması (Dornfeld, 1989)

Durum	Ağ Çıkış Verileri				Sensor Çıkış Verileri			
	Kuvvet (kN)	Güç (kW)	Sıcaklık (°C)	Yüz.Kalitesi (μm)	Kuvvet (kN)	Güç (kW)	Sıcaklık (°C)	Yüz.Kalitesi (μm)
1	3.349	7.020	250.8	3.121	3.530	6.840	256.2	5.070
2	2.579	7.582	231.8	2.548	2.730	8.044	272.0	2.770
3	2.440	3.286	150.8	2.146	3.630	2.640	154.0	2.514
4	2.498	10.000	319.4	3.149	2.587	10.220	326.5	3.210
5	1.305	4.202	201.0	0.828	1.323	4.160	210.0	0.839
6	1.225	3.630	167.4	0.538	1.100	3.232	171.4	0.440
7	1.768	9.944	358.0	2.495	1.880	9.334	347.5	2.621



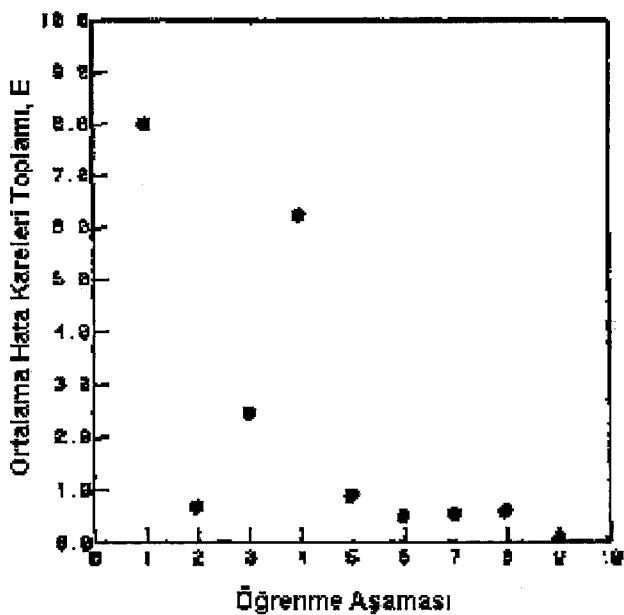
Şekil 3.3 Giriş parametrelerinin değişimi (Dornfeld, 1989)

Sentez aşamasında bir de artırmış tasarıma sahip bir yapay sinir ağı kullanılmıştır. Kümeleme ağ gibi dört adet gizli işlem elemanı kullanılan bu ağıda halihazırdağı öğrenme durumuna göre optimum giriş veri takımı tahmini yapılmış, bu tahminlere karşılık gelen olması gereken çıkış verilerine (teorik model hesaplamaları) göre ortalama hata karesi bulunmuştur. Şekil 3.3'de gösterildiği gibi başlarda ağ yüksek tahminlerde bulunmuştur çünkü bu çalışma şartlarıyla gerçekle oluşan çıkış değerlerinin konulan üst limitleri aştığını henüz bilmemektedir. Şekil 3.4'de görüldüğü gibi başlardaki çıkış verilerinin hepsinde



Şekil 3.4 Çıkış parametrelerinin değişimi (Dornfeld, 1989)

sınırlar dışına taşılmıştır. Ancak beş öğrenme çevriminden sonra ağ kuvvet, güç ve sıcaklık ilişkilerini öğrenmiştir fakat yüzey kalitesine etki eden tek faktörün ilerleme olduğunu anlamak sekizinci öğrenme çevrimine kadar mümkün olmamıştır. Ağ giriş değerlerinden kesme derinliği ve kesme hızı için ancak dokuzuncu çevirimde bir sayıda karar kılmuştur. Çıkış işlem elemanları ortalama hata kareleri toplamı da bu çevirimde minimum değere ulaşarak öğrenmenin gerçekleştigiğini tespit etmektedir. (Şekil 3.5) Çizelge 3.1'de verilen 7 değişik sınırlandırma durumu için aynı işlemler yapılmış ve öğrenmenin 9 ila 12 çevrim arasında gerçekleştiği görülmüştür. Daha önce elde edilmiş 125 kombinasyonda bu ağla yapılan test sonuçları ise oldukça zayıftır. Bunun nedeni açiktır; arttırmalı ağ sadece optimum bölgesinin bilgisine sahiptir, tecrübe her kesme şartında geçerlilik taşımamaktadır.



Şekil 3.5 Hata değişimi (Dornfeld,1989)

Son senelerde bulanık mantık (fuzzy logic) ile yapay sinir ağlarının birleştirilmesiyle modelleme yapmak pek çok çalışmanın esas aldığı popüler bir konudur. Y.H.Lee vd. (1999) tarafından yapılan böyle bir çalışmada ekonomik açıdan talaşlı imalat prosesinin optimizasyonuna gidilmiş, alınan sonuçlar yapay sinir ağı yardımıyla karar mekanizmasında kullanılmıştır. Bulanık mantığın görevi, tek bir parçanın maliyetini veren matematik modelin ana mil dönme hızı, ilerleme, kesme derinliği, yüzey kalitesi, kesme kuvveti ve tezgah gücü üst ve alt limitlerine göre optimizasyonunu yapmaktadır. Bu şekilde yapay sinir ağıının eğitimi için deneysel veri toplama zorunluluğu da ortadan kalkacaktır.

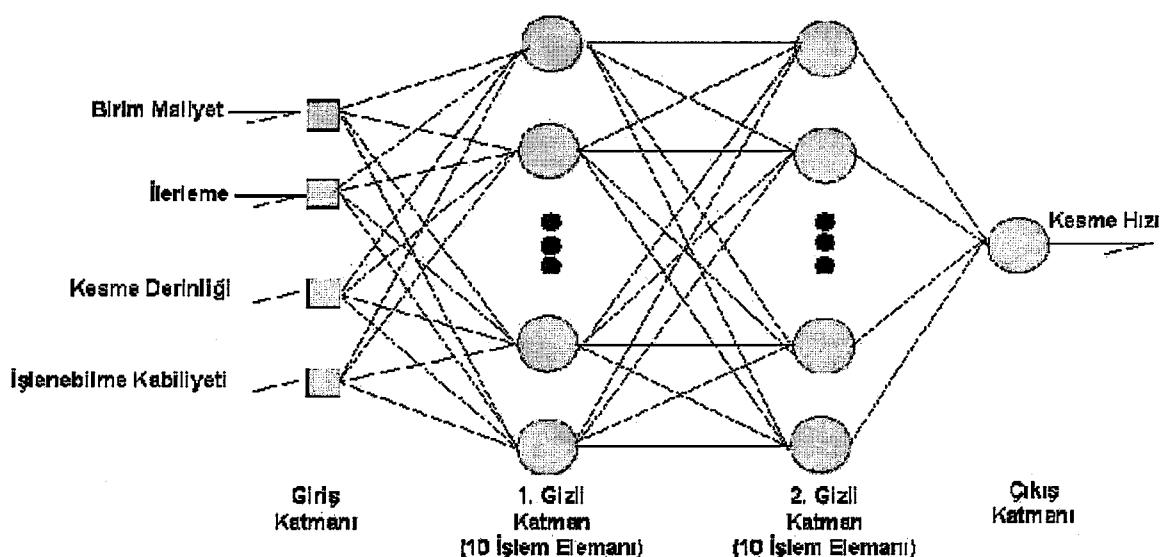
Çizelge 3.3 Yapay sinir ağı için eğitim ve kontrol verileri (Y.H.Lee vd., 1999)

Birim Maliyet (\$)	Önceden Belliilenen Parametreler		Tahmin Edilen Kesme Hızı (m/dak.)	Tahmin Edilen İşlenebilme Kapasitesi (mm ³ /dak.) x 10 ³
	Kesme Derinliği (mm)	İlerleme (mm/dəvər)		
11.1	0.515	0.750	63.1478	24.3908
11.2	0.380	0.519	44.1201	8.7014
11.3	0.255	0.603	46.5937	7.1645
:	:	:	:	:
14.9	0.395	0.768	55.9056	16.9595
15.1	0.484	0.618	47.1946	14.1165
15.2	0.545	0.635	49.9156	17.2745

Çizelge 3.3'te yapay sinir ağı için kullanılan eğitim ve kontrol verilerinin bir kısmı görülmektedir. Eğitim verileri bulanık mantık optimizasyon modelinden elde edilmiştir. Kontrol verileri ise imalat el kitabından alınmıştır. Şekil 3.6'da görüldüğü gibi yapılandırılan yapay sinir ağının kesme hızını ve işlenme kabiliyetini bu verilerin yerdeğiştirmeleriyle ayrı ayrı tahmin etmek üzere kurulmuştur. Yapay sinir ağında iki gizli katmanda 10'ar işlem elemanı bulunmaktadır. Öğrenme hızı 0.2, momentum 0.75 alınarak hatanın geriye yayınımı algoritması kullanılmıştır. Tahmin değerleri Çizelge 3.4'de verildiği gibidir. Çalışmada ortalama yüzde hatanın yaklaşık % 4.22 seviyelerinde olduğu belirtilmiş fakat hedef değerler ve net hata miktarları bildirilmemiştir. Alınan başarılardan ve pratikliğinden ötürü bulanık mantık ve yapay sinir ağının ortaklaşa kullanımı üzerine yapılan çalışmalar yepyeni modellerle artarak süreceğe benzemektedir.

Çizelge 3.4 Yapay sinir ağı test sonuçları (Y.H.Lee vd., 1999)

Birim Maliyet (\$)	Önceden Belirlenen Parametreler		Tahmin Edilen Kesme Hızı (mf/dak.)	Tahmin Edilen İşlenebilme Kabiliyeti ((mm ³ /dak.) × 10 ³)
	Kesme Derinliği [mm]	İlerleme (mm/drev)		
11.1	0.515	0.750	63.1478	24.3908
11.2	0.380	0.519	44.1201	8.7014
11.3	0.255	0.603	46.5937	7.1645
:	:	:	:	:
14.9	0.395	0.768	55.9056	16.9595
15.1	0.484	0.618	47.1946	14.1165
15.2	0.545	0.635	49.9156	17.2745



Şekil 3.6 Kesme hızını tahmin etmek için oluşturulan (4-10-10-1) yapısındaki yapay sinir ağısı(Y.H.Lee vd., 1999)

3.2 Yapay Sinir Ağı Yardımıyla Takım Aşınma Takibi

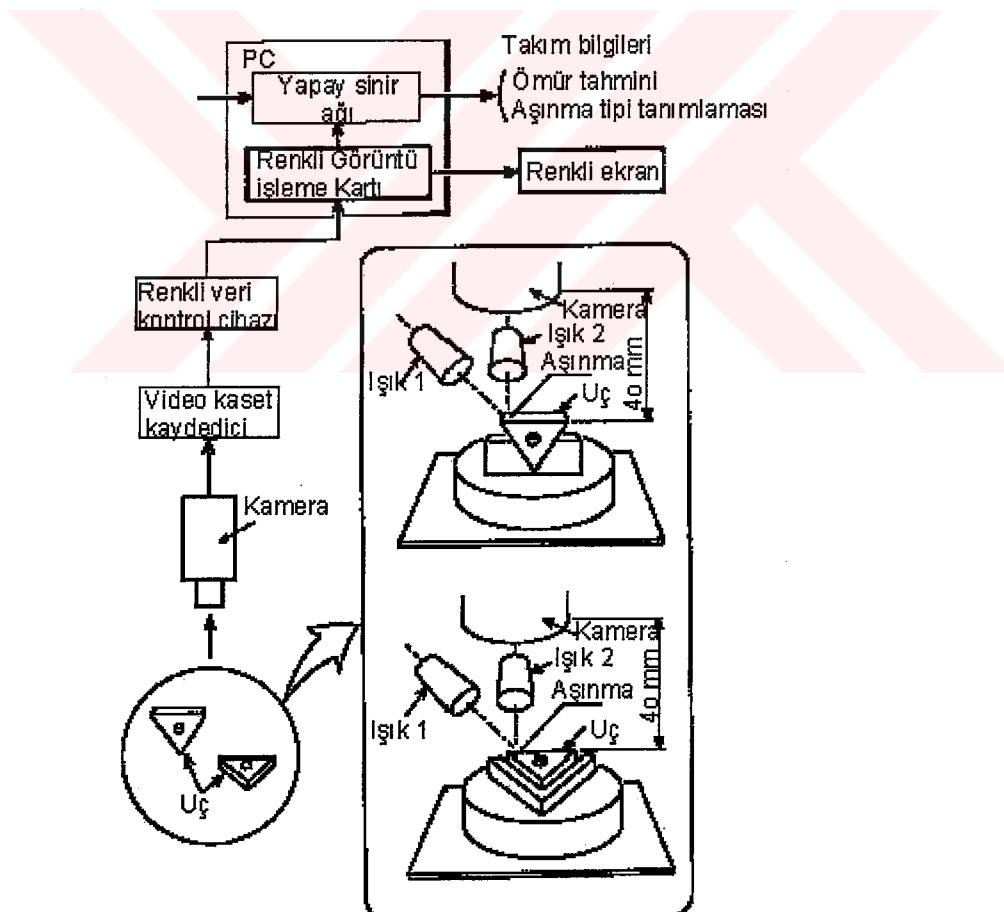
Yapay sinir ağlarının kullanımıyla talaşlı imalat şartlarının modellenmesi ve kesici takım aşınmasının anında takip edilmesi için önerilen modeller aynı paralelde geliştirilmiştir. Takım aşınmasını anında takip edecek, aşınmanın derecesini tahmin ederek erken uyarı verecek modellere olan ihtiyaç gün geçtikçe artmıştır.

Modelleme yapmadan önce kesici takım kırılmalarının nedenlerini iyi bilmek gereklidir:

- Yüksek sıcaklık ve gerilimlerden kaynaklanan plastik deformasyon,
- Yetersiz tokluk ve mukavemete karşın yüksek kuvvetlerden kaynaklanan mekanik kırılmalar,
- Adım adım gelişen aşınmadan dolayı kesici takım ucunun körelmesi

Çeşitli aşınma Şekillerinden serbest yüzeyde meydana gelen serbest yüzey aşınması ve bununla beraber gelişen çentik oluşumu ve talaş yüzeyindeki krater aşınması en önemlileridir.

Diğer aşınma çeşitleri kesici takım malzemesinin ve kesme parametrelerinin uygun seçimiyle

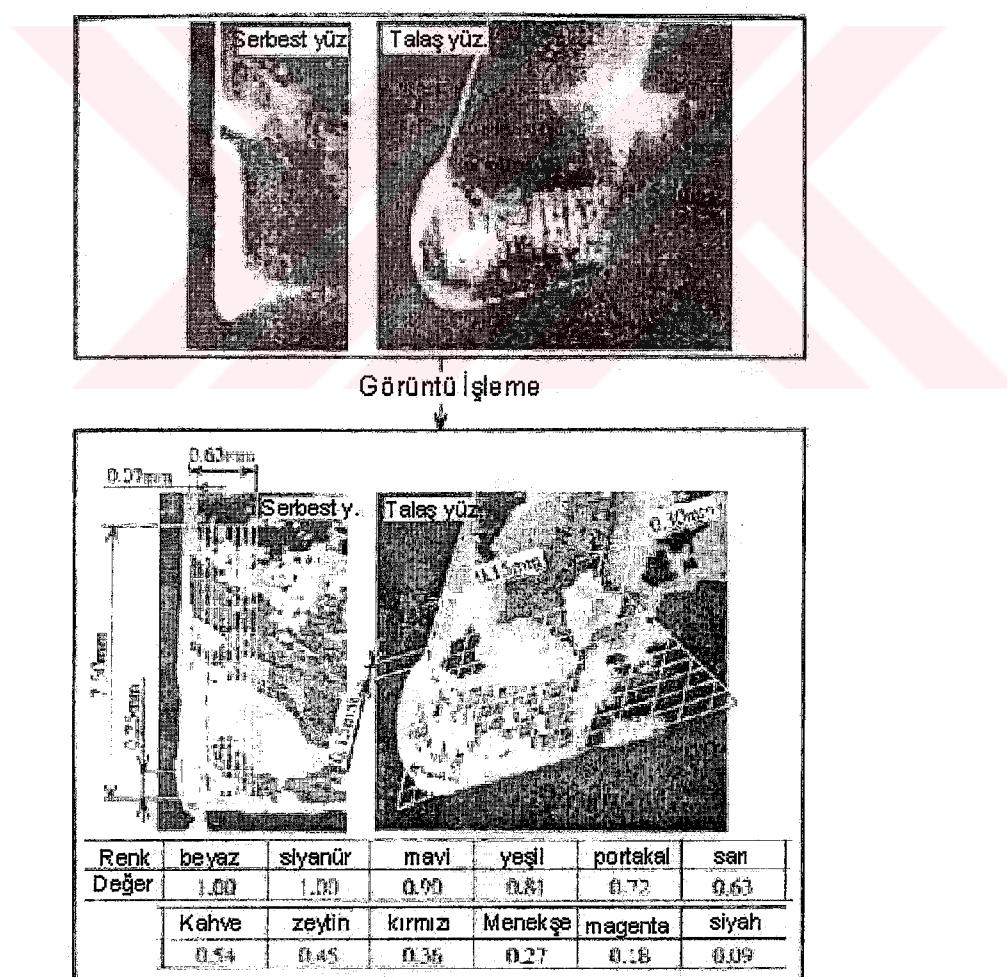


Şekil 3.7 Sistem kurulu (Teshima vd., 1993)

giderilebilir fakat krater ve serbest yüzey aşınmasından kaçış yoktur. Bu yüzden literatürdeki pek çok çalışma bu aşınma çeşitleri üzerinde odaklanmıştır.

Serbest yüzey aşınmasının iş parçası boyutlarına ve yüzey kalitesine en fazla etki eden aşınma çeşidi olduğu bilinmektedir. Otomatik imalat işlemlerinde kesici takım istenilen işi çıkarmada başarısızlığa düşmeden az evvel değiştirilmelidir ki iş parçası izin verilen tolerans değerlerinde üretilmeli.

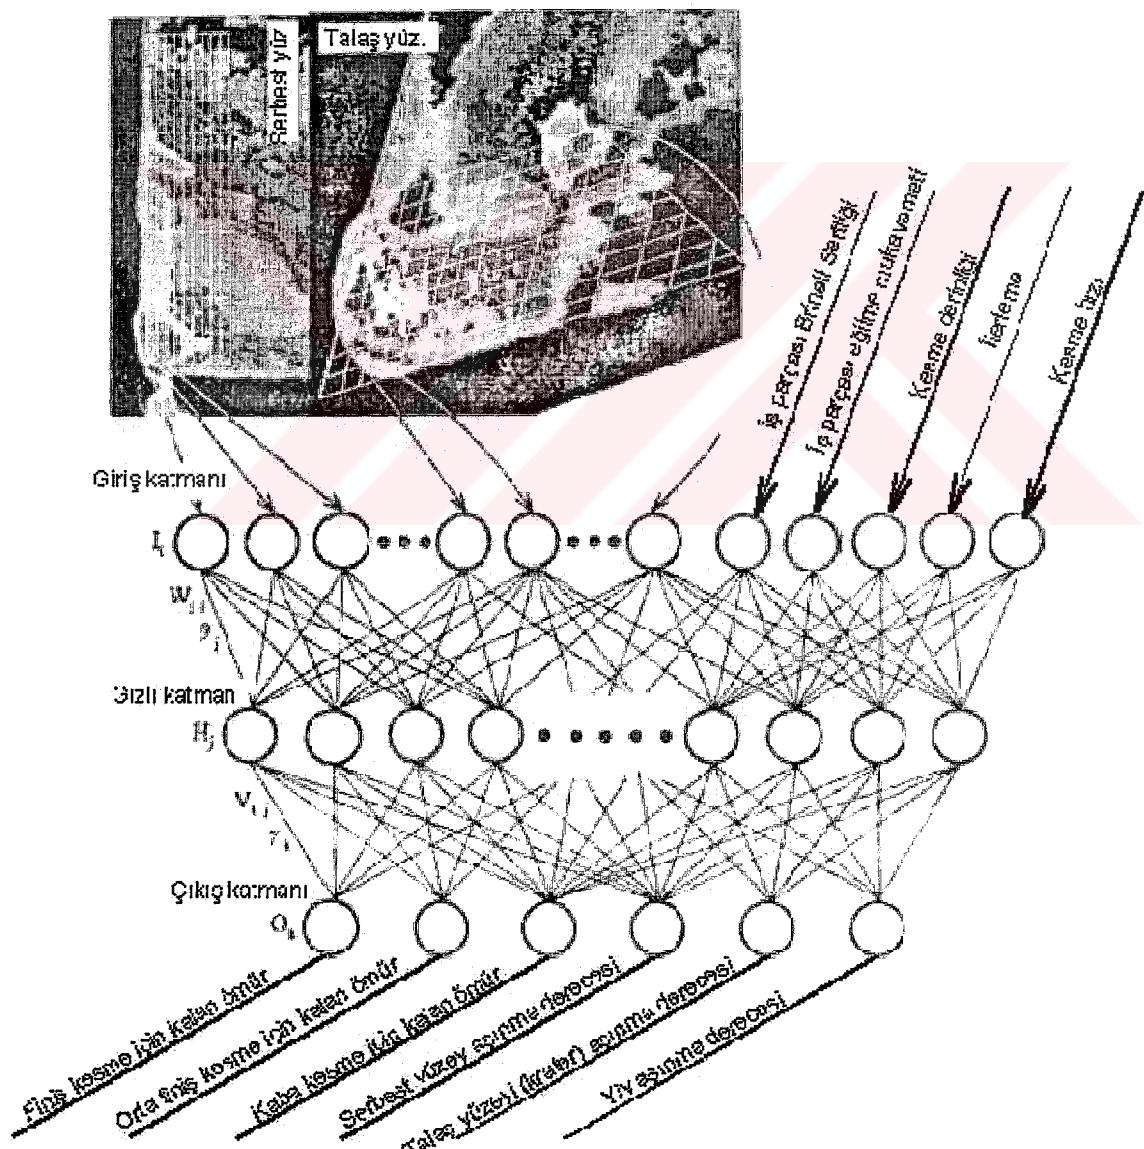
Takım aşınma takibi olarak ele alacağımız ilk çalışma Teshima vd. (1993) tarafından gerçekleştirilmiştir. Çalışmalarında önerdikleri yapay sinir ağı kesme şartlarından ve kesici takımın periyodik görüntülerinden yararlanarak kalan ömrü ve aşınma çeşidini tahmin etmektedir. Sistemin giriş verileri kamera görüntülerinden elde edilen serbest yüzey ya da krater aşınmasına göre kesici takımın durumu ve kesme şartlarıdır. Kamera görüntülerindeki yüzey pürüzlülüğüne, profile ve aşınma değerine göre değişen parlaklık kesici takım durumu



Şekil 3.8 Renkli görünüm verisinin oluşturulması (Teshima vd., 1993)

hakkındaki önemli bir ipucudur. Kesme şartlarından anlaşılan ise iş parçası malzemesi, kesici takım malzemesi, kesme derinliği, ilerleme ve kesme hızıdır. Bu giriş değerlerine karşılık gelen çıkış değeri ise kesici takımın kalan ömrü ve takımında oluşan aşınma çeşididir.

Laboratuar çalışması Şekil 3.7'de görüldüğü gibi bir kamera, video kaset kaydedici, renk veri kontrol cihazı, renk görüntü işleme kartı, kişisel bilgisayar ve renkli ekrandan oluşan bir düzenek ile gerçekleştirilmiştir. Takım durumunu gösteren görünüm bilgisi bu cihazlar tarafından sisteme verilmiştir. Kamera ve ışık mümkün olduğu kadar temiz görüntü alınabilecek şekilde sabitlenmişlerdir. Yüzey pürüzlülüğünden kaynaklanan farklı parlaklık dereceleri 12 değişik renge ayrıstırılarak renkli ekranda gösterilir. Parlaklıklarına göre bu renkler şöyle sıralanır; beyaz, siyanür, mavi, yeşil, portakal, sarı, kahverengi, zeytin, kırmızı,



menekşe, magenta, siyah. Şekil 3.8'de gösterildiği gibi birim alanlarda oluşan renklere karşılık gelen sayılar yapay sinir ağının giriş verilerindendir. Talaş yüzeyi 138, serbest yüzey ise 110 eşit birim alana ayrılmıştır.

Çalışmada Şekil 3.9'da gösterilen yapay sinir ağı kullanılmıştır. Ağ 253 işlem elemanlı giriş katmanı, 65 işlem elemanlı gizli bir katman ve 6 işlem elemanlı çıkış katmanından oluşmaktadır. Ağa öğretmede kullanılacak eğitim seti Çizelge 3.5'deki kesme şartlarında oluşturulmuştur. Örnekler düzenli zaman aralıklarıyla alınmıştır. Deneysel aşınma sonuçları da çizelgede gösterilmiştir. V_B , K_T ve V_N sırasıyla serbest yüzey aşınmasını, krater aşınmasını ve yiv aşınmayı gösterirler. Krater aşınması ekranda görülen aşınma alanının toplam incelenen alana oranı alınarak bulunmuştur. Takım ömrü kesme seslerine, talaş oluşumuna,

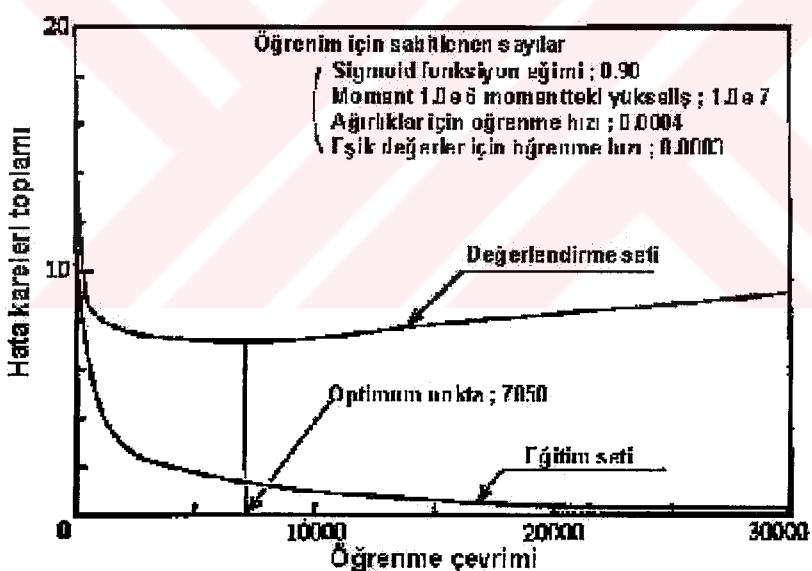
Çizelge 3.5 Deney kesme şartları ve sonuçları (Teshima vd., 1993)

No	İş parçası Malzemesi	Kesme Derinliği (mm)	İlerleme (mm/d.)	Kesme Hızı (m/dak.)	Kesme Prosesi	Takım Ömrü (Saniye)	Aşınma		
							V_B Mm	K_T %	V_N mm
A	Cr-Mo Çelik (SCM435)	1.5	0.24	100	Finiş	1096	0.20	13.5	0.49
					Orta-finiş	2004	0.18	15.5	0.51
					Kaba	2363	0.18	16.9	0.49
B	Cr-Mo Çelik (SCM435)	1.5	0.21	175	Finiş	181	0.18	17.5	0.00
					Orta-finiş	387	0.18	16.4	0.00
					Kaba	623	0.20	12.0	0.00
C	% 0.25C Çelik (S25C)	1.5	0.21	180	Finiş	829	0.09	18.7	0.23
					Orta-finiş	1160	0.17	18.1	0.37
					Kaba	1326	0.15	17.4	0.40
D	% 0.25C Çelik (S25C)	1.5	0.21	100	Finiş	1975	0.12	2.0	0.37
					Orta-finiş	2755	0.15	2.6	0.50
					Kaba	3916	0.47	2.5	0.65
E	Cr-Mo Çelik (SCM435)	1.0	0.24	145	Finiş	486	0.14	10.8	0.32
					Orta-finiş	956	0.26	17.7	0.48
					Kaba	1218	0.28	15.6	0.54
F	Cr-Mo Çelik (SCM435)	2.0	0.20	130	Finiş	750	0.17	13.5	0.21
					Orta-finiş	990	0.20	15.8	0.23
					Kaba	1314	0.24	20.1	0.34
G	Cr-Mo Çelik (SCM435)	1.0	0.33	90	Finiş	616	0.15	2.1	0.00
					Orta-finiş	1068	0.19	2.1	0.15
					Kaba	1490	0.23	7.2	0.25
H	Cr-Mo Çelik (SCM435)	2.0	0.24	90	Finiş	1209	0.26	8.4	0.37
					Orta-finiş	1760	0.26	12.5	0.42
					Kaba	2537	0.31	21.1	0.62
I	% 0.25C Çelik (S25C)	1.0	0.35	100	Finiş	590	0.08	3.6	0.00
					Orta-finiş	947	0.08	4.3	0.08
					Kaba	1293	0.09	2.5	0.12
J	% 0.25C Çelik (S25C)	2.0	0.24	100	Finiş	530	0.08	7.0	0.11
					Orta-finiş	1015	0.11	14.5	0.20
					Kaba	1685	0.14	18.6	0.28

Takım (-5°, -5°, 5°, 5°, 30°, 0°, 0.4 mm) P20, % ; krater aşınma alanının görüntülenen alana oranı

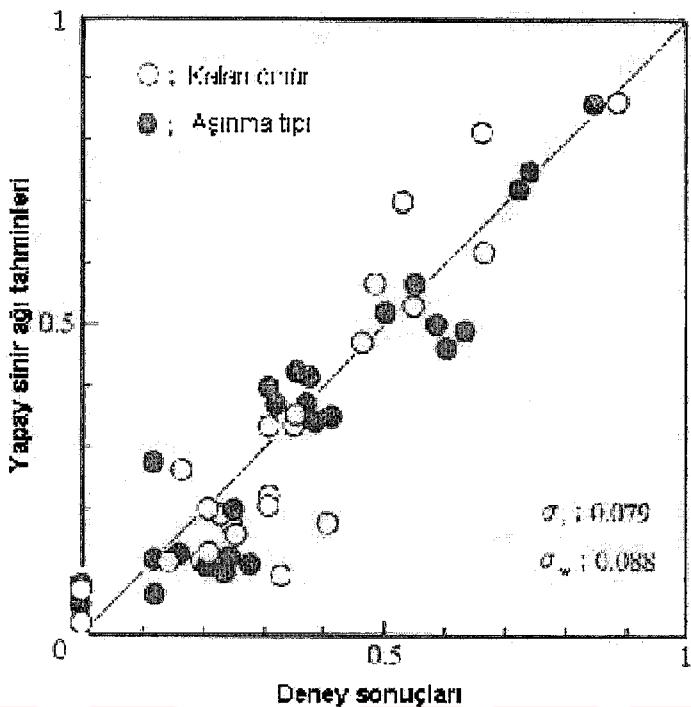
talaş rengine ve yüzey kalitesine bakılarak belirlenmiştir. Ağdan çıkış olarak alınan takım ömrü tahmini ve aşınma çeşidi sinyalleri [0,1] aralığında normalize edilmiştir. Toplam 80 adet örnek eşleştirme oluşturulmuştur.

Hata fonksiyonunda lokal minimuma düşmekten kurtulmak için momentum terimi delta kuralına eklenmiştir. Bu çalışmayı diğer bazı çalışmalarдан ayıran önemli bir husus da ağın öğrenimini sonlandırmak için farklı bir mekanizmanın kullanılmasıdır. Öğrenme esnasında diğer bir giriş-çıkış veri seti değerlendirme için kullanılmıştır. Şekil 3.10'da görüldüğü gibi eğitim seti için hata kareleri toplamı hesaplanırken, değerlendirme setinin de hata kareleri toplamı takip edilmiştir fakat değerlendirme seti yapay sinir ağının eşleştirme adaptasyonunda kılavuz olarak kullanılmamıştır. Eğer değerlendirme setindeki hata yükselirken öğrenim setindeki hata düşmeye başlamışsa ağ öğrenim seti üzerinde fazlaca uzmanlaşmaya başlamış demektir. Bundan dolayı değerlendirme setinin hata toplamının minimuma ulaşığı yeri öğrenimi sonlandırma noktası olarak alabiliriz. Bu tip bir mekanizma az sayıda bir öğretim seti ile genel bir öğrenime ulaşmaktaki zorluktan dolayı kullanılmıştır.



Şekil 3.10 Öğrenme çevrimi ve hata kareleri toplamı arasındaki ilişki (Teshima vd., 1993)

Eğitim safhası bittikten sonra daha önce ağın karşılaşmadığı 10 eşleştirme ile test yapılmıştır. Sonuçlar Şekil 3.11'de görüldüğü gibidir. Beyaz noktalar kalan takım ömrü tahminlerini, siyah noktalar ise aşınma tipi tahminlerini göstermektedir. Şekildeki σ_t ve σ_w sırasıyla ömrü ve aşınma standart sapmalarını belirtmektedir. Noktalar 45° eğrisine oldukça yakın olduklarından tahminlerin yerinde olduğunu söyleyebiliriz. Çizelge 3.6'da verilen tahminler ve deneysel sonuçlarda da büyük farklılıklar yoktur. Sonuçlar önerilen bu sistemin karar



Şekil 3.11 Yapay sinir ağı ve deney sonuçlarının karşılaştırılması (Teshima vd., 1993)

Çizelge 3.6 Sistem çıkış örnekleri (Teshima vd., 1993)

No	Kesme ucunun renkli görünümü ve giriş-çıkış parametreleri	Deney sonuçları		Sistem çıkışları	
1	<p>İş p.; Cr-Mo çelik, Kesme der.; 1.5mm, İI; 0.23mm/devir, k. hızı; 105m/dak (SCM435)</p>	Kalan ömür	Finiş kesme Orta finiş kesme Kaba kesme	0.000 (0 s.) 0.207 (621s.) 0.245 (980s.)	0.026 (52 s.) 0.108 (324s.) 0.177 (708s.)
		Aşınma tipi	Serbest yüzey a. Krater aşınması Yıl aşınma	0.531 (0.186 mm) 0.487 (% 11.20) 0.662 (0.430mm)	0.681 (0.328 mm) 0.568 (% 13.06) 0.786 (0.511mm)
		Kalan ömür	Finiş kesme Orta finiş kesme Kaba kesme	0.000 (0 s.) 0.000 (0s.) 0.059 (236s.)	0.022 (44 s.) 0.162 (486s.) 0.044 (176s.)
		Aşınma tipi	Serbest yüzey a. Krater aşınması Yıl aşınma	0.517 (0.181mm) 0.713 (% 16.40) 0.252 (0.164mm)	0.547 (0.191mm) 0.834 (% 19.18) 0.201 (0.131mm)
		İş p.; Cr-Mo çelik, Kesme der.; 1.5mm, İI; 0.18mm/devir, k. hızı; 160m/dak (SCM435)			
		Kalan ömür	Finiş kesme Orta finiş kesme Kaba kesme	0.000 (0 s.) 0.000 (0s.) 0.194 (776s.)	0.091 (182 s.) 0.037 (111s.) 0.189 (756s.)
3	<p>İş p.; %0.25C çelik, Kesme der.; 1.5mm, İI; 0.21mm/devir, k. hızı; 100m/d. (SCM435)</p>	Aşınma tipi	Serbest yüzey a. Krater aşınması Yıl aşınma	0.749 (0.262mm) 0.543 (% 12.49) 0.711 (0.462mm)	0.548 (0.204mm) 0.540 (% 12.42) 0.473 (0.307mm)

vermede en fazla %16 ve %24 arasında bir hata payının olduğunu ispatlamıştır. Eğitim setinin, ağıda yer alan gizli katman ve işlem elemanı sayılarının artırılması sistemin doğruluğunu daha iyi bir seviyeye getirecektir.

Takım aşınmasını takip edebilmek için iki metod mevcuttur. Direk metoddə takım aşınması direkt olarak takım üzerinden hacimsel kaybın ölçülmesiyle gerçekleştirilir. Endirek metoddə ise takım aşınmasının bazı sonuçları üzerinde durulur ve bunlar ölçülmeye çalışılır. Direk metod ile atölye ortamlarında kesici takım çalışırken ölçüm yapabilmek oldukça zordur. Endirek metoddə ise ölçümlerin sadece aşınmadan değil takım geometrisinin, iş parçası malzemesinin ve kesme şartlarının da değişimlerinden etkilenmesi dezavantajdır. Pek çok çalışmada tek bir sensorun verdiği bilgilerle takım aşınma derecesine karar vermekte yetersiz kalınmıştır. Robot uygulamalarında çok büyük bir atılma sebep olan bir çok sensorun verilerini birleştirme denemeleri talaşlı imalatta da denenmeye başlanmıştır. Değişik güvenirliklerde olsa da kesici takım durumu hakkında bilgi verebilecek birkaç sensorun çıkış verilerini birleştirmekle amaçlanan şartlar hakkında algılananın doğruluğunun artırılması ve şüphelerin giderilmesidir.

Sensor sinyallerinin birleştirmelerinde (sensor fusion) yapay sinir ağlarının kullanımından önce uygulanan fonksiyon teknikleri uzun zaman alan ve gerçek zamanlı proseslerde uygulanması zor çalışmalardır. Bu erken çalışmaların güçlüklerin üstesinden gelmek için ilk kez Rangwala ve Dornfeld (1987) yapay sinir ağıyla tornalama işleminde plaket kesici takım için akustik yayınım (acoustic emission) ve kuvvet sensorlarıyla elde edilen ölçümleri birleştirerek serbest yüzey aşınmasını izlemekte uygulanabilirlik fizibilitesini yapmışlardır. Dornfeld 1990'da çoklu sensor birleştirmelerinin etkinliğini test edebilmek için yeni bir çalışma yaptı. Bu çalışmada tornalama işleminde akustik yayınım, kuvvet ve ana mil motor akım sensor sinyallerini yapay sinir ağından geçirerek gelişen takım aşınmasını izlemekte kullandı. Bu sensorlardan alınan sinyaller otoregresif dizi model parametrelerine ya da güç spektrumu dalga genliklerine çevrilerek işlendi. Sinyallerin kesici takım aşınmasına en hassas olan kısımları önceden eğitilmiş bir yapay sinir ağına aktararak kesici takım durumu hakkında son kararın verilmesinde kullanıldı. Takım aşınmasını belirleyebilmek için giriş ve çıkış verilerinin birbirleriyle eşleştirilerek ağırlıklarının ve eşik değerlerinin ayarlanmasımda yani kıscası öğrenmenin gerçekleştirilmesinde hatanın geriye yayınımı algoritması kullanılmıştır.

Akustik yayınım, kuvvet ve ana mil motor akımı sırasıyla kesici takımına yerleştirilen bir akustik yayınım sensoru, fikstüre yerleştirilen bir dinamometre ve ana mil güç hattına

konumlanan bir elektromanyetik akım sensoru tarafından ölçülmüştür. Eğitim ve test amaçlı iki set elde edilmiştir. Her bir deney grubunda 10.2 cm çapında AISI 4340 silindirik çubuklar yeni ya da belli bir miktar aşınmış kesici takım ile tornalanmıştır. Aşınmış olarak kullanılan kesici takımların serbest yüzeylerinde 1.0 mm genişliğinde bir aşınma alanı mevcuttur. Kesme şartları kesme derinliğinde 0.127-2.032 mm, ilerlemede 0.254-1.778 mm/devir ve kesme hızında 76.2-106.7 m/dak. arasında değişmektedir.

Çıkış işlem elemanından alınan çıkış verisinin 0.5'den büyük olması halinde kesici takımın aşınmış olduğuna karar verilmiştir. Aşınma tahmininin verimliliği üzerine değişik denemelerde bulunulmuştur. Bunlardan ilki sinyallerin işlenmesinden doğan değişik giriş verilerinin başarıya etkisini görmek için yapılmıştır. Çizelge 3.7'de de görüldüğü gibi ağın en verimli olduğu optimum veri giriş sayısı 6'dır.

Çizelge 3.7 Giriş veri sayısının ağın verimliliğine etkisi (Dornfeld, 1990)

Giriş Veri Sayısı	Doğru Tanıma Oranı (%)
2	93
4	95
6	96
8	82
10	73

Çizelge 3.8 de gizli katmandaki işlem elemanı sayısının değişimiyle etkilenen ağ performansını göstermektedir. Bu çalışmada olduğu gibi görece basit giriş-çıkış veri eşleştirmelerinde çok geniş ağ yapılarına ihtiyaç yoktur. Verimlilik adına tahmin sisteminin performansı çok fazla değişimeyecekse küçük yapılı yapay sinir ağı tercih edilmelidir. Nitekim Dornfeld'in bu çalışmasında kullanılan yapay sinir ağı 6-4-1 yapısındadır. (6 giriş işlem elemanı, 4 gizli katman işlem elemanı, 1 çıkış işlem elemanı)

Çizelge 3.8 Gizli katman işlem elemanı sayısının ağın verimliliğine etkisi (Dornfeld, 1990)

Gizli Katman İşlem Elemanı Sayısı	Doğru Tanıma Oranı (%)
2	94
4	96
6	96
8	95
10	91

Eğitilen yapay sinir ağının performansı Çizelge 3.9, 3.10 ve 3.11'de görüldüğü gibi çok geniş kesme şartlarında test edilmiştir. Bu çizelgelerden anlaşıldığı kadarıyla ağır kesme şartlarında ağın tahminleri biraz daha iyidir.

Çizelge 3.9 Değişen kesme derinliklerinde ağın performansı (Dornfeld, 1990)

Kesme Derinliği (inç)	Doğru Tanıma Oranı (%)
0.005	92
0.01	97
0.02	100
0.04	98
0.06	100
0.08	100

Çizelge 3.10 Değişen ilerlemelerde ağın performansı (Dornfeld, 1990)

İlerleme (in/devir)	Doğru Tanıma Oranı (%)
0.01	98
0.04	100
0.07	100

Çizelge 3.11 Değişen kesme hızlarında ağın performansı (Dornfeld, 1990)

Kesme Hızı (ft/dak)	Doğru Tanıma Oranı (%)
250	100
350	100

Bütün bu denemelerin yanında ikili sensor kombinasyonlarından hangilerinin daha iyi bir tanıma yaptığı da test edilmiş ve Çizelge 3.12'deki sonuçlar bulunmuştur.

Çizelge 3.12 Değişik sensor kombinasyonlarında ağın performansı (Dornfeld, 1990)

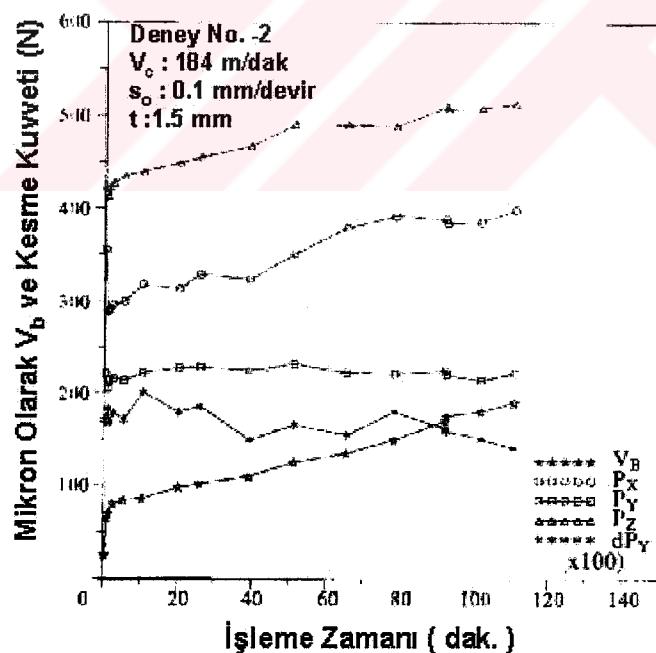
Sensor Kombinasyonu	Doğru Tanıma Oranı (%)
Akustik Yayım + Kuvvet	95
Kuvvet + Akım	73
Akustik Yayım + Akım	62

Kesici takım aşınma takibinde yapay sinir ağrı yardımıyla yalnızca kuvvet ölçümlerini esas alan da pek çok çalışma yapılmıştır. Santanu vd. (1996) buna iyi bir örnektir. Bu çalışmada hedef karbür plaketlerle yapılan bir tornalama işleminde basit fakat güvenilir aynı zamanda ekonomik bir takım durum takip sistemi oluşturmaktır. İş parçası malzemesi C-25 çeliğidir.

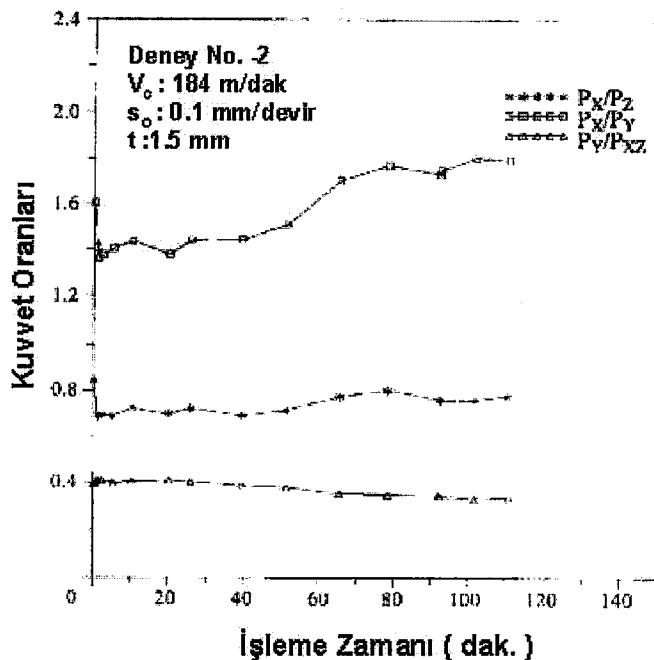
Çizelge 3.13 Deney seviyeleri (Uygulamalar) (Santanu vd., 1996)

Uygulama No	Kesme Hizi V_c (m/dak)	İlerleme s_o (mm/devir)
1	118	0.10
2	184	0.10
3	118	0.24
4	184	0.24
5	148	0.16
6	148	0.16

Kesme kuvveti bileşenleri olan P_x , P_y ve P_z Kistler marka bir dinamometre ile ölçülmüş, sisteme aynı zamanda ampilifikatör ve FFT hızlı fourier dönüşüm analiz cihazı da ilave edilmiştir. Kuvveti etkileyen aşınmadan farklı faktörlerin ölçümülerin sonuçlarına karışmaması için 40 ms süreli 5 sinyal çerçevesinin ortalaması alınmıştır. Optik mikroskop ile düzenli aralıklarla ölçülen ortalama serbest yüzey aşınması V_B ve buna paralel kuvvet sinyalleri kaydedilmiştir.



Şekil 3.12 Yüksek hız düşük ilerlemede işleme zamanıyla aşınmanın artışı ve kuvvet bileşenlerindeki değişim(Santanu vd., 1996)



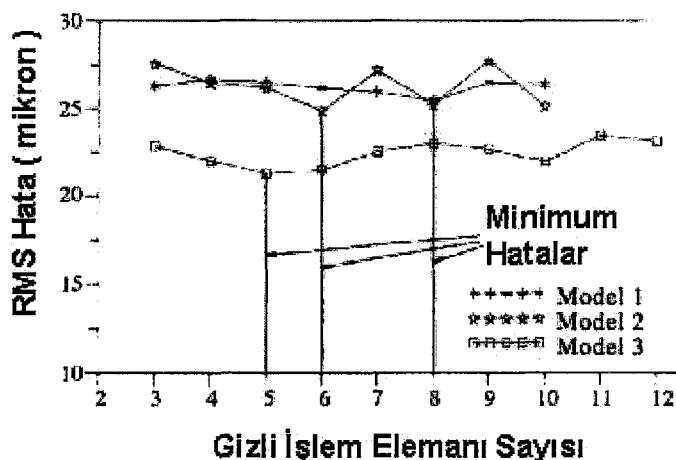
Şekil 3.13 Yüksek hız düşük ilerlemeye işleme zamaıyla kuvvet oranlarındaki değişim
(Santanu vd., 1996)

Deneyde kullanılan kesme şartları Çizelge 3.13'de verilmiştir. Şekil 3.12 ve 3.13'deki grafiklere göre kuvvet-aşınma ilişkileri yapay sinir ağına hangi bilgilerin giriş olarak verilebileceğini belirlemek için tek tek irdelemiştir. Teget kuvvet P_x , aşınmanın artması ile yükselmeye başlamıştır. Bunun altında yatan ana neden aşınma yüzünden sürüünmenin artmasıdır. Enine kuvvet P_y 'de ise farkedilir bir değişme olmamıştır. Temel kesme ucu açısının büyümesi ve ilerleyen aşınma safhalarında derin çentik oluşumu bunun muhtemel sebebidir. Ölçümlerde ard arda sinyallerin tepe ve çukur noktalarının birbirinden çıkarılmasıyla bulunan ve dP_y olarak gösterilen dinamik enine kuvvet ise artan aşınma ile düşüş göstermektedir. Buna neden sönümlenmenin yükselmesi olmalıdır.

Çizelge 3.14 Kullanılan yapay sinir ağ modelleri (Santanu vd., 1996)

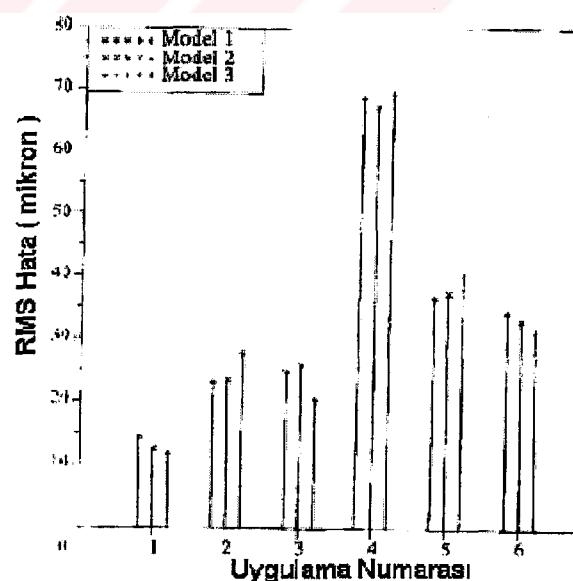
Model Numarası	Giriş Değişkenleri	Yapı
1	V_c, S_o, P_x, P_y, P_z	5-8-1
2	$V_c, S_o, P_x, P_z, P_x/P_z, P_x/P_y$	6-6-1
3	$V_c, S_o, P_x, P_z, P_x/P_z, P_x/P_y, P_y/P_{xz}, dP_y$	8-5-1

P_x/P_z oranı Şekil 3.13'de görüldüğü gibi artan aşınmaya bağlı olarak yükselseme eğilimi içindedir. Bu da büyük ihtimalle sürtünmenin artmasıyla ilerleme kuvveti P_x 'in de artmasından dolayıdır. P_x/P_y oranının artış halinde olacağı önceki grafikte görülen P_x ve P_y eğilimlerine göre beklenen bir şeydir. P_y 'nin P_x ve P_z bileşkesi ile oranında ise aşınmanın bir miktar etkisi olduğu anlaşılmaktadır.



Şekil 3.14 Eğitimde gizli işlem elemanı sayısının RMS hataya etkisi (Santanu vd., 1996)

Çalışmada kullanılan yapay sinir ağının geriye yayınımı algoritmasıyla eğitilen 3 katmanlı bir ağdır. Eğitimde 80 adet normalize edilmiş giriş-çıkış örneği kullanılmıştır. İşlem

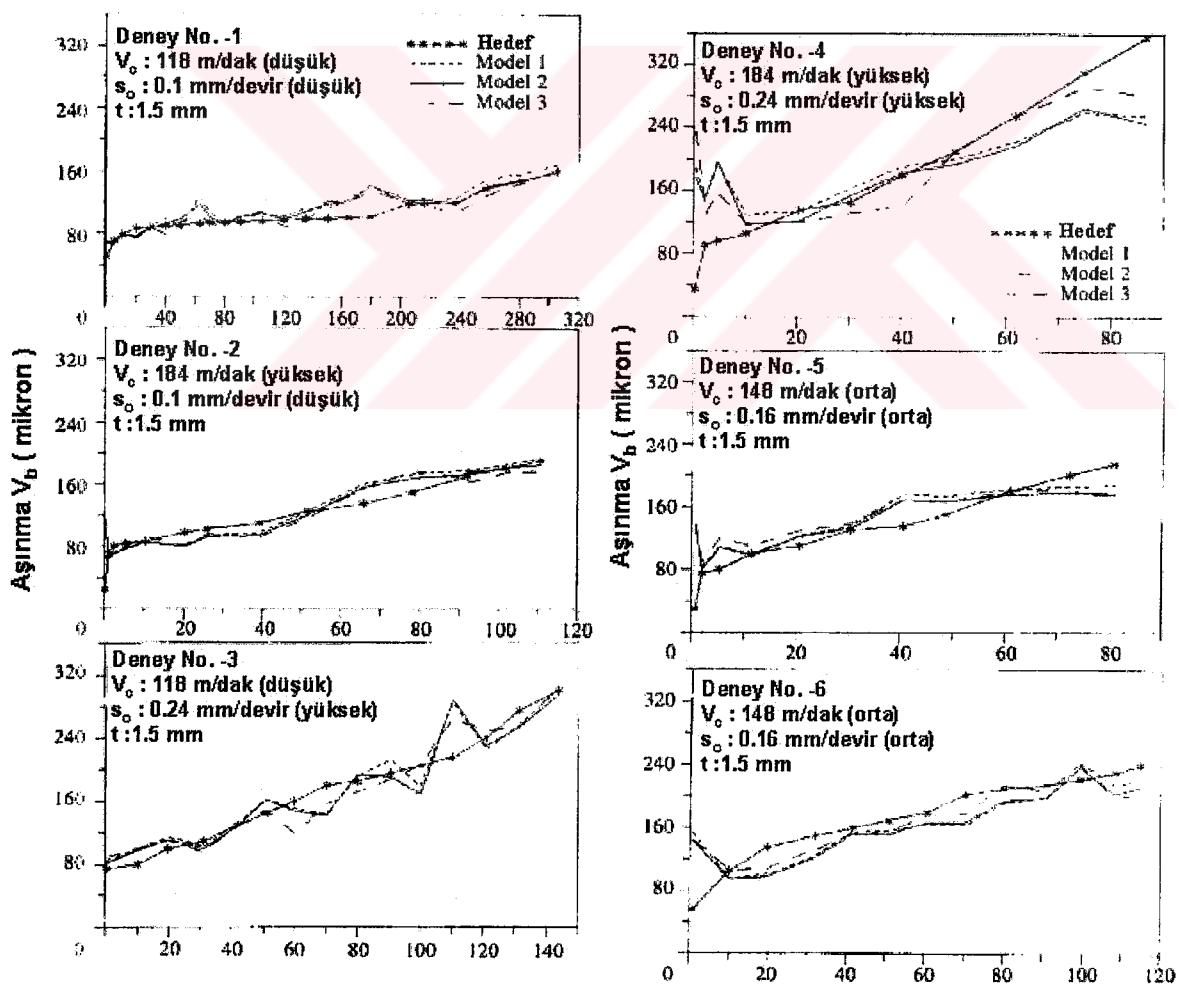


Şekil 3.15 Modellerin değişik uygulamalardaki hata karşılaştırması (Santanu vd., 1996)

elemanlarının ağırlıkları ve eşik değerleri ± 3 aralığında rastgele olarak başlatılmışlardır. Öğrenme hızı ve momentum faktörleri sırasıyla 0.075 ve 0.12 olarak seçilmiştir. Transfer fonksiyon olarak sigmoid fonksiyon kullanılmıştır.

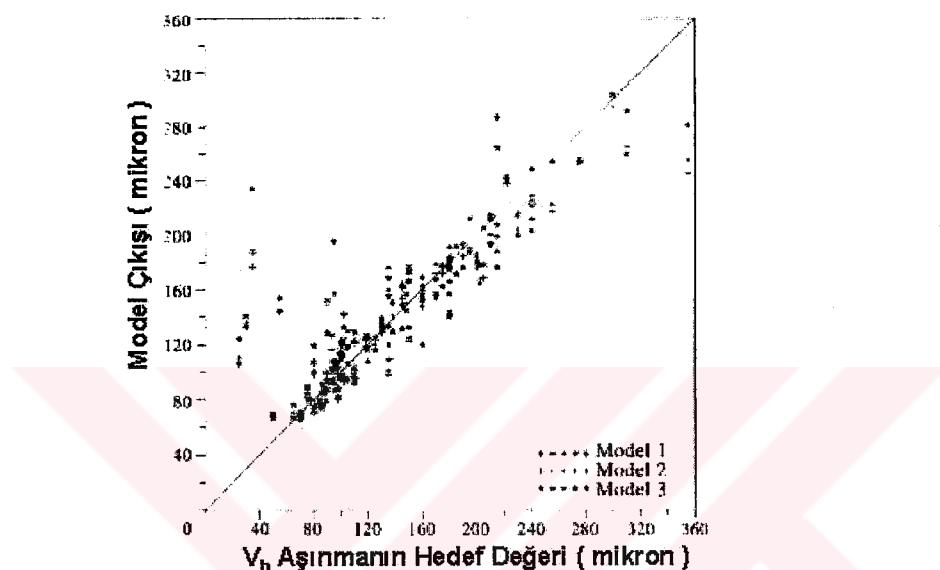
Eğitimde 4 000 ile 20 000 çevrim arasındaki hata kareleri ortalaması (Root mean square=RMS) çok düşük de olsa bu değerin sıfıra iyice yaklaşılması için 20000 çevrim uygulanmıştır. Eğitimden sonra 113 örnek üzerinde test çalışması yapılmıştır.

Çizelge 3.14'de görüldüğü gibi 3 değişik yapay sinir ağ modeli üzerinde çalışılmıştır. Bu modellere paralel olarak Şekil 3.14'de görüldüğü gibi oluşan hatanın değerine göre gizli katman işlem elemanı sayıları belirlenmiştir. Şekil 3.15'de ise Çizelge 3.13'deki 6 farklı uygulamaya paralel RMS hata değerleri verilmiştir. Üç model de aşınma tahmin değerlerini doğruya çok yakın yapmışlardır. Düşük ilerleme-hız kombinasyonlarında ve düşük ilerleme-yüksek hız kombinasyonlarında modellerin tahminleri birbirine yakındır. (Şekil 3.16)

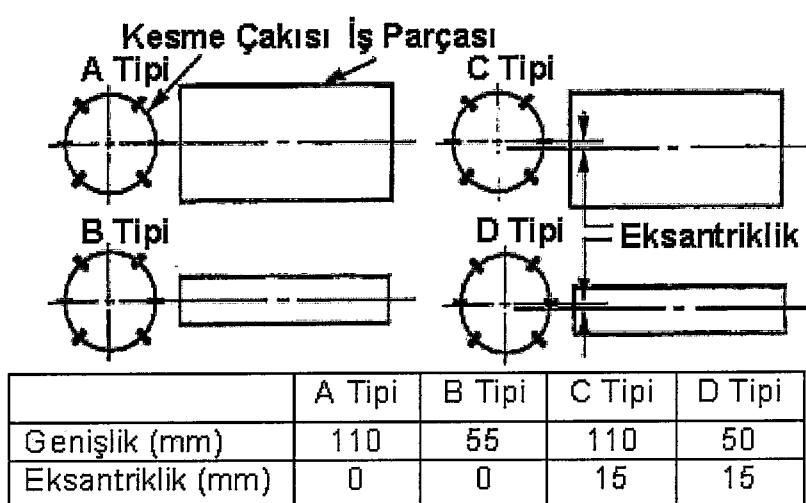


Şekil 3.16 Direkt olarak ölçülen aşınma miktarları ve değişik ağ modellerinin tahminleri (Santanu vd., 1996)

Düşük hız–yüksek ilerleme ve orta hız–ilerleme kombinasyonlarında da bazı sapmalar olsa da tahminlerin birbirine uyumu söz konusudur.(Şekil 3.16) Bu sapmaların sebebi yüksek ilerlemelerde yiğma ağız oluşumundan dolayı kuvvet sinyallerindeki dalgalanmalar olabilir. Bu kesme şartlarında yiğma ağız oluşumu deneyel olarak gözlemlenmiştir. Şekil 3.17'de hedef değerler ile tahminler arasında bir karşılaştırma yapılmıştır. Sonuç olarak model 3'ün genel anlamda tahminlerinin olması gereken değerlere daha yakın bulunduğu görülmüştür.



Şekil 3.17 Değişik ağ modellerinin aşınma tahmin doğruluk dereceleri (Santanu vd., 1996)



Şekil 3.18 İş parçası geometrisi (S.C.Lin ve R.J.Lin, 1996)

Santanu vd. (1996) çalışmasına benzer bir başka çalışma S.C.Lin ve R.J.Lin (1996) tarafından yapılmıştır. Bu çalışmada giriş verileri olarak ortalama kesme kuvvetlerinin ve ilerlemenin yanı sıra iş parçası geometrisi gibi farklı değerler de kullanılmıştır. Uygulamada yapay sinir ağı ortalama serbest yüzey aşınma miktarını tahmin etmek üzere eğitilmiştir. Gizli katman sayısı iki tane tutularak dört katmanlı bir ağ yapısı kullanılmıştır. Güzel bir yaklaşım kolaylık için ağ K-L-M-N sembolleriyile simgelenmiştir. Burada K, L, M, N sırasıyla giriş katmanı, birinci gizli katman, ikinci gizli katman ve çıkış katmanı işlem elemanı sayılarını ifade etmektedir. Kullanılan veri normalize edilerek ağa girişi yapılmıştır.

Transfer fonksiyonu pek çok çalışmadan farklı olarak hiperbolik teget fonksiyondur. İşlem elemanı çıkışı bu fonksiyona göre;

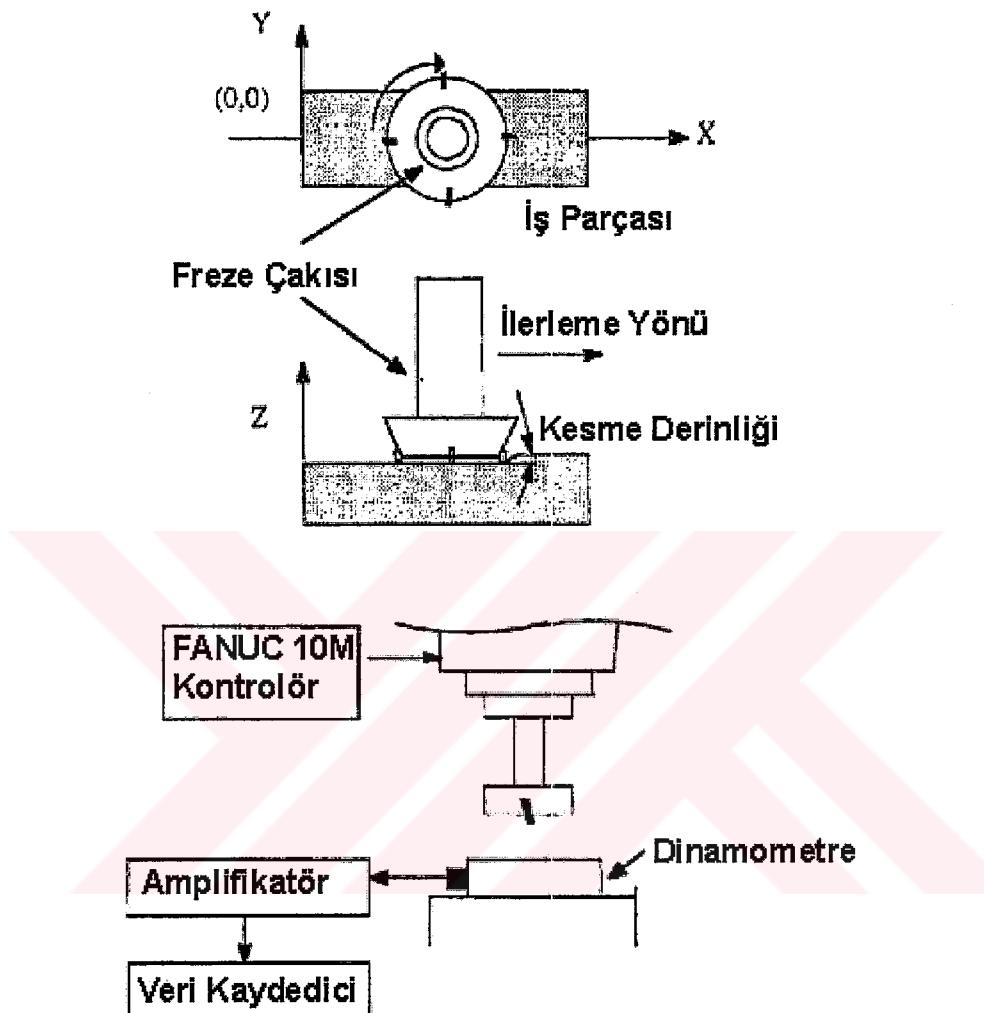
$$Y_i = \frac{\text{Exp}(S_j) - \text{Exp}(-S_j)}{\text{Exp}(S_j) + \text{Exp}(-S_j)} \quad S_i = \sum_{j=1}^N X_j W_{ji} \quad (3.5)$$

şeklindedir.

Geriye yayının algoritması için kullanılan delta kuralında momentum terimine yer verilmemiştir. Yapay sinir ağının eğitilmesi için değişen kesme koşullarında deneyler yapılmıştır. Deneyler 55 ve 110 mm olmak üzere iki değişik iş parçası çapına göre, 0 ve 15 mm'de iki farklı freze çaklı eksantrikliğinde, 0.1, 0.5 ve 0.9 mm'de üç değişik aşınma değerinde ve 0.05, 0.1 ve 0.15 mm/dış olarak üç seviyede ilerlemeye gerçekleştirilmişdir. Şekil 3.18'de kullanılan iş parçası geometrileri verilmiştir. Karbür plaketlerdeki (SECO S25M) istenen aşınma seviyesi yumuşak çeliğin işlenmesiyle elde edilmiştir. Şekil 3.19'da testlerde kullanılan freze çaklı geometrisi, frezeleme işleminin geometrisi ve deney düzeneği gösterilmiştir.

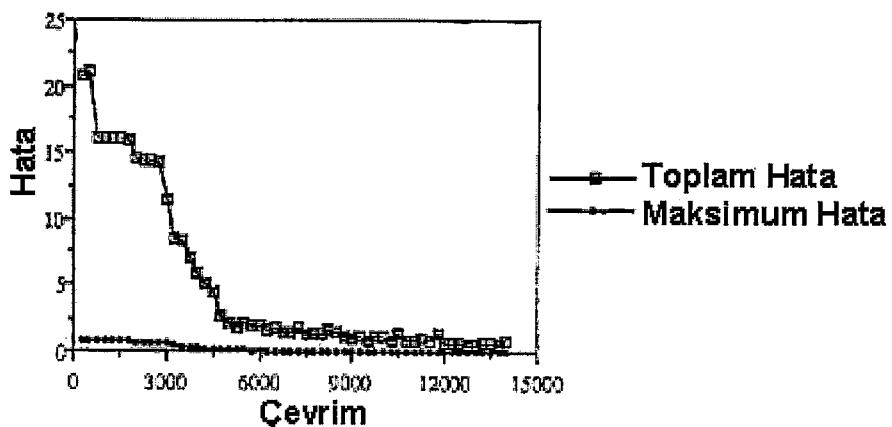
Frezelemede kesme kuvetinin aşınmadan dolayı arttığı bir geçektir fakat kesme kuvveti yalnız aşınmadaki değişimlerden değil iş parçası geometrisindeki, kesme şartlarındaki, freze çaklı geometrisindeki değişimlerden de etkilenir. Çalışmada x ve y eksenlerindeki ortalama kesme kuvvetleri, freze çakisının eksantrikliği, iş parçası geometrisi, ilerleme ve freze çakisı dış sayıları giriş parametreleri olarak kullanılmış yalnızca ortalama aşınma tahmini çıkış verisi olarak alınmıştır.

Çaklı Yarıçapı	Eksenel Talaş Açısı	Radyal Talaş Açısı	Dayanma Açısı	Uç Yarıçapı
53 mm	5°	5°	15°	0.8 mm



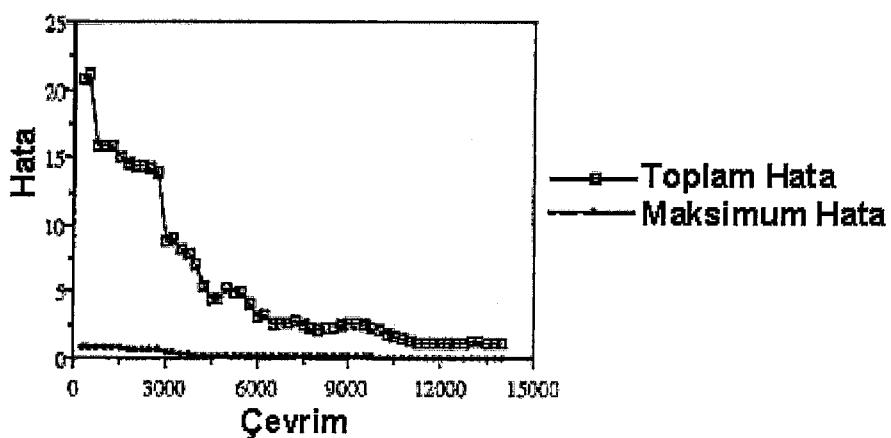
Şekil 3.19 Freze çaklı geometrisi, frezeleme işleminin geometrisi ve deney düzeneği (S.C.Lin ve R.J.Lin, 1996)

İşlem elemanlarının sayı değişimlerinin performans üzerindeki etkisinden bu çalışmada da bahsedilmiş ve en iyi konfigürasyona ulaşabilmek için üç farklı model denenmiştir. Bu modeller 6-24-12-1, 6-18-9-1 ve 6-12-6-1 şeklindedir. Eğitimin sonlandırılması kriteri hatanın belli bir sayının altına indirilmesi tarzındaki klasik yöntemdir. Şekil 3.20, 3.21 ve 3.22'de görüldüğü gibi 6000 eğitim çevrimi eğitim için yeterlidir fakat çalışmada üç model için de 14000 çevrim yapılmıştır.

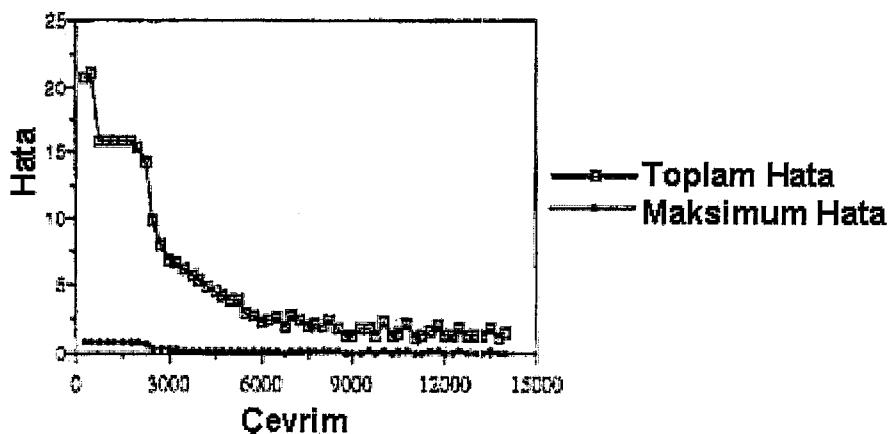


Şekil 3.20 Öğrenim hatasının değişimi, ağ yapısı:6-24-12-1 (S.C.Lin ve R.J.Lin, 1996)

Ortalama hatanın işlem elemanı sayısı az olan modelde; 6-12-6-1 ağ yapısında daha yüksek çıktıgı görülmüştür. Üç model de çok iyi eğitilmişlerdir çünkü üçü için de kesin hata 0.05 mm'den, ortalama kesin hata da 0.014 mm'den büyük değildir.



Şekil 3.21 Öğrenim hatasının değişimi, ağ yapısı:6-18-9-1 (S.C.Lin ve R.J.Lin, 1996)



Şekil 3.22 Öğrenim hatasının değişimi, ağ yapısı:6-12-6-1 (S.C.Lin ve R.J.Lin, 1996)

Eğitilen ağların kullanılabilirliğini anlayabilmek için 10 ekstra test örneğinde aşınma tahminleri alınmıştır. Bu aşamadaki en önemli özellik testlerde kullanılan kesme çakısı eksantrikliğinin, iş parçası genişliğinin ve ilerleme değerlerinin değiştirilmiş olmasıdır. Yapılmak istenen, denenen yapay sinir ağlarının genelleme gücünün ölçülmüşidir. Çizelge 3.15'de testlerde değiştirilen koşullar gösterilmektedir. Bu çalışmada nümerik metodlarla oluşturulan iki farklı fonksiyonun da uygulanabilirliği ölçülmüştür. Bu fonksiyonlar regresyon metoduyla oluşturulmuştur. Çizelge 3.16'da ölçülen ve tahmin edilen aşınma değerleri verilmiştir. Sonuçlar açıkça ortaya koymaktadır ki, yapay sinir ağı modelleri için maksimum tahmin hatası 0.21 mm'den ve ortalama hata da 0.065 mm'den daha yüksek değildir.

Çizelge 3.15 Ekstra doğrulama testlerinde kullanılan kesme parametreleri (S.C.Lin ve R.J.Lin, 1996)

Test No.	Genişlik (mm)	Eksantriklik (mm)	İlerleme (mm/dış)	Aşınma (mm)	Dış Sayısı
t ₁	110	0	0.075	0.1	1
t ₂	75	0	0.075	0.5	5
t ₃	75	0	0.125	0.9	6
t ₄	55	0	0.125	0.1	1
t ₅	75	5	0.125	0.9	1
t ₆	75	5	0.125	0.1	3
t ₇	55	5	0.075	0.5	5
t ₈	110	10	0.125	0.9	6
t ₉	75	10	0.125	0.1	6
t ₁₀	55	10	0.075	0.9	3

Konfigürasyon olarak da en fazla işlem elemanına sahip olan 6-24-12-1 ağı en iyi performansı vermiştir. Nümerik metodlarla bulunan değerler de çok kötü olmamakla beraber kullanılabilmeleri için ayrıca ortalama talaş kalınlığının, ortalama kuvvet katsayılarının veya sürtünme kuvvet katsayısının bilinmesine ihtiyaç vardır.

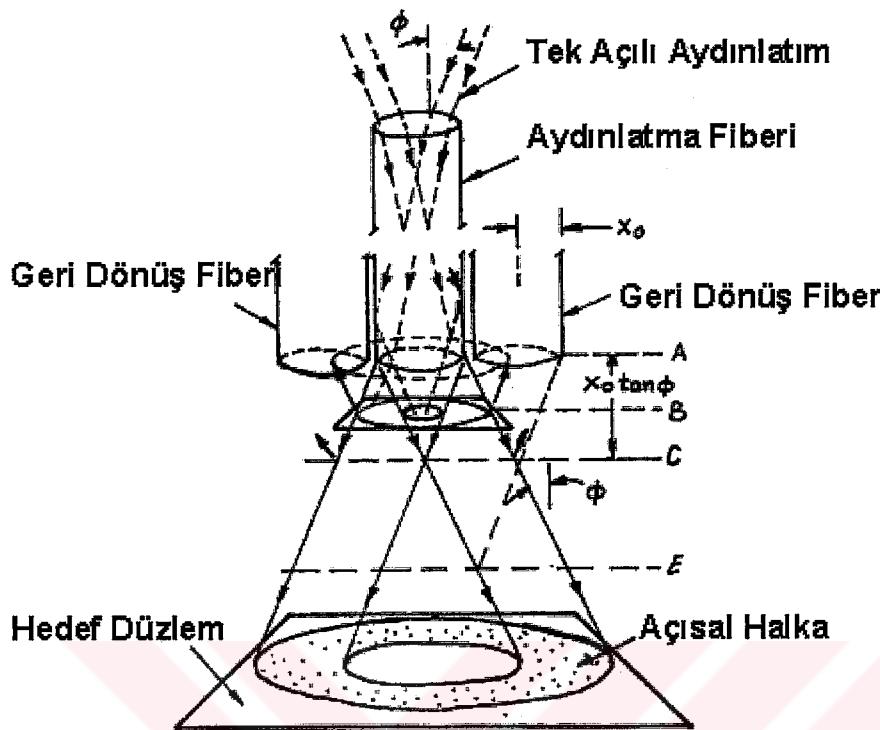
Çizelge 3.16 Ölçülen ve tahmin edilen aşınma değerlerinin karşılaştırılması (S.C.Lin ve R.J.Lin, 1996)

Test No.	Ölçülen Aşınma (mm)	Tahmin Edilen Aşınma [mm]			
		6-24-12-1	6-1B-9-1	6-12-6-1	1. Fonksiyon
1-1	0.1	0.085	0.102	0.113	0.082
1-2	0.5	0.315	0.705	0.401	0.357
1-3	0.9	0.872	0.447	0.905	1.023
1-4	0.1	0.380	0.058	0.071	-0.073
1-5	0.9	0.515	0.685	0.911	0.933
1-6	0.1	0.182	0.182	0.162	-0.022
1-7	0.5	0.392	0.444	0.397	0.414
1-8	0.9	0.617	0.369	0.598	0.795
1-9	0.1	0.111	0.089	0.199	0.129
1-10	0.9	0.869	0.902	0.865	0.831
Ortalama Hata		0.226	0.037	0.165	0.096
Maksimum Hata		0.592	0.205	0.197	0.173
					0.140

Değişik bir sensor verisinden istifade edip yapay sinir ağıyla takım aşınmasını izlemesiyle dikkat çeken bir çalışma Choudhury vd (1999) tarafından yapılmıştır. Bu çalışmada güvenilir ve hassas bir kesici takım takip sisteminin insansız imalatta işlem yarıda kesilmeden adapte olabilen bir kontrolör sayesinde gerçekleştirilemesinin önemi üzerinde durulmuş bunun için optoelektronik sensor verilerini kullanan bir yapay sinir ağı modeli önerilmiştir.

Çalışma tornalamada serbest yüzey aşınmasını izlemek için yapılmıştır. Optoelektronik sensor sisteminin ana görevi yeni işlenmiş parça yüzeyinden imalat işlemi devam ederken yansıtılan lazer ışınının takım aşınmasından dolayı ortaya çıkabilecek mesafe farklılıklarını tespit etmesidir. Optik fiberin çalışma prensibi Şekil 3.23'de verilmiştir. Algılayıcı-hedef arasındaki mesafe farklılıklarını alıcı fiberler tarafından ışın demetinin bir kısmının yakalanmasına yol açar. Gelen ışın bir fotodiot tarafından elektrik akımına çevrilir. Ampilifikatörle yükseltilen bu sinyal analog-dijital çevirici tarafından yapay sinir ağına girişi yapılmak üzere dijital veri şecline dönüştürülür.

Yapay sinir ağıının giriş değerleri olarak kesme hızı, ilerleme, kesme derinliği ve optoelektronik sensor sisteminden alınan mesafe farklılıkları verisi, istenen çıkış değeri olarak da kesici takımındaki serbest yüzey aşınma miktarı belirtilmiştir.



Şekil 3.23 Optik fiberin çalışma prensibi (Choudhury vd., 1999)

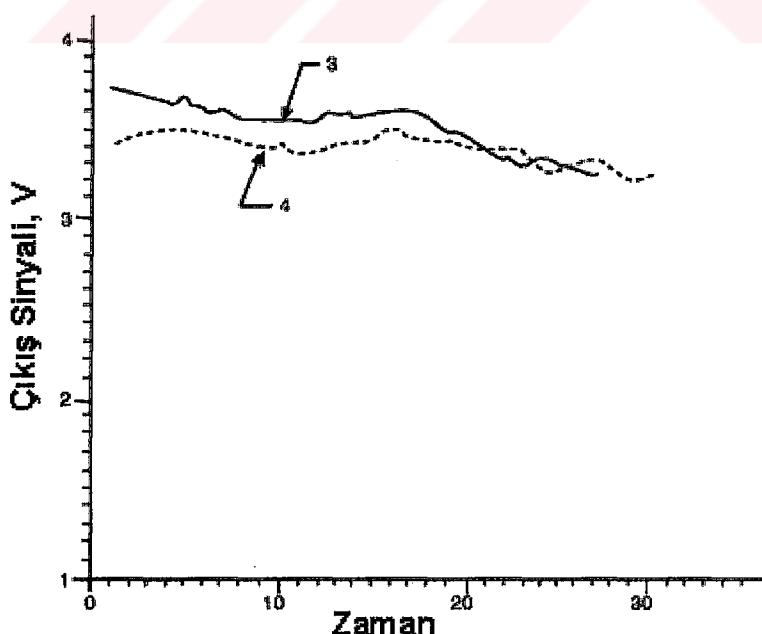
Hatanın geriye yayınımı algoritması ile yapay sinir ağı henüz aktif değilken eğitim yapılmıştır. Delta kuralında momentum terimi kullanılmıştır. Çalışmanın örnek olarak alınabilecek bir yönü eğitim yaklaşımıdır. Aktif eğitim olarak adlandırılan yöntemle henüz ağın ağırlık ve eşik değerlerinde bir adaptasyon değişimi yapılmadan bütün eğitim setindeki tahmin hataları bulunmuş ve ilk geriye yayının bu hataların en yüksek olduğu eşleştirmede yapılmıştır. Yapılan bir adaptasyon çevriminin ardından bütün set yeniden yapay sinir ağında denenmiş, yine hatanın en yüksek olduğu örnek hatanın geriye yayınımda kullanılmıştır. Bu çevrimler maksimum hatanın belli bir limitin altına inmesine kadar tekrarlanır. Bu yöntemin en büyük yararı farklı eşleştirmelerin birbirlerinin öğrenmedeki etkilerini gidermelerini önlemek olmuştur. Transfer fonksiyonu olarak hiperbolik teğet fonksiyon tercih edilmiştir.

Çizelge 3.17 Eğitim setinde kullanılan deney verileri (Choudhury vd., 1999)

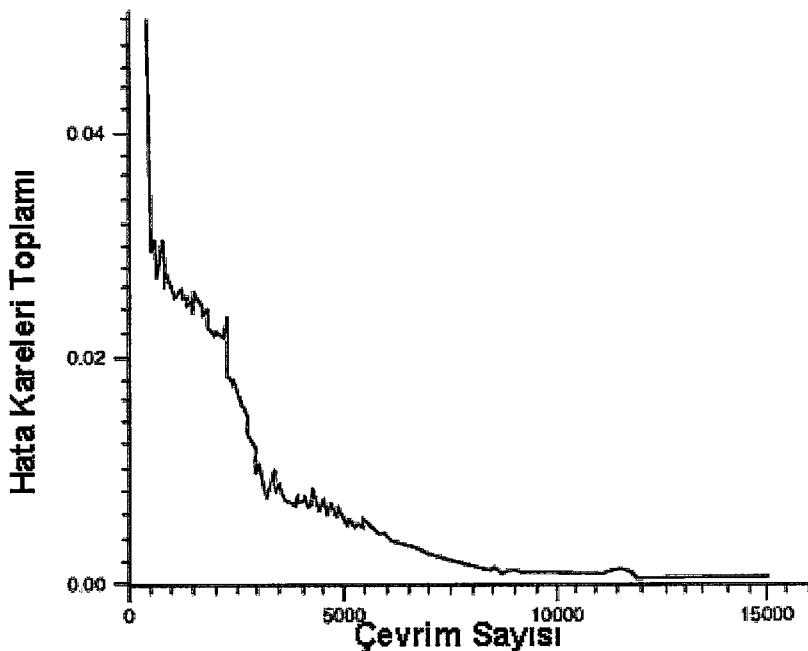
Deney No	Kesme Hızı (m/s)	İlerleme (mm/dev)	Kesme Derinliği (mm)	Çaptaki Değişim (mm)	Voltajdaki Değişim (V)	R _a (µm)	Ölçülen (nm)f	Hesaplanan (nm)f	Tahmin (nm)f
1	0.9715	0.1	1.5	0.16	0.12	4.42	0.34	0.30	0.33
2	0.9718	0.125	1.45	0.12	0.18	4.46	0.75	0.72	0.78
3	0.9734	0.113	1.45	0.07	0.06	4.82	0.13	0.12	0.13
4	0.9734	0.138	1.4	0.04	0.08	1.96	0.25	0.24	0.26
5	0.9979	0.15	1.5	0.16	0.18	5.17	0.89	0.96	0.87
6	0.7677	0.15	1.4	0.19	0.14	3.55	0.51	0.54	0.52
7	0.7686	0.125	1.35	0.02	0.05	4.3	0.13	0.12	0.12
8	0.7552	0.125	1.7	0.11	0.14	3.82	0.64	0.66	0.66
9	0.7588	0.15	1.7	0.16	0.29	6.25	0.99	0.96	0.97
10	0.5611	0.15	1.7	0.02	0.05	8.65	0.13	0.12	0.11
11	0.7023	0.125	1.7	0.1	0.04	6.05	0.05	0.06	0.06
12	0.7305	0.175	1.4	0.19	0.2	6.15	0.57	0.54	0.55
13	0.5761	0.1	1.25	0.08	0.12	4.28	0.45	0.48	0.42
14	0.8746	0.075	1.7	0.02	0.06	3.37	0.14	0.12	0.13
15	0.8739	0.125	1.7	0.16	0.08	5.2	0.35	0.36	0.36
16	0.8518	0.15	1.6	0.03	0.07	8.35	0.19	0.18	0.20
17	0.8533	0.1	1.6	0.03	0.06	6.01	0.19	0.18	0.20

Çizelge 3.18 Test setinde kullanılan deney verileri (Choudhury vd., 1999)

Deney No	Kesme Hızı (m/s)	İlerleme (mm/dev)	Kesme Derinliği (mm)	Çaptaki Değişim (mm)	Voltajdaki Dağılım (V)	R _a (µm)	Ölçülen (nm)f	Hesaplanan (nm)f	Tahmin (nm)f
1	0.9357	0.125	0.6	0.05	0.09	2.73	0.32	0.30	0.32
2	0.9167	0.1	0.5	0.11	0.16	4.3	0.64	0.66	0.64
3	0.9167	0.1	0.7	0.06	0.1	1.17	0.38	0.39	0.39
4	0.9167	0.15	0.7	0.03	0.057	3.82	0.19	0.18	0.19
5	0.9167	0.15	0.5	0.03	0.002	3.9	0.19	0.18	0.19
6	0.8977	0.125	0.6	0.14	0.067	5.8	0.25	0.24	0.26
7	0.8977	0.075	0.6	0.16	0.265	3.56	0.95	0.96	0.94
8	0.8977	0.175	0.6	0.03	0.075	5.96	0.19	0.18	0.20
9	0.8977	0.125	0.4	0.02	0.053	4.77	0.13	0.12	0.12
10	0.8787	0.1	0.7	0.18	0.35	3.08	1.06	1.08	1.05
11	0.8787	0.15	0.7	0.64	0.078	4.18	0.25	0.24	0.26

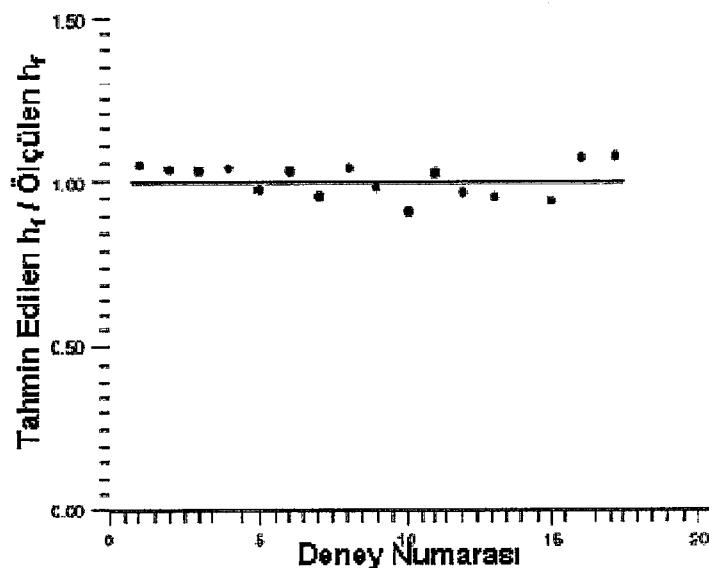


Şekil 3.24 Zamana bağlı sensor çıkış sinyali (Choudhury vd., 1999)



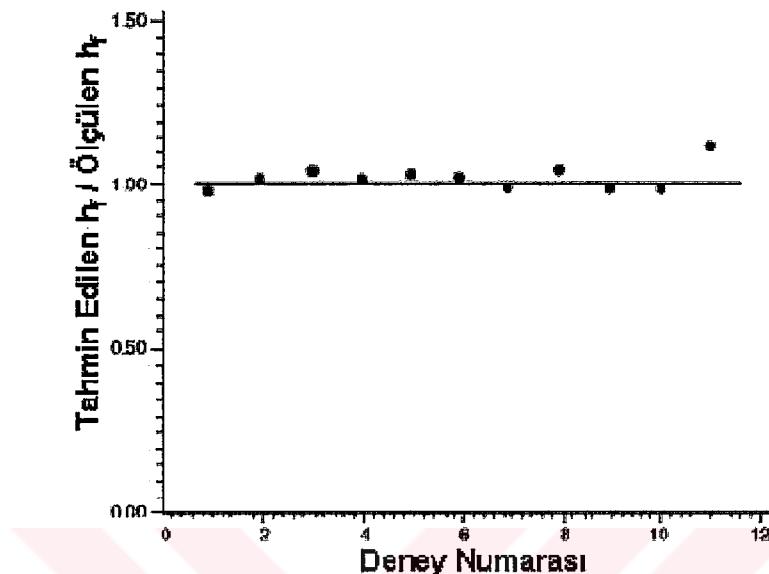
Şekil 3.25 Yapay sinir ağının öğreniminde hata değişimi (Choudhury vd., 1999)

Deneyselde iş parçası malzemesi olarak EN24 çelik ve kesici takım malzemesi olarak yüksek hız çeliği (HSS) kullanılmıştır. Çizelge 3.17 ve 3.18 kesme şartlarını, çıkış değerlerini ve yapay sinir ağının tahminlerini göstermektedir. Şekil 3.24 bu deneylerde veri olarak alınan zamana karşı sensor voltaj değişimini 3. ve 4. deneyler için örneklemiştir. Toplam 28 deney sonucundan 17'si eğitim seti olarak 11'i de test seti olarak kullanılmıştır. Ağ yapısını



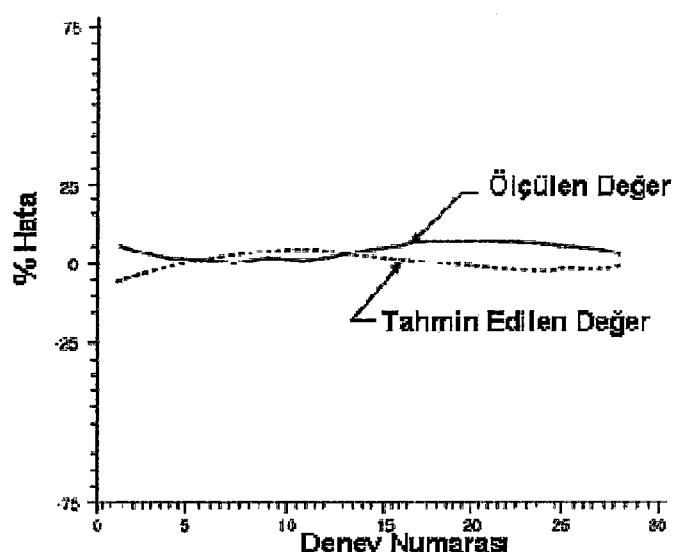
Şekil 3.26 Eğitim seti için tahmin edilen ve ölçülen aşınma değerlerinin oransal karşılaştırılması (Choudhury vd., 1999)

belirlemek için optimizasyon araştırması yapılmış ve sonuçta 4-9-1 modeli seçilmiştir. Şekil 3.25'deki eğitim seti müsade edilen 0.0004 hata kareleri toplamı değerine kadar çevrime tabi tutulmuştur. İşlem 90 dakika kadar sürmüştür.



Şekil 3.27 Test seti için tahmin edilen ve ölçülen aşınma değerlerinin oransal karşılaştırılması
(Choudhury vd., 1999)

Şekil 3.26 ve 3.27 tahmin edilen aşınmanın gerçekten ortaya çıkan oranını vermektedir. Yatay $y=1.0$ çizgisinden çok az sapmanın olması yapay simir ağının genelleme yapmadaki kabiliyetini ispatlar. Şekil 3.28 tahmin edilenle oluşan aşınmaları grafik halinde göstermiştir.



Şekil 3.28 Tahmin edilen ve ölçülen aşınma değerlerinin grafik karşılaştırması (Choudhury vd., 1999)

Deney sonuçları yapay sinir ağının bu sensor sistemiyle % 6'lık bir hata dilimi içinde çalışabildiğini göstermektedir.

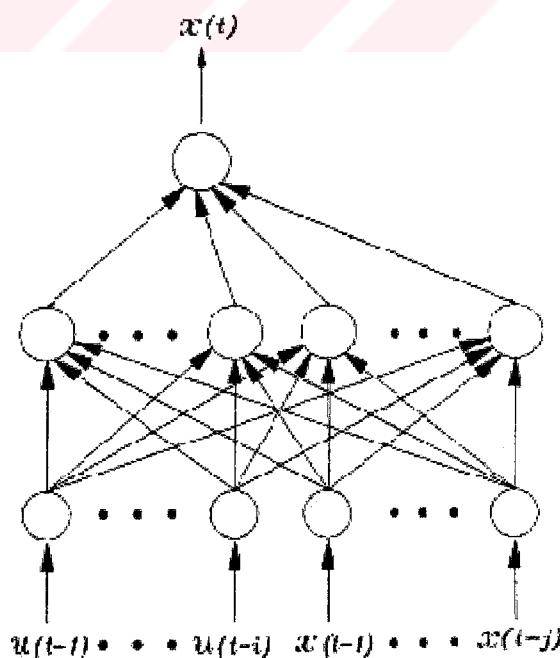
Yapay sinir ağıyla takım aşınma takibinde kullanılabilecek farklı bir metod önceki zaman dilimlerindeki kuvvet-aşınma değerlerini de giriş verisi olarak almaktır. Bir adım ötesini tahmin etmek (one step ahead prediction) olarak nitelendirebileceğimiz bu yöntemin en güzel uygulamalarından birini J.H. Lee ve S.J. Lee (1999) gerçekleştirmiştir. Çalışmalarında kuvvet oranlarından istifade etmişlerdir. Dikkat çekilen bir husus talaşlı imalat sırasında krater aşınmasının takım ucunda farklılaşma yaparak kesme kuvvetini düşürme yönünde bir işlev görmesidir. Buna rağmen radyal, teğet ve ilerleme kuvvet bileşkesi ve genel kesme kuvveti takım aşınmasıyla beraber yükselir. Kuvvet bileşenlerinin birbirlerine oranlarının alınmasının nedeni ise şöyle açıklanmaktadır; kesme hızı ve kesme derinliği gibi diğer koşullardan etkilenmesinden dolayı kuvvet bileşeninin sayısal değeriyle aşınma derecesini bir fonksiyonla ilişkilendirmek zorluğu. Çalışmada diğer kesme şartlarının kuvvete etkilerinin giderilmesi için iki kuvvet oranı ve kuvvet artım oranı tanımlanır;

$$\text{Oran 1} = F_f/F_t \quad (3.6)$$

$$\text{Oran 2} = \sqrt{(F_f^2 + F_r^2)} / F_t \quad (3.7)$$

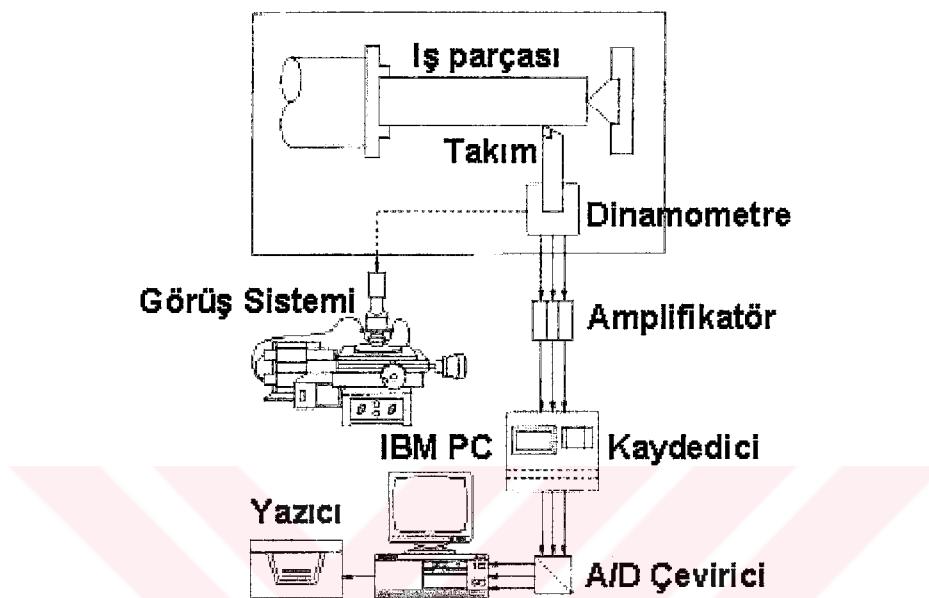
$$\text{Artım oranı}_t = F_t / F_{t,\text{başlangıç}} \quad (3.8)$$

$$\text{Artım oranı}_f = F_f / F_{f,\text{başlangıç}} \quad (3.9)$$



Şekil 3.29 Bir adım ötesini tahmin eden yapay sinir ağı modeli (J.H. Lee ve S.J. Lee, 1999)

Çalışmada giriş verisi olarak kullanılan kesme kuvvet oranları ($u(t)$) ile çıkış verisi olarak kullanılan serbest yüzey aşınma değerleri ($x(t)$) zamana bağlı değişkenler olarak gösterilmiştir. Bu nedenle bir giriş parametresinin altında işlem zamanının başlatılmasından o ana kadar pek çok verinin girişi yapılabilir. Yapay sinir ağını kabaca gösteren Şekil 3.29'da bu durum belirtilmiştir



Şekil 3.30 Deney düzeneği (J.H. Lee ve S.J. Lee, 1999)

Deney düzeneği Şekil 3.30'da görüldüğü gibidir. Dinamometre ile ölçülen kuvvet bileşenlerine ait sinyaller analog-dijital dönüşümüne tabi tutularak bilgisayara verilmiştir. Kesme takımı aşınması bir optik mikroskoba bağlı otomatik görüş sistemiyle belirlenmiştir. Deneyler 9 farklı kesme şartında gerçekleştirılmıştır;

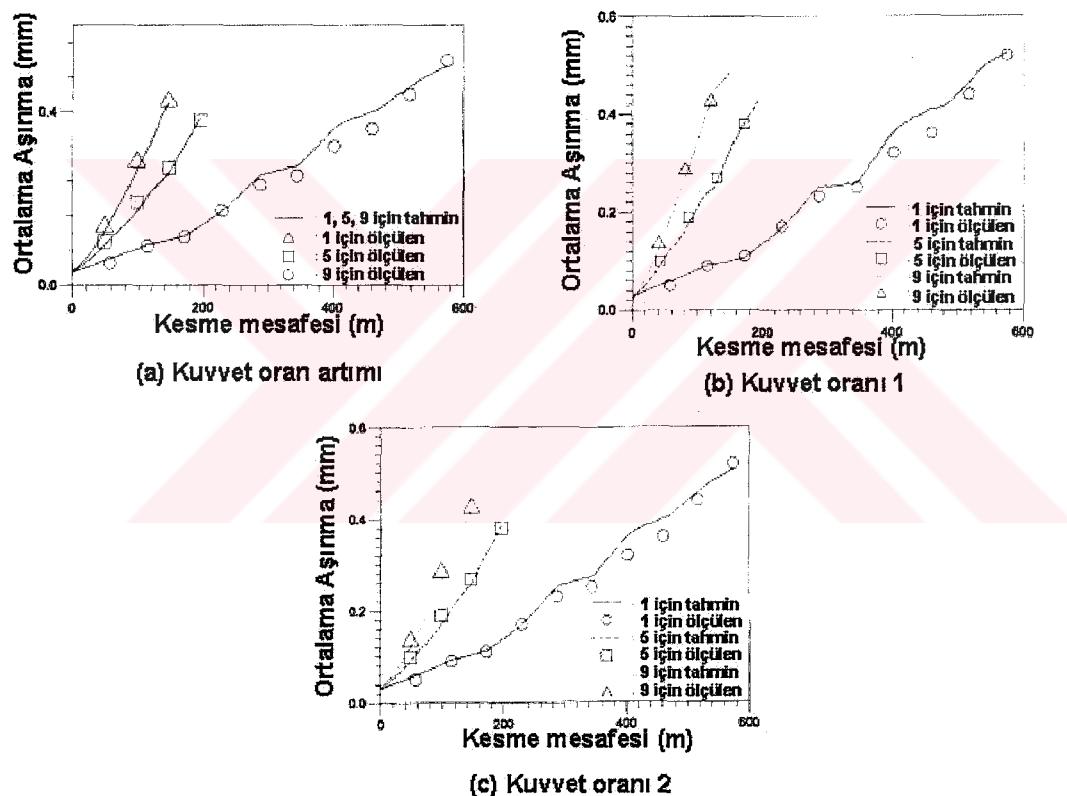
- Test 1 $v=140\text{m/dak.}$, $f=0.3 \text{ mm/devir}$, $d=1.2 \text{ mm}$
- Test 2 $v=180\text{m/dak.}$, $f=0.3 \text{ mm/devir}$, $d=1.2 \text{ mm}$
- Test 3 $v=220\text{m/dak.}$, $f=0.3 \text{ mm/devir}$, $d=1.2 \text{ mm}$
- Test 4 $v=140\text{m/dak.}$, $f=0.3 \text{ mm/devir}$, $d=1.6 \text{ mm}$
- Test 5 $v=180\text{m/dak.}$, $f=0.3 \text{ mm/devir}$, $d=1.6 \text{ mm}$
- Test 6 $v=220\text{m/dak.}$, $f=0.3 \text{ mm/devir}$, $d=1.6 \text{ mm}$
- Test 7 $v=140\text{m/dak.}$, $f=0.3 \text{ mm/devir}$, $d=2.0 \text{ mm}$
- Test 8 $v=180\text{m/dak.}$, $f=0.3 \text{ mm/devir}$, $d=2.0 \text{ mm}$
- Test 9 $v=220\text{m/dak.}$, $f=0.3 \text{ mm/devir}$, $d=2.0 \text{ mm}$

Giriş verilerinin değişimine göre üç farklı ağ denenmiştir. Üç ağda da 1, 5 ve 9 deneyleri ağın öğrenim seti olarak kullanılmıştır. Diğerleri ise test aşamasında değerlendirilmiştir. Ortak olan öğrenme kasayıları momentum=0.95, öğrenme sonlandırma kriteri olan hata oranı=1.04, öğrenme hızı=1.00, öğrenme hızı artışı=1.05 ve öğrenme hızı düşüşü=0.70 şeklindedir.

Küçük ilerlemelerde kuvvet oranı-takım aşınması eşleştirmelerinde istenen sonuçlar alınamadığı ve diğer kesme şartlarına karşı hassasiyetin arttığı gözönünde tutularak kuvvet oran artımları da giriş verisi olarak denenmiştir. Kuvvet oran artımlarına dayalı ağda giriş verileri t-1 ve t-2 zamanlarında alınan teget kuvvet ve ilerleme kuvveti oran artımları ile aşınma miktarlarıdır. Yapay sinir ağı yapısı 6-6-1 şeklinde tasarlanmıştır.

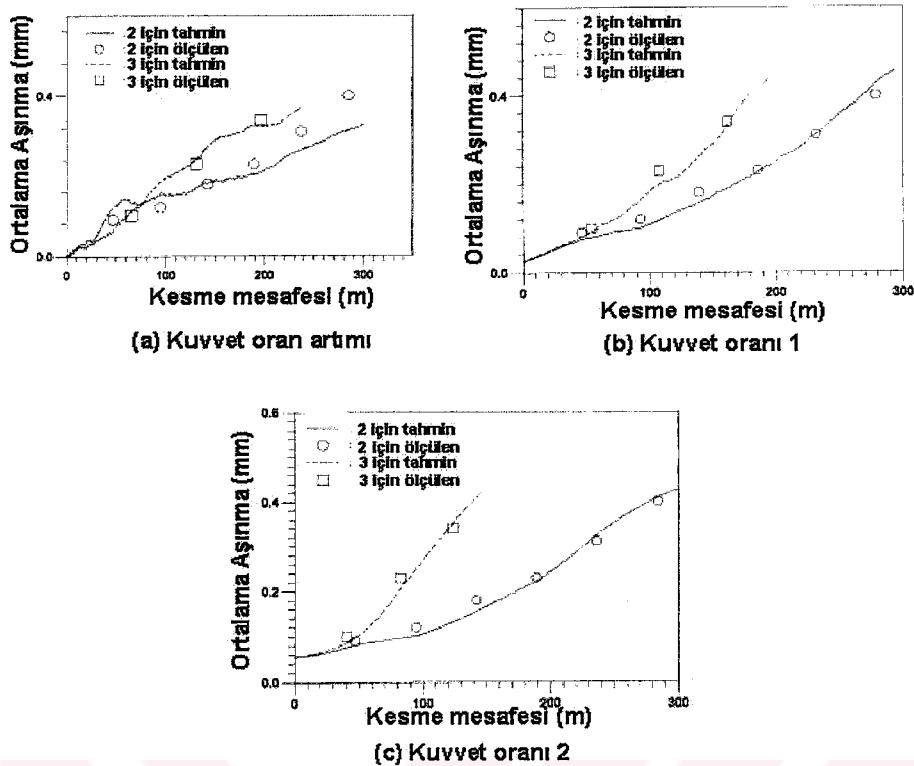
Kuvvet oranı 1'i eas alan yapay sinir ağı t-1 ve t-2 zamanlarındaki bu oranı ve aşınma değeri miktarlarını giriş verisi olarak kullanmıştır. Ağ yapısı 4-4-1 şeklindektir.

Kuvvet oranı 2'ye göre tasarlanan yapay sinir ağı da benzer şekilde bu oranın ve aşınma miktarlarının t-1 ve t-2 zamanlarındaki değerlerini giriş verisi yapmıştır. Ağ yapısı gene 4-4-1 şeklindektir.

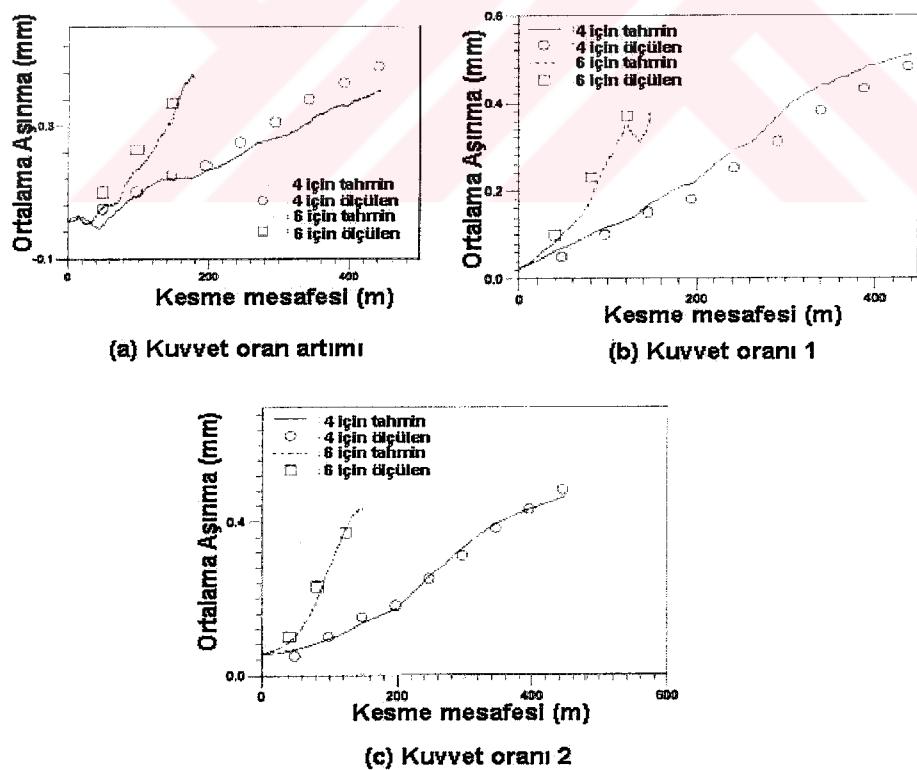


Şekil 3.31 Test 1, 5 ve 9 için öğrenme sonuçları (J.H. Lee ve S.J. Lee, 1999)

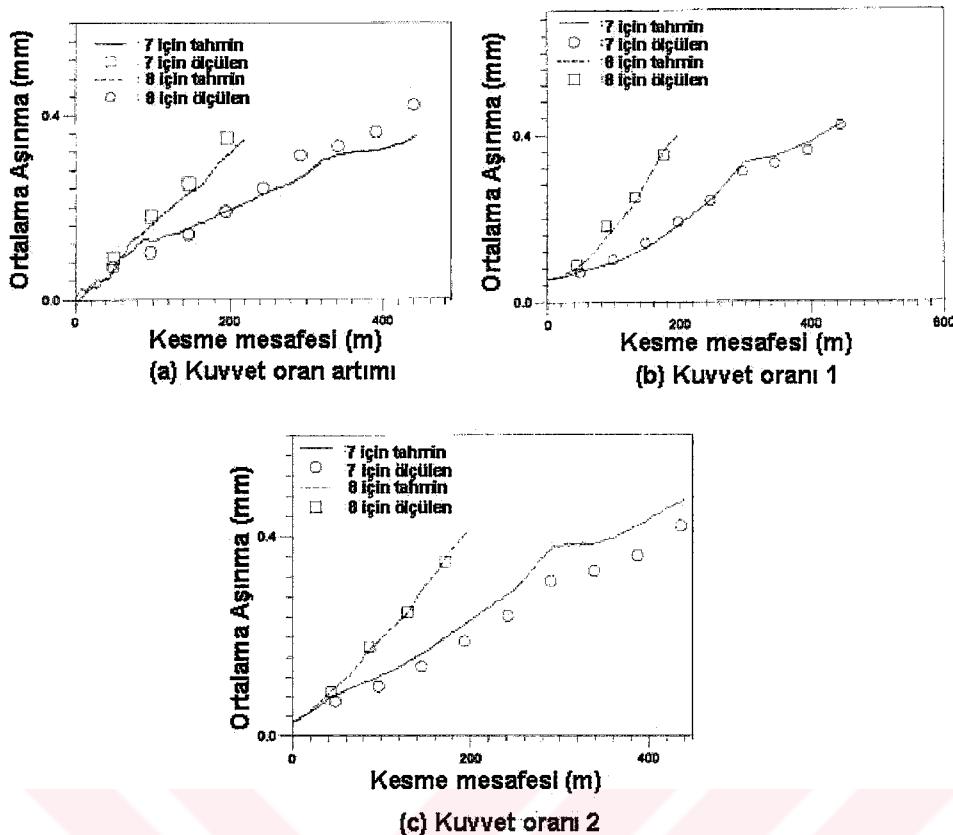
Eğitim ve test setleri ile ortaya çıkan sonuçlar Şekil 3.31, 3.32, 3.33 ve 3.34'de gösterilmiştir. Üç ağ da eğitim setlerindeki eşleştirmelere yaklaşmışlardır. Test setlerindeki performansları ise biraz farklıdır. Kuvvet artım oranlarını esas alan ağ aşınma miktarı 0.3 mm'yi aşıktan sonra gelişimi takip edememiştir. Diğer iki ağ içerisinde de grafik genelinde uygunluğunu en yüksek olan kuvvet oranı 2'ye göre tasarlanandır. Tahminde gerçek değerden maksimum



Şekil 3.32 Test 2 ve 3 için tahmin sonuçları (J.H. Lee ve S.J. Lee, 1999)

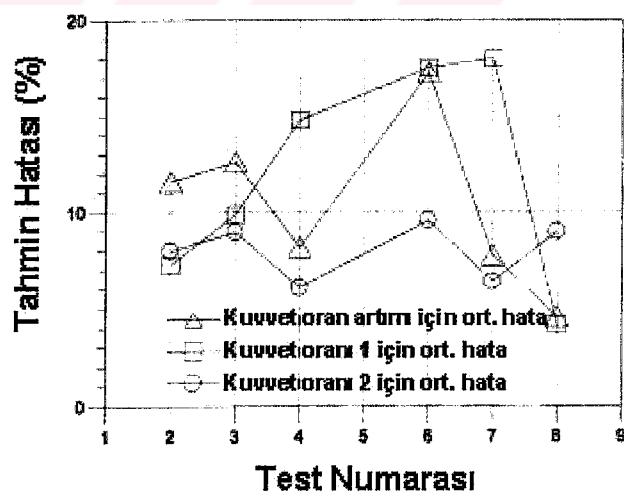


Şekil 3.33 Test 4 ve 6 için tahmin sonuçları (J.H. Lee ve S.J. Lee, 1999)



Şekil 3.34 Test 7 ve 8 için tahmin sonuçları (J.H. Lee ve S.J. Lee, 1999)

sapmasının 0.2 mm olması bunu doğrular. Ortalama hata yüzdeleri Şekil 3.35'de verilmiştir. Burada da kuvvet oranı 2'yi kullanan ağın üstünlüğü bir kez daha görülmektedir.



Şekil 3.35 Genel aşınma tahmin hataları (J.H. Lee ve S.J. Lee, 1999)

Yapay sinir ağının öğrendiği bilgiyi genelleme ile farklı kesme şartlarında uygulayıp uygulayamayacağı üstünde yapılan ana konulardan biridir. Altıntaş ve Liu (1999) çalışmalarında bu uygulamayı yapmışlardır. Çalışmada uygun kesme parametreleri ve iş parçasına difüzyona yüksek direnç gösterebilecek bir kesici takım malzemesi kullanımıyla talaş yüzeyindeki krater aşınmadan kurtulmanın mümkün olabileceği ifade edilmiştir. Serbest yüzey aşınması ise kesici ucun kaybına yol açarak yüzey kalitesini bozması nedeniyle incelemenin ana konusu olmuştur. Kesme derinliğini sabit tutmanın zorluğuna da dikkat çeken araştırmacılar özellikle profili simetrik olmayan parçaların tornalanmasında bu değerin sürekli değişeceğini gözönünde bulundurarak iş parçası geometrisinden bağımsız bir çalışma yapmak için kesme derinliği verisini kullanmamışlardır.

Serbest yüzey aşınmasını tahmine yönelik bu çalışmada giriş verileri olarak önceki ve şimdiki değerleriyle kuvvet oranı, kesme hızı, ilerleme ve aşınmanın önceki miktarı alınmıştır. Kullanılan kuvvet bileşenleri F_s teğet kuvvet (kesme kuvveti) ve F_f ilerleme kuvvetidir. Kuvvet oranı r_a , teğet kuvvetin, ilerleme kuvvetine oranıdır.

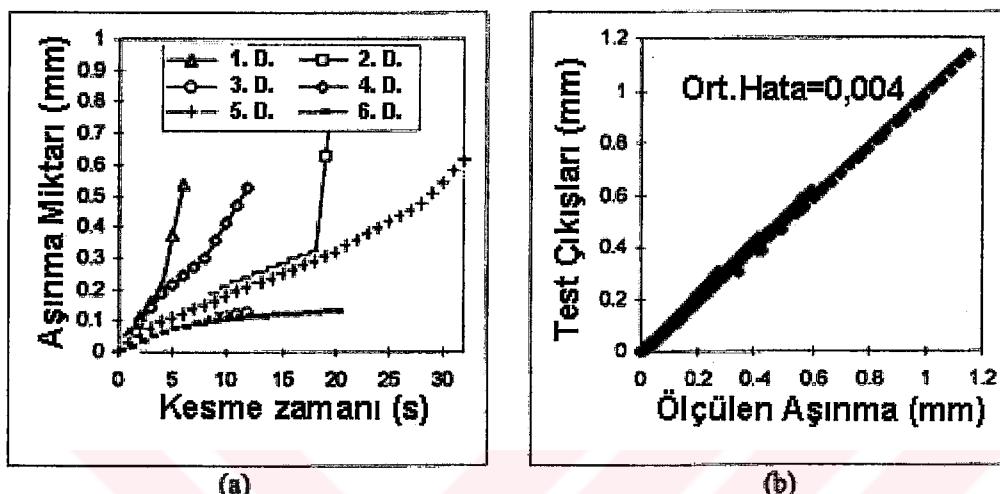
Çizelge 3.19 Veri toplamak için kullanılan kesme şartları (Altıntaş ve Liu, 1999)

Durum No.	V (m/dak.)	f (mm/dak.)/(mm/dəvir)	d (mm)
1	350	300/0.13	2.0
2	250	300/0.13	2.0
3	150	300/0.23	2.0
4	350	150/0.06	2.0
5	250	150/0.08	2.0
6	150	150/0.13	2.0
7	325	240/0.09	1.0
8	325	120/0.10	1.0
9	275	240/0.04	1.0
10	275	120/0.005	1.5

Yapay sinir ağının eğitilmesinde kullanılan örnekler Çizelge 3.19'da gösterilen deneyler neticesinde bulunarak normalize edilmişlerdir. Bu deneylerde 34 Rc sertliğindeki P20 döküm çeliğinden miller CNC tornada işlenmiştir. Kuvvet bileşenleri Kistler dinamometre ile algılanmıştır. Zaman aralıkları sabit kesme mesafelerine göre ayarlanmıştır. Aşınma miktarları takım mikroskopu ile prosese ara verilerek ölçülmüştür. Veriyi X olarak alırsak normalizasyon işlemi şöyle gerçekleştirilir:

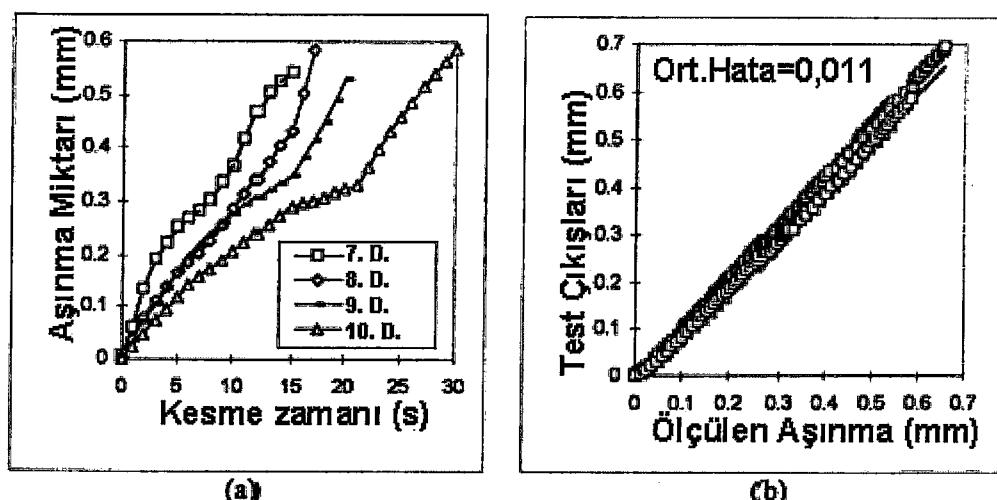
$$X = (X_R - X_{\min}) \frac{X_{N\max} - X_{N\min}}{X_{\max} - X_{\min}} + X_{N\min} \quad (3.10)$$

Burada X_R verinin normalize edilmeden önceki gerçek değeri, X_{\min} , X_{\max} normalize edilmeden önce verinin alabileceği minimum ve maksimum değerler ve $X_{N\min}$, $X_{N\max}$ da $0 < X_{N\min} < X_{N\max} < 1$ olacak şekilde verinin normalize olduktan sonraki maksimum ve minimum alabileceği değerlerdir.



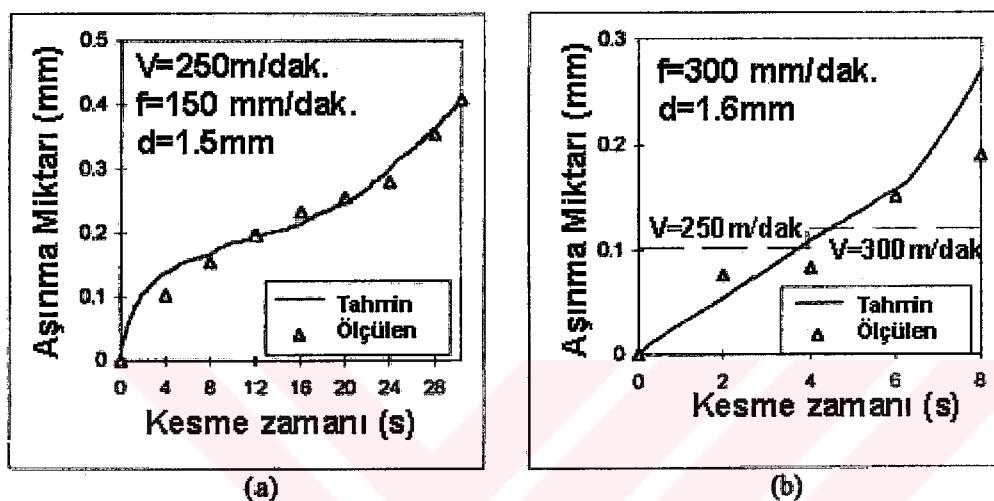
Şekil 3.36 Yapay sinir ağının eğitim sonuçları (Altıntaş ve Liu, 1999)

Ağ, hatanın geriye yayınımı algoritması ile momentum terimi kullanılarak eğitilmiştir. Ağ yapısı 4-5-1 şeklindedir. Eğitimi sonlandırma kriteri olarak ortalama hata karesi 0.004'e ayarlanmıştır. Deney sonuçlarının ilk altısı eğitim için kalan dördü ise test için kullanılmıştır ve Şekil 3.36 ve 3.37'de görüldüğü gibi tahminlerde uyum yakalanmıştır. Önceki deney koşullarından tamamen farklı iki kesme koşulu da yapay sinir ağının genelleme gücünü test



Şekil 3.37 Yapay sinir ağının test sonuçları (Altıntaş ve Liu, 1999)

etmek için aktif olarak kullanılmıştır. Bu kesme koşulları; a) Kesme hızı 250 m/dak., ilerleme 150 mm/dak. (0.073mm/devir), kesme derinliği 1.5 mm ve ani bir değişimle b) Kesme hızı 300 m/dak., ilerleme 250 mm/dak. (0.118 mm/devir), kesme derinliği 1.6 mm şeklindedir. Ani değişim yapılmadan önceki tahminler Şekil 3.36'da görüldüğü gibi olumludur. Yapay sinir ağının daha önceden öğrenmediği deney koşullarında test ediliyormasına karşın ani değişimden sonra yaptığı aşınma tahminleri de ölçülen değerlere oldukça yakındır. (Şekil 3.38)



Şekil 3.38 Yapay sinir ağının aktif test sonuçları (Altıntaş ve Liu, 1999)

Bazı çalışmalarındaki yapay sinir ağı modelleri sistem çıkış verisi olarak sayısal bir değeri vermemekte, bunun yerine daha önceden sınırları belirtilmiş sınıfları kullanmaktadır. Örneğin Dimla ve Lister'in (2000) çalışması buna yöneliktir. Dimla yapay sinir ağı ile aşınma derecesinin tahmini için P25 ve P15 kaplama karbür plaketlerle EN24 alaşım çeliğinin tornalanması işleminde üç doğrultuda kesme kuvveti ve ivme bileşenleri ile krater, uç ve serbest yüzey aşınma değerlerini kayıt altına almıştır. Alınan değerler üç farklı deneme ile yapay sinir ağında kullanılmıştır. İlk denemedede sadece serbest yüzey aşınması ele alınıp kesici takım keskin ve aşınmış şeklinde iki farklı sınıfa ayrılmıştır. İkinci denemedede sınıf sayısı ikidir ama bu sefer serbest yüzey aşınması ile uç aşınması birlikte mercek altına alınmıştır. Son denemedede ise kesici takımın ayrılabilceği ara sınıflar oluşturulmuştur.

İlk denemedede test ve eğitim için elde bulunan 156 örnek 0.1-0.9 aralığında normalize edilerek yapay sinir ağına girişleri yapılmıştır. Ağ yapısı 1'den 100'e kadar tek gizli katmandaki etkin

işlem elemanı sayısı araştırması yapılarak kurulmuştur. Sonuçta ortaya çıkan model 12-20-1 şeklindedir. Aşınma miktarına göre sınıflandırma kriteri şu şekildedir;

- Serbest yüzey aşınması uzunluğu < 0.15 mm ise işlevsel keskinliğe sahip
- Serbest yüzey aşınması uzunluğu > 0.15 mm ise aşınmış.

Ağdan çıkış verisi ikilidir; kesici takım 1 ile aşınmış, 0 ile de işlevsel keskinliğe sahip olarak tahmin edilir. Bu tip bir çıkışın alınabilmesi için çıkış değeri 0.5'e kadarsa 0'a, 0.5-1.0 açık aralığındaysa 1'e yuvarlanır. Delta kuralında geçen momentum 0.85, öğrenme hızı ise 0.2 alınmıştır. Hedeflenen ortalama hata karesi 0.01'dir. Başlangıçta işlem elemanları arasındaki bağlantı ağırlıkları (-1,1) aralığında rastgele seçilmişlerdir. Test sonuçları Çizelge 3.20'deki gibidir. Tahminlerinde çok da başarılı olmayan yapay sinir ağındaki bu durum az sayıda aşınmış kesici takım verisine sahip olunması, dolayısıyla öğrenmenin yetersiz kalması ve kesici takımı işlenen parça malzeme çiftlerinin aşınmada farklı devrelerden geçmeleri nedeniyle genellemeye imkan vermemeyle açıklanır.

Çizelge 3.20 Yapay sinir ağının çapraz tez sonuçları (Dimla ve Lister, 2000)

Eğitim kullanılan Veriler	Testte hatalı çıkan tahmin sayısı / örnek sayısı	
	Yalnız P15 verileri	Yalnız P25 verileri
Yalnız P15 verileri	6/48=%12.5	13/68=%18.1
Yalnız P25 verileri	22/88=%25	4/28=%14.3

Çalışmada uygulanan ikinci deneme serbest yüzey aşınması ile uç aşınmasının birlikte kullanılmasıyla oluşturulmuştur. Sınıflandırma kriteri şu şekildedir;

- Serbest yüzey aşınması uzunluğu < 0.15 mm ise işlevsel keskinliğe sahip
- Serbest yüzey aşınması uzunluğu > 0.15 mm ise aşınmış.(yüksek serbest yüzey aşınması)
- Uç aşınma uzunluğu < 0.2 mm ise işlevsel keskinliğe sahip
- Uç aşınma uzunluğu ≥ 0.2 mm ise aşınmış takım (+uç kısmı kırılmış ya da paralanmış)

Bu kategoriler ikili kodlara çevrilerek çıkış verisi olmaya hazır hale getirilmiştir;

- 000 - işlevsel keskinliğe sahip
- 100 - yüksek serbest yüzey aşınması
- 010 - yüksek uç aşınması

- 001 - kırılmış, paralanmış uç
- 110 - yüksek serbest yüzey ve yüksek uç aşınması
- 111 - yüksek serbest yüzey ve yüksek uç aşınması ayrıca kırılmış ya da paralanmış

Sadece P25 karbür plaket kullanılarak yapılan deneylerin sonucu olan 119 normalize edilmiş verinin 50 tanesi eğitimde, 65 tanesi de testte değerlendirilmiştir. Tek gizli katmanda 5 ve 20 adet gizli işlem elemanı tasarılanarak İki farklı ağ oluşturulmuştur. Çıkış katmanındaki işlem elemanı sayısı üç basamaklı kodlamadan da tahmin edileceği gibi 3'tür. Başarı oranları Çizelge 3.21'de görüldüğü gibidir. Burada yanlış sınıflandırmaların ana nedeninin eğitimde ve test aşamasında kullanılan verilerin yönlendirmesinden kaynaklanabileceği düşünülmüş ve ihtimal dahilinde yapılabilecek bir giriş veri sınırlandırması ya da genel eğilime uymayan, güvenilemeyecek örneklerin değerlendirmeye alınmaması planlanmıştır.

Çizelge 3.21 Yüzdelik olarak sınıflandırma başarısı (Dimla ve Lister, 2000)

Gizli işlem elemanı sayısı	Serbest Yüzey Aşınması	Uç Aşınması	Paralanma/Kırılma
5	95.7	89.9	94.2
20	97.7	94.2	91.3

Giriş verilerinin incelenmesinden çıkan sonuç 12 giriş verisinden 7'sinin tahminde etkisinin daha yüksek olduğunu göstermiştir. Bunlar ilerleme, üç doğrultuda statik kuvvet bileşenleri, dinamik kuvvetin x ve z doğrultularındaki bileşenleri ve x doğrultusundaki titreşim bileşenidir. Gene de diğer giriş verileri kullanılmadan oluşturulan yapay sinir ağı olumlu sonuç vermemiş, hata yüzdeleri artmıştır. Bu duruma tatmin edici bir cevap vermek güçtür, fakat eğitim setinde % 100'e varan başarının test setinde dramatik düşüşü, yapay sinir ağının eğitim setinde aşırı uzmanlaşlığı izlenimini vermektedir. Giriş verilerinde genel uyumu bozan örneklerin aranması işleminin sonucu olarak da aykırı örneklerin bulunmadığı tesbit edilmiştir.

Genel olarak sınıflandırma hatalarının, sigmoid fonksyonun çıkış olarak verdiği ve 0'a yuvarlanan (0.25-0.49) aralığındaki belirsizliğin hakim olduğu geçiş bölgesinden çıktıgı

görülünce ara bir sınıfın eklenmesi düşünülmüştür. Çalışmada kullanılan üçüncü deneme buna yönelikir. Bu denemedeki ikili kodlama şu şekilde düzenlenmiştir;

Serbest yüzey aşınması için;

- Uzunluk < 0.1 mm ise işlevsel keskinliğe sahip; 00
- Uzunluk $0.1-0.15$ mm aralığında ise orta seviyede; 10
- Uzunluk > 0.15 mm ise ciddi seviyede, yüksek aşınma; 11

Uç aşınması için;

- Uzunluk < 0.1 mm ise işlevsel keskinliğe sahip; 00
- Uzunluk $0.1-0.2$ mm aralığında ise orta seviyede; 01
- Uzunluk ≥ 0.2 mm ise ciddi seviyede, yüksek aşınma; 11

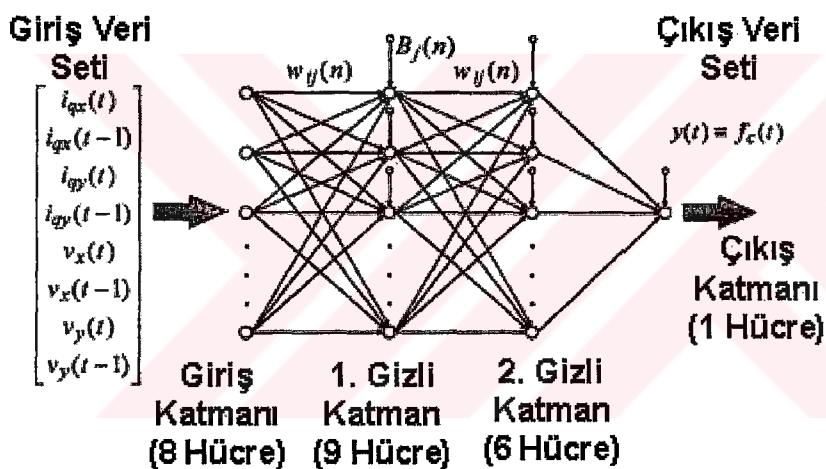
Birleştirilmiş aşınma kodlaması ise şöyle düzenlenmiştir;

- 0000 düşük uç-serbest yüzey aşınması,
- 0001 düşük serbest yüzey /orta uç aşınması,
- 1000 orta serbest yüzey /düşük orta uç aşınması,
- 1001 orta serbest yüzey/uç aşınması,
- 1101 yüksek serbest yüzey /orta uç aşınması,
- 1011 orta serbest yüzey /yüksek uç aşınması,
- 1111 yüksek serbest yüzey/uç aşınması.
- Kırılma paralanma durumu için ekstra bir çıkış verisi daha düşünülmüştür.

Yapay sinir ağı bu deneme 60 tane örnekle eğitilmiş 59 örnek de test amacıyla kullanılmıştır. Toplanan 12 veriden en etkin olan 7 tanesinin 10 adet dönüşümü giriş verisi olarak kullanılmıştır. Başarı oranı % 95.81'le en uygun ağ yapısı 10-24-5 olarak belirlenmiştir. Ortalama hata karesinde 0.003'e erişilmiştir. Belirlenen öğrenme hızı 0.01'dir. Sonuç önceki denemelerden biraz daha başarılıdır fakat 12 giriş verisinin hepsinin kullanıldığı yapay sinir ağı modeline göre beklenen gerçekleşmemiştir. Giriş verilerinin hepsinin kullanıldığı ağıda öğrenme sürecinin ardından giriş katmanında adapte olmuş bağlantı ağırlıklarına bakıldığından iyileştirme çalışmalarında seçilerek çıkarılan 5 verinin ağırlık değerlerinin düşük olduğu görülmektedir. Bu görüntüsüyle ağ seçici veri kullanımını desteklemektedir fakat veri sayısının indirilmesi performansı iyileştirmemiş aksine kötüleştirmiştir.

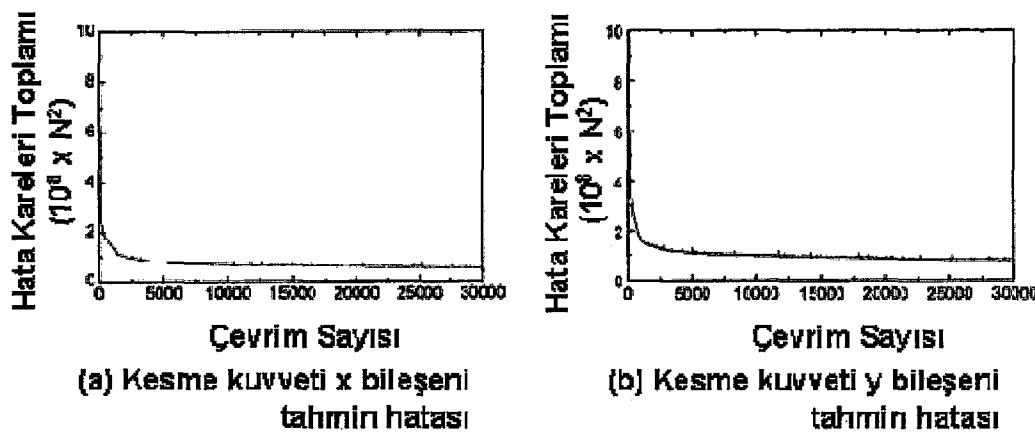
1.1 Yapay Sinir Ağı Yardımıyla Kesme Kuvvetinin Tahmini

Kontür yüzey frezelemede kesici takımın aşırı yüklenmelere maruz kalmasını önlemek için anlık bir kesme kuvveti takip sistemine ihtiyaç vardır. Her ne kadar dinamometre kullanımı takipte üstünlüğünü kanıtlamış olsa da tezgah üzerinde yerleştirilmesi için gereken alanın bazen yeterli olmaması, yüksek maliyetler gerektirmesi, ancak hassasiyet limitleri içerisinde ölçüm yapabilmesi, aşırı yüklenmelerde kırılabilmesi araştırmacıları dinamometreden başka arayışlara itmektedir. Bu sebeple servo-motor ve ana mil motor akımları pek çok araştırmacı tarafından talaşlı imalatta çok eksenli yüklenme takibinde kullanılmıştır. Genel olarak tezgah tabla kütlesinin ivmelenmesinden ve kılavuz yolda aşılması gereken sürütmelerden oluşan kuvvet bileşenlerinden dolayı servo-motorun akımıyla birebir doğrusal bir ilişki bulunamamıştır. Jongwon Kim vd (1999) işte bu doğrusal bir fonksiyonla eşleştirilemeyen iki değişken için bir yapay sinir ağı tasarlamışlardır.



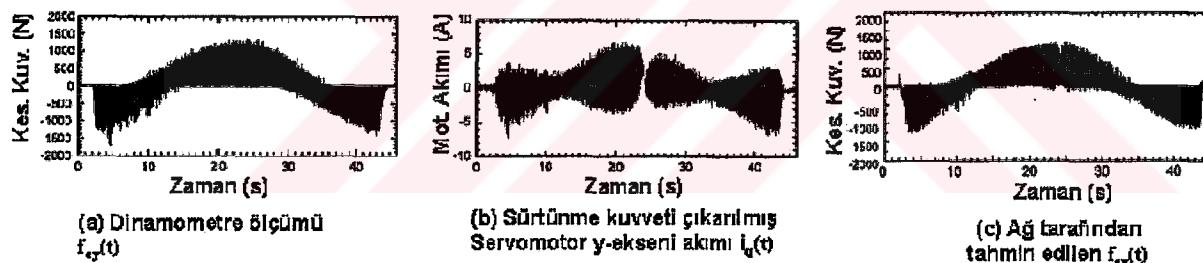
Şekil 3.39 Çok eksenli frezelemede dolaylı kesme kuvveti tahmini için tasarlanan yapay sinir ağının konfigürasyonu (Kim vd., 1999)

Çalışmada kullanılan yapay sinir ağının kofigürasyonu Şekil 3.39'da verilmiştir. $B_j(n)$ ayrı olarak gösterilen eşik değerleridir. Giriş verileri toplam 8 sinyalden oluşmaktadır; x ve y eksenlerinin servomotor akımlarının bir önceki ve şimdiki değerleri ($i_{qx}(t)$, $i_{qy}(t)$, $i_{qx}(t-1)$ ve $i_{qy}(t-1)$), gene x ve y eksenlerindeki servomotor ilerleme sinyallerinin bir önceki ve şimdiki değerleri ($v_x(t)$, $v_y(t)$, $v_x(t-1)$ ve $v_y(t-1)$). Çıkış verisi ise tek bir işlem elemanından kesme kuvvetinin kendisi veya x ya da y bileşenlerinden birisi olarak düşünülebilir. Çalışmada iki yapay sinir ağının ayrı ayrı x ve y kuvvet bileşenlerinin tahmininde kullanılmıştır. Eksenlerin karşılıklı etkileşimleri çıkış verisinin eksenine bakılmaksızın giriş verilerinin iki boyutta da alınmalarını gerektirir. Ağın yapısı 8-9-6-1 şeklindedir. Zaman olarak bir adım gerideki sinyalin alınması yapay sinir ağının değişimi kavrayabilmesi açısından çok önemlidir.

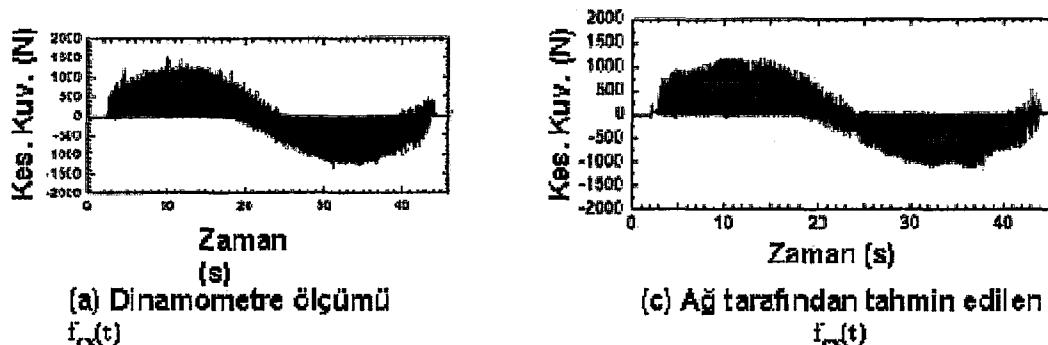


Şekil 3.40 Eğitim sürecinde yapay sinir ağının hata kareleri toplamı değişimi (Kim vd., 1999)

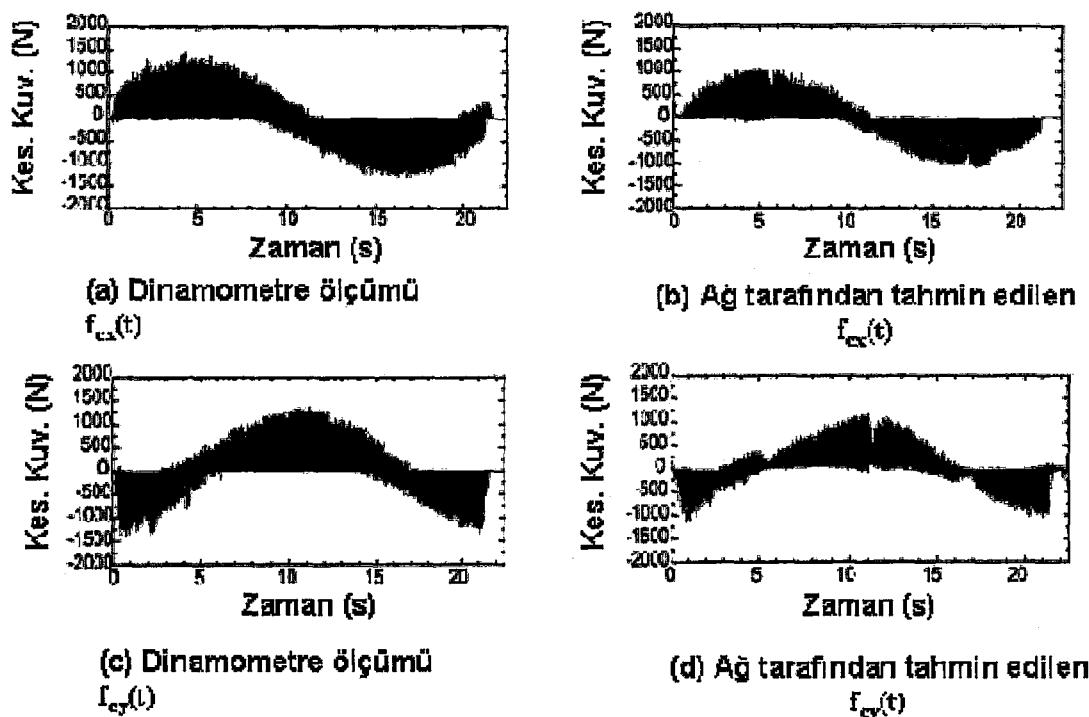
Hatanın geriye yayınımı algoritması çalışmada seçilen öğrenme metodudur. Şekil 3.40'da görüldüğü gibi 2000 çevrimde hata kareleri toplamı sürekli bir düşüşe sahiptir. Eğitimde kullanılan veriler yatay CNC frezede çelik iş parçasının kontür frezelenmesinde 2 mm eksenel kesme derinliği, 300 mm/dak. ilerleme, 600 rpm ana mil dönüş hızı ve 35 mm kesimde izlenen yol çapı şartlarında alınmıştır. Şekil 3.41 ve 3.42'de görülen x ve y eksenlerindeki kuvvet ölçümleri ve yapay sinir ağının tahminleri büyük paralellik göstermektedir. Ayrıca



Şekil 3.41 Kesme kuvveti y-ekseni bileşeninin tahmininde yapay sinir ağı performansı (Kim vd., 1999)



Şekil 3.42 Kesme kuvveti x-ekseni bileşeninin tahmininde yapay sinir ağı performansı (Kim vd., 1999)



Şekil 3.43 Farklı kesme koşullarında yapay sinir ağı kesme kuvveti tahmin performansı (Kim vd., 1999)

yapay sinir ağının genelleme kabiliyetini test edebilmek için eksenel kesme derinliği 1 mm'ye indirilmiş, ilerleme 600 mm/dak.'ya yükseltilmiş, ve diğer şartlar aynı bırakılarak gene dairesel bir kesme yolu takip edilmiştir. Ölçülen ve ağ tarafından tahmin edilen değer grafikleri Şekil 3.43'de görüldüğü gibidir. İlerlemenin y-ekseninde tersine çevrildiği bölgelerde tahmin genliğinde ölçüleninkiyle hafif bir uyumsuzluk göze çarpmaktadır. Bunun nedeni yatay frezede dikey haraketlenmelerde ana mil dişli kutusunun ağırlık etkisini gidermeye çalışarak dinamik balanslama yapan ters balans dişlisinin y-eksenindeki kuvvet genliğini yükseltmesidir.

Çalışmada karşılaştırma yapılabilecek bir model daha denenmiştir; Kalman filtresi. Servo-motor sinyallerinde istenmeyen ivmelenmelerden doğan kuvvet bileşenlerininfiltrelenmesi olarak özetleyebileceğimiz metodun sonuçları yapay sinir ağına göre düşük performanslıdır.

Yapay sinir ağı yardımıyla kesme kuvveti tahmininde örnek olarak gösterebileceğimiz ikinci çalışma K. Hans Raj vd. (2000) tarafından gerçekleştirılmıştır. Yapay sinir ağlarının genel olarak akıllı imalat sistemlerinde uygulanabilirliğinin irdelendiği bu çalışmada saç metal pres ve talaşlı imalattan iki örnek verilmiştir. Araştırmacılarla göre yapay sinir ağlarının uzman sistemler gibi belli gerçekler ve bilgilere dayanarak türdengelimi uygulamayıp sadece verilen eşleştirmelerden tümevarıma ulaşması bu tip uygulamalarda cazip kılmaktadır.

Yapay sinir ağının eğitiminde hatanın geriye yayınımı algoritması kullanılmıştır fakat delta kuralında hatanın yavaş azalmasını ve lokal minimuma düşme riskini azalttığı iddia edilen Levenberg-Marquardt(LM) yaklaşımı vardır. Buna göre ağırlık değişim denklemi şöyledir;

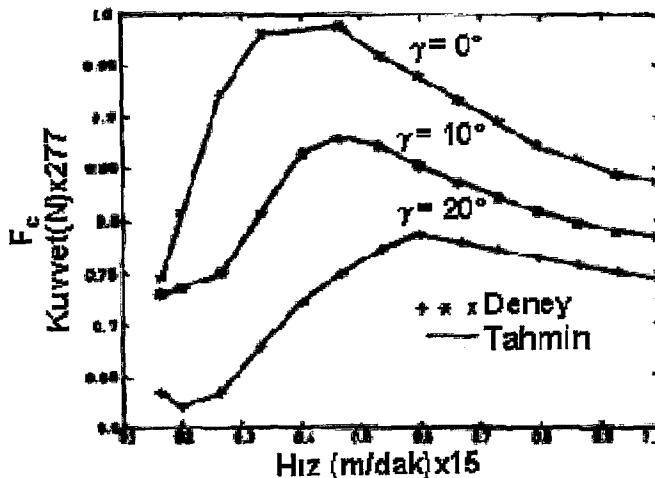
$$\Delta W = (J^T J + \mu I)^{-1} J^T e \quad (3.11)$$

Burada J her bir hatanın her bir ağırlığa göre türevinin jakoben matrisi, μ skaler bir büyüklük ve e hata vektörüdür. Eğer μ çok yüksek bir değer alırsa denklem bildiğimiz klasik olarak kullanılan gradyan düşüş metoduna yaklaşır, düşük bir değer alması durumunda da denklem Gauss-Newton metodu olur. Gauss-Newton metodu hatanın düşürülmesinde hızlı ve doğru sonuçlar veren bir metoddur. Bu nedenle denklemdeki μ 'nın değeri ancak bir önceki çevrimde hata yükselirse arttırmak şartıyla her bir başarılı çevrimde düşürülürek Gauss-Newton metoduna yaklaşılmasına çalışılır.

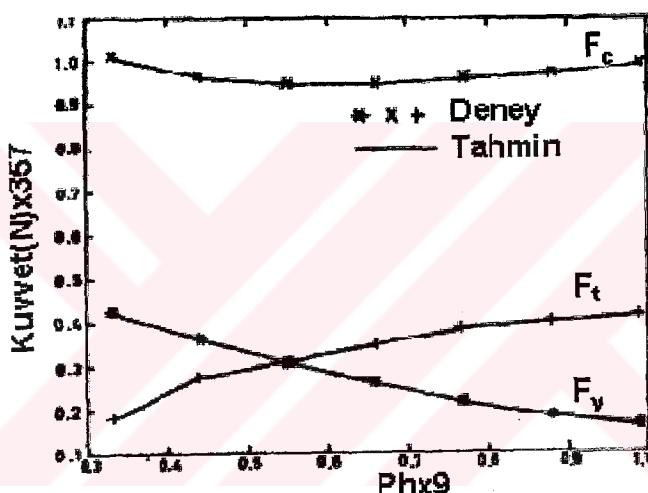
Çalışmada gizli katmanlardaki işlem elemanı sayısı çok yüksek tutulursa eğitim setinde özelleşmenin fazla olacağı, çok düşük tutulursa da istenilen öğrenmenin elde edilemeyeceği bu nedenle en uygun sayının seçilmesi gerekliliği üzerinde durulmuştur. Talaşlı imalatta yapay sinir ağı kullanımıyla amaçlanan deneysel veriler yardımıyla kesme hızı, ilerleme, kesme derinliği, ve takım geometrisinin kesme kuvveti üzerindeki değişim etkisini tahmin etmektedir. Üç farklı yapıda ve giriş verisine sahip yapay sinir ağı tasarlanmıştır. İlk ağıda giriş verileri kesme hızı, kesme derinliği ve ilerlemedir. Yapı iki gizli katman bulunacak şekilde 3-7-7-2 şeklindedir. Çıkış verileri F_c kesme kuvveti ve F_t ilerleme kuvvetidir. Transfer fonksiyonları her katman için farklı kullanılmıştır; ilk gizli katmanda sigmoid fonksiyon, ikinci gizli katmanda logaritmik sigmoid fonksiyon ve çıkış katmanında linner fonksiyon transfer fonksiyonu olarak alınmıştır. Başlangıçtaki öğrenme hızı 0.2, sondaki öğrenme hızı

Çizelge 3.22 Verilen kesme hızı, ilerleme ve kesme derinliği, deneylerde bulunan ve yapay sinir ağıyla tahmin edilen kesme kuvveti bileşenleri (Raj vd., 2000)

No.	Hız (m/dak.)	İlerleme (mm)	Kesme Derinliği (mm)	Kesme Kuvvetlerin Deneylerde Bulunan Değerleri (N)		Yapay Sinir Ağı Tahminleri (N)	
				F_c	F_t	F_c	F_t
1	29	0.212	1.0	437.1	361.9	437.1	361.2
2	22	0.137	1.0	276.2	209.5	275.3	215
3	17	0.107	1.0	238.1	142.8	237.1	147.3
4	14	0.212	1.0	373.4	285.7	372.3	286.4
5	29	0.212	1.2	571.4	428.5	571.2	429.7
6	22	0.212	1.2	457.4	342.9	459.6	346.5
7	17	0.212	1.2	475.2	380.9	474.4	377.6
8	13	0.107	1.2	323.8	280.9	322.9	288.9
9	29	0.212	1.5	523.8	428.6	524.7	427
10	22	0.212	1.5	619.1	523.8	617.4	525.1
11	17	0.212	1.5	523.8	428.5	523.4	429.2
12	13	0.212	1.5	428.5	333.3	429.1	332.7

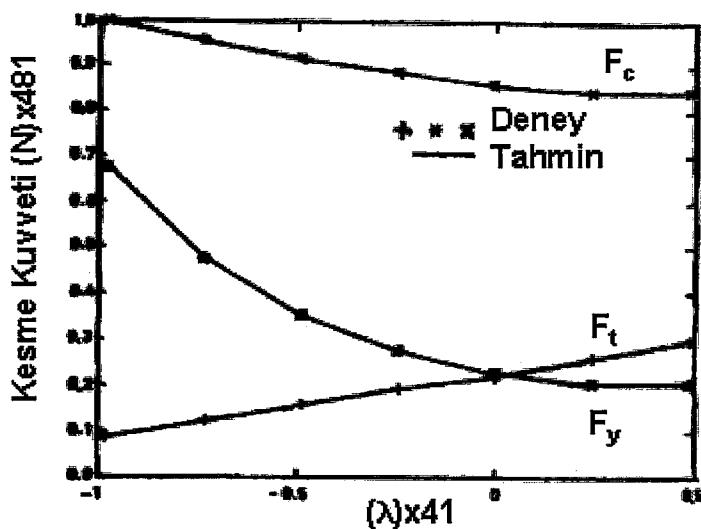


Şekil 3.44 Talaş açısının farklı hızlarda kesme kuvvetine etkisi (Raj vd., 2000)

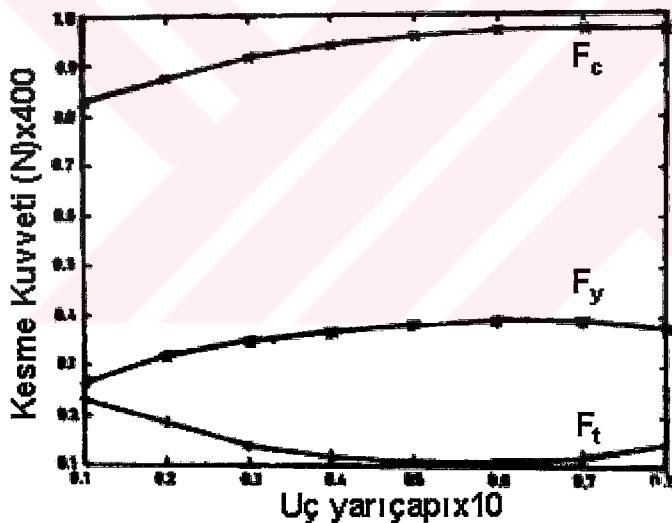


Şekil 3.45 Kesme açısının (ϕ) kesme kuvvetine etkisi (Raj vd., 2000)

10^{-5} olmak üzere 245 çevrimden sonra hata kareleri toplamı 0.0001996'ya inmiştir. Çizelge 3.22'de görüldüğü gibi tahmin değerleri deney sonuçlarına oldukça yakındır. Talaş açısının (γ) kuvvet üzerindeki etkisine dayanılarak oluşturulan ikinci yapay sinir ağı üç katmanlıdır. Ağ yapısı 1-3-1 şeklindedir. Tahminlerde ilerleme, kesme derinliği gibi diğer parametreler sabit tutulmuştur. Şekil 3.44 tahminle gerçek değer arasında birebir uygunluk bulduğunu göstermektedir. Kesme açısı (ϕ), eğim açısı (λ) ve takım uç yarıçapının kısaltası farklı takım geometrilerinin kesme kuvveti üzerindeki yönelik üçüncü yapay sinir ağı çalışmalarında giriş parametreleri ayrı ayrı bu üç değişkenden biri seçilerek üç katmanlı bir ağ ile F_c kesme kuvveti ve F_t ilerleme kuvveti ve F_y basma kuvveti tahminleri gerçekleştirılmıştır. Sonuçlar Şekil 3.45, 3.46 ve 3.47'de verildiği gibidir. Sonuçta ağırlıkların değiştirilmesinde kullanılan Levenberg-Marquardt (LM) yaklaşımı iyi tahmine ulaşmıştır.



Şekil 3.46 Eğim açısının (λ) kesme kuvvet bileşenlerine etkisi (Raj vd., 2000)

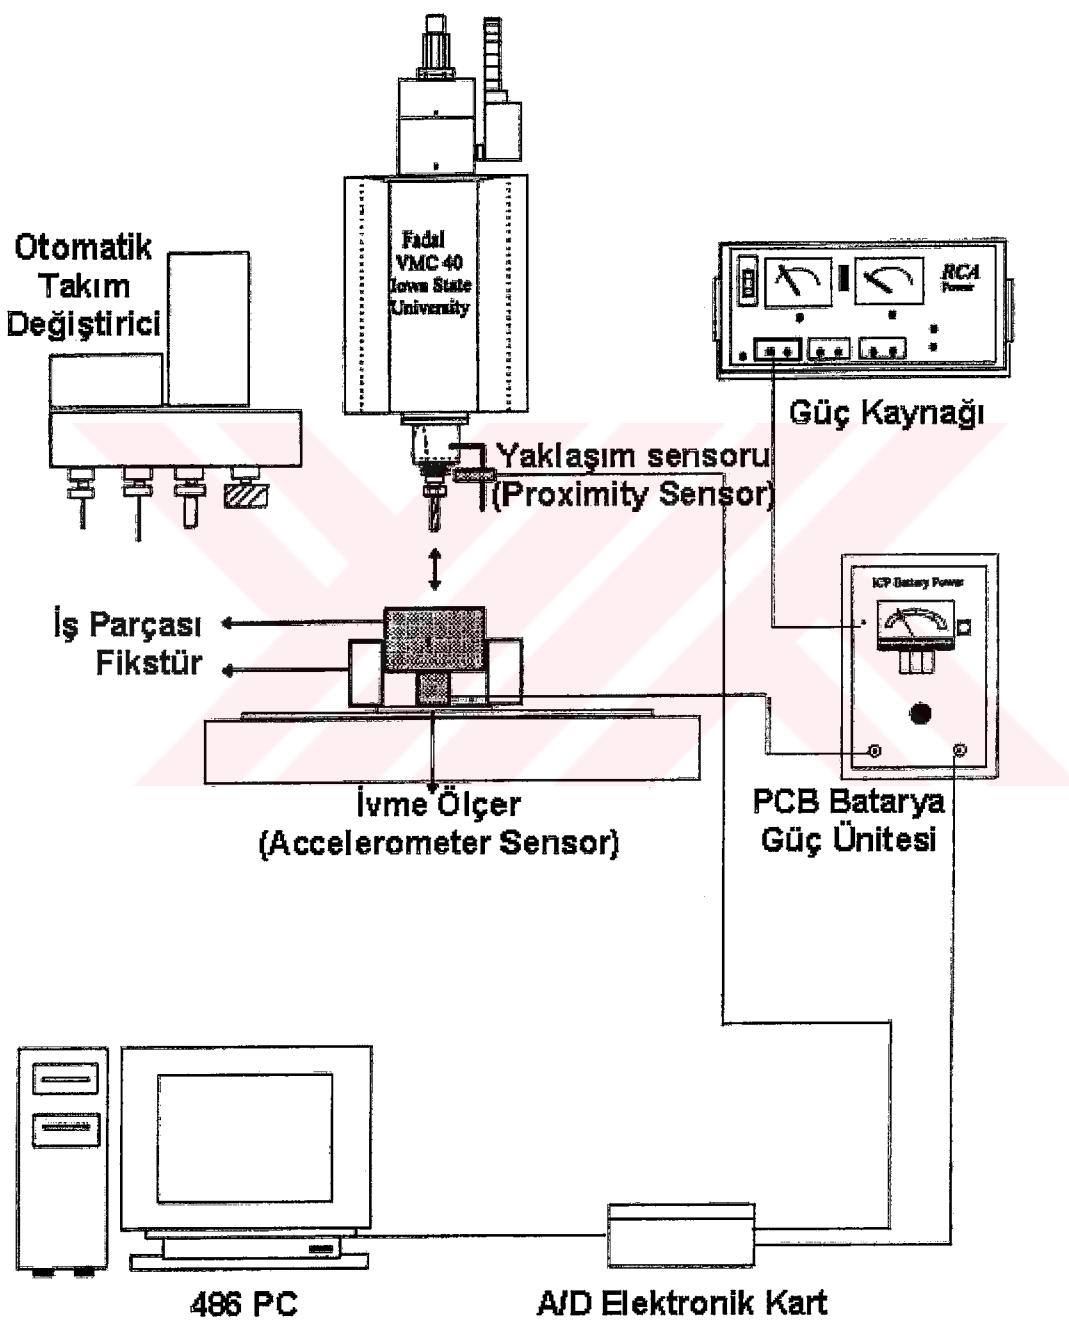


Şekil 3.47 Takım uç yarıçapının kesme kuvvet bileşenlerine etkisi (Raj vd., 2000)

1.2 Yapay Sinir Ağı Yardımıyla Yüzey Kalitesi Takibi

Talaşlı imalat esnasında aktif bir yüzey kalitesi takibi yapabilmek iş parçasını verilen yüzey kalitesi toleransları içerisinde üretebilmek açısından önemlidir. Finiş tornalamada yüzey kalitesi; ilerleme, iş parçası malzeme sertliği, yıgma ağız oluşumu, kesme derinliği, kesme hızı, takım uç yarıçapı, kesme yüzey açıları, iş parçası-imalat sisteminin titreşimlere karşı sabitliği, kesme sıvısı kullanımı gibi pek çok faktörden etkilenir. Yüzey finiş frezeleme gibi

çok noktadan talaş kaldırılan bir imalat prosesinde ise işlemin kompleksliğinden modelleme yapabilmek daha da zorlaşır. Bu işlemde yüzey kalitesini etkileyen olası faktörler şunlardır; ilerleme, kesme hızı, kesme derinliği, kesme kuvveti, freze çakı geometrisi, takım salgısı, aşınma miktarı ve dinamik kesme şartlarında oluşan takım titreşimi. Tsai vd. (1999) yapay sinir ağı yardımıyla yüzey kalitesini takip ettikleri çalışmada daha önceki benzer pek çok



Şekil 3.48 Deney düzeneği (Tsai vd., 1999)

çalışmada kullanılan akustik yayının sensorunun güvenilirliğine ciddi eleştiriler getirilmiştir. Öncelikle sensorun doğruluğunun büyük oranda ölçüm açısına ve iş parçası-sensor mesafesine bağlı olduğu belirtilmiştir. Bunun yanında talaş akışı, kesme sıvısının dinamiği, iş parçası-tezgah titreşimleri ve buna bağlı sesler sert kesme koşulları da sensor ölçümlerini etkiler. Ayrıca her farklı malzeme şartında değişen verileri ve pahalı bir cihaz olması akustik yayının sensorunun kullanımını cazip olmaktan çıkarır. Bu nedenlerden ötürü Tsai vd. çalışmalarında Accelerometer (ivme ölçer) kullanmayı tercih etmişlerdir.

Çalışmada kullanılan yapay sinir ağı hatanın geriye yayınımı algoritması ile eğitilmiştir. Eğitimin sonlandırılması için bir hata kriteri tanımlanmamış önceden eğitimdeki çevrim sayısı 2000 olarak belirlenmiştir. Deney düzeneği Şekil 3.48'de görüldüğü gibidir. Çizelge 3.23'de görülen kesme şartlarının toplam 48 kombinasyonunda (4 seviye ana mil dönme hızı x 4 seviye ilerleme x 3 seviye kesme derinliği) yüzey pürüzlülüğünü veren R_a değerleri tespit edilmiştir. Veri toplama zaman aralığı 0.54 saniye olmak koşuluyla ivme ölçer ve yaklaşım sensoru tarafından elde edilen toplam 6000 titreşim ve dönme verisine ulaşılmıştır. Yaklaşım sensoru sayesinde parçanın işlenmeye başlandığı uç kısmından 0.35 inç uzaklaşıldıktan sonra ölçüme başlanarak ilk anlardaki düzensiz titreşim aralığından kurtulmuştur. Bir tam devirde ivme ölçerden alınan sinyallerin matematiksel ortalaması ile hesaplanan devir başına ortalama titreşim 6000 veriyi 492' ye indirmiştir. Eşleştirilen ana mil dönme hızı, ilerleme, kesme derinliği, devir başına ortalama titreşim ve yüzey pürüzlülüğü örneklerinden 450 tanesi yapay sinir ağının eğitiminde kullanılmış, rastgele seçilen 42 tanesi ise test için kullanılmıştır.

Çizelge 3.23 Deney şartları (Tsai vd., 1999)

A. Mil D. Hızı (rpm)	İlerleme (inç/dak.)	Kesme Derinliği (inç)
1. Seviye	750	6
2. Seviye	1000	12
3. Seviye	1250	18
4. Seviye	1500	24
		—

Hemen hemen bütün çalışmalarında yapıldığı gibi giriş ve çıkış değerlerinin 0-1 aralığına normalize edilmesi bu çalışmada da rutin bir işlem olarak karşımıza çıkmaktadır. Çalışmada örnek alınabilecek en güzel taraf Çizelge 3.24'de görüldüğü gibi değişik gizli katman sayıları ve gizli işlem elemanları ile hatanın en küçük bulunabilindiği ağ yapısının araştırılmasıdır. Bu denemelerde tek gizli katmana sahip ağda 4-5-1 yapısı ve iki gizli katmana sahip ağda 4-7-7-1

yapısının en uygunu olduğu görülmüştür. Yapay sinir ağıyla karşılaştırma yapılabilinecek nümerik metodla kurulan matematik bir model üzerinde de çalışılmıştır; istatistiksel çoklu regresyon modeli. Eğitim ve test sonuçları Çizelge 3.25'de görüldüğü gibidir. En iyi performansı gösteren 4-7-7-1 yapısındaki ağdır.

Çizelge 3.24 Yapay sinir ağı model özeti; değişik yapılar ile eğitim test setindeki ortalama hataları (Tsai vd., 1999)

Gizli Katman Sayısı Yapı	Eğitim Çevrimi	Eğitim Örneklерinde Ort. Hata	Test Örneklерinde Ort. Hata	Eğitim Süresi(s)
0	4-0-1	2000	0,01387	0,01517
1	4-1-1	2000	0,01489	63
	4-2-1	2000	0,00877	77
	4-3-1	2000	0,00842	93
	4-4-1	2000	0,00803	106
	4-5-1	2000	0,00608	121
	4-6-1	2000	0,00633	134
	4-7-1	2000	0,00624	147
	4-8-1	2000	0,00823	161
2	4-1-1-1	2000	0,01385	72
	4-2-1-1	2000	0,00931	87
	4-2-2-1	2000	0,00900	101
	4-3-1-1	2000	0,00854	102
	4-3-2-1	2000	0,00690	117
	4-3-3-1	2000	0,00725	139
	4-4-1-1	2000	0,00685	115
	4-4-2-1	2000	0,00599	131
	4-4-3-1	2000	0,00585	147
	4-4-4-1	2000	0,00671	162
	4-5-1-1	2000	0,00802	129
	4-5-2-1	2000	0,00730	147
	4-5-3-1	2000	0,00315	164
	4-5-4-1	2000	0,00570	181
	4-5-5-1	2000	0,00504	198
	4-6-1-1	2000	0,00653	143
	4-6-2-1	2000	0,00561	162
	4-6-3-1	2000	0,00583	181
	4-6-4-1	2000	0,00451	201
	4-6-5-1	2000	0,00249	218
	4-6-6-1	2000	0,00383	239
	4-7-1-1	2000	0,00730	157
	4-7-2-1	2000	0,00615	178
	4-7-3-1	2000	0,00312	198
	4-7-4-1	2000	0,00342	218
	4-7-5-1	2000	0,00624	239
	4-7-6-1	2000	0,00172	258
	4-7-7-1	2000	0,00084	278
3	4-8-1-1	2000	0,00465	179
	4-8-2-1	2000	0,00451	194
	4-8-3-1	2000	0,00645	216
	4-8-4-1	2000	0,00182	238
	4-8-5-1	2000	0,00385	269
	4-8-6-1	2000	0,00119	279
	4-8-7-1	2000	0,00101	299
	4-8-8-1	2000	0,00249	321

Yapay sinir ağıının genelleme yapabilme kabiliyeti başka bir deyişle öğrendiği şartlardan çok daha farklılarında da gerçege yakın tahminlerde bulunabilmesi bütün uygulamalarda üzerinde durulan ana temalardan biridir. Burada da 9, 15 ve 21 inç/dak gibi farklı ilerleme değerlerinde 36 eşleştirme için performans testleri yapılmıştır. Test sonuçları Çizelge 3.26'da görüldüğü

gibidir. İstatistiksel metodlar yapay sinir ağlarının gerisinde kalmaktadır. Önceden tahmin edilebileceği gibi 4-7-7-1 yapısındaki ağ en başarılı modeldir. Bu sonuç doğrusal olmayan değişken ilişkilerinde aradaki kompleks etkileşimi kavrayamamıştır. Gizli katman sayısının arttırılmasının önemini de göstermektedir. Gizli katman sayısının arttırılmasının önündeki tek handikap eğitim zamanının uzamasıdır. Bu çalışmada 4-5-1 ağında 121 saniye, eğitim için yeterliyken, 4-7-7-1 ağının ancak 278 saniyede bu aşamayı bitirebilmektedir. Doğruluk yüzdeleri ise sırasıyla %95.78 ve %99.27 şeklindedir. Bu sonuçlar doğruluk ile eğitim süresinin de ağ yapısının seçiminde önemli iki faktör olduğunu göstermektedir.

Çizelge 3.25 Yapay sinir ağları ile istatistiksel metod sonuç karşılaştırması (Tsai vd., 1999)

Model	Yapı	Eğitim verilerinde yüzde sapma	Test verilerinde yüzde sapma
İstatistiksel (Çoklu regresyon)	Model A (Etkileşim terimleri olmayan)	14.03	13.82
	Model B (Etkileşim terimleri olan)	8.73	9.55
Yapay sinir ağları (Hatanın geriye yayınımı)	Tek gizli katman (4-5-1 yapısı)	5.34	4.13
	İki gizli katman (4-7-7-1 yapısı)	0.70	0.73

Çizelge 3.26 Performans testi sonuçları (Tsai vd., 1999)

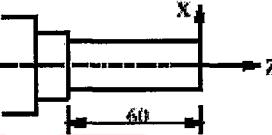
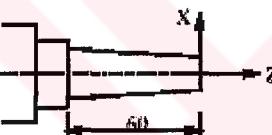
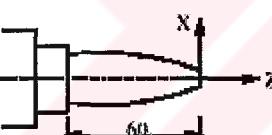
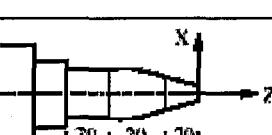
Model	Yapı	Tahminlerde yüzde sapma
İstatistiksel (Çoklu regresyon)	Model A (Etkileşim terimleri olmayan)	10.74
	Model B (Etkileşim terimleri olan)	8.73
Yapay sinir ağları (Hatanın geriye yayınımı)	Tek gizli katman (4-5-1 yapısı)	7.93
	İki gizli katman (4-7-7-1 yapısı)	3.93

Yüzey kalitesinin takibi ve iyileştirilmesi için CNC tezgah kodlarına anlık müdahaleleri beraberinde getiren ilginç bir çalışma da Suneel ve Pande'den (2000) gelmiştir. Çalışmalarında kullandıkları temel mantık tezgahta oluşan hatalardan ya da sapmalardan önceden haberdar olunursa bunların düzeltilebileceği şeklindedir. Yüzey kalitesini kesme hızı, ilerleme, takım geometrisi ve iş parçası, takım, fikstür sistem sabitliği gibi pek çok faktörün etkilediği belirtilmiştir, bu kompleks etkileşimin eşleştirilmesinde yapay sinir ağları kullanılarak tahmine dayalı düzeltmenin yapılabılırlığı araştırılmıştır.

Yapay sinir ağının eğitimi ve testi amacıyla Çizelge 3.27'de görüldüğü gibi farklı profillerde parçaların tornalandığı deneyler düzenlenmiştir. Parça teknik resmindeki nominal değerler alınarak, bir başka deyişle ideal şartlar düşünülerek hazırlanmış CNC programının sonucunda gerçekleşen boyut ve geometri sapmalarını görebilmek amacıyla parça boyunca 25 farklı noktada ölçümler yapılmıştır. Ölçüm hatasını azaltabilmek için ölçüm noktasında 120° açıyla üç okuma yapılarak ortalaması alınmıştır. Profil hatası yüzde olarak şu şekilde hesaplanır;

$$\epsilon_p = \% \frac{(D_i - D_a)}{D_i} \times 100 \quad (3.12)$$

Çizelge 3.27 Parça geometrileri ve işleme koşulları (Suneel ve Pande, 2000)

Profil Tipi	Parça Geometrisi	İşleme Parametreleri					Parça Sayısı
		V	F	D	S	L/D	
Silindir		80	0.1	0.3	3500	2.4	16
		90	0.15	0.3	3500	3	
		110	0.2	0.3	3500	4	
Eğimli		90	0.1	0.3	3500	2.4	16
		110	0.15	0.3	3500	2.67	
		90	0.1	0.3	3500	2.67	
Konvex		110	0.15	0.3	3500	3	8
		90	0.1	0.3	3500	2.67	
		110	0.15	0.3	3500	3	
Konkav		90	0.1	0.3	3500	2.67	8
		110	0.15	0.3	3500	3	
		90	0.1	0.3	3500	2.32	
Birleşik		110	0.15	0.3	3500	2.32	4
		90	0.1	0.3	3500	2.86	
		110	0.15	0.3	3500	2.86	
		90	0.1	0.3	3500	2.55	4
		110	0.15	0.3	3500	2.55	
		90	0.1	0.3	3500	2.55	

Burada e_p parça sapmasını, D_i ideal çapı (mm), ve D_a gerçekleşen çapı (mm) gösterir. Yarıçap sapması ise şu şekilde hesaplanır;

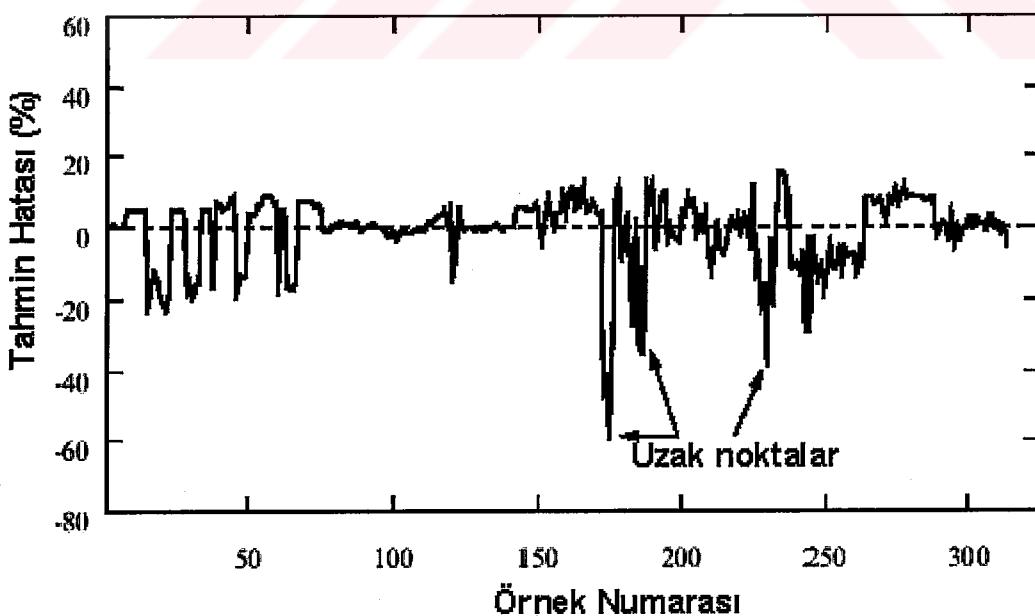
$$e_r = e_p \times R_i \quad (3.13)$$

Burada e_r yarıçap profil sapması ve R_i ideal profil yarıçapıdır. Yapay sinir ağı yapısı giriş verileri olarak kesme hızını, ilerlemeyi, L/D (iş parçası uzunluğu/çapı) oranını, takım pozisyonunu (ölçümlerin yapıldığı 25 noktadan biri, Zpos) ve nominal boyutu (X) alacak şekilde 5 giriş işlem elemanlı ve parça hatasını ($\% e_p$) verecek şekilde tek çıkış işlem elemanlı tasarlanmıştır. Optimum ağ parametrelerine ulaşabilmek için her bir farklı profil işlemede değişik gizli katman işlem elemanı sayısı ve aktivasyon fonksiyonu denenmiştir. CNC kodundaki düzeltme şu formüle göre yapılır;

$$D_{ic} = (1+e_n/100) \times D_i \quad (3.14)$$

Burada D_{ic} düzeltilmiş nominal çap (CNC'de düzeltilmiş X boyutu), D_i ideal çap (İdeal CNC komutlarındaki X boyutu) ve e_n yapay sinir ağı tarafından tahmin edilen yüzdelik sapmadır. Düzeltme doğal olarak tahminin yapıldığı iş parçası noktasında (Zpos) yapılır.

Silindirik profil işlemede parça malzeme elastikliğinin de hesaba katılabilmesi için üç değişik çapta parça işlenmiştir. Hatayı sıfıra en çok yaklaşırın ağ yapısı değiştirilmiş sigmoid



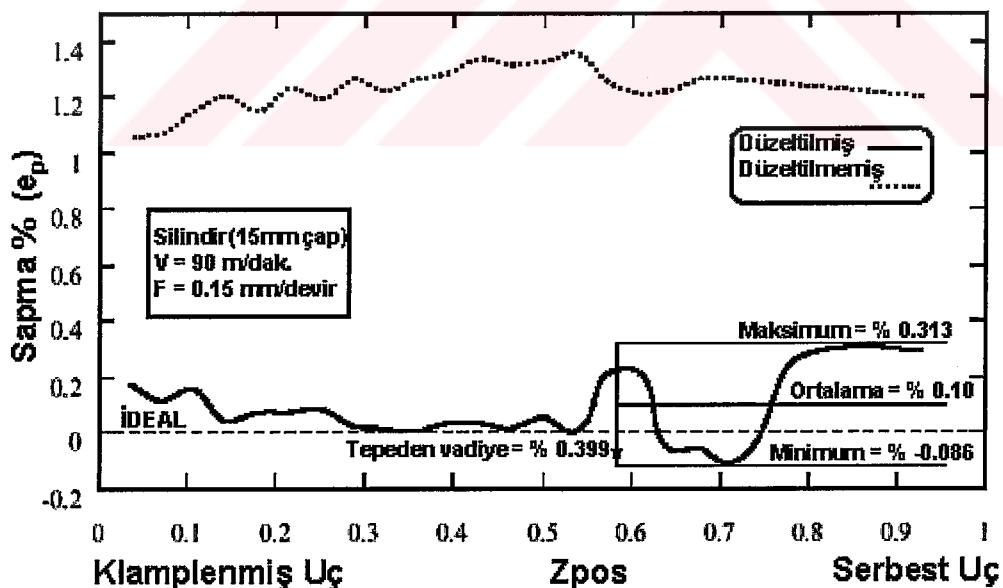
Şekil 3.49 Yapay sinir ağının tahmin doğruluğu (Silindir profil verileri) (Suneel ve Pande, 2000)

fonksiyonu aktivasyon fonksiyonu olarak kullanan 5-10-1 şeklindeki ağdır. Değiştirilmiş sigmoid fonksiyon şu şekilde tanımlanır;

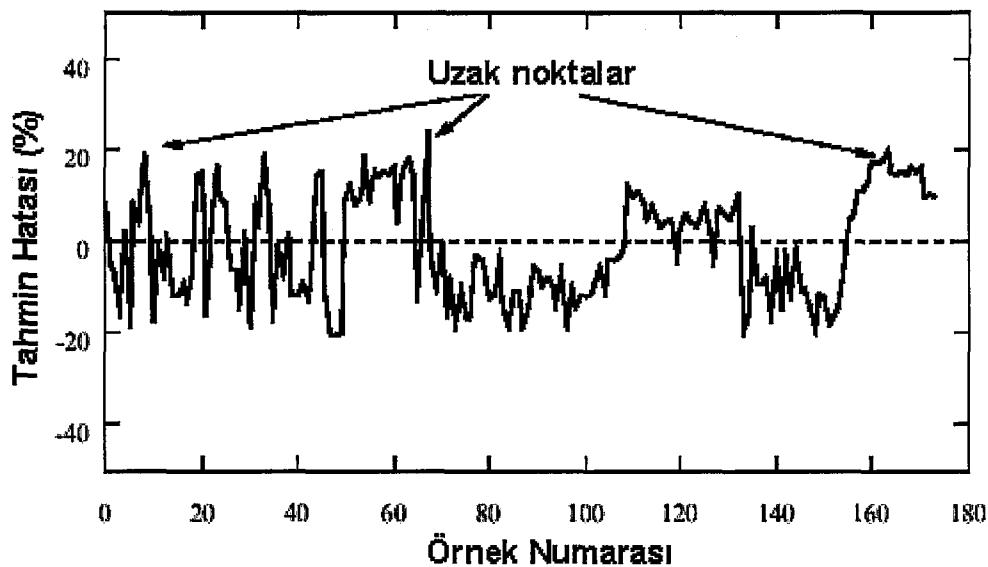
$$f(x) = \frac{1}{(1+e^{-bx})} \quad (3.15)$$

Eğitilen yapay sinir ağı 300 örnekle test edilmiştir. Ortalama sapma tahmin hatası % 8.52'dir. Şekil 3.49'da görüldüğü gibi ideal tahmin çizgisinden uzak bazı noktaları saymazsa yapay sinir ağının testi geçtiğini söyleyebiliriz.

İdeal CNC programıyla oluşan profil hataları ve yapay sinir ağının tahminleriyle düzeltlenen CNC programının profil hataları karşılaştırılmış olarak Şekil 3.50'de görülmektedir. Pozitif profil sapma (e_p) değeri gerçekleşen çapın idealden küçük olduğunu göstermektedir. Bu durumun düzeltilmesi CNC kodda X+ yönünde iş parçası çapından dışa doğru bir ayarlamayı gerektirir. Düzeltilmiş CNC programı hatayı ideal çizgiye getirmekte epey başarılıdır. Ortalama yarıçap profil hatası (e_r) 91 μm 'den 9 μm 'ye düşmüştür. Serbest uçtaki hata genliğinin diğer kısımlara göre biraz daha yüksek olması yapay sinir ağının düzeltmelerinin kısım kısım yapılması halinde daha büyük başarıya ulaşabileceğini izlenimini vermektedir.

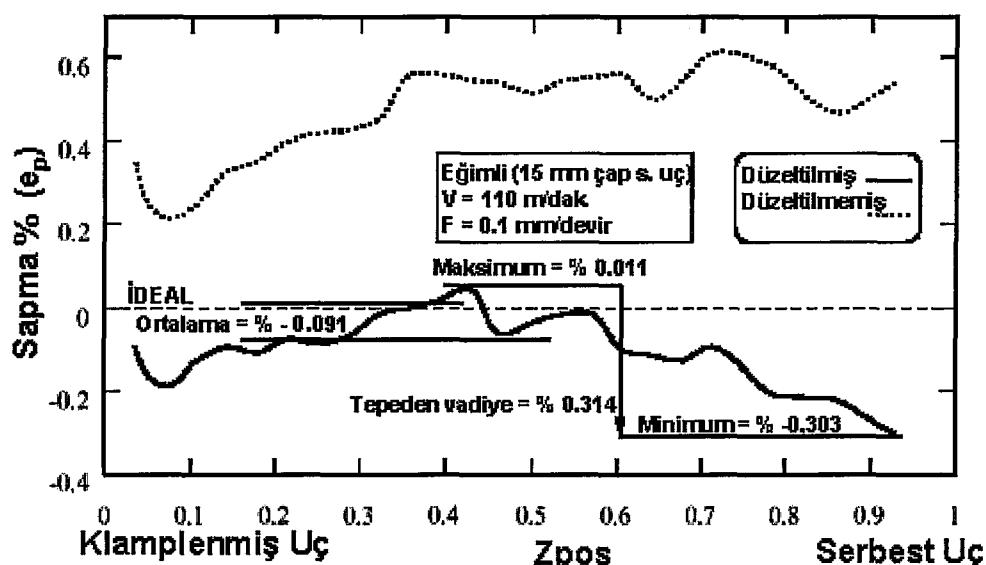


Şekil 3.50 Silindir tornalamada profil sapma karşılaştırması (Suneel ve Pande, 2000)



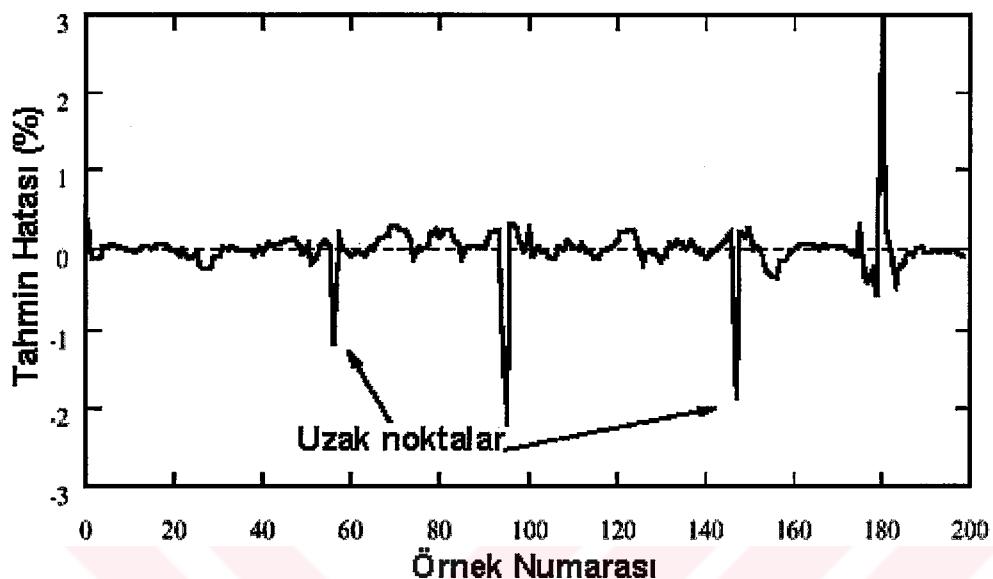
Şekil 3.51 Yapay sinir ağının tahmin doğruluğu (Eğimli profil verileri) (Suneel ve Pande, 2000)

Eğimli profillen işlenmesinde en uygun yapay sinir ağının 5-5-5-1 yapısı bulunmaktadır. Kullanılan işlem elemanlarının aktivasyon fonksiyonu değiştirilmiş sigmoid fonksiyondur. Eğitilen yapay sinir ağının 170 örnekte test edilmiştir. Şekil 3.51'de görülen tahmin sonuçları bir kaç uzak nokta dışında ideale uygunluk göstermektedir. İdeal boyutları temel alarak yazılan CNC programının ve yapay sinir ağıyla düzeltlenen CNC programının işlediği parçaların profil sapmaları Şekil 3.52'de verilmiştir. Düzeltlenen program parçaya

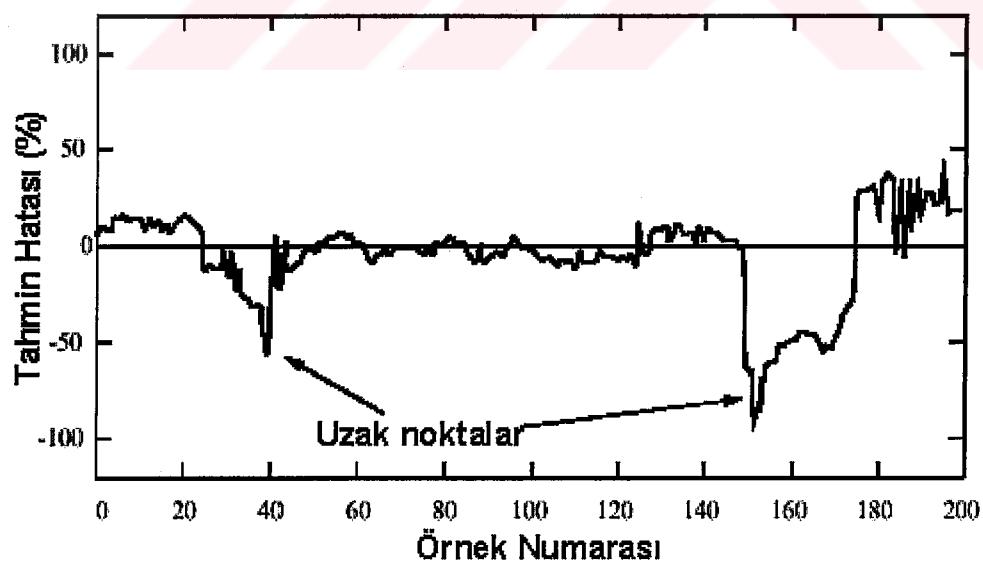


Şekil 3.52 Eğim tornalamada profil sapma karşılaştırması (Suneel ve Pande, 2000)

öncekine benzer bir sapma profili kazandırmıştır fakat boyut sapması oldukça düşmüştür. Serbest uca gidildikçe tepe-vadi arası sapmanın düzeltilen programla işlenen parçada çok az daha yüksek olduğu farkedilmiştir.

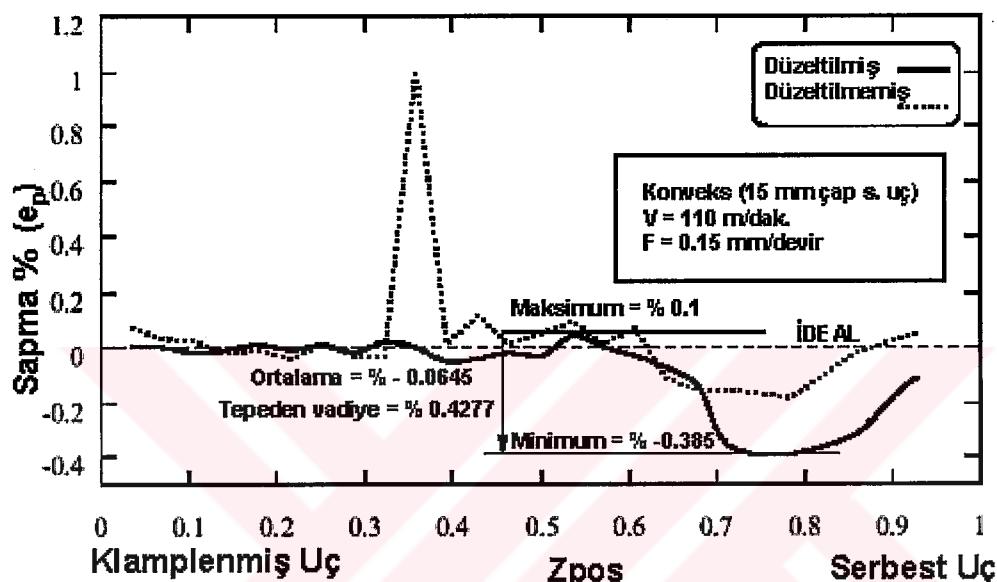


Şekil 3.53 Yapay sinir ağının tahmin doğruluğu (Konveks kavis profil verileri) (Suneel ve Pande, 2000)

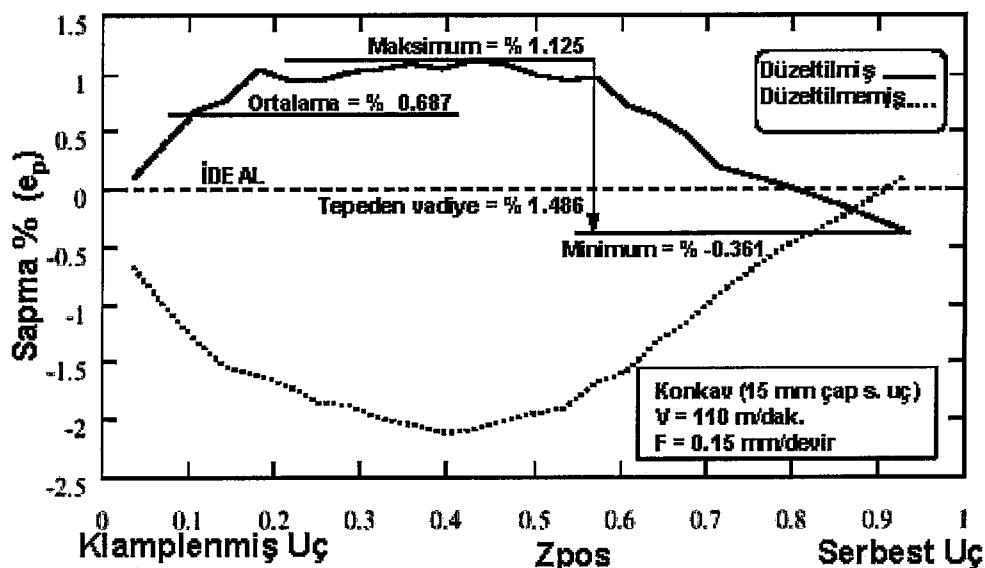


Şekil 3.54 Yapay sinir ağının tahmin doğruluğu (Konkav kavis profil verileri) (Suneel ve Pande, 2000)

Konveks ya da konkav kavisli profillerin işlenmesinde sırasıyla 5-10-1 ve 5-8-1 ağ yapıları kullanılmıştır. Yapay sinir ağlarının eğitilmesinden sonra test amaçlı 200 örnek üzerindeki tahmin sonuçları Şekil 3.53 ve Şekil 3.54'de görülmektedir. Şekil 3.55 ve Şekil 3.56 ise başta kullanılan ve düzeltlenen profil hata sonuçlarını vermektedir. İki farklı kaviste de düzeltlenen CNC programla birlikte sapmalar azaltılmıştır fakat konkav profilde sapmanın doğasının tersine çevrildiği gözden kaçmamaktadır. İdeale dayalı CNC programıyla profilden fazla talaş kaldırılırken düzeltilmiş programla parça daha az işlenmiştir.

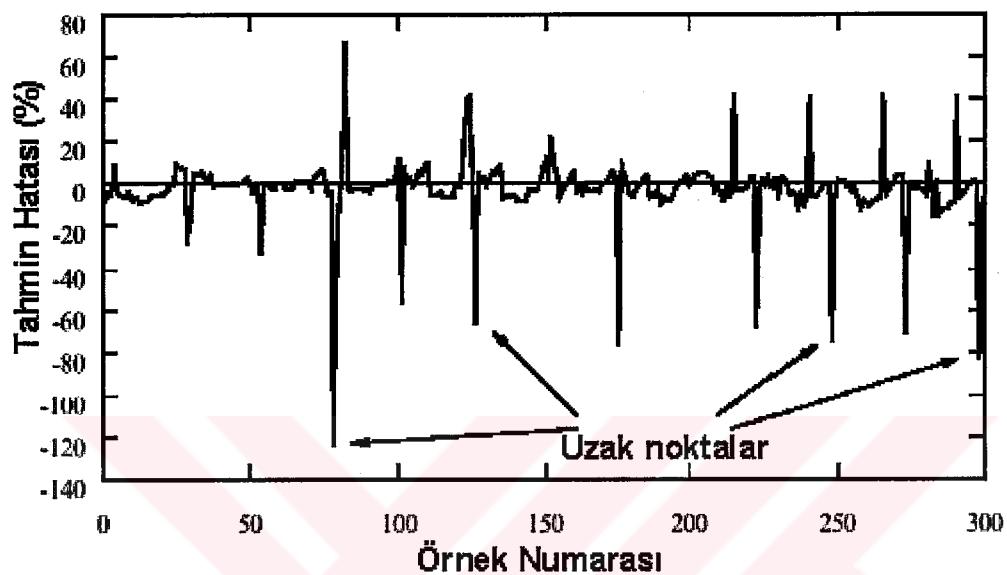


Şekil 3.55 Konveks kavis tornalamada profil sapma karşılaştırması (Suneel ve Pande, 2000)

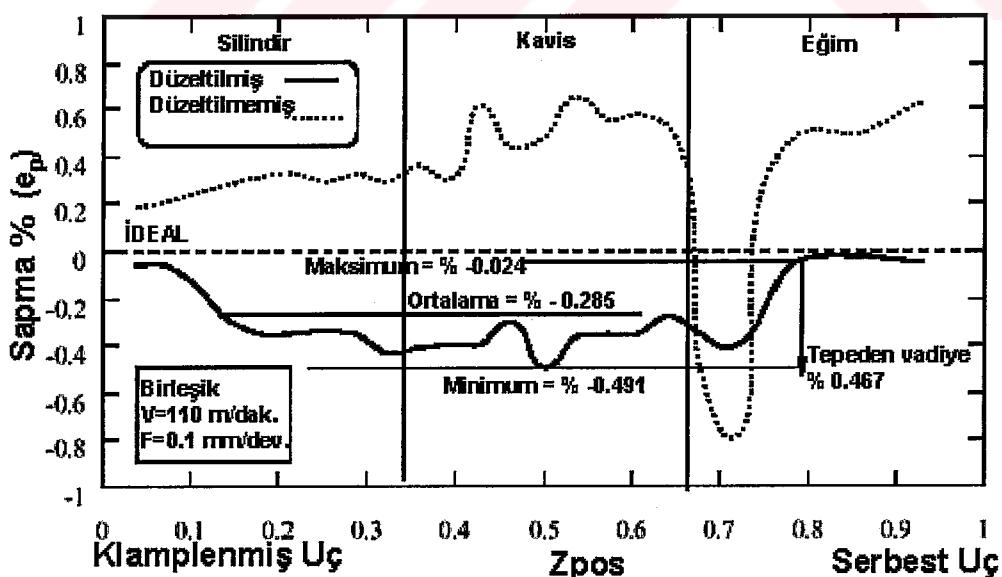


Şekil 3.56 Konkav kavis tornalamada profil sapma karşılaştırması (Suneel ve Pande, 2000)

Birleşik profilen işlenmesinde sigmoid fonksiyonun aktivasyon fonksiyonu olarak seçilmesiyle beraber 5-10-1 ağ yapısı kullanılmıştır. Eğitilen yapay sinir ağı 300 örnek üzerinde test edilmiş Şekil 3.57'de görüldüğü gibi bir kaç uzak nokta dışında ideale yakınlık gözlemlenmiştir. Daha önceki programla işlenen ve düzeltilmiş programla imal edilen



Şekil 3.57 Yapay sinir ağının tahmin doğruluğu (Birleşik profil verileri) (Suneel ve Pande, 2000)



Şekil 3.58 Birleşik geometri tornalamada profil sapma karşılaştırması (Suneel ve Pande, 2000)

parçaların profil sapmaları da Şekil 3.58'dedir. Sapmanın kavisten eğime geçişte epey

azaltıldığı gözlemlenmektedir.

Profil ve boyut sapmalarını düzeltmeye yönelik bu çalışmanın bütün CNC tezgahlarına uygulanabileceği, yüksek sayıda üretimlerde sistem değiştirilmeden daha doğru, nominal değerlere daha yakın parçalar üretilebileceği sonucuna varılmıştır. Genel mahiyette bulguları özetleyen Çizelge 3.28 bunu desteklemektedir.

Çizelge 3.28 Profil sapmalarının karşılaştırılması(Suneel ve Pande, 2000)

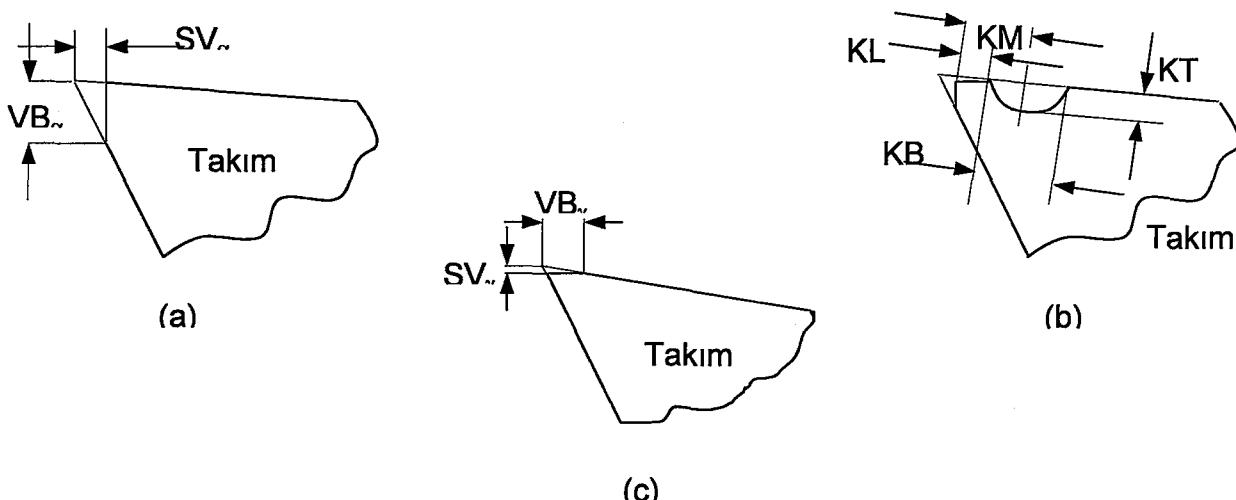
Profil Tipi	Hata Tipi	Düzeltilmemiş Kod % e_p (e_r)	Düzeltilmiş Kod % e_p (e_r)
Silindir	Maksimum	% 1.34 (100 µm)	% 0.313 (23 µm)
	Minimum	% 1.06 (79 µm)	% 0.0 (0 µm)
	Ortalama	% 1.22 (91 µm)	% 0.1 (7 µm)
	Tepeden vadiye	% 0.28 (21 µm)	% 0.399 (3 µm)
Eğimli	Maksimum	% 0.613 (52 µm)	% 0.303 (23 µm)
	Minimum	% 0.214 (26 µm)	% 0.015 (2 µm)
	Ortalama	% 0.472 (44.5 µm)	% 0.091 (9 µm)
	Tepeden vadiye	% 0.399 (26 µm)	% 0.344 (22 µm)
Konveks	Maksimum	% 1.002 (123 µm)	% 0.385 (27 µm)
	Minimum	% 0.26 (13 µm)	% 0.001 (2 µm)
	Ortalama	% 0.036 (5 µm)	% 0.065 (4 µm)
	Tepeden vadiye	% 1.185 (136 µm)	% 0.427 (31 µm)
Konkav	Maksimum	% 0.114 (8 µm)	% 1.125 (96 µm)
	Minimum	% -2.118 (185 µm)	% 0.36 (31 µm)
	Ortalama	% -1.432 (130 µm)	% 0.687 (61 µm)
	Tepeden vadiye	% 2.236 (193 µm)	% 1.486 (123 µm)
Birleşik	Maksimum	% -0.791 (84 µm)	% -0.024 (2 µm)
	Minimum	% 0.649 (69 µm)	% -0.491 (54 µm)
	Ortalama	% 0.315 (39 µm)	% 0.285 (37 µm)
	Tepeden vadiye	% 1.439 (138 µm)	% 0.467 (52 µm)

2. YAPAY SİNİR AĞIyla KESİCİ TAKIM AŞINMASI TAHMİN MODELİNİN OLUŞTURULMASI

2.1 Aşınma Geometrisi

Kesici takım aşınmasında ana hızlandırıcı etken sürtünme ve malzeme kaybına karşı mukavemeti azaltması yönyle sıcaklıktır. Kesme sürtünmesinin sürekli olarak taze yüzeylerde, yüksek sıcaklık, yüksek basınç koşulları ve nispeten küçük temas alanlarında oluşmasından dolayı takımların aşınması sürtünme, yapışma, yenme, difüzyon, korozyon gibi çeşitli aşınma şekillerini kapsayan karmaşık bir olaydır. (Özgürler (1987, 1988))

Serbest yüzeyde aşınma normal bir malzeme kaldırılması şeklindedir. (Şekil 4.1a) Bu aşınmanın oluşma nedeni iş parçasının işlenmiş yüzeyi ile takımın serbest yüzeyi arasındaki temas bölgesinde meydana gelen sürtünmedir. Talaş yüzeyindeki aşınma ise, bir oyuk (krater) biçiminde meydana gelir. (Şekil 4.1b) Krater aşınması talaş yüzeyi boyunca akan talaşın etkisi ile oluştugundan talaşın alt kısmının şekline uyar ve sadece talaş-takım temas bölgesinde ortaya çıkar. DIN standartlarına göre, serbest yüzeyde aşınan kısmın yüksekliği VB_{α} eni SV_{α} (α olayın serbest yüzeyde olduğunu gösterir) ; talaş yüzeyinde oluşan oyuk şeklinde aşınan kısmın genişliği KB , derinliği KT , orta kısımdan uca kadar olan mesafe KL ile gösterilir. Bazı hallerde talaş yüzeyinde de normal bir aşınma meydana gelebilir; bu durumda aşınan kısmın boyutları VB_{γ} ve SV_{γ} olarak gösterilir. (Şekil 4.1c) Oyuk biçimindeki aşınmanın en önemli boyutları kenar mesafesi ve derinliğidir. Kenar mesafesinin küçülmesi, takım ucunun zedelenmesine veya tamamen yokmasına nedendir. (Akkurt (2000), DeGarmo (1988))



Şekil 4.1 Takım Aşınma Geometrisi

Takımın aşınmış sayılması için;

- Serbest yüzeyde aşınma bölgesinin belirli bir boyuta ulaşması,
- Talaş yüzeyinde krater veya başka bir aşınma çeşidinin meydana gelmesi
- Kesme ağzından küçük parçacıkların kopması,
- Yüzey kalitesinin bozulması,
- Kesme kuvvetinin ve gücün aniden artması durumlarından biri veya birkaçı meydana gelmelidir.

2.2 Tornalama Veri Seçimi

Çalışmadaki ana amaç talaşlı imalatta çok ustalaşmış insanların takım aşınması üzerine belli parametrelere ve zamana bağlı olarak yapabilecekleri tahminlere yapay sinir ağının doğrusal olmayan eşleştirmeleriyle ulaşabilmektir. Yapay sinir ağının üzerinde uzmanlaşacağı temel konu aşınma olunca belli aşınma değerlerine karşılık gelen kesme hızı, kesme derinliği, ilerleme gibi kesme parametreleriyle, dinamometre yardımıyla ölçülebilen kesme kuvvetleri ve çalışma zaman değerlerine ihtiyaç duyulur. Makine imalat el kitaplarından elde edilemeyecek bu veriler ancak deney sonuçlarından çıkarılabilir. Bu nedenle çalışmaya esas teşkil edecek bilgi daha önce yapılmış deneylerden seçilmiştir.

S.Purushotaman ve Y.G.Srinavasa'nın 1994 ve 1998 yıllarında yayınlanan çalışmaları kesme parametrelerinin çok geniş bir aralıkta denenmesi ve uzun bir liste oluşturacak kadar çok veriye ulaşılması açısından eşsizdir. Çalışmada iş malzemesi küresel grafitli dökme demir, kesici takım da ticari ismi Widalon HK15 olan 13 tabaka ALON, TiC, TiN, Ti(C,N) kaplamalı karbür torna kalemidir. Kullanılan tezgah yüksek hız hassasiyetine sahip VDF tornadır. Deneyde ulaşılan kesme kuvvetleri dinamometreden aşınma ölçümü yapılmadan önce okunan son değerlerdir. Aşınma miktarı olarak mikroskopla ölçülen serbest yüzey aşınması genişliği (VB) alınmıştır.

Yapay sinir ağına giriş olarak verilen değerler kesme hızı (S), ilerleme (f), kesme derinliği (Dc), üç ana yönde kesme kuvvetleri (F_x , F_y , F_z) ve aşınma ölçümünün yapıldığı çalışma zamanıdır. Yapay sinir ağından çıkış olarak istenen ise serbest yüzey aşınması genişliğinin tahmin edilmesi, pratik olarak da $200 \mu\text{m}$ kritik aşınma değerinin ayırdığı iki sınıf arasından bir seçim yapılmasıdır. Deney sonucu elde edilen 113 adet veri grubu Çizelge 4.1'de gösterildiği gibidir.

Çizelge 4.1 Tornalamada toplanan veriler

S.no.	S (m/dak)	f (mm/devir)	Dc (mm)	Fx (N)	Fy (N)	Fz (N)	Zaman (saniye)	VB (µm)
1	450	0.10	1.5	150	115	350	45	15
2	450	0.10	0.5	60	50	115	38	15
3	450	0.10	2.0	180	130	450	32	15
4	350	0.10	0.5	60	90	125	30	15
5	300	0.06	0.5	45	80	70	428	20
6	300	0.06	0.5	40	85	65	428	20
7	200	0.06	0.5	40	65	75	428	20
8	400	0.10	0.5	60	85	110	428	20
9	300	0.08	0.5	50	90	85	428	20
10	300	0.08	0.5	45	90	85	428	20
11	400	0.06	0.5	40	75	95	428	20
12	500	0.08	0.5	50	40	105	428	20
13	200	0.10	0.5	60	90	110	428	20
14	400	0.08	0.5	55	90	100	428	20
15	500	0.10	0.5	50	95	110	428	20
16	200	0.10	0.5	45	85	105	428	20
17	450	0.10	1.0	115	105	250	428	20
18	300	0.10	0.5	45	110	105	428	20
19	300	0.10	0.5	40	105	105	428	20
20	200	0.06	0.5	35	65	70	428	20
21	500	0.06	0.5	45	70	90	428	20
22	200	0.08	0.5	40	75	80	428	20
23	200	0.08	0.5	50	75	90	428	20
24	400	0.20	0.5	75	115	195	428	20
25	300	0.25	0.5	70	140	225	428	20
26	200	0.20	0.5	50	125	190	428	20
27	200	0.20	0.5	120	130	190	428	20
28	400	0.25	0.5	80	125	230	428	20
29	300	0.20	0.5	65	130	185	428	20
30	500	0.25	0.5	60	115	215	428	20
31	500	0.20	0.5	60	110	195	428	20
32	200	0.25	0.5	85	160	220	428	20
33	200	0.25	0.5	60	150	210	35	20
34	450	0.10	0.5	60	55	105	92	30
35	350	0.10	0.5	55	85	140	75	30
36	450	0.10	1.5	130	115	345	65	30
37	450	0.10	2.0	100	140	450	60	30
38	450	0.10	1.0	100	105	250	70	40
39	400	0.10	0.5	55	85	110	129	45
40	350	0.10	0.5	60	100	120	42	45
41	450	0.10	0.5	25	70	85	111	55
42	450	0.10	2.0	160	140	470	85	55
43	350	0.10	0.5	60	100	125	165	60
44	450	0.10	1.5	150	105	330	94	65

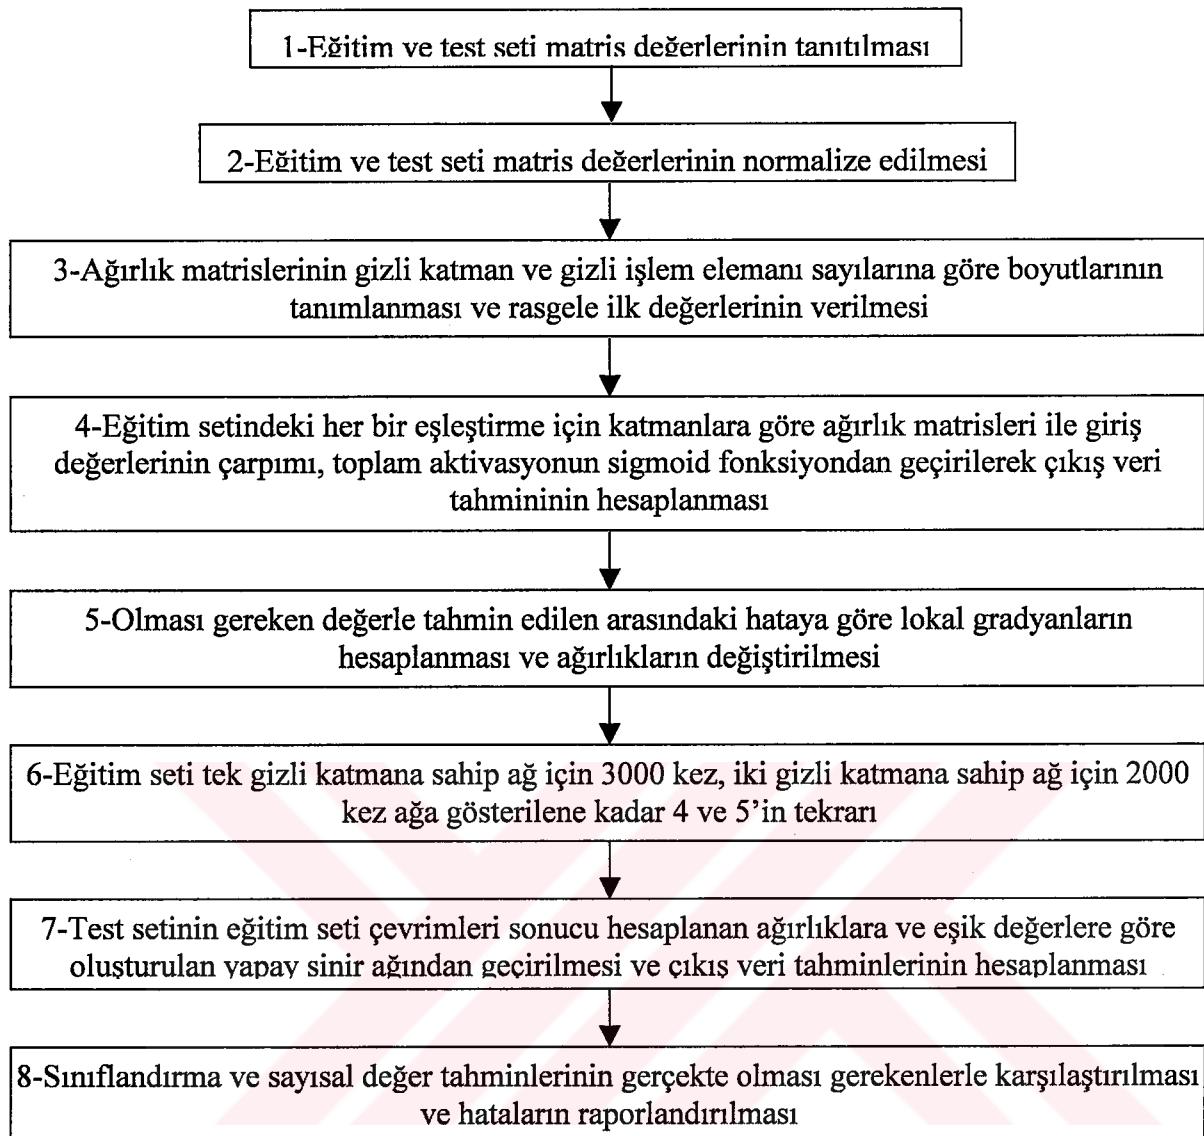
S.no.	S (m/dak)	f (mm/devir)	Dc (mm)	Fx (N)	Fy (N)	Fz (N)	Zaman (saniye)	VB (μm)
45	350	0.10	0.5	60	80	125	202	75
46	450	0.10	1.0	115	110	260	110	75
47	450	0.10	0.5	25	70	90	149	80
48	450	0.10	2.0	110	140	470	110	80
49	400	0.10	0.5	50	80	105	240	90
50	350	0.10	0.5	55	85	130	85	90
51	450	0.10	0.5	60	105	125	180	90
52	400	0.10	0.5	60	90	100	128	92
53	350	0.10	0.5	70	100	120	265	93
54	450	0.10	1.5	135	110	325	123	94
55	400	0.10	0.5	50	85	100	172	95
56	350	0.10	0.5	70	100	115	290	96
57	450	0.10	0.5	75	150	150	212	100
58	400	0.10	0.5	60	100	105	207	105
59	450	0.10	1.0	150	140	275	146	105
60	450	0.10	2.0	200	140	460	135	105
61	350	0.10	0.5	60	100	115	358	107
62	450	0.10	0.5	75	205	145	244	110
63	400	0.10	0.5	45	100	110	403	115
64	350	0.10	0.5	60	105	125	241	115
65	450	0.10	1.5	155	170	370	151	115
66	450	0.10	0.5	100	250	150	276	120
67	400	0.10	0.5	50	112	85	277	120
68	400	0.10	0.5	70	175	85	311	125
69	450	0.10	0.5	125	250	150	314	130
70	450	0.10	1.5	300	245	410	161	130
71	450	0.10	2.0	160	140	460	179	130
72	350	0.10	0.5	75	145	120	438	133
73	450	0.10	0.5	125	275	150	351	140
74	450	0.10	2.0	400	240	550	197	140
75	450	0.10	1.5	325	230	450	210	148
76	350	0.10	0.5	100	170	120	474	150
77	450	0.10	2.0	510	350	600	229	150
78	350	0.10	0.5	135	225	170	510	160
79	450	0.10	0.5	160	325	50	422	165
80	450	0.10	1.5	350	255	455	389	165
81	400	0.10	0.5	150	175	150	240	165
82	450	0.10	1.0	200	160	310	547	170
83	350	0.10	0.5	150	260	175	180	170
84	350	0.10	0.5	160	255	150	583	185
85	450	0.10	0.5	150	340	50	426	185
86	400	0.10	0.5	165	300	140	459	195
87	350	0.10	0.5	160	260	140	620	200
88	450	0.10	0.5	220	425	60	457	205
89	450	0.10	1.0	220	180	320	211	240
90	450	0.10	0.5	230	500	65	488	240
91	450	0.10	1.5	480	350	350	274	245

S.no.	S (m/dak)	f (mm/devir)	Dc (mm)	Fx (N)	Fy (N)	Fz (N)	Zaman (saniye)	VB (μm)
92	450	0.10	2.0	700	390	640	264	275
93	450	0.10	1.0	325	290	345	240	290
94	400	0.10	0.5	200	350	180	494	295
95	450	0.10	1.0	400	375	365	269	340
96	450	0.10	1.5	450	390	400	308	350
97	450	0.10	1.0	450	400	360	299	365
98	450	0.10	1.5	680	580	560	338	375
99	450	0.10	1.0	450	430	370	529	400
100	450	0.10	2.0	850	700	750	329	400
101	450	0.10	1.5	750	650	500	361	400
102	400	0.10	0.5	175	350	140	299	400
103	450	0.10	1.5	240	850	620	394	540
104	450	0.10	1.0	550	590	430	366	550
105	450	0.10	2.0	1100	1200	840	336	585
106	450	0.10	1.5	260	1200	800	427	690
107	450	0.10	1.0	570	700	450	403	755
108	450	0.10	2.0	1200	1400	1000	364	785
109	450	0.10	1.5	320	1800	1400	454	825
110	450	0.10	2.0	1500	1800	1000	396	880
111	450	0.10	1.0	950	700	500	440	980
112	450	0.10	1.5	380	1800	1500	482	980
113	450	0.10	2.0	1250	1440	1040	428	990

2.3 Gizli Katman Sayısına göre Uygun Konfigürasyonun Seçimi

Eldeki verileri bir yapay sinir ağında denemeden önceki ilk iş eğitim setinin ve test setinin belirlenmesi olmalıdır. Eğitim seti seçimi yapay sinir ağının genelleme kabiliyeti ile birebir ilişkili olduğu için önemlidir. Eğitim seti dışındaki faktörlerin öğrenmeye etkisinin incelendiği yapay sinir ağı denemelerinde ortalamalardan en fazla sapma gösteren örnekler öğrenmede kullanılmıştır. Bu örnekler Çizelge 4.1'de yer alan 5, 6, 11, 12, 13, 14, 22, 27, 32, 33, 41, 42, 44, 47, 48, 60, 71, 74, 75, 77, 102, 105, 106, 107, 108, 109, 110, 111, 112 ve 113'ten oluşan toplam 30 eşleşmedir. Geriye kalanlar ağın testlerinde kullanılmıştır.

Ekte kodları verilen C++ programlama dilinde yazılıp tasarlanan yapay sinir ağı 3 katmanlı veya 4 katmanlı ileri beslemeli, hatanın geriye yayınımı algoritmasına göre eğitilen bir yapıdadır. Yazılımda kullanılan genel algoritma da Şekil 4.2'de gösterildiği gibidir. Eğitim setinde yer alan ve yapay sinir ağına gösterilen her bir eğitim örneği için bir ileri sinyal gönderimiyle hata hesaplaması yapılmış, oluşan hatadan lokal gradyanların bulunmasıyla geri sinyal gönderiminde ağırlıklar değiştirilmiştir. Eğitim setindeki 30 örnek için ayrı ayrı bir kez tekrarlanan bu işlem sonunda 1 set çevrimi tamamlanmış olur. Her bir set çevriminde hata



Şekil 4.2 Yapay sinir ağı modellemesinde kullanılan genel algoritma

kareleri toplamı da hesaplanmakta ve rapor edilmektedir. Kullanılan konfigürasyona göre 2000 ya da 3000 set çevriminden sonra öğrenme işlemi sonlandırılmıştır.

2.4 Ağırlıkların ve Eşik Değerlerin Başlangıç Seçimleri

Yapay sinir ağıının performansını etkileyen bir başka önemli husus da eşik değerlerin ve ağırlıkların eğitim süreci öncesi seçimidir. Bu iş için genellikle 0 ila 1 arasında rasgele değerler seçilmektedir. Yapılan denemeler seçim aralığının önemini ortaya koymaktadır.

2.5 Momentum ve Öğrenme Hızı Değerlerinin Seçimi

Momentum yapay sinir ağını lokal minimumlara düşmekten alıkoyan bir parametre olarak tanımlanmaktadır. Genelleştirilmiş delta kuralından tahmin edilebileceği gibi çok büyük değerler alması halinde ağırlık değişimini yavaşlatacak çok küçük değerlerde de lokal minimumlara düşmeyi engellemekte başarısız olacaktır. Tersine öğrenme hızı, büyük değerlerle çok hızlı ağırlık değişimlerine neden olacak fakat lokal minimumlara düşme riskini de yükseltecektir. Düşük öğrenme hızınınsa öğrenmeyi yavaşlatma handikapı vardır. Göründüğü gibi iki değerin de optimize edilmesi gereklidir. Bu nedenle iki değer de 0-1 aralığında 0.1 artırılarak değiştirilmiş ve seçilen yapay sinir ağı yapılarında test edilmiştir.

2.6 Eğitim Setinin Her Bir Çevrimde Rasgele Sırayla Yapay Sinir Ağına Verilmesi

Literatürde dikkat çekilen bir diğer husus ise her bir eğitim seti çevriminde eğitim setinin düzenli bir sıra ile verilmemesi, sürekli olarak karıştırılmasıdır. Hatırlanacağı gibi delta formülünde ağırlık değişimleri bir önceki ağırlık değerlerinden ve momentum terimi sayesinde bir önceki ağırlık değişimlerinden etkilenmektedir. Düzenli bir sıra takip edildiğinde sürekli aynı değişimler etrafında dönüleceği düşünülmüş ve lokal minimumlara düşme risklerinden bahsedilmiştir. Eğitim setini her seferinde karıştırarak vermek işte bu duruma bir çözüm olarak önerilmiştir.

2.7 Normalizasyonun Yapay Sinir Ağının Öğrenmesine Etkisi

Giriş değerlerinin ve çıkış değerinin yapay sinir ağında işlenebilmesi için gerekli olan normalizasyon da üzerinde durulması gereken bir husustur. Sigmoid fonksiyonda minimum ve maksimumu veren 0 ve 1 tam değerlerine ulaşılması ancak sonsuzda mümkün olabildiği için literatürde normalizasyon bu rakamlara yakın 0.1 ve 0.9 gibi ondalıklı sayılarla yapılmaktadır. Denenen farklı bir normalizasyon tekniği ise şu formülle ifade edilebilir;

Giriş değerleri için;

$$X_i = \frac{X_i}{\sqrt{(X_1^2 + X_2^2 + \dots + X_n^2)}} \quad (4.1)$$

Çıkış değeri için;

$$X_i = \frac{X_i}{X_{\max}} \quad (4.2)$$

Tahmin edilebileceği gibi burada X normalize edilen değişken ve X_{\max} da bu değişkenin en yüksek değeridir. Geometrik ortalamanın görevlendirildiği bu tip bir normalizasyona duyulan ihtiyaç birbirinden çok farklı değerlerde bulunan ve geniş bir aralıkta değişen giriş ve çıkış verilerinden kaynaklanmaktadır.

2.8 İrdeleme Seti Kullanımı

Çalışmada kullanılan yapay sinir ağı modellerinde performansı artırmak için denemesi yapılan bir başka uygulama da Teshima vd. (1993) kullandığı irdeleme seti oluşturulması ve eğitim çevrimleri sırasında bu setin hata kareleri toplamındaki değişimlerin çevrim sonlandırmasında kriter olarak kullanılmasıdır. İrdeleme seti olarak Çizelge 4.1'deki örnekler içerisinde 3, 10, 23, 28, 45, 52, 61, 68, 76, 82, 89, 94, 97, 101, 104 örnekleri kullanılmıştır.

2.9 Farklı Eğitim Seti Kullanımıyla Genellemenin Araştırılması

Yapay sinir ağında genelleme kabiliyeti eğitim setinin seçimi ile birebir ilişkilidir, çünkü eğitim setinin uygun aralıklardaki giriş değerleriyle geneli yansıtması geriye bırakılan test setinde daha az hata yapılmasını sağlayacaktır. Başta kullanılan eğitim seti genel proses eğiliminden en fazla sapmaları gösteren örneklerle oluşturulmuştur. Bu şekilde doğrusal bir fonksiyon meydana getirmemek de garantilenmiştir. Bununla beraber öğrenmede kullanılan sapmaları yüksek bu setin test aşamasında görevlendirilmemesinin olası hatalı kararları azaltacağı da açıklıktır. Denenen ikinci 30'luk eğitim seti Çizelge 4.1'de yer alan şu örnekleri içermektedir; 3, 10, 21, 23, 26, 28, 36, 45, 46, 52, 55, 61, 64, 68, 70, 76, 80, 82, 84, 89, 94, 97, 100, 101, 103, 104, 106, 110, 111,112.

3. SONUÇLAR

Farklı gizli katman ve gizli katman işlem elemanı sayılarına göre oluşan program sonuçları Çizelge 5.2 ve Çizelge 5.3'de gösterildiği gibi 7-8-1 ve 7-7-4-1 ağlarının sınıflarında en iyi performansı sergilediklerini göstermektedir. Bu seçim test setinde yapılan doğru sınıflandırma sayısına göre yapılmıştır. Tek gizli katmana sahip ağda en az 7 sınıflandırma hatasına ulaşılabilirken, iki gizli katmana sahip ağda bu sayı 4'e kadar düşürülebilmiştir. İki gizli katmana sahip ağ eşleşmeler arasındaki doğrusal olmayan ilişkiyi daha iyi kavramıştır. Zaten ağda gizli katmanların ve bu katmanlardaki işlem elemanlarının esas görevi doğrusal olmayan ilişkilendirmeyi sağlamaktır. İkinci gizli katmanlarında 4 adet gizli işlem elemanı bulunan yapay sinir ağları diğerlerine nazaran daha üstün performans göstermektedirler. Buna göre ikinci gizli katmandaki optimum işlem elemanı sayısı 4 olarak seçilmiş ona göre tarama yapılmıştır.

Çizelge 5.1 Tek gizli katmanlı ağ performansları (3000 Set çevrimine göre)

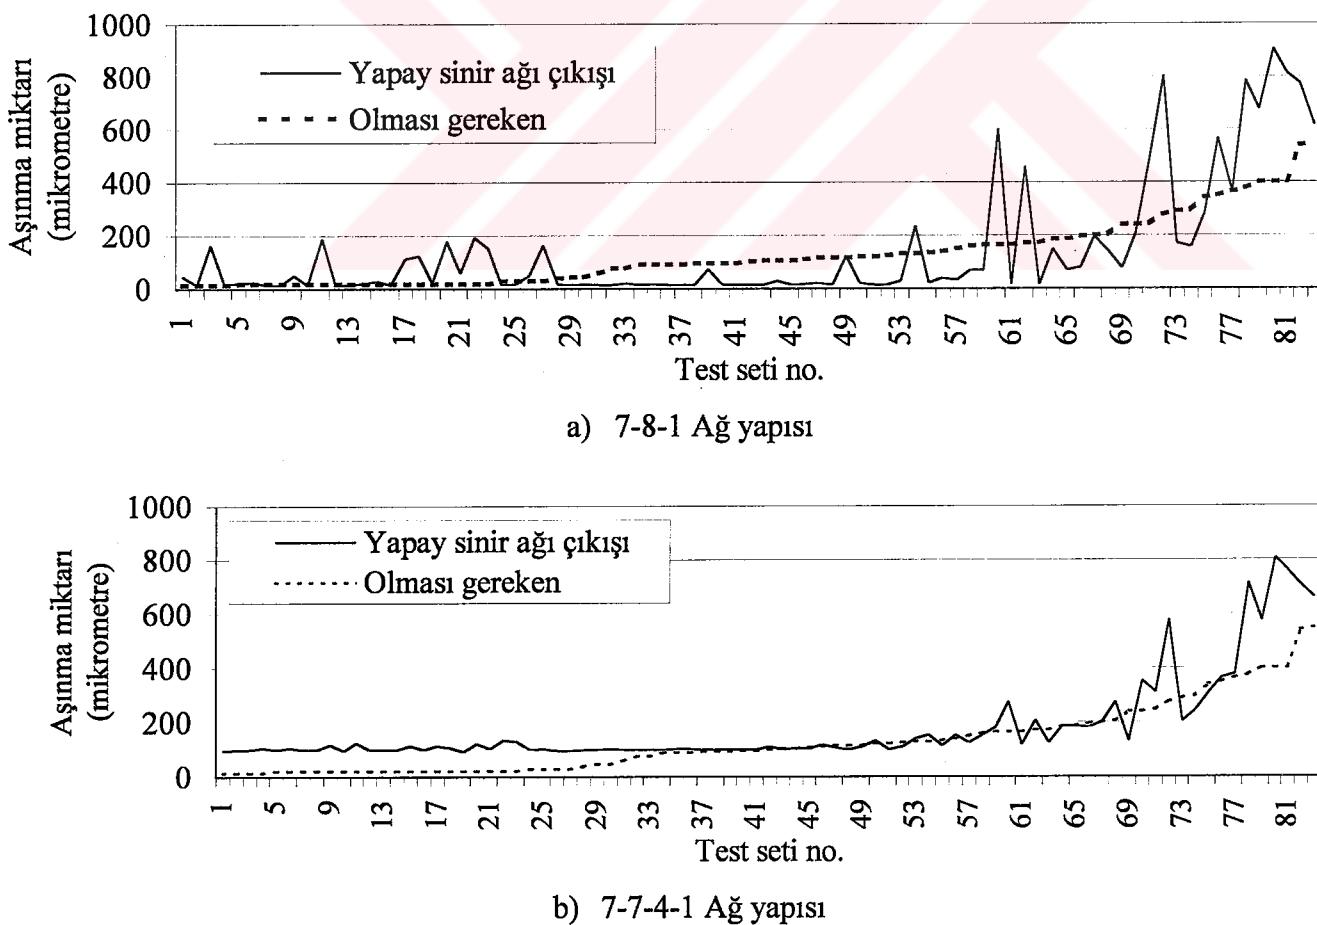
Ağ Yapısı	Eğitim Seti (2000 Çevrim)	Test Seti		
	Hata Kareleri Toplamı	Hatalı Sınıflandırma	Max Pozitif Hata (μ m)	Max Negatif Hata (μ m)
7-4-1	0,01613	17	166,922	610,836
7-5-1	0,012939	9	252,158	434,369
7-6-1	0,01338	9	254,437	442,61
7-7-1	0,008894	12	209,462	501,378
7-8-1	0,011804	7*	209,552	530,108
7-9-1	0,010106	7*	221,952	498,143
7-10-1	0,007717	13	212,322	503,89
7-11-1	0,009339	13	216,684	517,733
7-12-1	0,006481	11	212,686	713,817
7-13-1	0,006409	12	216,388	596,578
7-14-1	0,00703	13	230,396	528,239
7-15-1	0,010275	9	265,481	525,270
7-20-1	0,00606	11	221,035	715,72
7-30-1	0,005676	11	224,980	814,178

Çizelge 5.2 İki gizli katmanlı ağ performansları (2000 Set çevrimine göre)

Ağ Yapısı	Eğitim Seti (2000 Çevrim)	Test Seti		
	Hata Kareleri Toplamı	Hatalı Sınıflandırma	Max Pozitif Hata (µm)	Max Negatif Hata (µm)
7-1-1-1	0,020271	9	129,25	236,24
7-2-1-1	0,020266	9	129,36	234,92
7-2-2-1	0,020252	9	143,02	226,16
7-3-1-1	0,0291	16	154,86	437,36
7-3-2-1	0,000934	12	246,29	530,55
7-3-3-1	0,003075	9	123,59	395,595
7-4-1-1	0,070597	67	166,04	369,14
7-4-2-1	0,001054	14	298,53	582,2
7-4-3-1	0,0031	10	226,3	440,93
7-4-4-1	0,000818	11	173,5	505,6
7-5-1-1	0,070594	67	166,03	369,15
7-5-2-1	0,00091	14	297,62	555,74
7-5-3-1	0,00079	14	227,76	595,31
7-5-4-1	0,000809	16	259,20	601,82
7-5-5-1	0,001035	14	261,72	510,64
7-6-1-1	0,070592	67	166,02	369,14
7-6-2-1	0,000854	12	246,24	552,69
7-6-3-1	0,000881	15	287,95	566,73
7-6-4-1	0,003143	11	253,47	453,97
7-6-5-1	0,000657	11	146,53	550,8
7-6-6-1	0,000842	14	308,4	573,14
7-7-1-1	0,070592	67	166,02	369,14
7-7-2-1	0,00085	14	217,39	552,9
7-7-3-1	0,000937	15	310,97	561,9
7-7-4-1	0,002872	4*	156,51	429,46
7-7-5-1	0,000955	11	403,93	526,95
7-7-6-1	0,000742	14	281,95	547,73
7-7-7-1	0,000789	8	125,31	527,84
7-8-1-1	0,070591	67	166,02	369,14
7-8-2-1	0,000931	10	186,05	534,92
7-8-3-1	0,002783	8	149,75	445,37
7-8-4-1	0,002814	8	150,67	462,93
7-8-5-1	0,003148	9	256,44	451,20
7-8-6-1	0,001006	10	468,76	509,49
7-8-7-1	0,000843	15	332,61	579,1
7-8-8-1	0,000984	18	344,92	575,09
7-10-4-1	0,002776	7	148,83	360,3
7-11-4-1	0,002855	8	144,59	483,22
7-12-4-1	0,002823	7	139,47	400,6
7-13-4-1	0,001678	7	197,64	497,15
7-24-4-1	0,001589	4*	197,94	497,74
7-20-20-1	0,005988	5*	220,36	599,78

Öğrenmede ana gösterge durumundaki hata kareleri toplamı değerleri, en düşük sınıflandırma hatasına sahip ağlarda beklenenin aksine minimum değerlerde değildir. Maksimum hedef sapmalarında da en düşük değerler bu iki ağdan çıkmamıştır. Bütün bunların nedeni çok geniş bir aralıkta seçilen kesme parametrelerinin çıkış değeri olan aşınmaya ulaşmada farklı aralıklarda farklı etkiler göstermesi kısacası eşleşmedeki doğrusal olmamanın yüksekliğidir. Farklı yapay sinir ağı yapılarıyla detaylar daha çok öğrenildikçe başka bir ifadeyle hata kareleri toplamı daha da düşürüldükçe diğer örneklerden çok büyük sapmalar gösteren eşleşmelerde yanlış kararlar verilmeye başlanmıştır.

Seçilen yapay sinir ağlarının direkt olarak sayısal tahminleri ve olması gereken değerler Şekil 5.3'de verildiği gibidir. İki farklı yapının da yaklaşmaları gereken çıkış değerlerine genel uyumlardan, yapay sinir ağlarının belli bazı bölgelerde daha iyi tahminlerde bulunabileceği anlaşılmaktadır. Genelde Aşınma değerlerinin çok az ve çok fazla olduğu kısımlarda tahminler pek parlak değildir. Bu bölgelerdeki başarının artırılması bölgeye mahsus örneklerle eğitilecek özel yapay sinir ağlarının kullanımını gerektirmektedir.



Şekil 5.1 Yapay sinir ağlarının çıkış değer karşılaştırmaları

Ağırlık ve eşik değerlerin başlangıç aralığı seçiminde 7-8-1 yapısındaki ağda ağırlıklar 0.2 ila 0.4 arasında rasgele seçilmişken hata kareleri toplamının 0,013172 ve hata sayısının da 11 olduğu görülmüştür. Aynı değerler 0.2 ila 1.0 arasında rasgele seçilen ağırlıklarla 0,011804 ve 7'ye düşmektedir. 7-7-4-1 yapısındaki ağda ise rasgele seçilen ağırlık aralığı 0.2-1.0'den 0.2-0.4'e daraltılıncaya hata kareleri toplamı 0,002872'den 0,000792'ye düşmesine rağmen hata sayısı 4'den 11'e yükselmektedir. Dar aralıkta seçilerek başlatılan ağırlıkların hata yükseltme etkisi tek gizli katmanlı ağda lokal minimumlara düşülmesi iki gizli katmanlı ağda ise detaylarda fazla uzmanlaşmayla açıklanabilir. Sonuçta en iyi performans çevrimler başlamadan 0.2-1.0 aralığındaki rasgele ağırlıklarla ve eşik değerleriyle elde edilmektedir.

Denenen yapay sinir ağlarında öğrenme hızı (η) 0.5, ve delta formülünde yer alan momentum (α) 0.3 olarak alınmıştır. Bu değerler hata sınıflandırmalarında en iyi performansı gösteren ağlar üzerinde denenerek bulunmuştur. Çizelge 5.4, 5.5, 5.6 ve 5.7 farklı momentum ve öğrenme hızı değerlerine göre değişen ağ performanslarını göstermektedir.

Çizelge 5.3 Yapısı 7-8-1 olan ağında momentum denemeleri ($\eta=0,5$)

Momentum (α)	Hata Kareleri ToplAMI (3000 set çevrimi)	Hatalı Sınıflandırma Miktari
0	0,007822	13
0,1	0,007701	13
0,2	0,007744	12
0,3*	0,007683	7
0,4	0,007981	9
0,5	0,008431	9
0,6	0,010377	8
0,7	0,01278	9

Çizelge 5.4 Yapısı 7-8-1 olan ağda öğrenme hızı denemeleri ($\alpha=0,3$)

Öğrenme Hızı (η)	Hata Kareleri ToplAMI (3000 set çevrimi)	Hatalı Sınıflandırma Miktari
0,3	0,009427	13
0,4	0,007506	12
0,5*	0,007683	7
0,6	0,010375	10
0,7	0,012442	9

Çizelge 5.5 İki katmanlı ağ yapılarında öğrenme hızı denemeleri

Öğrenme Hızı (η)	Hatalı Sınıflandırma Miktarı		
	7-7-4-1	7-24-4-1	7-20-20-1
0,1	9	67	-
0,2	7	9	-
0,3	8	10	11
0,4	8	8	5
0,5*	4	4	5
0,55	10	8	9
0,6	10	9	18

Çizelge 5.6 İki katmanlı ağ yapılarında momentum denemeleri ($\eta=0,5$)

Öğrenme Hızı (η)	Hatalı Sınıflandırma Miktarı		
	7-7-4-1	7-24-4-1	7-20-20-1
0,1	8	8	11
0,2	8	8	5
0,3*	4	4	5
0,4	10	10	16
0,5	12	7	12
0,6	10	7	-
0,7	14	4	-
0,8	9	11	-
0,9	9	16	-

Sıralı olarak değilde karışık olarak ağa verilen eğitim seti 7-8-1 ve 7-7-4-1 ağlarında hata kareleri toplamını düzenli olmasa da az bir miktar düşürmüştür. Bununla beraber yapılan test hataları sırasıyla 7'den 9'a ve 4'ten 15'e kadar yükselmiştir. Bu sonuç eğitim setinin iyi kavrandığını fakat eğitim setiyle uyum göstermeyen sapmaları yüksek test seti örneklerinden dolayı sınıflandırma hatalarına düşündüğünü bir kez daha ortaya çıkarmaktadır.

Çalışmada başlarda 0,1 ve 0,9 olarak belirlenen aritmetik ortalamalı normalizasyon 7-8-1 ağ yapısında 18 hata gibi çok büyük test hatalarını sonuçlandırdığı için 0,001 ve 0,999 aralığı kullanılmıştır. Geometrik normalizasyonun kullanımı ile, daha önce denenen eğitim setinin her bir set çevriminde karışık sırada gösterilmesi iyi bir uyum oluşturmaktadır. Tek gizli katmana sahip yapay sinir ağında minimum test hata miktarı olan 7'ye ulaşlamamışsa da denenen pek çok konfigürasyonda (7-5-1, 7-6-1, 7-7-1, 7-8-1, 7-9-1, 7-10-1, 7-11-1, 7-12-1, 7-15-1, 7-20-1, 7-25-1, ..., 7-50-1) sıkılıkla 8'de olmak üzere test hata miktarı 8-10 aralığının dışına çıkmamıştır. Ayrıca bu şartlarda ve konfigürasyonlarda 4000 eğitim seti çevrimine gelindiğçe hata kareleri toplamı düzenli olarak 0,008 civarına kadar inmiştir. İki gizli katmana sahip ağa

da bu normalizasyonun kullanımıyla hata kareleri toplamında düzenli bir düşüşe sahip olunmuş fakat minimum test hata sayısı olan 4'ten çok uzaklaşılmış, test hata sayısı miktarı 17-19 aralığında hapsolmuştur. Düzenli öğrenmeye rağmen test hata sayısındaki artış, genel eğilimden fazlaca sapma gösteren test örneklerinin bulunması ve yapay sinir ağının bunları eğitim setindeki aşırı uzmanlaşmasından ötürü tatmin edici şekilde sınıflandırılamaması ile açıklanabilir.

Irdeleme setinin hata kareleri toplamının takibine dayalı öğrenme çevrimi durdurma kriteri, performansı arttırmamıştır çünkü hem eğitim setinde hem de irdeleme setinde hata kareleri toplamı düşüşü düzensiz seyretmekte, titreşim göstermektedir. Çok düşük titreşimlerin önüne geçebilmek için irdeleme setinde ancak 0,001'den daha yüksek hata kareleri toplamı artışı için çevrim sonlandırılması denenmiş, fakat gene de standart 3000 ya da 2000 çevrim sonucunda elde edilen düşük test hatalarına dahi ulaşılamamıştır. Bu öğrenim metoduyla tek gizli katmana sahip 7-8-1 ağında test hata sayısı 7'den 12'ye, iki gizli katmana sahip 7-7-4-1 ağında da test hata sayısı 4'den 7'ye yükselmiştir.

Farklı eğitim setinin kullanımı denemesinde ise daha önce seçilmiş olan iki yapay sinir ağı bu görevlendirilmiştir. Sonuçlar önceki eğitim setine göre kötüdür; 7-8-1 yapay sinir ağında test hata sayısı 17, 7-7-4-1 yapay sinir ağında ise 9 olarak bulunmuştur. İlk kullanılan eğitim seti ile yapay sinir ağlarının genelleme kabiliyeti daha iyidir.

Sonuç olarak kullanılan yapay sinir ağlarıyla test setinde yapılan hatalar en az 4'e çekilmiştir. Test setinde 83 eşleşmenin bulunduğu düşünülürse % 95.2'lik bir sınıflandırma başarısından söz edilebilir. Kullanılan algoritmalar bu halleriyle biraz daha geliştirilebilirlerse ileride yapay sinir ağlarından oluşturulmuş kontrol sistemleriyle takım aşınma takibinin yapılması yakın gibi gözükmektedir.

KAYNAKLAR

- Akkurt, M. (2000), Talaş Kaldırma Yöntemleri ve Takım Tezgahları, Birsen Yayınevi, İstanbul.
- Altıntaş, Y. ve Liu, Q.(1999), “On-Line Monitoring of Flank Wear in Turning with Multilayered Feed-Forward Neural Network”, International Journal of Machine Tools & Manufacture, 39:1945–1959.
- Choudhry, S.K., Jain, V.K. ve Rama Rao, Ch.V.V. (1999), “On-Line Monitoring of Tool Wear in Turning Using A Neural Network”, International Journal of Machine Tools & Manufacture, 39:489–504.
- Chryssolouris, G. ve Gulliot M. (1990), “A Comparison of Statistical and AI Approaches to the Selection of Process Parameters in Intelligent Machining”, Journal of Engineering for Industry, 112:122-131.
- Dimla, Sr.D.E. ve Lister, P.M. (2000), “On-Line Metal Cutting Tool Condition Monitoring. II: Tool-State Classification Using Multi-Layer Perceptron Neural Networks”, International Journal of Machine Tools & Manufacture, 40:769–781.
- DeGarmo, E.P., Black, J.T., ve Kohser R.A. (1988), Materials and Processes in Manufacturing, Macmillian Publishing Company, Newyork.
- Dimla, Jr D.E., Lister, P.M. ve Leighton, N.J. (1997), “Neural Network Solutions to the Tool Condition Monitoring Problem in Metal Cutting - A Critical Review of Methods”, International Journal of Machine Tools & Manufacture, 37(9):1219–1241.
- Dornfeld, D.A (1990), “A. Neural Network Sensor Fusion For Tool Condition Monitoring”, Annals of the CIRP, 39(1):101-105.
- Dornfeld, D.A. ve Rangwala, S. (1989), “Learning and Optimization of Machining Operations Using Computing Abilities of Neural Networks”, IEEE Transactions on Systems, Man, and Cybernetics, 19(2):299–314.
- Haykin S. (1994), Neural Networks, Mac Millan, New York.
- Kim, T.Y., Woo, J., Shin, D. ve Kim, J.(1999), “Indirect Cutting Force Measurement in Multi-axis Simultaneous NC Milling Processes”, International Journal of Machine Tools & Manufacture, 39:1717–1731.
- Lee, J.H. ve Lee, S.J. (1999), “One Step-Ahead Prediction of Flank Wear Using Cutting Force”, International Journal of Machine Tools & Manufacture 39:1747–1760.
- Lee, Y.H., Yang, B.H. ve Moon, K.S. (1999), “An Economic Machining Process Model Using Fuzzy Non-Linear Programming And Neural Network”, International Journal of Production Research, 37(4):835–847.
- Lin, S.C., Lin, R.J. (1996), “Tool Wear Monitoring in Face Milling Using Force Signals”, Wear, 198:136-142.
- Masters, T. (1993), Practical Neural Network Recipes in C++, A Harcourt Science and Technology Company, San Diego.
- Özgürler, M.(1987), “Talaş Kaldırma Tekniğinin Kavramları”, Makine Mühendisleri Odası İstanbul Şubesi Cumartesi Konferansları, İstanbul.

Özgürler, M. (1988), "Kesici Takımlarda Aşınma ve Takım Ömrü", II. Ulusal Üniversite Sanayii İşbirliği Sempozyumu, Erciyes Üniversitesi, Kayseri.

Purushothaman, S. ve Srinivasa, Y.G. (1994), "A Back Propagation Algorithm Applied to Tool Wear Monitoring", International Journal of Machine Tools & Manufacture 34(5):625–631.

Purushothaman, S. ve Srinivasa, Y.G. (1998), "A Procedure for Training an Artificial Neural Network with Application to Tool Wear Monitoring", International Journal of Production Research, 36:911-918.

Raj, K.H., Sharma, S.R., Srivastava, S. ve Patvardhan, C.(2000), "Modelling of Manufacturing Processes with ANNs for Intelligent Manufacturing", International Journal of Machine Tools & Manufacture, 40:851–868.

Rangwala S., ve Dornfeld, D.A. (1987), "Integration of Sensors via Neural Networks for Detection of Tool Wear States", Proc. Symposium on Integrated And Intelligent Manufacturing Analysis And Synthesis, ASME, New York, 109–120.

Santanu D., Chattopadhyay, A.B., ve Murthy, A.S.R. (1996), "Force Parameters For On-Line Tool Wear Estimation: A Neural Network Approach", Neural Networks, 9(9):1639-1645.

Schey J.A. (1987), Introduction to Manufacturing Processes, McGraw-Hill Book Company, Newyork.

Suneel, T.S. ve Pande, S.S. (2000), "Intelligent Tool Path Correction for Improving Profile Accuracy in CNC Turning", International Journal of Production Research, 38(14):3181–3202.

Teshima, T., Shibasaki T., Takuma, M. ve Yamamoto, A. (1993), "Estimation of Cutting Tool Life by Processing Tool Image Data with Neural Network", Annals of the CIRP, 42(1):59–62.

Tsai, Y., Chen, J.C., ve Lou, S., (1999), "An In-Process Surface Recognition System Based on Neural Networks in End Milling Cutting Operations", International Journal of Machine Tools & Manufacture, 39:583–605.

*YÜKSEK ÖĞRETİM KURUMU
MÜDEKKİ ANTASİON İMZA*

ÖZGEÇMİŞ

Doğum tarihi	23.08.1975	
Doğum yeri	Eskişehir	
Lise	1989-1992	Eskişehir Fen Lisesi, Eskişehir Cumhuriyet lisesi
Lisans	1992-1997	Ortadoğu Teknik Üniversitesi Mühendislik Fak. Makina Mühendisliği Bölümü
Yüksek Lisans	1998-2002	Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Makina Müh. Anabilim Dalı, İmal Usulleri Programı

Çalıştığı kurum(lar)

1997-1998	Kalekalıp Makina ve Kalıp San A.Ş.
1998-1999	Tezsan Takım Tezgahları San. ve Tic.A.Ş.
1999-2000	Yedeksubay (Tank 2000 Projesi, Amerikan Ekibi İrtibat ve Veri toplama Subayı)