

**KOCAELİ ÜNİVERSİTESİ \* FEN BİLİMLERİ ENSTİTÜSÜ**

**YAPAY SİNİR AĞI YAKLAŞIMIYLA, PEÇETE MAKİNESİ İMALATI  
YAPAN İŞLETMEDE MAKİNE İŞLEME SÜRELERİNİN TAHMİN  
EDİLMESİ**

**YÜKSEK LİSANS**

**Endüstri Müh. Burcu ÖZCAN**

**Anabilim Dalı: Endüstri Mühendisliği**

**Danışman: Yrd. Doç. Dr. Pınar KILIÇOĞULLARI**

**KOCAELİ, 2007**

**KOCAELİ ÜNİVERSİTESİ \* FEN BİLİMLERİ ENSTİTÜSÜ**

**YAPAY SİNİR AĞI YAKLAŞIMIYLA, PEÇETE MAKİNESİ  
İMALATI YAPAN İŞLETMEDE MAKİNE İŞLEME  
SÜRELERİNİN TAHMİN EDİLMESİ**

**YÜKSEK LİSANS**

**Endüstri Müh. Burcu ÖZCAN**

Tezin Enstitüye Verildiği Tarih: 04 Haziran 2007

Tezin Savunulduğu Tarih: 12 Temmuz 2007

Tez Danışmanı

Üye

Üye

Yrd.Doç.Dr.Pınar KILIÇOĞULLARI Prof.Dr.Alpaslan FIĞLALI Yrd.Doç.Dr.Semra BORAN

( *PK* )

( *alpaslan* )

( *Boran* )

**KOCAELİ, 2007**

## **ÖNSÖZ VE TEŞEKKÜR**

Veri toplama aşaması işletmeler için en önemli ve en uzun süreçlerden biridir. Tüm analizler ve süreç iyileştirmeler toplanılan veriler üzerine kurulmuştur. Bu çalışmayla yüksek doğrulukta cevap veren yapay sinir ağı yapısı oluşturularak veri toplama süresi kısaltılacak ve üretilen yeni ürünlerle ilgili verilere sahip olunacaktır.

Tez çalışmam sırasında her konuda beni destekleyen ve yol gösteren danışmanım Sayın Yrd. Doc. Dr. Pınar KILIÇOĞULLARI, çalışmamın her aşamasında bilgi ve fikirleriyle beni aydınlatan Sayın Prof. Dr. Alparslan FIĞLALI ve Prof. Dr. Nilgün FIĞLALI'ya, bilgi ve deneyimlerini benimle paylaşan Dr. Mehlika ŞENGÜL'e, bana uygulama imkanı veren I.C.M. Makine ve Mühendislik Ltd. Şirketi sahibi Sn. Çınar ULUSOY ve uygulamamda işletme hakkında beni aydınlatan I.C.M. Makine ve Mühendislik Ltd. Şirketi Üretim Planlama Uzmanı Sn. Vicdan UMUR'a, çalışma arkadaşım ve hocam Arş. Gör. Ümit TERZİ'ye ve maddi, manevi desteklerini benden esirgemeyen sevgili aileme sonsuz teşekkür ederim.

## İÇİNDEKİLER

ÖNSÖZ VE TEŞEKKÜR .....	i
İÇİNDEKİLER .....	ii
ŞEKİLLER DİZİNİ .....	v
TABLolar DİZİNİ .....	vi
SEMBOLLER .....	vii
ÖZET .....	viii
ABSTRACT .....	ix
BÖLÜM 1. GİRİŞ .....	1
BÖLÜM 2. YAPAY SİNİR AĞLARI .....	4
2.1 Yapay Sinir Ağlarına Giriş .....	4
2.2 Yapay Sinir Ağlarının Tanımı .....	5
2.3 Yapay Sinir Ağlarının Tarihçesi .....	6
2.4 Yapay Sinir Ağlarının Genel Kullanım Alanları .....	9
2.5 Yapay Sinir Ağlarının Üstünlükleri ve Sakıncaları .....	12
2.6 Yapay Sinir Ağının Modeli .....	13
2.6.1 Biyolojik sinir ağı sistemi .....	13
2.6.2 Yapay sinir hücresi ve modeli .....	14
2.6.2.1 Sigmoid fonksiyonu .....	16
2.6.2.2 Basamak fonksiyonu .....	17
2.6.2.3 Sınırlandırılmış lineer fonksiyonu .....	18
2.6.2.4 Signum fonksiyonu .....	19
2.6.2.5 Hiperbolik tanjant fonksiyonu .....	19
2.7 Farklı Yapay Sinir Ağları Yapıları .....	21
2.7.1 İleri beslemeli ağlar .....	21
2.7.2 Geri beslemeli ağlar .....	22
2.8 Yapay Sinir Ağlarının Çalışma Şekli .....	23
2.9 Yapay Sinir Ağlarının Eğitimi .....	24
2.10 Yapay Sinir Ağlarında Öğrenme .....	26
2.10.1 Danışmalı öğrenme .....	27
2.10.2 Danışmansız öğrenme .....	29
2.10.3 Hebb kuralı .....	30
2.10.4 Hopfield kuralı .....	30
2.10.5 Delta kuralı .....	30
2.10.6 Eğimli iniş kuralı .....	31
2.10.7 Kohonen öğrenme kuralı .....	31
2.11 Yapay Sinir Ağlarında Bilginin Depolanması ve Geri Alınması .....	32
2.12 Yapay Sinir Ağlarının Oluşturulması .....	32
2.13 Ağ Oluşturmanın Genel Kuralları .....	33
2.14 Uygulamada Kullanılan Matematiksel Hesaplamalar .....	34
2.14.1 İleri doğru hesaplama .....	35
2.14.2 Geriye doğru hesaplama .....	36
2.14.2.1 Ara katman ile çıktı katmanı arasındaki ağırlıkların değiştirilmesi .....	36

2.14.2.2 Ara katmanlar arası veya ara katman ile girdi katmanı arasındaki ağırlıkların değiştirilmesi .....	38
<b>BÖLÜM 3. DENEY TASARIMI YAKLAŞIMI .....</b>	<b>39</b>
3.1 Deney Tasarımı.....	40
3.2 Deney Tasarımı Aşamaları .....	41
3.3 Klasik Deney Tasarımı Yöntemleri .....	42
3.3.1 Bir kerede bir faktör .....	43
3.3.2 Deneyleerin tam faktöriyel tasarımı .....	43
3.3.3 Deneyleerin kısmi faktöriyel tasarımı.....	46
3.4 Taguchi Yöntemi .....	46
3.4.1 Kalite mühendisliği .....	52
3.4.2 Çevrim içi kalite kontrol.....	53
3.4.2.1 Prosesin belirlenmesi ve ayarlanması.....	54
3.4.2.2 Tahmin ve düzeltme .....	54
3.4.2.3 Ölçme ve Faaliyet .....	54
3.4.3 Çevrim dışı kalite kontrol .....	55
3.4.3.1 Sistem tasarımı.....	55
3.4.3.2 Parametre tasarımı.....	56
3.4.3.3 Tolerans tasarımı.....	62
3.4.4 Ortogonal diziler .....	63
3.4.5 Serbestlik derecesi.....	65
3.4.6 Analiz yöntemi.....	66
3.4.7 Kalite karakteristikleri.....	67
3.4.8 Faktörlerin sınıflandırılması .....	69
3.4.8.1 Kontrol faktörleri .....	70
3.4.8.2 Gürültü faktörleri .....	70
3.4.8.3 Sinyal/Gürültü (S/G) oranı .....	71
<b>BÖLÜM 4. YAPAY SİNİR AĞIYLA İŞLEM SÜRESİ TAHMİN MODELİ.....</b>	<b>75</b>
4.1 İşlem Süresine Etki Eden Faktörlerin Belirlenmesi.....	75
4.2 Veri Toplama.....	76
4.3 Yapay Sinir Ağı Parametrelerinin Belirlenmesi .....	76
4.4 En İyi Ağ Topolojisi .....	77
4.5 Yapay Sinir Ağının Performansının Ölçülmesi.....	78
<b>BÖLÜM 5. UYGULAMA: SİPARİŞE GÖRE PEÇETE MAKİNESİ İMALATI YAPAN İŞLETMEDE MAKİNE İŞLEME SÜRESİNİN YAPAY SİNİR AĞI YAKLAŞIMIYLA TAHMİN EDİLMESİ .....</b>	<b>81</b>
5.1 İşletme Tanıtımı.....	81
5.1.1 Ürünler.....	81
5.1.2 Organizasyon şeması.....	82
5.1.3 Yerleşim düzeni .....	83
5.2. Uygulamaya Giriş .....	83
5.3 Çalışmanın Yapılış Nedeni.....	84
5.4 Çalışma Metodolojisi .....	86
5.4.1 İşlem süresine etki eden faktörlerin belirlenmesi .....	86
5.4.2 Veri toplama .....	86
5.4.3 Yapay sinir ağı parametrelerinin belirlenmesi.....	86
5.4.4 En iyi ağ topolojisi .....	88
5.4.5 Yapay sinir ağının performansının ölçülmesi.....	90

5.5 Matkap Tezgahı İçin Parametre Etkileşimlerinin Belirlenmesi, Yapay Sinir Ağının Kullanımı ve Sonuçların Analizi .....	90
5.5.1 Matkap için belirlenen faktörler .....	90
5.5.2 Matkap tezgahı için parametre etkileşimleri ve optimizasyonu .....	91
5.5.2.1 Matkap tezgahı için elde edilen sonuçlar .....	91
5.5.2.2 Matkap tezgahı için belirlenen en önemli faktörler .....	92
5.5.2.3 Matkap tezgahı için parametrelerin etkileşimlerinin analizi .....	94
5.5.2.4 Matkap tezgahı için en iyi faktör seviyeleri kombinasyonu .....	94
5.5.3 Matkap tezgahı için elde edilen en iyi sonuç:.....	95
5.5.4 Matkap tezgahı için istatistiksel analiz.....	100
5.6 Freze Tezgahı İçin Parametre Etkileşimlerinin Belirlenmesi, Yapay Sinir Ağının Kullanımı ve Sonuçların Analizi .....	101
5.6.1 Freze ve torna tezgahı için belirlenen faktörler .....	101
5.6.2 Freze tezgahı için parametre etkileşimleri ve optimizasyonu .....	102
5.6.2.1 Freze tezgahı için elde edilen sonuçlar.....	102
5.6.2.2 Freze tezgahı için belirlenen en önemli faktörler .....	103
5.6.2.3 Freze tezgahı için parametreler etkileşimlerinin analizi:.....	104
5.6.2.4 Freze tezgahı için en iyi faktör seviyeleri kombinasyonu .....	105
5.6.3 Freze tezgahı için elde edilen en iyi sonuç.....	105
5.6.4 Freze tezgahı için istatistiksel analiz.....	109
5.7 Torna Tezgahı İçin Taguchi Deney Tasarımı, Yapay Sinir Ağının Kullanımı ve Sonuçların Analizi .....	111
5.7.1.Taguchi deney tasarımı aşamaları.....	111
5.7.1.1 Problemlerin tanımlanması .....	111
5.7.1.2 Faktör ve seviyelerinin belirlenmesi .....	111
5.7.1.3 Ortogonal diziler ve seçimleri.....	112
5.7.1.4 Faktörlerin kolonlara atanması .....	112
5.7.1.5 Deneylerin gerçekleştirilmesi ve verilerin toplanması.....	112
5.7.1.6 Torna tezgahı için elde edilen sonuçlar.....	113
5.7.1.7 Freze tezgahı için en iyi faktör seviyeleri kombinasyonu (Optimum faktör seviyelerinin seçimi) .....	114
5.7.1.8 Doğrulama deneyi (Torna tezgahı için elde edilen en iyi sonuç) .....	115
5.7.2 Torna tezgahı için istatistiksel analiz .....	116
5.8 Uygulama Sonuçları.....	117
SONUÇ .....	118
KAYNAKLAR.....	120
EKLER.....	123
ÖZGEÇMİŞ.....	128

## ŞEKİLLER DİZİNİ

Şekil 2.1: Biyolojik nöron .....	13
Şekil 2.2: Bir biyolojik nöronun matematiksel modellenmesi .....	14
Şekil 2.3: Yapay sinir ağı modeli .....	15
Şekil 2.4: Yapay nöronun detaylı yapısı .....	16
Şekil 2.5: Sigmoid fonksiyonu .....	17
Şekil 2.6: Basamak fonksiyonu .....	18
Şekil 2.7: Sınırlandırılmış lineer fonksiyonu .....	18
Şekil 2.8: Signum fonksiyonu .....	19
Şekil 2.9: Hiperbolik tanjant fonksiyonu .....	20
Şekil 2.10: Y.S.A. mimarisinin temel elemanları.....	21
Şekil 2.11: İleri beslemeli Y.S.A. modeli .....	22
Şekil 2.12: Gizli katmanlı geri beslemeli Y.S.A. modeli.....	23
Şekil 2.13: YSA'nın eğitilmesi.....	23
Şekil 2.14: Danışmalı öğrenme .....	28
Şekil 2.15: Danışmansız öğrenme .....	29
Şekil 3.1: Deney tasarımı bakış açısı .....	40
Şekil 3.2: Kalite mühendisliği ve bileşenleri .....	53
Şekil 3.3: Parametre tasarımı akış diyagramı .....	57
Şekil 3.4: Fonksiyonel değişimlerin sebepleri .....	72
Şekil 3.5: Kayıp fonksiyonu ile gürültü arasındaki ilişki .....	73
Şekil 5.1: I.C.M. organizasyon şeması .....	82
Şekil 5.2: İşletmenin yerleşim düzeni.....	83
Şekil 5.3: Ağ yapısı ve kullanılan fonksiyonlar .....	88
Şekil 5.4: Kullanılan eğitim parametreleri.....	88
Şekil 5.5: Yapay sinir ağında kullanılan girişler ve çıkış .....	91
Şekil 5.6: Matkap tezgahı için $\alpha =0.05$ düzeyindeki en önemli etki .....	93
Şekil 5.7: Matkap tezgahı için pareto diyagramı.....	93
Şekil 5.8: Matkap tezgahı için faktörlerin etkileşimleri.....	94
Şekil 5.9: Matkap tezgahı için ana etkiler için en iyi düzeyler .....	95
Şekil 5.10: Toplam karesel hatanın iterasyona bağlı değişimi.....	96
Şekil 5.11: Matkap tezgahı için en iyi sonuç veren ağ yapısı .....	96
Şekil 5.12: Matkap tezgahı için elde edilen en iyi eğitim sonuçları.....	97
Şekil 5.13: Matkap tezgahı için elde edilen en iyi test sonuçları .....	99
Şekil 5.14: Freze tezgahı için $\alpha =0.10$ düzeyindeki en önemli etki.....	104
Şekil 5.15: Freze tezgahı için Pareto diyagramı.....	104
Şekil 5.16: Freze tezgahı için faktörlerin etkileşimleri.....	105
Şekil 5.17: Freze tezgahı için ana etkiler için en iyi düzeyler.....	105
Şekil 5.18: Toplam karesel hatanın iterasyona bağlı değişimi.....	106
Şekil 5.19: Freze tezgahı için en iyi sonuç veren ağ yapısı .....	106
Şekil 5.20: Freze tezgahı için elde edilen en iyi eğitim sonuçları .....	107
Şekil 5.21: Freze tezgahı için elde edilen en iyi test sonuçları.....	109
Şekil 5.22: Sinyal gürültü oranlarına göre en iyi etmenler .....	114
Şekil 5.23: Toplam karesel hatanın iterasyona bağlı değişimi.....	115

## TABLolar DİZİNİ

Tablo 1.1: Üretim alanında tahminleme uygulamaları .....	2
Tablo 2.1: Y.S.A.'nın tarihsel gelişimi .....	9
Tablo 2.2: Y.S.A. ve uygulama alanları.....	12
Tablo 2.3: Y.S.A.'nın üstünlükleri ve sakıncaları .....	12
Tablo 2.4: Biyolojik sınır ile Y.S.A.'nın karşılaştırılması .....	16
Tablo 2.5: Öğrenme yöntemlerine göre ağ yapıları.....	27
Tablo 3.1: Yedi faktörlü tam faktöriyel deney tasarım matrisi .....	44
Tablo 3.2: İki seviyeli iki faktör deney tasarım matrisi .....	45
Tablo 3.3: Teklif edilen deney tasarımları .....	64
Tablo 4.1: L16 tam faktöriyel deney .....	78
Tablo 4.2: $\mu_1 - \mu_2$ için büyük örnek Z testi.....	80
Tablo 5.1: Üretilen peçete makineleri.....	82
Tablo 5.2: Sipariş edilen makineler için sözleşme, teslim tarihleri ve gecikmeler ....	85
Tablo 5.3: Deneyde kullanılan faktör ve seviyeler.....	87
Tablo 5.4: Tam faktöriyel deneyde kullanılan parametre kombinasyonları .....	89
Tablo 5.5: Eğitim verilerinin sonuçları.....	92
Tablo 5.6: Test verileri sonuçları.....	92
Tablo 5.7: Matkap tezgahı için elde edilen en iyi eğitim sonuçları.....	98
Tablo 5.8: Matkap tezgahı için elde edilen en iyi test sonuçları .....	99
Tablo 5.9: Matkap tezgahı için test verilerinin istatistiksel analizi.....	100
Tablo 5.10: Eğitim verilerinin sonuçları .....	103
Tablo 5.11: Test verileri sonuçları.....	103
Tablo 5.12 Freze tezgahı için elde edilen en iyi eğitim sonuçları .....	108
Tablo 5.13: Freze tezgahı için elde edilen en iyi eğitim sonuçları .....	109
Tablo 5.14: Freze tezgahı için test verilerinin istatistiksel analizi .....	110
Tablo 5.15: L8 ortogonal tablosu .....	112
Tablo 5.16: Torna tezgahı için elde edilen sonuçlar ve sinyal/gürültü oranları.....	113
Tablo 5.17: Sütun farkları yöntemine göre belirlenmiş faktör etkileri .....	113
Tablo 5.18: Her makine için elde edilen sonuçların değerleri .....	117



## SEMBOLLER

R	: Reel Sayılar Kümesi
P	: Predicted Value (Tahminlenen Değerler)
A	: Actual Value (Gerçek Değerler)

## Kısaltmalar

A.N.N.	: Artificial Neural Network (Yapay Sinir Ağı)
D.T.	: Deney Tasarımı Tekniği
E.B.	: En Büyük
E.K.	: En Küçük
S/G	: Sinyal Gürültü
T.K.Y.	: Toplam Kalite Yönetimi
U.S.	: Uzman Sistemler
Y.S.A.	: Yapay Sinir Ağları
Y.Z.	: Yapay Zeka
MAE	: Mean Absolute Error (Ortalama Mutlak Hata)
RMSE	: Root Mean Square Errors (Ortalama Karesel hata)
MAPE	: Mean Absolute Percentage Error (Ortalama Mutlak Yüzdellik Hata)
ARIMA	: The Autoregressive Integrated Moving Average (Birleştirilmiş Otoregresif Hareketli Ortalama)
M.L.P.	: Multilayer Perceptron (Çok Katmanlı Algılayıcı)
A.R.T	: Adaptive Resonance Theory (Adaptif Rezonans Teorisi)
N.I	: National Income (Milli Gelir)
POP	: Population (Nüfus)
G.D.P	: Gross of Domestic Production (Yerli Üretim Büyüklüğü)
C.P.I.	: Consumer Price Index (Müşteri Fiyatı İndeksi)

# YAPAY SİNİR AĞI YAKLAŞIMIYLA, PEÇETE MAKİNESİ İMALATI YAPAN İŞLETMEDE MAKİNE İŞLEME SÜRESİNİN TAHMİN EDİLMESİ

**Burcu ÖZCAN**

**Anahtar Kelimeler:** İşlem Süresi Tahmini, Yapay Sinir Ağları, Deney Tasarımı.

**ÖZET:** İşletmeler arasındaki artan rekabet nedeniyle, müşterinin istediği özelliklerde ürün üretmek (müşteri memnuniyeti), tam zamanında teslim ve maliyetlerin düşürülmesi tüm işletmeler için önem arz etmektedir. İşletmeler için, müşterilerinin istedikleri özellikleri, spesifikasyonları taşıyan ürünleri, istedikleri zamanda ya da işletmenin öngördüğü zaman dilimi içerisinde teslim etmeleri çok önemlidir. Zamanında teslim edilemeyen geciken ürünler işletmenin prestijini olumsuz yönde etkilemektedir.

Bu çalışmada makine işlem sürelerinin tahminine yönelik bir yapay sinir ağı geliştirilmiş ve performansı belirlenmiştir. Yapay sinir ağı topolojisinin belirlenmesinde deney tasarımı yaklaşımı kullanılmış, yapay sinir ağının ürettiği sonuçların gerçeği ne kadar temsil ettiği istatistiksel olarak araştırılmıştır.

Uygulama siparişe göre peçete makinesi imalatı yapan işletmede yapılmıştır. İşletmenin en önemli sorunu müşteriden gelen siparişleri yetiştirememesi ve dolayısıyla zamanında teslimin gerçekleşmemesidir. Bu işletme için teslim süresindeki gecikme işletme kayıtlarına göre 117 günü bulmaktadır. Bunun en önemli nedeni ise müşterinin istediği spesifikasyondaki peçete makinesinin üretimi için gerekli olan parçaların işletmedeki makinelerdeki işlem süresinin bilinmemesinden kaynaklanmaktadır. Özellikle diğer peçete makinelerinden farklılık gösteren makinelerin tamamlanma süresini sezgisel olarak hesaplamak daha da zordur.

Çalışmada makineler ve bu makinelerde çalışan işçilerin yaptıkları faaliyetler kameraya alınarak bu konuda uzman kişilerle birlikte beyin fırtınası yöntemi uygulanarak işlem süresine etki eden faktörler belirlenmiştir. İşletmede bu faktörler göz önünde tutularak iş etüdü çalışması yapılmıştır. Her bir makine için 100'den fazla örnek alınarak Yapay Sinir Ağına örnek verisi olarak girilmiştir. Test verileriyle deney sonuçlarının güvenilirliği araştırılmış; elde edilen sonuçların istatistiksel olarak anlamlı olduğu görülmüştür. İşletme yapay sinir ağının girdisi olarak belirlenen faktörleri göz önüne alarak tasarımı yapılmış olan yeni makinelerin çizimlerinden hareketle işlem sürelerini tahmin edebilecektir ve böylelikle işletmeler için en uzun aşamalardan biri olan veri toplama aşaması tamamlanmış olacaktır.

# **APPLICATION OF ARTIFICIAL NEURAL NETWORK IN FORECASTING MACHINE MANUFACTURING TIME OF A NAPKIN MACHINE PRODUCER**

**Burcu ÖZCAN**

**Key Words:** Forecasting, Artificial Neural Networks, Design of Experiment

**ABSTRACT:** High quality but low-cost products and processes are necessary to compete in today's global economy. Increasing competition is forcing businesses to pay more attention to customer satisfaction, just in time delivery and cost reduction. It is crucial for enterprises to deliver products with desired features punctually. Products not delivered on time have a demoting effect on enterprise reputation.

This implementation is conducted in a napkin machine producer. The biggest bottleneck in the managing of the enterprise is the inability to fulfill the requisitions of the customers on time. The delay in delivery time is up to 117 days for the enterprise (Company Records). The main reason for the delay is the lack of manufacturing time information for the required parts of the napkin machine with a different specification. Especially for the machines with different specifications, it is harder to calculate the manufacturing time intuitively.

During execution machines and the processes done by the operators captured on film. The factors affecting the manufacturing times are determined by subject matter experts by using brain storming methodology. While bearing in mind the affecting factors, a work study is conducted. For each machine a sample group with more than 100 instances entered into the Artificial Neural Network. The accuracy of the results checked against the test data. The enterprise will be able to forecast the manufacturing time for newly designed machines in the light of learned factors. Therefore the data collection phase which is one of the time consuming events for an enterprise is concluded.

## **BÖLÜM 1. GİRİŞ**

Her endüstriyel kuruluşun amacı; mal ve hizmet yapımı işlevlerini yürütmek ve bunların pazarlamasını yapmaktır. Bu amacın yerine getirilmesinde üretim öğelerinin sürekli olarak kullanılması gerekir. Böylece örnek bir endüstri işletmesi için binalar, makineler, teknik tesisler, enerji, işgücü, çeşitli türden hizmet çalışmaları ve hammaddeler gerekli olur. Bunlar üretimin amaçlarına göre işletmenin her bölümüne yerleştirilir. Kuramsal olarak incelendiğinde, üretim çalışmaları bir kombinasyon işlemidir. Bu kombinasyonda var olan tüm üretim öğeleri, maddeleri satışa hazır duruma getirmek üzere en sonuncu işleve değin birbirleri ile kaynaşırlar.

Böyle bir çalışma önemli bir yönetim faaliyeti olan planlamayı gerektirir. Çünkü örgütlerin en iyi hedefleri başarıları etkin planlara bağlıdır. Etkin bir plan, uygun hedeflere, hedeflerin başarılması için yerine getirilmesi gereken faaliyetlere ve her faaliyetin düzgün ve etkin biçimde başarılması için yeterli ön sürelerle bağlı olarak yürütülür. Bu nedenle planlama çalışmalarında birincil odak olan üretim planlamasına, mamul karışımlarının belirlenmesi ve bu mamullerin üretilmesi için mevcut verimli kapasitenin ilk aşamasında sürecin planlanması ile işe başlanır.[1]

Birincil odak olan üretim planlamanın yapılması için etkin bir çizelgeleme yapılmalıdır. Etkin bir çizelgeleme için ise doğru verilerle işe başlanmalıdır. Bu verilerin toplanabilmesi için çeşitli yöntemler mevcuttur. Belirli koşullar altında yapılan belli bir işin öğelerinin zamanını ve derecesini kaydederek ve bu yolla toplanan verileri çözümleyerek, o işin tanımlanan bir çalışma hızında yapılabilmesi için gereken zamanı saptamakta kullanılan bir ölçme tekniği olan zaman etüdü ve doğrudan gözlemler ve ölçümlere dayanmadan, çeşitli hareketler için önceden belirlenmiş zaman standartlarından yararlanarak, çeşitli işlemlerin yapılabilmesi için gereken zamanı saptamak amacıyla uygulanan önceden saptanmış zaman standartları (pts) [2] bu yöntemlerdendir.

Sonuç olarak bu ölçme teknikleri var olan bir iş üzerinden hareket etmektedir. Henüz hiç üretilmemiş ya da revizyona uğramış bir ürünün işlem süresini belirleyememektedir. Bu amaçla sınıflandırma, tahmin, modelleme gibi işlevleri olan yapay sinir ağı yaklaşımının, imalat alanında işlem sürelerini tahmin yeteneği ve performansı bilimsel olarak incelemeye değer bir konudur. Bu amaçla üretimde tahminleme alanındaki yapay sinir ağı çalışmaları incelenmiş ve Tablo 1.1’de sunulmuştur.

Tablo 1.1: Üretim alanında tahminleme uygulamaları

Yazar Adı	Uygulama Konuları
Erasmus Cadenasa, Wilfrido Rivera [3]	Rüzgar enerji istasyonlarının üretiminde 7 yıllık süre zarfında rüzgar hızının tahmini için ANN ve ARIMA methodlarına başvurulmuştur.
Raul Pino, Jose Parreno, Alberto Gomez, Paolo Priore [4]	İspanyadaki elektrik üretim piyasasında enerji fiyatlarının tahmini için Box-Jenkins, ARIMA ve ANN modeli kullanılmıştır. Bu makalede ANN modelinde hem çok katmanlı algılayıcı ve A.R.T yapıları kullanılmıştır.
Qing Wang [5]	Yapay sinir ağı kullanılarak maliyet modeli geliştirilmiştir.
Hsiao-Tien Pao [6]	Tayvandaki elektrik tüketiminde dört ekonomik faktörün etkisi, (ulusal gelir (N.I), nüfus (POP), yerli üretimin büyümesi (G.D.P), müşteri ücretleri indeksi (C.P.I)) yapay sinir ağını da içeren doğrusal ve doğrusal olmayan istatistiksel modellerle incelenmiştir
Parag C. Pendharkar [7]	Kaynak kod dökümantasyonunu etkileyen faktörler yapay sinir ağı tahminleme modeli ve lineer regresyon modeliyle araştırılmıştır. Non linear değişkenlerin çoklu girdiler ve çoklu çıktılar arasında ölçek ekonomisi var olduğu durumlarda yapay sinir ağlarının daha iyi performans gösterdiği görülmüştür
Philip Doganis, Alex Alexandridis, Panagiotis Patrinos, Haralambos Sarimveis [8]	Gıda endüstrilerinde kısa raf ömürlü çok sayıda ürün için genetik algoritma ve the radial basis function (R.B.F.) neural network kullanılarak tahminleme yapılmıştır.
Bahman Kermanshahi, Hiroshi Iwamiya [9]	Japonyada 2020 yılına kadar olan elektrik yükünün tahmin edilmesi için 10 faktör ele alınmıştır. (yerli ürünler, nüfus, hissedar sayısı, hava koşulları, CO2 miktarı, endüstri üretim indeksi, benzin fiyatları, enerji tüketimi ve elektrik fiyatları). Yapay sinir ağı yaklaşımıyla elektrik yükü tahmin edilmiştir.
Soteris A. Kalogirou [10]	A.N.N. kullanılarak güneş ışınımı ve rüzgar hızı tahmini, fotovoltaik sistemler, inşaat servis sistemlerinin iş yükleme tahminleri yapılmıştır.
Louis Sanzogni, Don Kerr [11]	Süt üretimi için standart geri beslemeli yapay sinir ağı çoklu doğrusal regresyon yöntemi kullanılmıştır.
Soteris A. Kalogirou [12]	Isınmada, havalandırmada, güç üretim sistemlerinde, yük tahminlemede yapay sinir ağı kullanılmıştır.

Yapılan literatür araştırmasında makine işlem süresinin tahminlenmesi için Y.S.A. kullanımına rastlanmamıştır. Henüz imalatına başlanmamış olan yeni tasarımlar için gözlemler yaparak standart zaman belirleme olanağı olmadığından güvenilir bir

planlama yapmak için gereken işlem süreleri yapay sinir ağı yaklaşımıyla tahmin edilmeye çalışılmıştır.

İkinci bölümde, Yapay Sinir Ağlarının Tanımı, Tarihçesi, Genel Kullanım Alanları, Üstünlükleri ve Sakıncaları, Yapay Sinir Ağı Modeli, Farklı Yapay Sinir Ağları Yapıları, Yapay Sinir Ağlarının Çalışma Şekli hakkında bilgi verilerek genel bir çerçeve çizilmiş ve en çok kullanılan yapay zeka yöntemleri özetle anlatılmıştır.

Üçüncü bölümde ise geliştirilen yapay sinir ağının topolojisine karar vermek üzere yapılacak çok sayıdaki deneyi sistematik hale getirmek ve parametre etkileşimlerini araştırmak üzere kullanılacak olan deney tasarımı konusu, klasik deney tasarımı yöntemleri, Taguchi yöntemi genel hatlarıyla anlatılmıştır.

Dördüncü bölümde, peçete makineleri üreten işletme hakkında bilgi verilmiş, uygulama yapılan işletmede, matkap, freze ve torna tezgahı için işlem süreleri yapay sinir ağı yöntemiyle tahmin edilmiş ve tahmin kalitesi istatistiksel olarak araştırılmıştır.

## **BÖLÜM 2. YAPAY SINİR AĞLARI**

### **2.1 Yapay Sinir Ağlarına Giriş**

Zamanla pek çok problemin çözümünde ve klasik manada algoritmik çözümü bulunamamış işlerin çözümlenmesinde çok yaygın olarak kullanılacakları tahmin edilen Y.S.A., insan beynindeki nöronlara benzer olarak meydana getirilen yapay nöronların değişik bağlantı geometrisi ile birbirlerine bağlanması sonucu oluşan kompleks sistemlerdir.

Y.S.A. ilk olarak insan beyninin biyolojik yapısının yapay olarak benzetimi çabalarının bir sonucu olarak ortaya çıkmıştır. Yapay sinir ağlarını oluşturan hücreler, insan sinir sistemini oluşturan nöronların (sinir hücreleri) görevini yapacak şekilde organize edilirler. İyi oluşturulmuş bir Y.S.A. insan beyninin davranışlarını kısmen taklit edebilir. Yani tecrübe ile öğrenebilir, tahmin yapabilir, daha önce öğrendiği bilgileri değerlendirerek bilgileri sınıflandırabilir, giriş bilgilerinden faydalı ve faydasız olanları ayırabilir ve bu insan beynine özgü birçok işlevi yerine getirebilir.

Y.S.A., insan beynindeki birçok sinirin karşılığı olarak yapay basit işlemcilerin birbirlerine bağlanmasıyla oluşan karmaşık bir ağ olarak düşünülebilir. Önceleri tıp biliminde insan beynindeki nöronların matematiksel modelleme çabalarıyla başlayan çalışmalarda, bilgisayar biliminin gelişimi ve çok hızlı işlemcilerin geliştirilmesi ile birçok başarılı sonuç alınmıştır.

Yapay zeka çalışmaları kapsamında ortaya çıkan ve bir noktada yapay zeka çalışmalarına destek sağlamakta olan farklı alanlardan bir tanesi de Y.S.A. teknolojisidir. Dolayısıyla, yapay zeka alanının bir alt dalını oluşturan Y.S.A. teknolojisi öğrenebilen sistemlerin temelini oluşturmaktadır. İnsan beyninin temel işlem elemanı olan nöronu (neuron) şekilsel ve işlevsel olarak basit bir şekilde taklit

eden Y.S.A.'lar, bu yolla biyolojik sinir sisteminin basit bir simülasyonu için oluşturulan programlardır. Bu şekilde, insanoğluna özgü deneyerek (yaşayarak) öğrenme yeteneğini bilgisayar ortamına taşıyabildiği düşünülen Y.S.A. teknolojisi bir bilgisayar sistemine birçok avantajlar sunmaktadır. Çeşitli avantajlar sunan ve gün geçtikçe gelişen bu teknolojiden, günümüzde bir çok alanda olduğu gibi ekonomi ve istatistik alanlarında da faydalanılmaktadır. Özellikle, “Evrensel Fonksiyon Yakınsayıcı Yöntem (Universal Function Approximators)” olarak tanınmalarından dolayı tahmin ve öngörü gibi verinin içerdiği yapının tanımlanmasını gerektiren alanlarda sıkça kullanılmaktadırlar. [13]

Y.S.A.'ların pratikte kullanımı genelde çok farklı yapıda ve formlarda bulunabilen verilerin hızlı bir şekilde tanımlanması ve algılanması ile ilgili uygulamalardır. Son yıllarda mühendislik uygulamalarında Y.S.A.'nın geniş çaplı kullanımının en önemli nedeni klasik tekniklerle çözümü zor problemler için etkin bir alternatif oluşturmasıdır.

Günümüzde Y.S.A., mühendislik başta olmak üzere, bir çok alanda, doğrusal olmayan problemlerin çözümü üzerinde yapılan araştırmalarda başarılı bir şekilde kullanıldığı görülmektedir. Y.S.A. olayları öğrenerek karar verme prensibi üzerine gelişmiştir. Ortaya atılan öğrenme metot ve tekniklerinin sayısı her geçen gün artmaktadır. Bu teknoloji bilgisayar dünyasında yeni ufuklar açmış, insanoğlunun anatomisindeki merkezi sinir sisteminin ve beyninin çalışma yapısını taklit etme prensibine dayalı, günümüzdeki teknolojiye bilgiyi paralel işleme şeklinde yeni bir yaklaşım getirmiştir.

## **2.2 Yapay Sinir Ağlarının Tanımı**

Yapay Sinir Ağları, insan beyninden esinlenerek geliştirilmiş, ağırlıklı bağlantılar aracılığıyla birbirine bağlanan ve her biri kendi belleğine sahip işlem elemanlarından oluşan paralel dağıtılmış bilgi işleme yapılarıdır. Y.S.A., bir başka deyişle, biyolojik sinir ağlarını taklit eden bilgisayar programlarıdır. Y.S.A. zaman zaman bağlantıcılık (connectionism), paralel dağıtılmış işlem, sinirsel-işlem, doğal zeka sistemleri ve makine öğrenme algoritmaları gibi isimlerle de anılmaktadır.



İnsanlığın doğayı araştırma ve taklit etme çabalarının en son ürünlerinden bir tanesi Y.S.A. teknolojisidir. Y.S.A.'ları, normalde bir insanın düşünme ve gözlemlemeye yönelik doğal yeteneklerini gerektiren problemlere çözüm üretmektedir. Bir insanın, düşünme ve gözleme yeteneklerini gerektiren problemlere yönelik çözümler üretebilmesinin temel sebebi ise insan beyninin ve dolayısıyla insanın sahip olduğu yaşayarak veya deneyerek öğrenme yeteneğidir.

Genel olarak Y.S.A. metodolojisinin uygulama adımlarına bakıldığında, Y.S.A.'nın basit ama yoğun yapısı ve bazı temel özellikleri daha açık anlaşılabilir. Tipik olarak, bir Y.S.A.'nın mimarisi (veya yapısı) oluşturulur ve çeşitli matematiksel algoritmalarla bir tanesi kullanılarak üretilen çıktının doğruluk (accuracy) düzeyinin maksimize edilmesi için gerekli olan ağırlık değerleri belirlenir. Y.S.A.'lar önceki örnekleri kullanarak ağırlıkları belirlemek yoluyla girdi değişkenler ile tahmin edilen değişkenler arasındaki ilişkiyi ortaya çıkartırlar; diğer bir deyişle Y.S.A.'lar eğitilir. Bir kez bu ilişkiler ortaya çıkartıldıktan sonra (yani ağ eğitildikten sonra), Y.S.A. yeni verilerle çalıştırılabilir ve tahminler üretilebilir. Bir ağın performansı, amaçlanan sinyal ve hata kriteri ile ölçülür. Ağın çıktısı, amaçlanan çıktı ile karşılaştırılarak hata payı elde edilir. Geri Yayılma (back propagation) olarak adlandırılan bir algoritma hata payını azaltacak şekilde ağırlıkları ayarlamak için kullanılır. Bu işlem defalarca tekrar edilerek ağ eğitilir. Eğitim işleminin amacı performans ölçümleri bazında optimum çözüme ulaşmaktır.

### **2.3 Yapay Sinir Ağlarının Tarihçesi**

İnsan beyni hakkındaki çalışmalar binlerce yıl öncesine dayanır. Modern elektroniğin gelişmesi ile birlikte, bu düşünce işlemi kullanmaya çalışmak doğal bir hale gelmiştir. İlk Yapay Sinir Ağı modeli 1943 yılında, bir sinir hekimi olan Warren McCulloch ile bir matematikçi olan Walter Pitts tarafından gerçekleştirilmiştir. McCulloch ve Pitts, insan beyninin hesaplama yeteneğinden esinlenerek, elektrik devreleriyle basit bir sinir ağı modellemiştir.

1948 yılında Wiener "Cybernetics" adlı kitabında, sinirlerin çalışması ve davranış özelliklerine değinmiştir. 1949'da ise Hebb "Organization of Behavior" isimli kitabında, öğrenme ile ilgili ilk teoriyi ele aldı.

Hebb kitabında öğrenebilen ve uyum sağlayabilen sinir ağı modeli için temel oluşturacak Hebb Kuralı'nı ortaya koymuştur. Hebb Kuralı sinir ağının bağlantı sayısı değiştirilebilirse, öğrenebileceğini öngörmekteydi. 1950'li yıllardan sonra birçok araştırmacı Hebb Kuralı'ndan esinlenerek Y.S.A.'nın hesaplama gücünü artırıcı yönde çalışmalar yapmıştır. IBM araştırma laboratuvarlarında yapılan bir sinir ağı benzetimi (simülasyon) çalışmaları başarısızlıkla sonuçlanmasına karşın sonraki girişimlerde başarı sağlanmıştır. 1957 yılında Frank Rosentvlantt'ın Perceptron'u gerçekleştirmesinden sonra Yapay Sinir Ağı alanındaki gelişmeler hızlanmıştır. Perceptron, beyin işlevlerini modelleyebilmek amacıyla yapılan çalışmalar neticesinde ortaya çıkan tek katmanlı eğitilebilen ve tek çıkışa sahip olan Yapay Sinir Ağıdır.

Bu çalışmalara yardımcı olmak için, John Von Neuman vakum tüplerini ve telgraf rölelerini kullanarak basit bir sinir işlevlerini taklit etmeyi önermiştir. Frank Rosentblantt ise anlama ve kavrama hakkında çalışmalara başlamıştır. Rosentblantt, bir sineğin göz işlemleriyle ilgilenmiştir. Bir sineğe kaçmasını söyleyen işlemlerin çoğu sineğin beyni yerine gözünün içinde yapılması, "kavrama düğümü" diye adlandırılan ağ yapısının kurulmasını sağlamıştır. Tek katmanlı bir kavrama düğümünde, giriş değerleri ağırlıklı toplamı hesaplanarak, bir eşik değeri çıkarılmakta ve iki olası değerden biri sonuç olarak alınmaktadır. Kavrama düğümü bugün kullanımda olan en eski sinir ağıdır.

1959 yılında, Bernard Widrow ve Marcian Hoff (Stanford Üniversitesi'nde) ADALINE ve MADALINE diye adlandırdıkları ağ modellerini geliştirdiler. MADALINE, telefon hatlarında oluşan yankıları yok eden bir uyarlanabilir süzgeç olarak kullanılmış, gerçek dünya sorunlarına uygulanmış olan ilk sinir ağıdır ve hala kullanımda bulunmaktadır. Bu dönemde en dikkat çekici çalışma Widrow'un 1963 yılında yaptığı "ters sarkaç" denetleyicisidir.

1969 yılında Minsky ve Papert Perceptron'un yetersizliğini görmüşler ve XOR problemini çözemediğini ispatlamışlardır. Bunun için iki katlı ileri beslemeli ağların kullanılabileceği ileri sürmüşlerdir. Fakat gizli katmanların ağırlıklarının nasıl

değiştirileceği konusunda bir yöntem önerememişlerdir. Bu soruna Rumelhart ve arkadaşları geri yayılım yöntemi ile bir çözüm getirmişlerdir.

Bu erken başarılar, insanların sinir ağlarının potansiyelini abartması sonucunu doğurdu. Abartılı beklentilerin gerçekleştirilememesi bu beklentileri hayal kırıklığına düşürdü. Aynı zamanda, bazı bilim kurgu yazarları “düşünen makinelerin” insanları nasıl etkileyeceğini ele almalarına yol açtı. Asimov robotlar hakkındaki kitaplarında, düşünen makinelerin, özellikle insanoğlunun ahlaki değerlerine olan etkilerini konu aldı. Diğer bazı yazarlar ise çok daha korkunç bilgisayarların yaratılacağı hakkında abartılı kitaplar yazdılar. Bu yersiz ve abartılı iddialar, Y.S.A. araştırmalarının kesilmesine yol açtı. Bu ilginç gelişme 1981 yılında sona erdi.

Tüm bunlara rağmen, Anderson, Wilshaw, Kanerva ve Kohonen gibi az sayıdaki sinir ağının savunucuları sessiz araştırmalarına devam ettiler. Son yıllarda yapılan çalışmalarla, Y.S.A. her alanda yaygın olarak kullanılmaya ve başarılı sonuçlar alınmaya başlanmıştır.

Seksenli yıllar sinirsel hesaplama çalışmaları için bir atılım dönemi olmuştur. Hopfield 1982 yılında ağların önemli sınıflarının matematik temellerini üretmiştir. John Hopfield Ulusal Bilimler Akademisinde bir makale sundu. Hopfield’in yaklaşımı beyne benzeyen bir model değil, kullanışlı bir alet yaratmaktı. Açık ve matematik analizleri kullanarak, böyle bir aletin nasıl çalışabileceğini ve ne yapabileceğini gösterdi.

1982-1984 ‘de Kohonen öz düzenlemeli harita (self organization map)’yı tanımladı. Bu sinirlerin düzenli sıralanışına eşleme özelliği için danışmasız (eğitici-siz) öğrenme ağıdır. Bu ağ kendi adıyla anılmaktadır.

1985 yılına kadar Amerikan Ulusal Fizik Akademisi (National Academy of Sciences of the USA), Y.S.A. ile ilgili gelişmeleri izlemiş ve desteklemiştir.

1986 yılında Rumelhart ve McClelland karmaşık ve çok katmanlı ağlar için geriye yayımlı öğrenme algoritması ortaya koymuşlardır.

1987 yılında Elektrik Elektronik Mühendisliği Enstitüsü (Institute of Electrical Electronical Engineering) tarafından sinir ağlarını konu alan ilk uluslararası konferans, 1800'ü aşkın katılımcıyla gerçekleştirilmiştir.

1988 yılında Chua ve Yang hücrel sinir ağlarını geliştirdiler.

Özetle Y.S.A. 1950'li yıllarda ortaya çıkmalarına rağmen, ancak 1980'li yılların ortalarında genel amaçlı kullanım için yeterli seviyeye gelmişlerdir.

Yapay sinir ağlarının başlangıcından günümüze kadar gelişim süreci içinde en iyi bilinen mimarilerin kısa bir tarihçesi Tablo 2.1'de görülmektedir.[14]

Tablo 2.1: Y.S.A.'nın tarihsel gelişimi

Yıl	Ağ Mimarisi	Bulan Bilim Adamı
1942	McCulloch-Pitts Hücresi	McCulloch-Pitts
1957	Algılayıcı (Perceptron)	Rosenblatt
1960	Madaline	Widrow
1969	Cerebellatron	Albus
1974	Geri yayılım (Back propagation)	Werbos, Parker, Rumelhart
1977	Bir kutu içinde zeka	Anderson
1978	Neocognitron	Fukushima
1978	Adaptif Rezonans Teorisi	Carpenter, Grossberg
1980	Öz Düzenlemeli Harita	Kohonen
1982	Hopfield	Hopfield
1985	İki Yönlü Birleşik Hafıza	Kosko
1985	Boltzman Makinesi	Hinton, Sejnowsky, Szu
1986	Sayı yayılım (Counterpropagation)	Hecht-Nielsen
1988	Hücrel Sinir Ağı	Chua, Yang

## 2.4 Yapay Sinir Ağlarının Genel Kullanım Alanları

Y.S.A.'lar gerçek hayatta karşılaşılan problemlerde oldukça geniş bir uygulama alanı kazanmışlardır. Bugün, bir çok endüstride başarılı şekilde kullanılmaktadırlar.

Uygulama alanları için bir sınır yoktur fakat, öngörü, modelleme ve sınıflandırma gibi bazı alanlarda ağırlıklı olarak kullanılmaktadır. Y.S.A.'lar 1950'li yıllarda ortaya çıkmalarına rağmen, ancak 1980'li yılların ortalarında genel amaçlı kullanım için yeterli seviyeye gelmişlerdir. Bugün, Y.S.A.'lar bir çok ciddi problem üzerinde uygulanmaktadır ve bu problemlerin sayısı giderek artmaktadır. Verideki trend veya yapıyı (pattern) en iyi tanımlayan yöntem olmaları dolayısıyla, tahmin (prediction) ve öngörü işlemleri için çok uygundur. Y.S.A.'ların gerçek hayattaki yaygın uygulama alanlarına şu örnekler verilebilir. [15]

- Kalite Kontrol
- Finansal Öngörü
- Ekonomik Öngörü
- Kredi Derecelendirme
- Konuşma ve Yapı Tanımlama
- İşlem Modelleme ve Yönetimi
- Laboratuvar Araştırmaları
- İflas Tahmini
- Petrol ve Gaz Arama
- Denetim
- Sistem Modelleme
- Ses Tanıma
- El Yazısı Tanıma, Parmak İzi Tanıma
- Elektrik İşaret Tanıma
- Meteorolojik Yorumlama
- Otomatik Araç Denetimi
- Fizyolojik İşaretleri (Kalp fonksiyonları gibi) İzleme, Tanıma ve Yorumlama
- Zaman Serilerinin Yorumlanması ve Gelecek Dönemin Tahmin Edilmesi

Yukarıda verilen başlıklara ilave olarak, Y.S.A., her türlü bilgiyi işlemek ya da analiz etmek amacıyla kullanılır. İş hayatı, finans, endüstri, eğitim ve karışık problemlerin çözümünde, doğrusal olmayan sistemlerde başarıyla uygulanmaktadır.

Y.S.A.'lar, tanımlanmamış girdi veriler hakkında karar verirken genelleme yapabildikleri için iyi birer yapı tanımlayıcısı (pattern recognition engine) ve sağlam

sınıflandırıcıdır (robust classifier). Fonksiyonel tahmin (prediction) ve sistem modelleme gibi fiziksel işlemin anlaşamadığı veya aşırı karmaşık olduğu problemler yanında konuşma, karakter ve sinyal tanımlama gibi çeşitli sınıflandırma problemleri için çözüm yolları sağlamaktadırlar. Ayrıca, kontrol problemlerinde de uygulama sahası bulmaktadırlar. Y.S.A.'nın başlıca uygulama alanları sınıflandırma, tahmin ve modelleme olarak ele alınabilir.

Sınıflandırma: Müşteri/Pazar profilleri, tıbbi teşhis, imza tetkikleri, borçlanma/risk değerlendirmeleri, ses tanıma, şekil tanıma, spektrum tanımlanması, mal değerleri, hücre tiplerinin sınıflandırılması, mikroplar, modeller, örnekler.

Tahmin: İleriki satışlar, üretim ihtiyacı, pazar performansı, ekonomik deliller, enerji ihtiyacı, tıbbi sonuçlar, kimyasal reaksiyon ürünleri, hava tahminleri, at yarışları, çevresel risk, jüri panelleri.

Modelleme: İşlem kontrolü, sistem kontrolü, kimyasal yapılar, dinamik sistemler, işaret karşılaştırma, plastik kalıpcılık, kaynak kontrolü, robot kontrolü ve diğer bir çok uygulama. [16]

Y.S.A.'lar yoğun bağlantılı ve komplike işlem yapıları nedeniyle çalışabilecekleri özel ortamlara ihtiyaç duymaktadırlar. Bu yüzden, Y.S.A.'lar, bu amaca yönelik olarak hazırlanmış özel yazılımlar ile bilgisayarlarda çalıştırılmaktadırlar. Günümüzde ise, gittikçe artan oranda yoğun ve karmaşık sinir ağlarını çalıştırabilmek ve daha hızlı işlem yapabilmek için özel donanımlar geliştirilmektedir.

Günümüzde sinirsel ağ uygulamaları geleneksel bilgisayarlar üzerinde yazılım simülatörleri kullanılarak, veya özel donanım içeren bilgisayarlar kullanarak gerçekleştirilmektedir. Kredi risk değerlemesinden imza kontrolü, mevduat tahmini ve imalat kalite kontrolüne kadar uzanan uygulamalar yazılım paketlerinden faydalanılarak yapılmaktadır.

Uygulama alanına göre kullanılan Yapay Sinir Ağları Tablo 2.2'deki gibi sınıflandırılabilirler.

Tablo 2.2: Y.S.A. ve uygulama alanları[16]

Uygulama	Ağ Türü
Tahmin	Geri Yayılım Ağı Delta Bar Delta Genişletilmiş Delta Bar Delta Yüksek Seviyeli Ağlar Öz Örgütlemeli Harita Perceptron
Sınıflandırma	Geri Yayılım Ağı Öğrenme Vektörü Nicelemesi Perceptron Olasılıksal Sinir Ağları Kohonen Ağı Boltzman Makinesi
Veri Birleştirme	Hopfield Boltzman Makinesi Hamming Ağı İki Yönlü Çağırışım Belleği Yığın Ağları Vektör Nicelemesi Ağı
Veri Kavramlaştırma	Uyarlanır Rezonans Ağı Öz Örgütlemeli Harita Ağı
Veri Süzme	Yeniden Dolaşım
Resim veya Görüntü İşleme	Geri Yayılım Ağı Perceptron

## 2.5 Yapay Sinir Ağlarının Üstünlükleri ve Sakıncaları

Y.S.A.'nın en büyük üstünlükleri, öğrenme kabiliyeti olması ve farklı öğrenme algoritmaları kullanabilmesidir. Bunun yanı sıra en sık belirtilen sakıncaları ise sistemin çalışmasının analiz edilememesi ve öğrenme işleminde başarılı olunamama riski olmasıdır. Y.S.A.'nın üstünlükleri ve sakıncaları Tablo 2.3'de verilmiştir.

Tablo 2.3: Y.S.A.'nın üstünlükleri ve sakıncaları[17]

Üstünlükler	Sakıncalar
Matematik modele ihtiyaç duyulmaz.	Sistem içerisinde ne olduğu bilinemez.
Kural tabanı kullanımı gerektirmez.	Bazı ağlar hariç kararlılık analizleri yapılamaz.
Öğrenme kabiliyeti vardır ve farklı öğrenme algoritmaları ile öğrenebilir.	Farklı sistemlere uyarlanması zor olabilir.

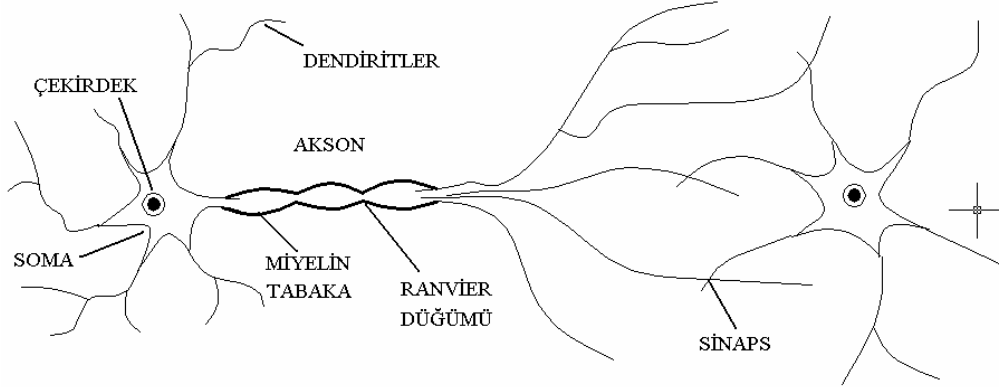
İki temel durumda Y.S.A.'nın kullanımı efektif olmaktadır:

1. Geniş veri takımlarının yorumlanması istenen incelemelerde
2. Giriş ve çıkış verileri belli, fakat bu veriler arasındaki ilişkilerin iyi bilinmemesi durumunda.

## 2.6 Yapay Sinir Ağının Modeli

### 2.6.1 Biyolojik sinir ağı sistemi

Şekil 2.1'de de görüldüğü üzere biyolojik nöron, bir çekirdek, gövde ve iki türlü uzantıdan oluşmaktadır. Bunlardan kısa ve dallanmış olan Dendrit, giriş bilgilerini alır, uzun ve tek olan akson ise çıkış bilgilerini diğer nöronlara taşır. Akson ve Dendritin birleşim yerine Sinaps adı verilir. Bunlar nöronlardan aldığı sinyalleri değerlendirirler ve eşik değeri üzerinde bir giriş varsa bir sonraki hücreye iletirler.



Şekil 2.1: Biyolojik nöron


Soma ise, sinir hücresinin gövdesidir. Akson, çıkış bilgilerinin üretildiği elektriksel olarak aktif gövde uzantısıdır. Bir akson birden fazla dendrit ile bilgi bağlantısına girebilir. Dendrit, diğer hücrelerden gelen bilgileri toplayan elektriksel olarak pasif hücre kollarıdır. Sinaps, iki farklı hücrenin dendritlerinin bağlantı noktalarıdır. Miyelin tabaka, sitoplazma ile hücreler arası sıvı arasındaki kapasiteyi düşürerek, bilgilerin yayılma hızını artırmaya yarayan yalıtım malzemesidir. Ranvier düğümü, Miyelin tabaka ile kaplı akson üzerinde birkaç mm'de bir yer alan ve bilgileri periyodik yeniden üretmeye yarayan boğumdur.



## 2.6.2 Yapay sinir hücresi ve modeli

Matematiksel olarak modellenirilmiş biyolojik bir nöron Şekil 2.2’de görülmektedir. Bu tür nöronlar Mc Culloch-Pits nöronu olarak bilinirler. Bunlar ağın her bir işlem birimini temsil ederler ve birbirleriyle bağlanarak ağı oluştururlar. Her bir nöron basit bir anahtar görevi yapar ve şiddetine göre gelen sinyali ya söndürür ya da iletir. Böylece ağ içerisindeki her bir nöronun belli bir yükü olur.


Sinirsel (neural) hesaplamaların merkezinde dağıtılmış, adaptif ve doğrusal olmayan işlem kavramları vardır. Y.S.A.’lar, geleneksel işlemcilerden farklı şekilde işlem yapmaktadırlar. Geleneksel işlemcilerde, tek bir merkezi işlem elemanı her hareketi sırasıyla gerçekleştirir. Y.S.A.’lar ise herbiri büyük bir problemin bir parçası ile ilgilenen, çok sayıda basit işlem elemanlarından oluşmaktadır. En basit şekilde, bir işlem elemanı, bir girdiyi bir ağırlık kümesi ile ağırlıklandırır, doğrusal olmayan bir şekilde dönüşümünü sağlar ve bir çıktı değeri oluşturur. İlk bakışta, işlem elemanlarının çalışma şekli yanıtıcı şekilde basittir. Sinirsel hesaplamaların gücü, toplam işlem yükünü paylaşan işlem elemanlarının birbirleri arasındaki yoğun bağlantı yapısından gelmektedir.



Şekil 2.2: Bir biyolojik nöronun matematiksel modellenmesi

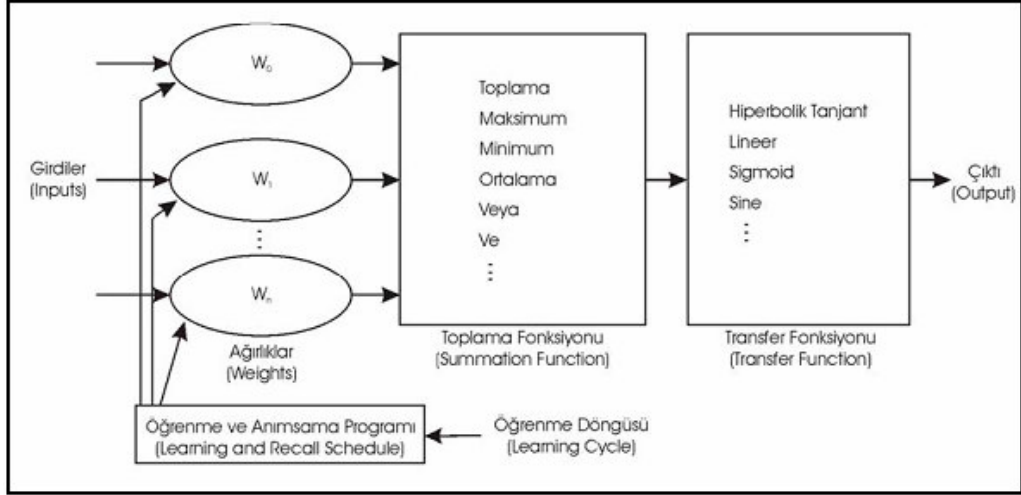
Yapay sinir, biyolojik sinirin giriş işlem ve çıktı karakteristiğini taklit etmek için tasarlanmıştır. Y.S.A.’da bulunan her bir hücre istenilen sayıda giriş ve giriş ağırlıkları, bir toplama noktası, bir lineer olmayan aktivasyon fonksiyonu ve tek çıkıştan meydana gelir. Hücre çıkışı aynı anda farklı birçok hücreyi besleyebilir.

Burada her bir giriş kendi ağırlığı ile çarpılmakta ve bu çarpımların hepsi toplanmaktadır. Bu toplam sinaptik kuvvete benzetilebilir ve nöronun aktivasyon seviyesini belirlemek için kullanılır. Şekil 2.3 bu modeli göstermektedir.



Şekil 2.3: Yapay sinir ağı modeli

Burada  $x_i$ 'ler girişleri,  $y_{out}$  çıkışı,  $w_i$ 'ler ağırlıkları göstermektedir. Toplam blok, biyolojik hücrenin yapısını göstermektedir. Giriş vektörü  $x$  ( $x_1, x_2, \dots, x_n$ ) hücre girişine uygulanır ve ağırlık vektörü  $w$  ( $w_1, w_2, \dots, w_n$ ) ile çarpılır. Ağırlıklı girişler toplanarak aktivasyon fonksiyonu seviyesi  $y_{net}$  adı verilen bir çıkış meydana getirir. Elde edilen  $y_{net}$ 'e, aktivasyon fonksiyonu  $f_{ak}$  uygulanarak çıktı işareti ( $y_{out}$ ) elde edilir. Aktivasyon fonksiyonları çıkış değerini birkaç sonlu değere sıkıştıran fonksiyonlardan seçilir. Genelde bu sonlu değerler  $[0,1]$  veya  $[-1,1]$  aralığında seçilir. Şekil 2.4'de, daha önce tanımlanan basit bir yapay nöron yapısının daha detaylı bir şeması sunulmaktadır. Şekilde, girdi değerler işlem elemanına üst sol bölümden girmektedir. İşlemde ilk adım, bu girdi değerlerin her birinin ilgili ağırlıklarla  $w(i)$  ağırlıklandırılmalarıdır. Bir nöron genellikle, eşzamanlı olarak birçok sayıda girdi alır. Her girdinin kendi nispi ağırlığı vardır. Bu ağırlıklar, biyolojik nöronların değişen sinaptik etkileri ile aynı görevi üstlenirler. Her iki durumda da, bazı girdiler diğerlerine göre daha önemli hale gelirler. Bu sayede, işlem elemanının bir sinirsel tepki üretmesi işleminde daha fazla etkili olurlar. Ayrıca, ağırlıklar girdi sinyalin güçlüğüne belirleyen adaptif katsayılarıdır. Yani, girdinin bağlantı gücünün bir ölçüsüdür. Bu bağlantı güçleri, çeşitli eğitime setlerine göre değiştirilebilirler.



Şekil 2.4: Yapay nöronun detaylı yapısı

Sonuç olarak yapay sinir ile biyolojik sinirler arasındaki benzerlik Tablo 2.4'deki gibi gösterilebilir.

Tablo 2.4: Biyolojik sinir ile Y.S.A.'nın karşılaştırılması[17]

<b>Biyolojik Sinir Ağı</b>	<b>Yapay Sinir Ağı</b>
Sinir Sistemi	Sinirsel Hesaplama Sistemi
Sinir	Düğüm (Sinir, İşlem Elemanı)
Sinaps	Sinirler Arası Bağlantı Ağırlıkları
Dentrit	Toplama İşlevi
Hücre Gövdesi	Etkinlik İşlevi
Akson	Sinir Çıkışı

### 2.6.2.1 Sigmoid fonksiyonu

En önemli eşik fonksiyonu Sigmoid fonksiyonudur. Bu fonksiyon, seviyeli lineer olmayan çıkış veren, sınırlı, monoton artan, türevi alınabilen bir fonksiyondur.

Denklemini,


$$y(x) = \frac{1}{1 + e^{-ax}} \quad (2.1)$$

şeklindedir. Y.S.A. çıkışı;

$$y_{out} = \frac{1}{1 + e^{-ay_{net}}} \quad (2.2)$$

şeklinde olur.

Sigmoid fonksiyonuna a kazancı ilave edilmesiyle şekli değiştirilebilir. a'nın değişik değerleri için bulunan sigmoid fonksiyonları Şekil 2.5'te gösterilmiştir. Eğer a çok artırılırsa Sigmoid fonksiyonu basamak fonksiyonuna dönüşür. Her iki fonksiyonda [0,1] aralığında değişir fakat Sigmoid fonksiyonunun türevinin alınabilmesi Y.S.A. teorisi ve özellikle Geriye Yayılım (Back-Propagation) teorisinde çok önemlidir.




Şekil 2.5: Sigmoid fonksiyonu

### 2.6.2.2 Basamak fonksiyonu

Basamak Fonksiyonu ise aşağıdaki gibi tanımlanır.

$$y(x) = \begin{cases} 1 & \Rightarrow x \geq 0 \\ 0 & \Rightarrow x < 0 \end{cases} \quad (2.3)$$

Şekil 2.6'da basamak fonksiyonu gösterilmiştir.




Şekil 2.6: Basamak fonksiyonu

### 2.6.2.3 Sınırlandırılmış lineer fonksiyonu

Bu fonksiyon için matematiksel tanımlama denklemi aşağıda gösterilmektedir.

$$y(x) = \begin{cases} 1 & \Rightarrow x \geq \frac{1}{2} \\ ax & \Rightarrow -\frac{1}{2} < x < \frac{1}{2} \\ 0x & \Rightarrow x < -\frac{1}{2} \end{cases} \quad (2.4)$$

Burada a sabit bir sayıdır. Şekil 2.7’de basamak fonksiyonu a’nın değişik değerleri için gösterilmiştir.




Şekil 2.7: Sınırlandırılmış lineer fonksiyonu

#### 2.6.2.4 Signum fonksiyonu

Yukarıda anlatılan aktivasyon fonksiyonları  $[0,1]$  aralığında çıkış vermektedirler. Bazı uygulamalarda aktivasyon fonksiyonunun  $[-1,1]$  aralığında değer alması istenir. Bu durumlarda basamak fonksiyonu denklemi aşağıdaki gibi düzenlenir.

$$y(x) = \begin{cases} 1 & \Rightarrow x \geq 0 \\ 0 & \Rightarrow x = 0 \\ -1 & \Rightarrow x < 0 \end{cases} \quad (2.5)$$

Bu fonksiyon signum fonksiyonu olarak bilinmektedir ve Şekil 2.8'de gösterilmektedir.




Şekil 2.8: Signum fonksiyonu

#### 2.6.2.5 Hiperbolik tanjant fonksiyonu

Sigmoid fonksiyonuna benzeyen fakat negatif çıkışta üretebilen diğer bir fonksiyonda hiperbolik tanjant fonksiyonudur. Denklemi ve fonksiyonu aşağıdaki gibidir.

$$y(x) = \tanh(x) = \frac{1 - e^{-x}}{1 + e^{-x}} \quad (2.6)$$



Şekil 2.9: Hiperbolik tanjant fonksiyonu


Y.S.A. teknolojisi hesaplamalarda tamamen farklı bir yaklaşım getirmektedir. Y.S.A., paralel hesaplama tekniğinin bütün avantajlarını kullanabilen ve algoritmik olmayan bir metottur. Belirli bir problemi, programlama yerine direkt olarak mevcut örnekler üzerinden eğitilerek öğrenirler. Ayrıca Y.S.A., klasik bilgisayar belleği gibi belirli bilgileri belirli yerlerde saklama yerine, öz şeklindeki bilgileri nöronlar arasındaki bağlantılar üzerindeki ağırlık değerleri ile ağ üzerine dağıtarak saklarlar.

Y.S.A.'nın ana ögesi olan matematiksel fonksiyon, ağın mimarisi tarafından şekillendirilir. Daha açık bir şekilde ifade etmek gerekirse, fonksiyonun temel yapısını ağırlıkların büyüklüğü ve işlem elemanlarının işlem şekli belirler. Y.S.A.'ların davranışları, yani girdi veriyi çıktı veriye nasıl ilişkilendirdikleri, ilk olarak nöronların transfer fonksiyonlarından, nasıl birbirlerine bağlandıklarından ve bu bağlantıların ağırlıklarından etkilenir.

Bu bilgiler ışığında bakıldığında, Y.S.A.'ların yapısı üç ana eleman içermektedir ve Şekil 2.10'daki gibidir. Şekilden de görülebileceği gibi, Y.S.A.'ların yapısını oluşturan üç ana eleman temel işlem elemanı olan nöron, girdi ve çıktı yolunu sağlayan bağlantı ve bu bağlantıların sağlamlığını gösteren bağlantı ağırlığıdır.

Y.S.A. çeşitli bağlantılarla birbirine bağlı birimlerden oluşmuş sistemlerdir. Her birim basitleştirilmiş bir nöronun niteliklerini taşır. Sinir ağları sinir sisteminin parçalarının benzetimini yapmakta, faydalı cihazlar yapmakta ve beynin işleyişine ilişkin genel kuramları sınamakta kullanılır. Sinirsel ağ içindeki birimler, her birinin

belli işlevi olan katmanlar şeklinde örgütlenmiştir, bu yapıya “Yapay Sinir Ağı Mimarisi” denir.



Şekil 2.10: Y.S.A. mimarisinin temel elemanları

## 2.7 Farklı Yapay Sinir Ağları Yapıları

Bugüne kadar pek çok Y.S.A. mimarisi geliştirilmiştir. Bu yapıların geliştirilmesinde biyolojik sinir sistemlerinin prensibinden ve mühendislik biliminden yararlanılmıştır. Genel olarak Y.S.A.’lar ileri beslemeli ve geri beslemeli ağlar olarak ikiye ayrılmaktadır.

### 2.7.1 İleri beslemeli ağlar

Tek katmanlı ileri beslemeli ağlar (Feed-Forward)


İşaretin, ağ girişinden ağ çıkışına doğru tek yönlü olarak iletiildiği ağlara İleri Beslemeli Ağ (İ.B.A.) denmektedir. Bir katmandaki hücreler sadece bir önceki katmandaki hücrelerin çıkışlarıyla beslenebilir. Ayrıca girişlerde ve çıkışta geciktirme elemanı yoktur. Şekil 2.11’de Tek katmanlı ileri beslemeli Y.S.A. modeli gösterilmektedir.

Çok katmanlı ileri beslemeli ağlar

Tek katmanlı İ.B.A.’dan farkı, giriş ve çıkış arasında gizli katmanların bulunmasıdır. Uygulamalarda, tek gizli katman kullanılıyorsa da birden fazla gizli katmanda kullanılabilir. Ağa gizli katmanların eklenmesi ile giriş ile çıkışı ilişkilendiren daha karmaşık işlemleri gerçekleştirmek kolaylaşmaktadır. Çünkü düşünülen sistemin girişi ile çıkışını ilişkilendiren daha çok parametre, gizli katmandaki ağırlıklara göre




ayarlanabilir. Şekil 2.11’de Çok katmanlı ileri beslemeli Y.S.A. modeli verilmiştir. Giriş düğümleri, girişleri ağırlıklar üzerinden gizli katmana aktarmaktadır. Birbirine bağlı hücrelerden oluşan ağlara tam bağlantılı ağlar denilir. Bazı durumlarda bazı bağlantılar gereksiz olabilmektedir. Tüm hücrelerin veya girişlerin kendisinden sonraki katmana giriş vermediği ağlara ise kısmi bağlantılı ağlar denilmektedir.



Şekil 2.11: (a) Tek katmanlı ileri beslemeli Y.S.A. modeli,  
(b) Çok katmanlı tam bağlantılı tek gizli katmanlı ileri beslemeli Y.S.A. modeli.

### 2.7.2 Geri beslemeli ağlar

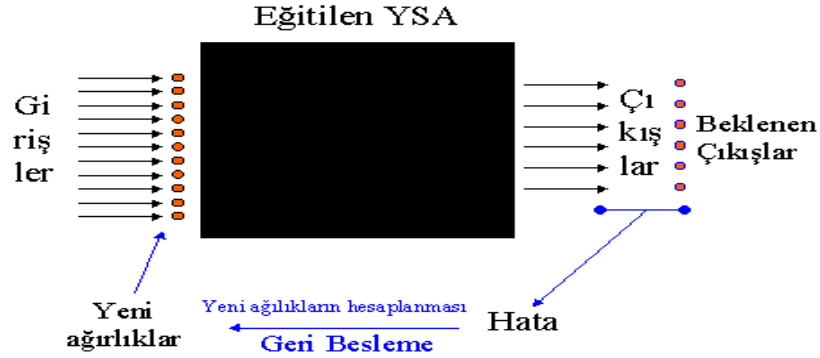
İşaretin ağ girişinden çıkışa doğru iletilmesinin yanında en az bir hücre sonraki katmanlardaki hücrelerin çıkışlarıyla beslenen ağlardır. Girişlerde ve çıkışlarda geciktirme elemanları olabilmektedir. Hücre çıkışının yine kendi girişini beslediği ağlara öz geri beslemeli ağ denir. Şekil 2.12’de gizli katmana sahip geri beslemeli bir ağ yapısı görülmektedir. Gizli katman, aynı zamanda çıkışları birim gecikmelerle girişi beslemektedir. Bu geri besleme öz geri beslemedir. Y.S.A.’da geri besleme, katmanlı durağan bir girişe durağan bir çıkışı eşleştirir. Bu yapı giriş-çıkış ilişkisinin zamandan bağımsız olduğu problemleri çözmede kullanılmaktadır. Fakat gerçek zamanlı uygulamalarda, zaman önemlidir. Bu uygulamalarda, zaman Y.S.A. yapısı içinde tanımlanmalıdır. Bunun için ağa dinamiklik getirilmelidir. Y.S.A.’nın dinamik olması belleğe sahip olması ile mümkündür. Bundan dolayı Y.S.A. geri beslemeli yapılmalıdır. Geri beslemeli ağlar ileri beslemeli ağlara göre daha dinamiktir.



Şekil 2.12: Gizli katmanlı geri beslemeli Y.S.A. modeli

## 2.8 Yapay Sinir Ağlarının Çalışma Şekli

Y.S.A.'ların iki türlü çalışma şekli vardır. Biri eğitime diğeri kullanma aşamasıdır. Y.S.A.'lar kullanma aşamasında eğitime aşamasına göre daha hızlı çalışırlar. Bir Y.S.A.'nın kullanılabilmesi için önce eğitilmesi gerekir. Bu durumu Şekil 2.13'de görmekteyiz.



Şekil 2.13: YSA'nın eğitilmesi

Eğitime aşamasında Y.S.A.'nın içindeki düğümlerin (node) birbirine bağlantı yüzdelerini gösteren ve ağırlık (weight) diye tabir edilen değerler hesaplanır. Bu aşamada genellikle kullanılan algoritma geriye yayılma ya da geriye yansıma (Back Propagation) algoritmasıdır. Geriye yayılma algoritmasının özü; ilerleme sonucunda ortaya çıkan hatanın, geriye doğru yansıtılarak, ağırlıkların daha doğru sonuçlar verecek şekilde değiştirilip yeniden hesaplanarak düzeltilmesidir.

Eğitme aşamasında ağırlıkların hesaplanabilmesi için Y.S.A.'ya girişler ve karşılık gelen çıkışlar verilir. Y.S.A. için öğrenme bu giriş ve çıkış verileri arasında bir çeşit bağlantı kurmak diye de tanımlanabilir. Eğitim aşamasında hesaplanan bu ağırlık değerleri daha sonra sadece girişlerin verilip çıkışların hesaplanmasının istenildiği kullanma aşamasında işe yararlar. Eğitim aşamasının bir basamağı hem ilerleme hem de geri yayılma safhalarını içerirken, kullanma aşamasında sadece ilerleme işlemi uygulanır. Zaten gerçek sonuçlar bilinmediğinden hatanın hesaplanıp geri yansıtılması mümkün değildir.

Kullanma aşamasındaki algoritma eğitme aşamasına göre daha basittir. Dolayısıyla Y.S.A.'lar kullanma aşamasında eğitme aşamasına göre daha hızlı çalışırlar. Yani bir kere tam manasıyla eğitilmiş olan bir Y.S.A. eğitim aşamasında güçlükler çıkarmış olsa da, kullanma aşamasında özellikle hız açısından o kadar sorun çıkarmaz. Eğitimde de, kullanma aşamasında girişlere karşılığı istenen değerler konulur. Eğitim aşamasında hesaplanan ağırlık değerleri bu aşamada, sadece giriş değerlerinin verilip çıkışların Y.S.A. tarafından hesaplanmasında kullanılır.

Eğitme yöntemleri Y.S.A.'nın çok önemli bir aşamasıdır. Y.S.A.'nın öğrenmesi, hücreler arasındaki ağırlıkların, uygun değerlere ayarlanması anlamındadır. Eğitim ve öğrenme farklı kavramlardır. Eğitim, ağırlık öğrenmesi için gerçekleştirilen adımlardır, öğrenme ise eğitim işleminin sonucudur. Eğitim yöntemi ilgilenilen problemin özelliğine göre öğrenme kuralını Y.S.A.'ya nasıl uyarlayabileceğini belirtir.

## **2.9 Yapay Sinir Ağlarının Eğitimi**

1. Yapay sinir ağının ne yapması istenildiğine karar verilir. Verilen karara göre yapay sinir ağını eğitmek üzere örnek veriler toplanır. Bazı durumlarda, bu veriler üzerinde bir ön işlem yapmak gerekebilir. Bu ön işlemin amacı, aynı şeyi temsil eden verilerin birbirine benzer, farklı şeyleri temsil eden verilerin ise farklı hale getirilmesidir. Ama eğer veriler bu şekilde ise ön işleme gerek yoktur.

2. Yapay sinir ağı eğitilir. Bu esnada giriş ve çıkış diye ayrılan veriler arasında doğru bir bağlantı kurulana kadar ağ içindeki bağlantı ağırlıkları (weights) ayarlanacaktır.

Bu işlem hata belli bir oranın altına düşene ya da eğitime işlemi belli bir tekrar sayısına ulaşına kadar devam eder.

3. Yapay sinir ağı test edilir. Yapay sinir ağını iyi eğitip eğitemediğini anlamak için, yapay sinir ağına daha önce hiç görmediği veriler verilmelidir. Eğer hiç eğitilmediği ve daha önce karşılaşmadığı verilerle de doğru sonuçlar veriyorsa, o zaman yapay sinir ağı veriler arasındaki bağlantıları doğru kurmuş ve kullanılmaya hazır demektir. Eğer büyük bir hata oluşuyorsa daha çok ya da daha iyi veriler ile yapay sinir ağının yeniden eğitilmesi gerekecektir. Ayrıca yapay sinir ağının yapısını yani düğüm sayılarını değiştirmek de işe yarayabilir. Çok az düğüm sayısı öğrenme oranını düşürdüğü gibi çok fazla düğüm veya katman sayısı da hem öğrenmeyi yavaşlatacak hem de bazı durumlarda öğrenmeyi zorlaştıracaktır. Bu sayılar öğrenilmesi istenen bağlantıya bağlıdır, ancak henüz nasıl belirleneceklerine dair kesin bir yöntem yoktur. Şimdilik en uygun yöntem deneme-yanılamadır.

4. Artık yapay sinir ağı kullanılabilir. Yeni veriler girilmeli ve sonuçları görülmelidir. Başarılı bir yapay sinir ağı geliştirmenin sırrı yeterli miktarda iyi veriye sahip olmaktır. Çünkü yapay sinir ağı da bir insan gibi tecrübe ederek öğrenir. Yani geçmişteki sonuçlardan faydalanıp geleceği tahmin ederler. Yapay sinir ağı için tecrübenin esası da işte bu geçmişteki verilerdir. Bu veriler ne kadar çok, çeşitli ve sağlam olursa öğrenme de o kadar etkin olur.

Test verileri ile eğitime verileri aynı ise aşırı eğitime ile karşılaşmaz. Ancak bu bir aldanmacadır çünkü test verileri ile eğitime verileri ayrı olmalıdır. Çünkü; yapay sinir ağları genelleştirilmiş çıkarımlar yaparlar, yani tamamen aynı olmayan iki şeyin benzerliklerinden, aynı türden olduklarını söyleyebilirler. Eğer bir yapay sinir ağı aynı verilerle çok fazla eğitilirse bu sefer yapay sinir ağı sadece o verileri tanır hale gelir, işte buna “aşırı eğitime” denir. Bu durumdan kurtulmanın yolu eğitime için çok sayıda örnek kullanmaktır. Ama eldeki bütün örnekler de eğitime için kullanılmamalı, bazıları (mesela yarısı ya da 1/3’ü) test aşaması için saklanmalıdır. Böylece yapay sinir ağını daha önce hiç karşılaşmadığı verilerle test etme imkanı olur. Eğer bu şekilde çalışılırsa test sonuçlarına bakılarak aşırı eğitime yapıp yapılmadığı anlaşılabilir, zaten bunu anlamının da başka pratik bir yolu yoktur.[17]

## 2.10 Yapay Sinir Ağlarında Öğrenme

Y.S.A.'da öğrenme kuralı Hebbain öğrenme kuralı denilen basit bir modele dayanır. Hebbain öğrenme kuralı temel olarak “Eğer iki düğüm arasında aynı zamanda etkin ise aralarındaki bağ gücü artar” kuramına dayanmaktadır. Öğrenme ağın içinde bulunduğu ortam tarafından, devam eden bir süreçte bağımsız ağ parametrelerinin ayarlanması işlemidir. Yani kısaca herhangi bir sistemi modellemek amacıyla tasarlanan bir ağda bağlantı ağırlıklarının ve hücre eşiklerinin istenilen giriş-çıkış eşleştirmesini sağlayacak şekilde belirleme işlemine öğrenme denir.

Y.S.A.'nın arzu edilen davranışı gösterebilmesi için amaca uygun olarak tasarlanması gerekir. Bu durum, hücreler arasında doğru bağlantıların yapılması ve bağlantıların uygun ağırlıklara sahip olması gerektiğini ifade eder. Y.S.A.'nın karmaşık yapısı nedeniyle bağlantılar ve ağırlıklar önceden ayarlı olarak verilemez ya da tasarlanamaz. Genellikle ağırlıklar, rasgele ya da sabit bir değerde seçilir. Y.S.A.'nın, istenen davranışı gösterecek şekilde ilgilendiği problemten aldığı eğitim örneklerini kullanarak problemi öğrenmelidir. Belli bir hata kriterine ve öğrenme algoritmasına göre, ağırlıkların yenilenerek, artık değişmediği durumda öğrenmenin gerçekleştiği söylenebilir.

Öğrenme yöntemi veya ağ mimarisi, hangi parametrelerin değiştirileceğine bağlıdır. Öğrenme işlemi gerçekleştirilmek üzere tanımlanmış kuralların tümüne öğrenme algoritması denilir. Bu güne kadar çeşitli öğrenme algoritmalarının her birinin kendine has üstünlükleri ve eksiklikleri vardır.

Danışmalı ve danışmasız olmak üzere iki tip öğrenme türü vardır. Danışmalı öğrenmede bir öğretmene ihtiyaç vardır. Öğretmen, bir veri alıştırma kümesi veya ağ sonuçlarının performansını derecelendiren bir gözlemci olabilir. Danışmalı öğrenmede eğitilmiş sınırlara öğretme işaretini göndererek sınırlar eğitilir. Bu işaretin bağlantısındaki ağırlıkları ayarlamakta kullanılır.

Bütün Y.S.A.; sınırlar, bağlantılar ve aktarım işlevlerine bağlı olduğu için, farklı mimariler, yapılar ya da sinir ağları arasında bir benzerlik bulunmaktadır. Çeşitliliğin

çoğunluğu farklı öğrenme kurallarından ve bu kuralların bir ağın yapısını nasıl değiştirdiğinden kaynaklanmaktadır. Öğrenme yöntemlerine göre ağ yapıları Tablo 2.5’de görülmektedir.

Tablo 2.5: Öğrenme yöntemlerine göre ağ yapıları[17]

Ağ Yapıları	
Danışmalı	Danışmansız
Perceptron	Hopfield Ağı
Çok Katmanlı Perceptron	Olasılıksal Sinir Ağı
Geri Yayılım Ağı	Uyarlanı Rezonans Ağı
Daha Yüksek Düzeyli Sinir Ağı	Öz örgütlemeli Harita Ağı
İşlevsel Bağ Ağı	Boltzman Makinesi
	Hamming Ağı
	Geri Yayılma İçine Özörgütlemeli Harita Ağı
	İki Yönlü Çağırışım Belleği
	Yığın Ağı
	Karşı Yayma Ağı
	Öğrenme Vektör Nicelendirmesi
	Rekabetçi Öğrenme Ağları

### 2.10.1 Danışmalı öğrenme

Y.S.A.’da gerçek bir çıkış, istenen çıkışla kıyaslanır. Rasgele değişen ağırlıklar ağ tarafından öyle ayarlanır ki, bir sonraki döngüde gerçek çıkış ile istenen çıkış arasında daha yakın karşılaştırma üretebilsin. Öğrenme yöntemi, bütün işleme elemanlarının anlık hatalarını en aza indirmeye çalışır. Bu hata azaltma işlemi, kabul edilebilir doğruluğa ulaşıncaya kadar ağırlıklar devamlı olarak derlenir.

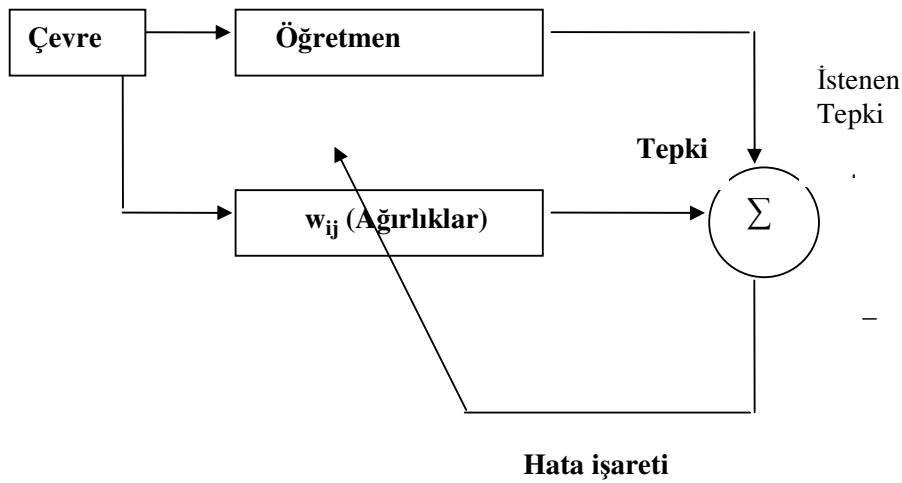
Danışmalı öğrenmede, Yapay Sinir Ağı kullanılmadan önce eğitilmelidir. Eğitime işlemi, sinir ağına giriş ve çıkış bilgileri sunmaktan oluşur. Bu bilgiler genellikle eğitime kümesi olarak tanımlanır. Yani, her bir giriş kümesi için uygun çıkış kümesi ağa sağlanmalıdır.

Birçok uygulamada, ağa gerçek uygulanmak zorundadır. Bu eğitime safhası uzun zaman alabilir. Sinir ağı, belirli bir sıralamadaki girişler için istenen istatistiksel doğruluğu elde ettiği zaman eğitime işlemi tamamlanmış kabul edilir ve eğitime işlemi bitirilir. Öğrenim aşaması tamamlandıktan sonra ağ kullanılmaya başlandığında, bulunan ağırlıkların değeri sabit olarak alınır ve bir daha değiştirilmez. Bazı ağ yapılarında ağ çalışırken çok düşük oranda eğitmeye izin verilir. Bu işlem ağların değişen koşullara uyum sağlamasına yardımcı olur.

Eğer sistemin önemli olan özellikleri ve ilişkileri öğrenmesi gerekiyorsa, o zaman eğitime kümesi, bütün ihtiyaç duyulan bilgileri içermesi gerekir. Eğer ağ sadece bir örnekle eğitilirse, bir olay için çok hassas olan bütün ağırlıklar kümesi, bir sonraki olayda yeterli çözüm vermez. Yeni şeyler öğrenme safhasında eski olaylar unutulabilir. Sonuç olarak, sistem gerekli bilgilerle birlikte öğrenmek zorundadır.

Giriş ve çıkış bilgilerinin nasıl sunulacağı veya nasıl kodlanacağı, bir ağı başarılı bir şekilde yönlendirmek için önemli bir unsurdur. Y.S.A. sadece sayısal giriş bilgileriyle çalışırlar. Bu nedenle ham bilgiler genellikle ölçeklendirilmelidirler.

Danışmalı öğrenmede giriş ve çıkış çiftlerinden oluşan eğitim bilgileri vardır. Ağ giriş bilgisine göre ürettiği çıkış değerini, istenen değerle karşılaştırarak ağırlıkların değiştirilmesinde kullanılacak bilgiyi elde eder. Girilen değerle istenen değer arasındaki fark hata değeri olarak önceden belirlenen değerden küçük oluncaya kadar eğitime devam edilir. Hata değeri istenen değer altına düştüğünde tüm ağırlıklar sabitlenerek eğitim işlemi sonlandırılır. Eğitim işlemi sırasında her bir eğitim bilgisi çifti için oluşan hata değerine göre ağırlıkların değiştirilmesine 'örüntü kipi' öğrenme, tüm eğitim kümesi için hataların toplanarak toplam hata değerine göre ağırlıkların değiştirilmesine ise 'küme kipi' öğrenme denilmektedir. Danışmalı öğrenme Şekil 2.14'de gösterilmiştir.




Şekil 2.14: Danışmalı öğrenme

Eğer verilen girişe karşılık amaçlanan çıkış üretileniyorsa , ağıın çıkış değerindeki hatayı en küçükleyecek şekilde bağlantı ağırlıklarının değiştirilmesi sağlanır.

### 2.10.2 Danışmansız öğrenme

Danışmansız öğrenmede sistemin doğru çıkış hakkında bilgisi yoktur ve girişlere göre kendi kendisini örnekler. Danışmansız olarak eğitilebilen istenen ya da hedef çıkış olmadan giriş bilgilerinin özelliklerine göre ağırlık değerlerini ayarlar. Danışmansız öğrenmeye, Hebbian öğrenme, Grossberg öğrenme, Kohonen'in öz örgütlemeli harita ağı örnek olarak verilebilir. Kohonen tarafından geliştirilen danışmansız öğrenme yönteminin kullanıldığı öz örgütlemeli harita ağı da biyolojik sistemlerdeki öğrenmeden esinlenmiştir. Bu yöntemde sinirler öğrenmek için elverişli durum ya da ölçülerini güncellemek için yarışır. En büyük çıkış ile işlenen sinir, kazananı belirler ve komşularına bağlantı boyutlarını güncellemeleri için izin verir. Şekil 2.15'de danışmansız öğrenme ana hatlarıyla gösterilmiştir.



Şekil 2.15: Danışmansız öğrenme

Danışmansız öğrenmede ağı istenen dış verilerle değil, girilen bilgilerle çalışır. Bu tür öğrenmede gizli sinirler dışarıdan yardım almaksızın kendilerini örgütlemek için bir yol bulmalıdırlar. Bu yaklaşımda, verilen giriş vektörleri için önceden bilinebilen performansını ölçebilecek ağı için hiç bir çıkış örneği sağlanamaz. Yani ağı yaparak öğrenmektedir.



Danışmansız öğrenme gelecek için büyük ümitler vaat etmektedir. Danışmansız öğrenme ile gelecekte bilgisayarların kendi kendilerine gerçek robotik hareketleri öğrenebilecekleri öne sürülmektedir.

### **2.10.3 Hebb kuralı**

İlk ve en iyi bilinen öğrenme kuralı Donald Hebb tarafından tanıtılmıştır. Tanımlama 1949 yılında yazdığı “The Organization of Behavior” adlı kitabında görünür. Temel kural: Eğer bir sinir başka bir sinirden bir giriş alırsa ve her ikisi de yüksek aktif ise (matematiksel olarak aynı işaretli), sinirler arasındaki boyut kuvvetlendirilir.

### **2.10.4 Hopfield kuralı**

Bu kural, kuvvetlendirme veya zayıflatmanın genliğini belirleyebilmesi istisnası haricinde Hebb kuralıyla benzerdir. Buna göre, “Eğer istenilen çıkış ve girişin her ikisi de aktif veya her ikisi de durgun ise, bağlantı boyutlarını öğrenme oranı kadar arttır, aksi halde boyutu öğrenme oranı kadar azalt”. (Öğrenme fonksiyonlarının çoğunun öğrenme oranı veya öğrenme sabiti için bazı koşulları vardır).

Ayrıca Boltzman Makinesi ve Hamming Ağı öğrenme kuralları Hopfield Kuralının değişik açılardan geliştirilmiş halleridir. Boltzman Makinesi Hopfield ağına ilave olarak özgün modelleme tekniğinde benzer işlev ve işlemleri kullanırlar. Boltzman Makinesi model seviyelerini araştırıp durum uzayında kavramları benzeterek birleştirmiştir. Hamming Ağı ise giriş vektörleri için en az ikili sayı hatasının temel sınıflandırılması yerine getirmektedir. Burada Hamming tarafından hata aralığı tanımlanmaktadır.

### **2.10.5 Delta kuralı**

En çok kullanılan kurallardan biri olan Delta kuralı, Hebb kuralının daha geliştirilmiştir. Bu kural bir sinirin gerçek çıkışı ile istenilen çıkış değeri arasındaki farkı azaltmak için giriş bağlantı hücrelerini sürekli olarak geliştirme fikrine dayanır. Bu kural ağ hatasının karesini minimize etmek için bağlantı boyutlarını değiştirir. Hata bir önceki katmana geri çoğalır. Her bir zaman dilimi için bir hata şeklinde bu

geri çoğaltma işlemi ilk katmana ulaşınca kadar devam eder. Bu tip ağ İleri Beslemeli Ağ olarak isimlendirilir. Geri Yayılım adı, bu hata terimlerini toplama yönteminden türetilir.

Bu kural ayrıca Windrow-Hoff Öğrenme ve En Küçük Ortalamalar Karesi (Least Mean Square ) Kuralı olarak da bilinir.

Bu öğrenme kuralı zaman içinde geliştirilerek yeni öğrenme kuralları oluşturulmuştur. Bunlardan bazıları şöyle sıralanabilir: Delta Bar Delta, Genişletilmiş Delta Bar Delta, İşlevsel-Bağ Ağı (Daha Yüksek Düzeyli Sinir Ağı). Bu kuralların değişik durumlarda birbirlerine göre üstün ve zayıf yönleri vardır. Bu kurallar aynı temel mantığa sahip olmalarının rağmen öğrenme oranları, moment terimi, hata farkı değişkeninin ağ üzerindeki etkisi vb. noktalar üzerinde bir takım gelişmeler ve değişiklikler içermektedirler.

#### **2.10.6 Eğimli iniş kuralı**

Bu kural Delta kuralına benzer çünkü transfer fonksiyonunun türevi bağlantı ağırlıklarına uygulamadan önce, Delta hatasını düzeltmek için kullanılır. Bu kural durağan bir noktaya çok bir şekilde yaklaşmasına rağmen sıkça kullanılır. Bir ağı farkı katmanların için öğrenme oranları, öğrenme işleminin daha hızlı olmasına yardımcıdır. Giriş verilerinin güçlü bir modelden çıkarılmadığı uygulamalarda, bu işlem özellikle önemlidir.

#### **2.10.7 Kohonen öğrenme kuralı**

Kohonen tarafından geliştirilen bu yöntem biyolojik sistemlerdeki öğrenmeden esinlenmiştir. Bu yöntemde sinirler öğrenmek için elverişli durum veya ölçütlerini güncellemek için yarışrlar. En büyük çıkış ile işlenen sinir, kazanımı ilan eder ve komşularına bağlantı boyutlarını güncellemeleri için izin verir.

## 2.11 Yapay Sinir Ağlarında Bilginin Depolanması ve Geri Alınması

Y.S.A.'ya herhangi bir örnek giriş verisinin tanınabilmesi ve bunun daha sonra kullanılabilmesi için verinin ağda nasıl temsil edildiğini, nerede saklandığını ve nasıl geri alındığının bilinmesi gerekmektedir.

Klasik bilgisayarlarda bilgi 0 ve 1 serileri ile temsil edilirken, sinir ağlarında matematiksel işlev ile temsil edilir. İşlem elemanları arasındaki bağlantının ağırlıkları bu işlevin değişkenleri olarak görev yaparlar. Burada ağırlıklar saklanan bilginin ne olduğuna karar verir, fakat kendilerinin bir anlamı yoktur.

Sinir ağlarındaki bilgi, ağ içindeki bağlantılarda ve birçok ağırlıklar yoluyla dağıtılmaktadır. Klasik bilgisayar, bilgiyi belleğinde belirli bir yerde saklar. Sinir ağları ise bilgiyi tüm ağ boyunca dağıtır. Bu durum dağıtılmış bellek olarak bilinir.

Klasik bilgisayarda bilgi, belirli bellek bölgesine ulaşılarak alınır. Sinir ağlarında ise, bilgi muhtemelen güdültülü ya da tamamlanmamış giriş örneği olarak ağa sunulur. Ağ, giriş örneği hakkında eldeki bilgi olarak temsil edilir. Bu durum ise birleştirilmiş bellek olarak bilinir.

## 2.12 Yapay Sinir Ağlarının Oluşturulması

Y.S.A. düğüm ve sinir olarak adlandırılan çok sayıda işlem elemanının bir araya gelmesinden oluşur. Psikolog Frank Rosentblant'ın öğrenme yeteneğine sahip olan bir örnek tanıma aygıtını ortaya çıkarmış olduğu 1958 yılından bu yana, hiyerarşik sinir ağı en çok üzerinde çalışılmış olan bir ağ yapısı olmuştur. Bu tür ağların özelliği sahip oldukları basit dinamiklerdir. Eğer giriş katmanına bir işaret girerse, bu işaret sinirler arasındaki bağlantılar yoluyla diğer katmanlara iletilir. Giriş katmanı düğümleri tarafından öteki katmana iletilmeden önce bu işaret üzerinde basit bir işlem yerine getirilir. Bu süreç çıkış katmanına erişinceye kadar tekrar edilir.

Y.S.A. düğümleri ve bağlantıları çok değişik biçimlerde bir araya getirilebilir. Ağlar bu düğüm ve bağlantı mimarilerine göre değişik isimler alır.

Yapay Sinir Ağı mimarileri, sınırlar arasındaki bağlantıların yönlerine göre veya ağ içindeki işaretlerin akış yönlerine göre birbirlerinden ayrılmaktadır. Buna göre Y.S.A. için, ileri beslemeli (feedforward) ve geri beslemeli (feedback veya recurrent) ağlar olmak üzere iki temel ağ mimarisi vardır.

Ağ içerisinde düğümler katmanlar halinde yerleştirilir. İlk katmandaki girişe verilen bilgi ağ içinde ileriye doğru yayılır. Her katmandaki düğümlere sadece önceki katmandaki düğümlerden girişlere izin verilir. Bir düğüm kendisinden sonraki herhangi bir düğüme bağlanabilirken kendisine asla bağlanamaz. Son katmandaki işaretler ağın çıkışıdır. Geri beslemeli veya tekrarlanan ağlarda en azından bir düğümün geriye yayıldığı bir dönüş bağlantısı vardır. Tekrarlanan ağlar da tamamen parçalı olarak geri besleme yollarına sahiptirler. Bu tür ağların tasarımları ve davranışları oldukça karmaşıktır.

Sinir ağlarında istenen sonucun elde edilmesi için ağın uyarlanabilir olması gerekir. Bunu sağlamak için uygun değerli ağırlıklar doğru bağlantılar seçilmelidir. Ağ bu şartları karşılayabilmek için sistemin davranışlarını öğrenmeli ya da kendi kendini örgütlemelidir. Öğrenme kalıcı yenilemeler için gözleme veya eğitim faaliyetlerinden çıkan sonuçlar olarak tanımlanabilir. Öğrenme Yapay Sinir Ağın ayrılmaz bir parçasıdır. Öğrenme; giriş değerlerine veya bu girişlerin çıkışlarına bağlı olarak ağın bağlantı ağırlıklarını değiştiren veya ayarlayan öğrenme kuralı ile gerçekleştirilir.

### **2.13 Ağ Oluşturmanın Genel Kuralları**

Bir yapay sinir ağının düğüm ve katman sayısının nasıl belirleneceği hakkında kesin bir kural veya yöntem olmamakla birlikte tez çalışmasında geri yayılım ağından faydalanılarak uygulama yapılacağı için bu ağ yapısının kurulması ile ilgili deneyimlerle kazanılmış birkaç kural aktarılacaktır.

Tipik bir geri yayılım ağının, bir girdi katmanı, bir çıktı katmanı ve en az bir gizli katmanı vardır. Gizli katmanların sayısı için teorik olarak bir sınırlama yoktur. Yapılan bazı çalışmalar, herhangi bir derecede karmaşıklığa sahip problemleri

çözmek için en az dört katmanın (üç gizli katman ve bir çıktı katmanı) bulunması gerektiğini göstermiştir.

Geri yayılım ağlarında katman sayısı ve her katmandaki düğüm sayısı dikkatle seçilmelidir. Bu sayıların ne olacağı hakkında kesin bir yöntem yoktur. Takip edilmesi faydalı olabilecek kurallar şöyle sıralanabilir.

Girdi verisi ve istenilen çıktı arasındaki ilişkinin karmaşıklığı artınca, gizli katmanlardaki işleme elemanlarının sayısı da artmalıdır.

Eğer ele alınan süreç bir çok aşamalara ayrılabilirse, fazla sayıda gizli katman kullanılmalıdır. Eğer süreç aşamalara ayrılmıyorsa, çok fazla sayıda gizli katman kullanılırsa ağda yalnızca ezberleme ortaya çıkar ve yanlış genel sonuçlara yol açar. Ağda kullanılan eğitim verisinin miktarı, gizli katmandaki işleme elemanlarının sayısı için bir üst sınır oluşturmaktadır. Bu üst sınırı bulmak için önceden eğitim kümesindeki girdi ve çıktı çiftlerinin sayısı bulunur. Bulunan bu sayı ağdaki toplam giriş ve çıkış düğümlerinin sayısına bölünür. Çıkan sonuç, beş ile on arasında bir dereceleme faktörüne bölünür. Daha büyük dereceleme faktörleri göreceli olarak işitsel veriler için kullanılmaktadır. İşitsel veriler 20-50 arasında bir faktör gerektirirken, çıktı ile belirgin bir ilişkisi olan çok temiz girdi verisi faktörü 2 civarına kadar düşürülebilir. Gizli katmanların az miktarda işleme elemanına sahip olması önemli bir faktördür.

## **2.14 Uygulamada Kullanılan Matematiksel Hesaplamalar**

Öğretmenli öğrenme stratejisine göre çalışan Çok Katmanlı Ağın Öğrenme Kuralı uygulanmıştır. Yani bu ağlara eğitim sırasında hem girdiler hem de o girdilere karşılık çıktılar gösterilmiştir. Ağın görevi her girdi için o girdiye karşılık çıktıyı üretmektir. Çok Katmanlı Ağın Öğrenme Kuralı en küçük kareler yöntemine dayalı Delta Öğrenme Kuralının genelleştirilmiş halidir. Ağın öğrenbilmesi için eğitim setine ve örneklerden oluşan sete ihtiyaç vardır. Bu set içinde hem girdiler hem de o girdiler için ağın üretmesi gereken çıktılar belirlenmiştir. Genelleştirilmiş Delta kuralı iki safhadan oluşur.

- 1 İleri doğru hesaplama: Ağın çıktısını hesaplama safhasıdır.
- 2 Geriye doğru hesaplama: Ağırlıkları değiştirme safhasıdır.

### 2.14.1 İleri doğru hesaplama

Girdi safhasında herhangi bir bilgi işleme söz konusu değildir. Girdiler ara katmana direk gönderilirler. Yani girdi katmanındaki k. proses elemanının çıktısı  $C_k^i$  şu şekilde belirlenir.

$$C_k^i = G_k \quad (2.7)$$

Ara katmandaki her proses elemanı girdi katmanındaki bütün proses elemanlarından gelen bilgileri bağlantı ağırlıklarının ( $A_{1j}, A_{2j}, \dots$ ) etkisi ile alır. Ara katmandan proses elemanına gelen net girdi ( $NET_j^a$ ) şu formülü kullanarak hesaplanır.

$$NET_j^a = \sum_{k=1}^n A_{kj} C_k^i \quad (2.8)$$

$A_{kj}$  k. girdi katmanı elemanını j. ara katman elemanına bağlayan bağlantının ağırlık değerini göstermektedir. j. ara katman elemanın çıktısı ise bu net girdinin aktivasyon fonksiyonundan geçirilmesi ile hesaplanır. (Aktivasyon fonksiyonu olarak türevi alınabilen Sigmoid fonksiyonu kullanılmıştır.) Türevi alınabilen herhangi bir aktivasyon fonksiyonu da kullanılabilir.

Geriye doğru hesaplamada burada kullanılan fonksiyonun türevi alınması gerekmektedir. Sigmoid fonksiyonu kullanılması halinde çıktı,

$$C_a^j = \frac{1}{1 + e^{-(NET_j^a + \beta_j^a)}} \quad \text{şeklinde olacaktır.} \quad (2.9)$$

Burada  $\beta_j$ , ara katmanda bulunan j. elemana bağlanan eşik değer elemanın ağırlığını göstermektedir. Bu eşik değeri ünitesinin çıktısı sabit olup 1'e eşittir. Ağırlık değeri ise sigmoid fonksiyonun oryantasyonu belirlemek üzere konulmuştur. Eğitim esnasında ağ bu değeri kendisi belirlemektedir. Ara katmanın tüm proses elemanları

ve çıktı katmanının proses elemanlarının çıktıları aynı şekilde kendilerine gelen NET girdinin hesaplanması ve sigmoid fonksiyonundan geçirilmesi sonucu belirlenir.

### 2.14.2 Geriye doğru hesaplama

Ağa sunulan girdi için ağın ürettiği çıktı ağın beklenen çıktıları (B1,B2,...) ile karşılaştırılır. Bunların arasında fark hata olarak kabul edilir. Amaç bu hatanın düşürülmesidir. O nedenle geriye hesaplamada bu hata ağın ağırlık değerlerine dağıtılarak bir sonraki iterasyonda hatanın azaltılması sağlanır. Çıktı katmanında m. proses elemanı için oluşan hata ( $E_m$ ).

$$E_m = B_m - \zeta_m \quad (2.10)$$

olacaktır. Bu bir proses elemanı için oluşan hatadır. Çıktı katmanında oluşan toplam hatayı bulmak için bütün hataların toplanması gerekir. Bazı hata değerlerinin negatif olması durumunda toplam hatanın toplamının 0 olmaması için ağırlıkların kareleri alınarak sonucun karakökü alınır. ÇKA ağının eğitilmesinde amaç bu hatayı en azlamaktır. TH şu şekilde bulunur:

$$TH = \frac{1}{2} \sum_m E_m^2 \quad (2.11)$$

Toplam hatayı en azlamak için bu hatanın kendisine neden olan proses elemanlarına dağıtılması gerekmektedir. Bu ise proses elemanlarının ağırlıklarını değiştirmek demektir. Ağın ağırlıklarının değiştirilmesi için iki durum söz konusudur.

- Ara katman ile çıktı katmanı arasındaki ağırlıkların değiştirilmesi
- Ara katman ile ara katman veya ara katman ve girdi katmanı arasındaki ağırlıkların değiştirilmesi

#### 2.14.2.1 Ara katman ile çıktı katmanı arasındaki ağırlıkların değiştirilmesi

Ara katmandaki j. proses elemanını çıktı katmanındaki m. proses elemanına bağlayan bağlantının ağırlığındaki değişim miktarına  $\Delta A^a$  denirse; herhangi bir t zamanda (t. iterasyonda) ağırlığın değişim miktarı şöyle hesaplanır.

$$\Delta A_{jm}^a(t) = \lambda \delta_m C_j^a + \alpha \Delta A_{jm}^a(t-1) \quad (2.12)$$

Burada  $\lambda$  öğrenme katsayısını,  $\alpha$  momentum katsayısını göstermektedir. Öğrenme katsayısı ağırlıkların değişim miktarını, Momentum katsayısı ise ÇKA ağının öğrenme esnasında yerel bir noktaya takılıp kalmaması için ağırlık değişim değerinin belirli bir oranda bir sonraki değişime eklenmesini sağlarlar.

$$\delta_m = f'(NET).E_m \quad (2.13)$$

$\delta_m$  : m. çıktı ünitesinin hatasını göstermektedir.

$f'(NET)$ : Aktivasyon fonksiyonun türevidir. Sigmoid fonksiyonun kullanılması durumunda;

$$\delta_m = C_m(1 - C_m).E_m \quad (2.14)$$

olacaktır. Değişim miktarı hesaplandıktan sonra ağırlıkların t. iterasyondaki yeni değerleri şöyle olacaktır.

$$A_{jm}^a(t) = A_{jm}^a(t-1) + \Delta A_{jm}^a(t) \quad (2.15)$$

Benzer şekilde eşik değer ünitesinin de ağırlıklarını değiştirmek gerekmektedir. Onun için öncelikle değişim miktarını hesaplamak gerekir. Eğer çıktı katmanında bulunan proses elemanlarının eşik değer ağırlıkları  $\beta^c$  ile gösterilirse; bu ünitenin çıktısının sabit ve 1 olması nedeni ile değişim miktarı,

$$\Delta \beta_m^c(t) = \lambda \delta_m + \alpha \Delta \beta_m^c(t-1) \quad (2.16)$$

olacaktır. Eşik değeri t. iterasyondaki ağırlığının yeni değeri ise,

$$\beta_m^c(t) = \beta_m^c(t-1) + \Delta \beta_m^c(t) \quad (2.17)$$

şeklinde hesaplanacaktır.



### 2.14.2.2 Ara katmanlar arası veya ara katman ile girdi katmanı arasındaki ağırlıkların değiştirilmesi

Ara katman ile çıktı katmanı arasındaki ağırlıkların değişiminde her ağırlık için sadece çıktı katmanındaki proses elemanının hatası dikkate alınmıştır. Bu hataların oluşmasında girdi katmanı ve ara katman arasındaki ağırlıkların, varsa iki katman arasındaki ağırlıkların payı vardır. Çünkü en son katmana gelen tüm bilgiler girdi katmanı veya önceki katmandan gelmektedir. O nedenle girdi katmanı ile ara katman arasındaki (veya iki katmanın arasındaki) ağırlıkların değiştirilmesinde çıktı katmanındaki proses elemanlarının hepsinin hatasından payını alması gerekir. Bu ağırlıklardaki değişimi (mesela girdi katmanı ile ara katman arasındaki ağırlıkların değişimi)  $\Delta A^i$  ile gösterilirse değişim miktarı;

$$\Delta A_{kj}^i(t) = \lambda \delta_j^a \zeta_k^i + \alpha \Delta A_{kj}^i(t-1) \quad (2.18)$$

olacaktır. Burada hata değeri  $\delta^a$  ise şöyle hesaplanmaktadır:

$$\delta_j^a = f'(NET) \sum_m \delta_m A_{jm}^a \quad (2.19)$$

Aktivasyon fonksiyonu olarak Sigmoid fonksiyonu düşünülürse bu hata değeri şu şekilde hesaplanacaktır:

$$\delta_j^a = \zeta_j^a (1 - \zeta_j^a) \sum_m \delta_m A_{jm}^a \quad (2.20)$$

Hata değeri hesaplandıktan sonra yukarıda verilen eşitlik ile değişim miktarını bulmak mümkün olur. Ağırlıkların yeni değerleri ise,

$$A_{kj}^i(t-1) + \Delta A_{kj}^i(t) \quad (2.21)$$

şeklinde olacaktır. Benzer şekilde, eşik değer ünitesinin yeni ağırlıkları da yukarıdaki gibi hesaplanır. Ara katman eşik değer ağırlıkları  $\beta^a$  ile gösterilirse değişim miktarı,

$$\Delta \beta_j^a(t) = \lambda \delta_j^a + \alpha \Delta \beta_j^a(t-1) \quad (2.22)$$

olacaktır. Ağırlıkların yeni değerleri ise t. iterasyonda şöyle hesaplanacaktır.

$$\beta_j^a(t) = \beta_j^a(t-1) + \Delta \beta_j^a(t) \quad (2.23)$$

### **BÖLÜM 3. DENEY TASARIMI YAKLAŞIMI**

Ürünler, müşterilerin beklenti ve gereksinimlerine göre performanslarını tanımlayan bazı özelliklere sahiptirler. Bir aracın kullandığı yakıt miktarı ya da balık tutmakta kullanılan ipin sağlamlığı gibi özellikler ürünlerin kalitesini belirlemektedir. [19] En genel şekliyle kalite, ilgilenilen karakteristiklerin hedef civarındaki değişmezliği veya kullanım amacına uygunluk olarak tanımlanabilir. [20]

Müşteri beklenti ve ihtiyaçlarının karşılanma ölçütü olan kalite, yüzyılımızda hızla artan rekabet nedeniyle işletmeler için kaçınılmaz bir zorunluluk haline dönüşmüştür. Toplam Kalite Yönetimi (T.K.Y.), kalite geliştirme ve sürekli iyileştirme süreçleri birçok işletme ve organizasyonun temel kalite stratejilerini oluşturur. Birçok şirket ürünlerini ve proseslerini geliştirmek amacıyla T.K.Y. sistemini benimsemiş ve uygulamaya başlamıştır. T.K.Y. kuralları ve araçlarıyla bir bütün olarak, şirket çapında uygulanan bir yönetim sistemidir.

T.K.Y., tüketici isteklerini en ekonomik düzeyde karşılamak amacı ile, işletme organizasyonu içindeki çeşitli ünitelerin kalitenin yaratılması, yaşatılması ve geliştirilmesi yolundaki çabalarını birleştirip koordine eden etkili sistem şeklinde tanımlanabilir.[21]


T.K.Y.'nin doğru uygulanabilmesi için aşağıdaki beş temel ögenin bir araya getirilmesi gerekir:

1. Üst yönetimin liderliği,
2. Müşteri odaklılık,
3. Firma elemanlarının eğitimi,
4. Takım çalışması,
5. Sürekli geliştirme (Kayzen) yaklaşımı.

Bu ögelerden ilk dördü beşincisi için gereklidir. Toplam kalitenin en önemli unsuru olan sürekli gelişimin gerçekleştirilmesi için Deming çemberi olarak tanınan “Planla, Yap, Doğrula, Karar Ver” süreci genel çerçeve olarak alınmaktadır. Bu çemberdeki değişik aşamalarda çoğu istatistiksel olmak üzere Pareto grafiği, çetele tablosu, histogram ve kontrol çizelgesi gibi birçok teknik ve yöntem kullanılabilir. Deming çemberinde temel amaç mevcut şartlar yerine farklılarını deneyerek üründe gelişme sağlamaya çalışmaktır. Ancak ürün tasarımı ve üretim aşamalarında karşılaşılan pek çok durumda ürün kalitesini etkileyen çok sayıda faktörün varlığı dikkati çeker. Bu durumda istatistiksel olarak tasarlanmış deneyler gereklidir. [22]

### 3.1 Deney Tasarımı

Deney tasarımı, incelenen ürün ya da sürece etki eden faktörleri ve elde edilen sonuçları sistematik bir yaklaşım içerisinde inceleyerek, faktörler ve sonuçlar arasındaki ilişkiyi ortaya koyarak daha iyi sonuçlar elde etmek üzere yapılan çalışmalar olarak tanımlanabilir.



Şekil 3.1: Deney tasarımı bakış açısı

Deney Tasarımı Tekniği (D.T.) işletmelerde ürünün oluşumunda önemli bir yer almakta ve deneysel çalışmalarda yoğun olarak kullanılmaktadır. D.T. değişimleri, değişimlerin nedenlerini araştırarak azaltmayı, müşteri memnuniyetini ve sistemin güvenilirliğini arttırmayı hedefler.

Değişim, üründe ve/veya proseste olması gereken özelliklerin veya davranışların bazen belirlenebilen, bazen de belirsiz faktörlerin etkisinde değişmesi anlamında olup, genelde istenmeyen bir olaydır.

### 3.2 Deney Tasarımı Aşamaları

Deney tasarımı konusu, temelde tüm tasarım uygulamalarındaki yaklaşımla eş değer olarak, problemin çözümüne yönelik aşamaları içerir. Bu aşamalar şunlardır:

**Problemin durumu ve tanımlanması:** Deney tasarımına başlamadan önce, amaç ve ilkelerin açıkça tanımlanmış olması gereklidir. Problem sistemde ve/veya üründe ürünü kullanan müşteri veya üretici tarafından belirlenen bir hata veya eksiklik olabileceği gibi rekabet gücünü artırmak için ürün veya üretim sisteminde yapılan bir Ar-Ge faaliyeti de olabilir.

**Faktörlerin belirlenmesi ve seviyelendirilmesi:** Ürün geliştirme çalışmaları esnasında belirlenen özellikler üzerine en etkili faktörlerin seçilip indirgenmesinden sonraki aşama bu faktör seviyelerinin belirlenmesidir.

**Seviye;** deneylerdeki faktörlere verilen özel değerler olarak tanımlanır. Seviyelerin belirlenmesinde bilimsel verilerden çıkarılacak ipuçlarından faydalanılacağı gibi deneyimlerden de faydalanılabilir.

Seçilecek deneylerin tasarım yöntemine bağlı olarak faktörlerin yanı sıra faktörler arası etkileşimlerin de ortaya konması gereklidir. Faktörler arası etkileşimlerin deneylerin tasarımında kullanılması oldukça önemlidir. Etkileşim, faktörler arası ilişkiler olarak bilinir.

Deneyde etkili faktörler X ve Y olarak belirlenmiş olsun. Bu faktörler deney sonucu üzerinde her biri tek etkiye sahipken her ikisi birlikte deneyin sonucuna etki edebilir. Bu nedenle bu etkinin belirlenmesi gereklidir.

**Sonuç değişkenlerin seçimi:** Sonuç değişkeni; araştırmacının gözlemlediği deneyde deneyin çıktısı olan değişkendir. Sistem veya ürünün kalite karakteristiği olarak bilinir. Bu aşamada çalışma ile incelenecek değişken belirlenir.

Sonuç deęişkenlerin belirlenmesi aşamasında aynı zamanda bu deęişkenlerin doęru görünlenebileceęi ölçüm yöntemlerinin de belirlenmesi gereklidir.

Deneilerin tasarım yöntemlerinin seçimi: Deneilerin tasarım yöntemleri istatistiki ve matematiksel yaklaşımların yoğun olarak kullanıldığı yaklaşımları içerir. Bu yaklaşımların ortak amaçları faktörlerin optimizasyonu, dolayısıyla ürün ve üretim proseslerinin optimizasyonunu sağlayarak deęişimleri azaltmaktır.

Deneilerin yürütülmesi: Deneilerin yürütülmesinde seçilen deney tasarımı yönteminde, belirlenen plan yani deney matrisi üzerinden hareket edilir. Bu matriste önceki aşamalarda seçilen faktörlerin belirlenen deęişik seviyelerinin hangi sırada ve hangi kombinasyonda ele alınması gerektięi gösterilmiştir. Deneyler bu planlarda belirlenen şartlar üzerinden gerçekleştirilir ve sonuçlar kaydedilir.

Sonuçlar ve tavsiyeler: Her faktör ve faktörler arası etkileşimlerin etkilerinin elde edildięi grafikler ve deneylerin analizi sonucunda elde edilmiş veriler yardımı ile hangi faktörlerin hangi seviyede ele alınması gerektięine karar verilir. Sonuçta çıkan faktör seviye kombinasyonunun doęruluęunu kontrol etmek için doęrulama deneylerinin yapılması gereklidir. [23]

### **3.3 Klasik Deney Tasarımı Yöntemleri**

Klasik deney tasarımlarında ele alınan parametreler kontrol edilebilen faktörlerdir. Klasik deney tasarım yöntemleri uygulamada, kendi aralarında üçe ayrılır.

- 1 Bir kerede bir faktör (One factor at a time)
- 2 Tam faktöriyel (Full factorial)
- 3 Kısmi faktöriyel (Fractional factorial)

Klasik deney tasarım yöntemleri arasındaki bu ayrımın sebebi, faktörler arası etkileşimlerin deney matrisinde ele alınıp alınmaması esasına dayanır.

### **3.3.1 Bir kerede bir faktör**

Deneylerin tasarım yöntemleri arasında en eski ve en çok uygulananıdır. Bir kerede bir faktör değiştirilerek yapılan tasarım, oldukça basittir. Bu yaklaşım, bilimsel çalışmalarda, adım adım her faktörün proses üzerine etkisini belirlemek için kullanılır. Bu yöntemde, her işlemde yalnızca bir faktör değiştirilip diğerleri sabit tutulur.

Bir kerede bir faktör değiştirilerek yapılan deneylerin dezavantajlarından biri maliyetin yüksekliği diğeri de faktörler arası etkileşimlerin belirlenememesidir. Bu yöntemde her denemede bir faktörün değiştirilmesi neticesinde, bu faktörün sonuca doğrudan etkisi gözlenir.

### **3.3.2 Deneylerin tam faktöriyel tasarımı**

İki veya daha fazla seviyeli ve iki veya daha çok sayıda faktörün tüm kombinasyonlarının ele alındığı deney tasarım yöntemine tam faktöriyel tasarım adı verilir.

Tam faktöriyel deneylerin tasarım yöntemlerinde, deneylerin tekrarı için faktörlerin tüm bileşimleri gösterilir, işlem sayısı faktörlerin tümünün seviyelerinin çarpımına eşittir. Örneğin bir televizyon üretiminde televizyon montaj süresi sonuç değişkeni olarak ele alınırsa; operatörün ustalığı (6 seviye), ışıklandırma (3 seviye) ve eğitim programı (4 seviye) olmak üzere etkili faktörlerdir. Bu durumda işlem sayısı  $6 \times 3 \times 4 = 72$  dir. Bu durumda faktörlerin sayısı ve seviyeleri arttığında işlem sayısı artar.

Tam faktöriyel deneylerin tasarım tekniğinin, bir kerede bir faktör değiştirilerek yapılan tekniğe göre en büyük üstünlüğü, faktörler arası etkileşimlerin hesaplanmasına olanak vermesidir. Bunun yanı sıra; deneylerin boyutunun üstel olarak faktör sayısı ve seviyeleri ile artması, tüm bu deneylerin maliyetinin yüksek olması ve etkileşimlerin yüksek düzeyli olanlarının açıklanmasındaki zorluklar, bu yöntemin en belirgin dezavantajlarıdır.

Bu yöntemde amaç, her faktörün mümkün olan tüm seviyelerinin denenmesidir. Eğer 3 tane faktör var ve bunlar 2 seviyeli ise yapılması gereken işlem sayısı  $2^3 = 8$ 'dir. Deneylerde belirlenmiş olan faktörlerin sayısı ve seviyelerinin artmasına bağlı olarak işlem sayısı da üstel olarak artar.

Genel olarak, p düzeyli k faktör ve q düzeyli m faktörden oluşan bir deneyde, tam faktöriyel tasarım için gerekli olan deney sayısı  $p^k q^m$  dir.

Deney matrisinde de görüldüğü üzere iki seviyeli yedi faktör için yapılması gerekli deney sayısı, tüm bileşimleri ele alan tam faktöriyel deney tasarımı için, 128'dir. Bu yöntemle değerlendirilebilen faktörler arası etkileşimlerin saptanması, hem zaman hem de maliyet açısından büyük yük getirmektedir. Tam faktöriyel deney tasarımı, araştırılacak faktör sayısı ve bunların düzeyleri (seviyeleri) az sayıda ise uygulanabilirliği vardır [24]. Tam faktöriyel tasarımın yedi faktörlü ve iki seviyeli bir durum için tüm kombinasyonlarını içeren deney matrisi Tablo 3.1'de verilmektedir.

Tablo 3.1: Yedi faktörlü tam faktöriyel deney tasarım matrisi

				A1				A2			
				B1		B2		B1		B2	
				C1	C2	C1	C2	C1	C2	C1	C2
D1	E1	F1	G1								
			G2								
		F2	G1								
			G2								
	E2	F1	G1								
			G2								
		F2	G1								
			G2								
D2	E1	F1	G1								
			G2								
		F2	G1								
			G2								
	E2	F1	G1								
			G2								
		F2	G1								
			G2								

Tam faktöriyel deney tasarım yönteminin uygulanması için gerekli adımları sırasıyla incelemek gerekirse:

1. Ön hazırlık safhası: İncelenecek faktörlerin seçilmesi ve seviyelerinin belirlenmesi. Belirlenen seviyelerde düşük olan negatif (-) işareti ile ve yüksek olan seviye pozitif (+) işareti ile gösterilir.
2. Tam faktöriyel deney matrisinin oluşumu: Faktör sayısına bağlı olarak tüm olası etkileşimler göz önüne alınarak gerçekleştirilir.
3. İşlem sırası: Deneyler tesadüfi sıra ile gerçekleştirilir.
4. Tüm işlemler bittikten sonra tekrar deneyleri yapılır.
5. Deney matrisinin oluşumu ve deneylerin yürütülmesi aşamaları sonucunda deneyin analizi aşamasına geçilir. Deneylerin analizinde amaç tek tek faktörlerin ve etkileşimlerinin sonuç değişken üzerine katkılarını belirlemek ve en uygun faktör kombinasyonu seçmektir.

Tablo 3.2’de iki seviyeli A ve B için deney matrisi gösterilmiş olup aynı zamanda AB etkileşimi de matrise dahil edilmiştir.

Tablo 3.2: İki seviyeli iki faktör deney tasarım matrisi

Deneme	A	B	AB
1	-	-	+
2	-	+	-
3	+	-	-
4	+	+	+

İki seviyeli iki faktör ele alınırsa (A ve B) matrisin birinci sütununa A ve ikinci Sütununa B faktörü yerleştirilir ve aralarında tek etkileşim AB olduğu için üçüncü sütunda yer alır. Daha sonra AB etkileşiminin işaretleri A ve B sütunlarındaki işaretler çarpılarak belirlenir.



### **3.3.3 Deneilerin kısmi faktöriyel tasarımı**

Bu yöntemin oluşturulmasındaki sebep, tam faktöriyel deney tasarımındaki yüksek maliyet ve zaman faktörleridir. Bunun yanı sıra klasik tasarım teknikleri, uzman personele ihtiyaç duymaktadır. Kısmi faktöriyel deneylerde amaç işlem sayısını azaltmaktır. Faktörlerin sayısında değil etkileşimlerde azaltma yapılmaktadır. Bu da incelenen faktörlerden ödün vermeden incelenen etkileşimlerin sayısını azaltarak sağlanabilir.

Kısmi faktöriyel deney tasarımı mantığında yer alan etkileşim azaltma kavramından etkileşimleri göz ardı etmek anlaşılmamalıdır. Zaten etkileşimlerin göz ardı edilmesi demek bir kerede bir faktör değiştirilerek yapılan deneylere geri dönmek anlamındadır. Kısmi faktöriyelde ilke, probleme katılması durumunda çok sayıda işlem gerektiren fakat gerçekte katkısının analizlerde çok az çıkacağı tespit edilen yüksek serbestlik derecesine sahip olan etkileşimleri deney matrisine yerleştirmemektir.

Kısmi (kesirli) faktöriyel deneyler ile faktörlerin ve bazı önemli etkileşimlerin etkisi belirlenmeye çalışılır. Taguchi tekniğinde de kesirli faktöriyel dizilerden ortogonal diziler kullanılmaktadır.

### **3.4 Taguchi Yöntemi**

Kalitenin iyileştirilmesi için kullanılan Gürbüz mühendisliğin (Robust Engineering) temelleri Genichi Taguchi tarafından uzun yıllar boyu süren araştırmalar sonucunda ortaya koyulmuştur. Gürbüz mühendislik 1950'lerden itibaren işletmelere küresel pazarda rekabet güçlerini koruyabilmeleri için maliyet bakımından etkin yöntemler ortaya koymaktadır. [25]

Kalitenin amacı "kullanıma uygun" ürünün elde edilmesidir. Kullanıma uygunluk kavramı; ürünün tasarımına ilişkin bir özellik olduğundan, üretim süresince kontrol altında tutulması gerekmektedir. Kalite ve fiyat üzerinde kontrol kurmak isteyen bir işletmenin; üretim boyunca tasarıma uygunluktan sapmaları en aza indirebilen

işletme olduğu söylenebilir. Dolayısıyla, bir ürüne kullanıma uygunluk niteliğini kazandırmak için bu işe tasarım aşamasından başlamak gerekmektedir. Kalite teknolojisi ve bilimindeki gelişme sürecinin önemli kilometre taşlarından biri olan Taguchi Yaklaşımı, kalite tanımına değişik bir bakış açısı getirmiştir. Kalite mühendisliği (ya da Gürbüz Mühendislik) olarak da anılan bu metod, tasarım kalitesi ve kalite-maliyet konularını analiz eder. Taguchi Yöntemi'nin açıklanmasında üzerinde durulması gereken yedi konu bulunmaktadır. Bu konular şunlardır:

1. İmal edilmiş bir ürünün kalitesi o ürünün kullanımı sırasında toplumda neden olduğu zararla orantılıdır. Taguchi'ye göre bir ürünün fabrikadan tüketiciye sevkinden sonra ortaya çıkan toplumsal kayıp, bu ürünün talebini etkileyen önemli bir faktördür. Bu kayıp ne kadar küçük olursa talep o kadar artacaktır. Burada sözü edilen toplumsal kayıp; ürünün kullanım amacına, dolayısıyla tüketici gereksinmelerine uygunsuzluğu, kendisinden beklenen performans düzeyine ulaşmaması ve kullanımı sırasında ortaya çıkan zararlı yan etkilerden kaynaklanmaktadır. İşte zayıf performansın neden olduğu bu kayıplar söz konusu ürünün kalite düzeyini belirlemektedir.

Kalitenin toplumsal yönü kapsamlı bir konudur. Buna göre kalite kontrolünün esas hedefi, toplumsal kaybı en aza indirmektir. Kalite kontrol fonksiyonunun görevi ise toplumsal net kazançlar sağlayacak yeni teknikleri bulmak ve uygulamaktır. Etkili bir kalite kontrol programının toplumsal kapsamda sağlayacağı kazanç, programın maliyetinden daha fazla olacaktır ve burada sözü edilen kazançtan tüm toplum yararlanacaktır. Toplumsal kayıp kavramı bize kalite geliştirme programına yapılacak yatırımlar için yeni bir buluş geliştirme fırsatı vermektedir. Kalite geliştirme projelerine yapılan yatırımlar, tüketicilerin kazançlarında meydana gelen artışlar bu yatırımların maliyetinden yüksek olduğu sürece yararlı olarak kabul edilir. Bunu bir örnek üzerinde inceleyelim: Bir fabrikanın üretmiş olduğu ürünler tüketicisinin elinde iken birim ürün başına 1000 TL'lık bir kayba neden olsun. Tüketicinin bu 1000 TL'lık kayıptan kurtulması için üretici firmanın birim ürün başına yapması gereken yatırım 200 TL olsun. Bu durumda toplam toplumsal kazanç 800 TL (1000 TL - 200 TL) dır. Birim ürün başına 200 TL'lik önleme yatırımının yapılmaması halinde bunun üreticiye maliyeti ise; tüketicinin güveninin azalması ve

pazar payının düşmesi ile ortaya çıkabilecek olan milyarlarca liralık kayıp olacaktır. Kalite geliştirme yatırımlarının değerlendirilmesinde uzun dönemdeki etkilerinin göz önünde bulundurulması gerekmektedir.

2. Rekabetçi bir ekonomide işletmelerin yaşamını sürdürebilmesi için kalite geliştirme ve maliyet azaltma çalışmalarının sürekli olması gerekmektedir. Çalışmaları sonucunda, gereken oranda kar elde edemeyen işletme varlığını sürdüremeyecektir. Tüketicilerin ürünlere ilişkin gerçek bilgiler elde etme ve ürünler arasında serbest seçim yapabilme olanağının bulunduğu piyasalarda, satış fiyatının oluşumunda rakip firmaların benzer ürünlerinin satış fiyatı ile piyasanın koşulları da etkili olmaktadır. Bu nedenle bir işletmenin karını belirleyen en önemli faktörler işletmenin pazar payı ile imalat sürecidir.

Bir işletmenin pazar payını artırabilmesinin en emin yolu pazara uygun fiyatlı, kaliteli ürünler sunabilmesidir. Bu nedenle işletmenin rekabetçi stratejileri, üretim maliyetlerini aşağı çekerken, ürün kalitesini de yükseltme ilkesine göre oluşturulmaktadır. Bu firmalar aynı zamanda ürünlerinin kalitesinin hiçbir zaman yeteri kadar iyi, üretim maliyetlerinin yeteri kadar düşük olmadığını düşünen firmalardır. Çünkü günümüzde pazar koşullarının dinamizmi içinde tüketicilerin beklentileri sürekli olarak değişmektedir. Serbest rekabet ortamında işletmelerin, kalite geliştirme ve maliyet minimizasyonu çalışmalarının bu nedenle sürekli olması gerekir.

3. Sürekli bir kalite geliştirme programı, ürün performans karakteristiklerinin hedef değerden sapmasının sürekli olarak azaltılması çalışmalarını içermelidir. Bir ürünün kalite karakteristikleri belirlenerek ölçülmediği sürece, kaliteyi iyileştirmek mümkün değildir. Sürekli bir kalite iyileştirme programı ise söz konusu kalite karakteristiklerinin, ideal değerlerine ilişkin bilgiye de bağlıdır. Kalite karakteristikleri değişkenlik gösterebilen büyüklüklerdir. Bu değişkenlik aynı üretim sürecinden aynı anda alınan benzer ürünler arasında olabileceği gibi bu süreçten farklı zamanda alınan ürünlerde zamana bağlı bir değişme şeklinde de ortaya çıkabilir.

Bir ürünün kalite iyileştirme sürecinde bütün kalite karakteristiklerine ilişkin ayrı ayrı iyileştirme çalışması yapılması pratik bir yaklaşım değildir. Yapılması gereken, ürünün birincil kalite karakteristiklerinin iyileştirilmesidir. Burada performans karakteristiğinden anlaşılması gereken, ürünün temel fonksiyonlarını yerine getirmesi için gerekli ve belirleyici olan özelliklerdir. Örneğin bir radyo alıcısı için sesin niteliği, bir TV alıcısı için görüntünün yoğunluğu performans karakteristiği için örnekler olarak verilebilir. Performans karakteristiğinin ideal değerine “hedef değer” adı verilmektedir. Performans karakteristiğinin bu hedef değerden sapmasına da “performans sapması” denilmektedir. Bu sapma küçüldükçe ürünün kalitesi artacaktır.

Ürün performans karakteristiği ölçümlerinin anlamlı ve kullanılabilir olması için bu ölçümlerin “sürekli ölçüle” yapılması gerekir. Ancak bu sayede kalitedeki küçük değişikliklerin tespit edilebilmesi olanaklıdır. Bir otomobilin sürekli ölçekte ölçülmesi gereken performans karakteristiklerine örnek olarak; egzoz gazındaki karbon monoksit oranı, belirli bir hız ve fren pedalına belirli bir basma basıncı için otomobilin frenleme mesafesi, hızın saatte 0 km’den 55 km’ye çıkması için geçen süre ve motorun çalışırken çıkardığı gürültü miktarını verebiliriz.

Bir ürünün sürekli performans karakteristiklerine ilişkin tüm hedef spesifikasyonlarının ve beraberinde toleranslarının ne olduğunun ifade edilmesi gerekir. Endüstriyel uygulamalarda tolerans değerleri ve sınırları için tanımlanan alan ile hedef değer tanımlanması uygulaması yaygındır. Bu uygulama bir yanlışlığa da neden olmaktadır. Bir ürünün kalitesi alt ve üst tolerans değerleri ile belirtilen spesifikasyon limitleri içerisinde aynıdır ve performans değeri bu limitlerin dışına çıktığında ürünün kalitesinde ani bir bozulma meydana gelmiş gözükmemektedir. Doğal olarak bu durumun doğruluğu kabul edilemez. Ancak hedef değer olarak ürünün performans karakteristiğinin en ideal hali yerine yukarıdaki gibi belirli spesifikasyon limitleri arasında kalan bir aralığın alınması, bu tür yanlışlıkların yapılmasına neden olmaktadır.

Buradan şu sonuca varılabilir: Aynı tasarıma göre üretilmiş olan iki üründe belirli bir performans karakteristiğine göre yapılan ölçüm değerlerinin spesifikasyon limitleri

arasında ve birbirinden farklı olması; bu iki ürünün her bilinin neden olduğu toplumsal kaybın farklı olması demektir. Yani salt spesifikasyon limitleri arasında kalmak kalitenin zayıf bir ölçüsüdür.

4. Bir ürünün performansındaki sapmanın neden olduğu tüketici kaybı, söz konusu performans karakteristiğinin, hedef değerden sapmasının karesi ile doğru orantılıdır. Kayıp fonksiyonu kavramını somut hale dönüştürmek için, formülasyonunu incelememiz uygun olacaktır.

k : Maliyet Katsayısı

Y : Ölçülen Kalite Karakteristiğinin Değeri

m : Hedef Değer.

L(Y) Ürünün kullanım ömrü içinde Y'nin m'den sapmasının neden olduğu kaybın parasal değeri (Kayıp Fonksiyonu) olarak alırsak, kayıp fonksiyonu;

$$L(Y) = (Y-m)^2 \quad (3.1)$$

şeklinde ikinci dereceden bir denklemlerle ifade edilebilir.

5. Bir ürünün kalitesi ve üretim maliyeti, ürünün ve bu ürünün üretildiği prosesin mühendislik tasarımları tarafından belirlenir. Ürün geliştirme sürecinin, hepsi birbirini izleyen üç aşaması vardır. Bunlar; ürün tasarımı, süreç tasarımı ve imalattır. Bu aşamalar, birinin çıktısı, diğerinin girdisi olan birçok basamaktan oluşmaktadır. Bu nedenle maliyet ve nihai kalitenin belirlenmesinde bu basamakların ayrı ayrı etkisi vardır. Modern teknoloji ürünlerinin artan kompleksliği ürün ve süreç tasarımının önemini daha da artırmıştır. Ürün kullanımı sırasında ki çevresel etkiler, insan faktörü, bozulmalar ve imalat kusurları da ürünün işlevsel performansı üzerine etkili olabilmektedir. Performansı olumsuz etkileyen bu faktörler, daha güçlü bir tasarım kaçınılmaz hale getirmişlerdir. Ürünün performansında çevresel koşullardaki değişimler nedeni ile meydana gelebilecek sapmalar karşısında gerekli önlemler, ancak ürün tasarımı sırasında, tasarımın özelliği olarak alınabilmektedir.

Bir ürünün imalat maliyeti ile imalat kusurları için imalat sürecinin tasarımı büyük ölçüde belirleyici olmaktadır. Bu nedenle süreç kontrolleri imalat kusurlarını azaltacaktır, ancak süreç kontrolü pahalı bir işlemdir. Önemli olan, imalat kusurları ile imalat süreci üzerinde kontrol gereksinmesini birlikte azaltabilmektir. Bu da ancak maliyetleri aşağı çekecek bir süreç tasarımı geliştirmekle mümkündür.

6. Bir ürün ya da sürecin performansında meydana gelecek sapma, bu ürün ya da sürece ilişkin parametrelerin performans karakteristiği üzerindeki dolaylı etkilerin ortadan kaldırılması ile azaltılabilir

Toplam Kalite sürecini tasarım ve üretim etkinlikleri bakımından iki kısma ayırabiliriz. Bunlar; Off-Line (Çevrim Dışı) Kalite Kontrol Metotları ve On-Line (Çevrim İçi) Kalite Kontrol Metotlarıdır. Çevrim dışı kalite kontrol, ürün tasarım sürecindeki teknik destek çalışmalarını, çevrim içi kalite kontrol ise imalat sürecindeki kalite ve maliyet kontrolüne ilişkin teknik çalışmaları içermektedir. Kalite kontrolünün etkili olabilmesi için ürün kalitesinin izlenmesi ve değerlendirmesinden çok, Çevrim Dışı Kalite Kontrol Metotları olarak adlandırılan ürün ve süreç tasarımı çalışmalarına ağırlık verilmesi gerekmektedir.

Ürün performansının hedef seviyede olabilmesi için tüm parametrelerin ideal değerde olması gerekmektedir. Ürün ve sürece ilişkin ideal değerlere uygunluğu sağlama çalışmaları sürekli kalite iyileştirmenin itici gücünü oluşturmaktadır.

Taguchi, ürün ve sürece ilişkin nominal değerlerle toleransların üç aşamada belirlenebileceğini ifade etmektedir. Bu aşamalar şunlardır:

- Sistem Tasarımı
- Parametre Tasarımı
- Tolerans Tasarımı

7. İstatistiksel deney tasarımı, ürün ve süreçteki sapmaları en aza indirecek olan parametrelerin belirlenmesinde kullanılabilir. Taguchi, ürün ve sürece ilişkin performans karakteristiklerini etkileyen değişkenleri iki grup altında toplamıştır.

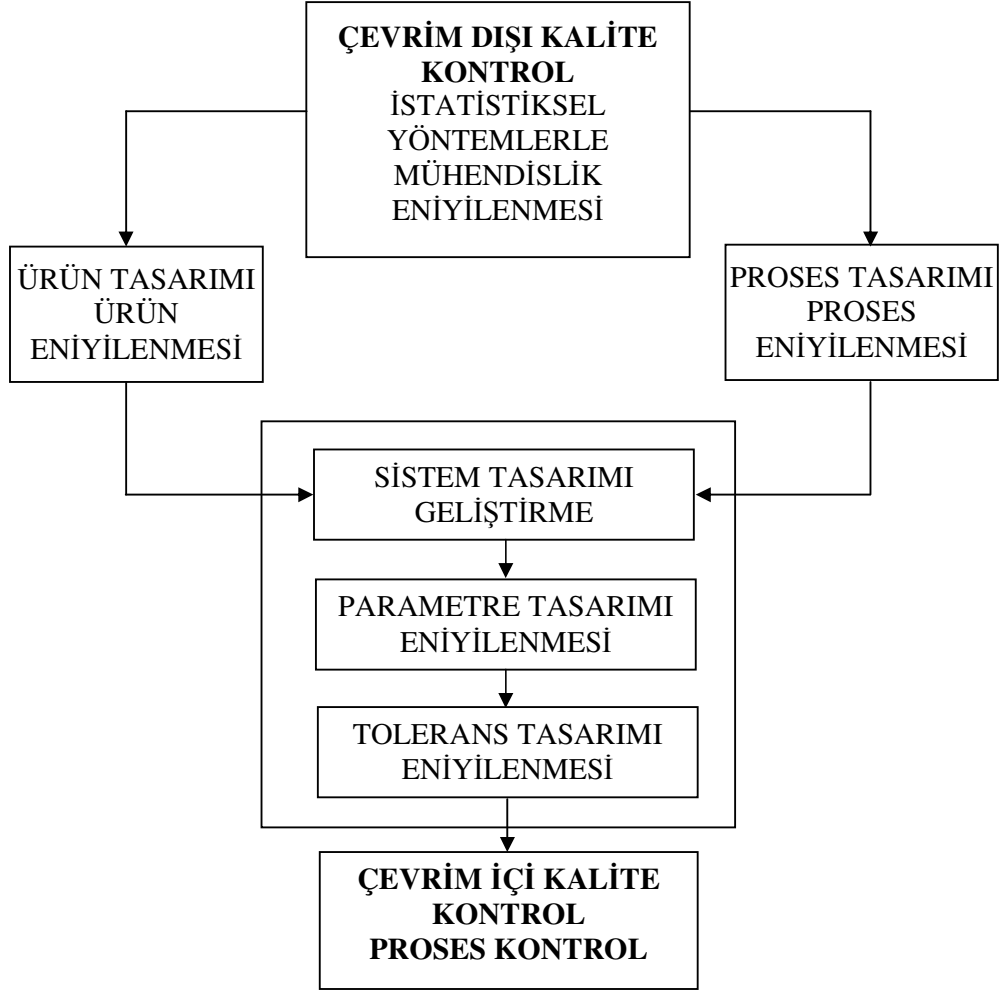
- Kontrol Edilebilen Faktörler (Tasarım Parametreleri, Kontrol Faktörleri)
- Kontrol Edilemeyen Faktörler (Gürültü Faktörleri)

Deneysel tasarımın hedefi; kontrol edilemeyen faktörlerden (gürültü faktörleri), en az etkilenen kontrol edilen faktörler (tasarım parametreleri) kombinasyonunu oluşturmaktır.

### **3.4.1 Kalite mühendisliği**

Taguchi yaklaşımı sadece hedef değerlere ulaşmak için yapılan deneylerle ilgili değildir. Gerçekte Taguchi yöntemi kalite ile geniş anlamda ilgili olduğu gibi kalite teknikleri ve araçları da ilgilidir. Taguchi'nin kalite felsefesi "Kalite Mühendisliği" olarak da anılmaktadır. Şekil 3.2'de Kalite mühendisliği bileşenleri gösterilmektedir.

Kalite mühendisliği ürün araştırma geliştirme, proses tasarımı, üretim ve müşteri memnuniyetinin her fazında oluşturulmuş kalite kontrol faaliyetlerini kapsamaktadır. Bu faaliyetler devamlı gelişmeleri, yani hızlandırılmış buluşları, hızlı problem çözümlerini, mali verimliliği ve kalite kazançlarının devamını sağlayacak tüm amaçları destekleyici olması nedeniyle iki kategoride incelenir.



Şekil 3.2: Kalite mühendisliği ve bileşenleri [25]

### 3.4.2 Çevrim içi kalite kontrol

Çevrim içi kalite kontrol faaliyetleri ürünün üretim sürecini içerir. Bu faaliyetler üretimi görüntülemekte, kalitenin nereye gittiğini ölçmekte, potansiyel problemlerin belirtilerini tespit etmekte ve doğrultucu hareket içermektedirler.

Üretim çevrimi boyunca, mamul kalitesini kontrol etmenin birçok yöntemi vardır. Üretim boyunca mamullerin kontrol edilmesi, yapılan işlerin belirlenmesi, üretim prosesinin ayarlanması ve geliştirilmesi ile otomatik kontrol sistemlerinin kullanılması, bu yöntemlerden sadece birkaçıdır. Aynı zamanda bu metotlar çevrimiçi kalite kontrolün bir kısmını teşkil eder.



Mamul üretimi boyunca, değişkenliğe sebep olan. ürün kalitesini etkileyen bu kaynakları genel olarak şu şekilde tanımlayabiliriz.

- Malzemedan (ham ve yardımcı malzeme) ve satın alınan ekipmandan kaynaklanan değişkenlikler,
- İş akışından, kullanılan aletlerden, makine arızalarından vb. kaynaklananlar,
- Yöneticilerden kaynaklananlar,
- İşçilikten kaynaklanan değişkenlikler.

Çevrim içi kalite kontrolde, tüm bu değişkenlikleri azaltmak ve üretim karakteristiklerini amaç değerinde veya yakın bir aralıkta tutmak için üç ayrı yöntem kullanılmaktadır. Bunlar;

#### **3.4.2.1 Prosesin belirlenmesi ve ayarlanması**

Bu aynı zamanda proses kontrolü olarak da bilinmektedir. Proses için düzenli bir aralık belirlenir, aralık normal ise üretim normal seyrinde devam edecektir,

#### **3.4.2.2 Tahmin ve düzeltme**

Bu yöntem de sayısal karakteristiklerin düzenli aralıklarla ölçü kontrolünden geçirilmesi ve karakteristiklerinin ortalama değerlerinin tahmin edilmesi ile üretim prosesi ayarlanmadan, üretimin sürekliliği sağlanmış olur. Eğer tahmin edilen değer, amaç değerinden farklı ise, düzeltme faktörleri yardımı ile değişkenlik azaltılmaya çalışılır. Bu metod geri beslemeli kontrol yöntemi olarak isimlendirilir. Bu durum çoğunlukla sistem tasarımı ile ilgilidir.

#### **3.4.2.3 Ölçme ve Faaliyet**

Bu yöntem aynı zamanda muayene olarak isimlendirilir. Üretilen her bir mamulün ölçüsü spesifikasyonların dışında ise yeniden üretilir veya düzeltilir. Bu metod sadece mamulle ilgili 1. ve 2. metotlar ise prosesle ilgilidir. Bu metotta,

muayeneden geçen mamul grupları ile muayeneden geçemeyen mamul grupları tespit edildiği gibi, üretim ile ilgili doğru faaliyetlerde belirlenir.

### **3.4.3 Çevrim dışı kalite kontrol**

Çevrim dışı kalite kontrol müşteri istek ve ihtiyaçlarının doğru olarak tanımlanmasıyla başlayan ve bu ihtiyaç ve isteklere göre ürün tasarımının yapılması, bu tasarımın ekonomik olarak üretimi ve bu üretime uygun açık yazılmış spesifikasyon, standart ve prosedürlerin hazırlanmasına kadar uzanan geniş bir çalışma alanını kapsar. Çevrim dışı kalite kontrol müşteri ihtiyaç ve beklentilerini karşılayan, imal edilebilir yeni ürün geliştirerek veya varolan ürünü modifiye ederek, ürün tasarımı safhasını gerçekleştirir. Proses ve ürün tasarımı aşamasında gerçekleştirilen spesifikasyonlara uygun imalat prosesi geliştirmek, amaç edinilmiştir.

Taguchi, çevrim dışı kalite kontrolde ürün ve proses tasarımı aşamalarından her biri için üç adım geliştirmiştir. Bu üç adım Sistem Tasarımı, Parametre Tasarımı ve Tolerans Tasarımı'dır.

Taguchi kalite anlayışı çerçevesinde tanımladığı kalite mühendisliği kapsamında hedef değere yaklaşmak için önce kalite karakteristiklerinin belirlenmesi gereklidir. Performans karakteristiklerinin hedef değere ulaşması, etkili olan faktörlerin tasarımının en uygun şekilde yapılması ile orantılıdır.

#### **3.4.3.1 Sistem tasarımı**

Sistem Tasarımı, Taguchi Metodunun üç adımından ilkinin oluşturulmasıdır. Kalitenin tasarımı ve geliştirilmesi çalışmalarının, yatırıma dönük aşaması da denilebilir. Kalite tasarımının ürüne ve sürece yönelik olmak üzere iki yönü vardır. Bir karakteristiğin istenen seviyede müşteri tatmini sağlaması için ürünün ve prosesin güçlü bir tasarımdan geçmesi gerekir. Taguchi Metoduna göre bu tasarımı sağlayıcı çalışmaların ilkinin sistem tasarımı oluşturur.

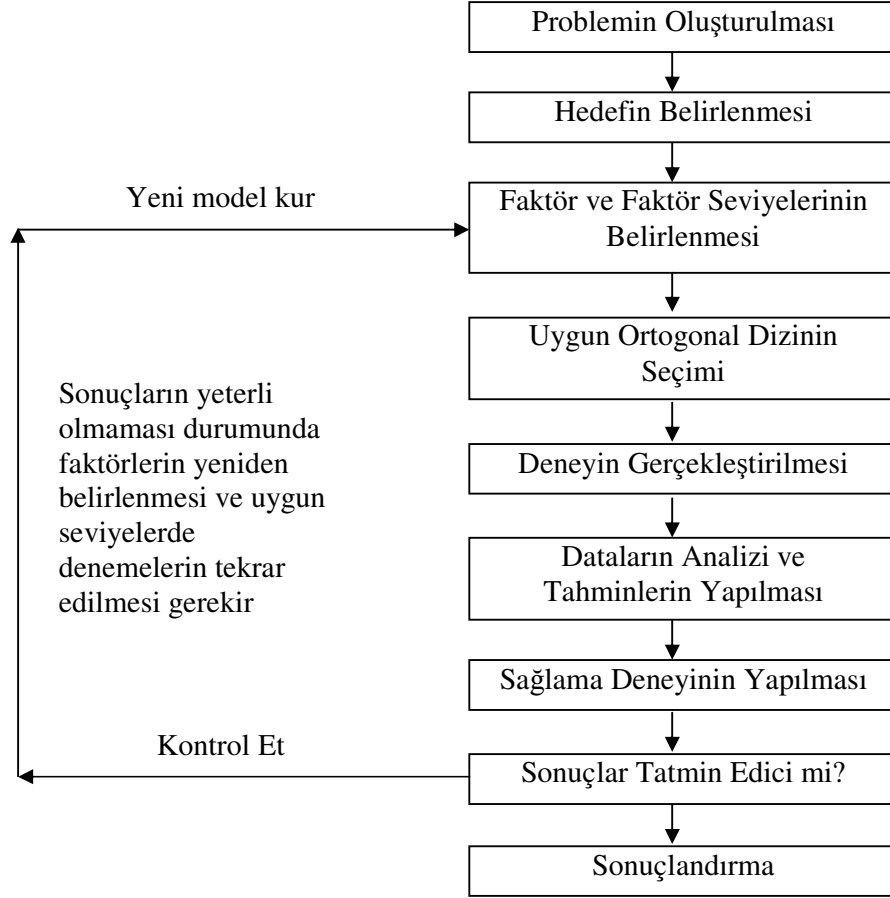
Bir ürünün tasarımında yapılacak sistem tasarımı faaliyetleri temel prototip tasarımının geliştirilmesinden ibarettir. Geliştirme işlemleri tam sağlayacak olan hedef değerden minimum sapma ile yapılmalıdır. Bunun için pazar araştırması, teknolojik gelişmeler ve bilimsel buluşlardan faydalanılabilir. Ayrıca bu konuda malzeme alımında, ürün ağacındaki parçaların spesifikasyonlarının iyileştirilmesinde bir takım kararlar verilir. Örneğin daha hassas bir tezgah gerekiyorsa bununla ilgili değerlendirmeler ve kararın verilmesi bu aşamada gerçekleştirilir.

Herhangi bir ürün için sistem tasarımı, süreç içinde gerçekleştirilir. Süreç ürünü etkileyebilecek faktörlere karşı minimum duyarlı hale getirilir. Burada amaç ürünü en ideal kalitede ve mümkün olduğunca minimum maliyetle belirlenen tolerans limitleri içerisinde, üretilebilecek bir üretim sistemini tasarlamaktır.

Sistem tasarımı yeni ürün ve proses gelişiminin evrensel safhasıdır. Kavramlar önceki deneyimleri, bilimsel temelleri, mühendislik bilgileri yeni gelişmeleri ve bunların her üçünün uygun kombinasyonlarını temel almaktadır. Sistem tasarımı arkasındaki strateji; yeni fikirler almak ve çalışır hale getirmektir.

### **3.4.3.2 Parametre tasarımı**

Parametre tasarımı proses ve ürünün iyileştirilmesi çalışmalarının ikinci adımındır. Taguchi Metodunda en fazla uygulama parametre tasarımı aşamasında görülür. Belirlenen bir kalite karakteristiğinin beklenen tatmini sağlayabilmesi için yapılan çalışmalar, genellikle büyük maliyetler almaktadır. Halbuki parametre tasarımı aşamasında yapılan geliştirme çalışmaları, minimum maliyetlerle hedefi yakalamayı başarmaktadır. Taguchi, parametre tasarımını istatistiksel deney tasarımı metodlarına göre gerçekleştirmiş ve elde edilen verileri de Varyans Analizi ile incelemiştir. Bu bakımdan metod bütün tartışmalara rağmen, istatistiksel bir metoddur. Taguchi'nin parametre tasarımı metodu Şekil 3.3'deki akış diyagramıyla açıklanmıştır.



Şekil 3.3: Parametre tasarımı akış diyagramı [25]

Parametre tasarımının aşamalarını da maddelerle izah edilmiştir

Problemin oluşturulması: Kalite geliştirme sürecinde kısa zamanla uygulaması sınırlandırılan iyileştirmeler sonuç vermez. Rekabet şartlarıyla savaşta, kalitenin sürekliliğin sağlanması kaçınılmazdır. Gerek hizmet ve gerekse imalat sektöründe problemin yokluğunu kabul etmek, gelişmelere kapılan kapatmak demektir, işletmenin güçlü olabilmesi için; daima birtakım problemlerin olabileceğini kabul etmesi, mevcut problemlere çözümler üretmesi ve her problemin elimine edilmesinden sonra yenileşme oluşturup kalite sürecindeki zorlu yola devam etmesi gerekmektedir.

Bir probleme çözüm getirmek, potansiyel olarak düşünmenin ötesinde, somut olarak problemin ele alınmasıyla mümkündür. Bir problemin çözümünün gerçekleştirilebilmesi için, öncelikle o problemin neleri kastettiğine bakmak gerekir.

Problem ismini kazanmışsa; çözümlenmeye aday demektir. Sonraki aşama olan hedef tespitine geçilmelidir.

Hedefin belirlenmesi: Potansiyel bir problemin çözüm bekler hale getirilmesi; etrafı çizilmiş, soyutluktan kurtarılmış ve hedefi belirlenmiş olması demektir. Hedef belirleme çalışmalarına daha önce belirlenmiş ölçülerle başlanır, eğer mümkünse müşteri görüşleri ve eğilimlerinden faydalanılarak hedef daha hassaslaştırılır. Meydana gelen sapmaların ne gibi kayıplar getirdiği iyice belirlenir. Söz konusu kayıplar; itibar kaybı, maliyetlerin yükselmesi, müşteri tatminsizliği vs. olabilir. Bunlar arasından maliyet kaybını ölçmek kolay iken diğerlerini ölçmek gayet zordur, etkileri uzun dönemde ortaya çıkar. Taguchi'nin üzerinde özellikle durduğu kayıplar da esasen uzun dönemde etkilerini göstermesi beklenen ölçülemeyen kayıplardır. Zorlu rekabet şartlarında itibarda ve dolayısıyla müşteride meydana gelebilecek kayıplar uzun dönemde önemli maliyet kayıpları haline dönüşür. Dolayısıyla hedefin bu tür kayıpları önleyebilecek hassasiyette olmasına ve de müşteri tatminini azami derecede sağlayabilmesine özen göstermek gerekmektedir.

Faktör ve faktör seviyelerinin belirlenmesi: Hedefi belirlenmiş bir problemin çözümünün ilk aşamasıdır. Önce meydana gelen hedeften sapmaların kaynakları araştırılır. Bu kaynaklara faktörler adını veriyoruz. Faktörler sonuç değişkenleri üzerinde belli etkilere sahip olan herhangi bir etken olabilir. Bu bakımdan prosesin dikkatlice incelenmesi gerekir.

Faktörler genellikle iki türdür. Bunlar kontrol edilebilen faktörler ve kontrol edilemeyen faktörler olarak anılır. Kontrol edilebilen faktörlere Kontrol Faktörleri, diğerlerine de Gürültü Faktörleri veya Bozucu Faktörler denilmektedir. Faktör seçiminde kontrol ve gürültü faktörleri birbirlerinden ayrılırlar. Faktör belirleme işlemleri kalite araçlarından yararlanılarak yapılır.

Faktörlerin yanında birde faktörler arasında olması beklenen karşılıklı etkileşimler de belirlenir. Örneğin sıcaklığın bir faktör ve nemin bir faktör olduğu durumlarda, sıcaklık ve nemin etkileşimi de ayrı bir faktör olarak ele alınmalıdır. Bu aşamadan sonra belirlenen faktör ve etkileşimlerin seviyelerinin belirlenmesi gerekmektedir.

Seviyelerin belirlenmesinde bir faktörün söz konusu karakteristik üzerine kaç türlü etkiye yapabileceğine bakılacaktır. Bir faktörün deneye dahil edilebilmesi için en az iki faktörlü olması gerekir. Birden fazla kademesi olmayan faktörün alternatif seviyesi yok demektir ve serbestlik derecesi de 0'dır. Alternatif sunamayan bir faktör ancak gürültü faktörü olarak tanımlanır. Bununla beraber faktör kademelerinin fazla yüksek olmamasına özen gösterilir. Taguchi kademeleri çok önemli bir zorunluluk olmadıkça 2 veya en fazla 3 seviyeli olarak belirlemeyi önermektedir. Fazla seviyeli faktörler mevcutsa özel birtakım işlemlerle 2'li veya 3'lü faktörler haline getirilirler. Bu işlemleri yapmanın sebebi kolaylıkla sonuca gitmek ve imkanları geniş olan 2 kademeli deneysel tasarım tekniğinden en verimli şekilde yararlanabilmektir. Seviyeler belirlendikten sonra, deneyde faktör şartlarını belirleyen Ortogonal Diziyi belirlemeye geçilir.

Ortogonal diziler (Orthogonal arrays): Bu aşamada hangi faktörün hangi seviyesinin kullanılacağı belirlenir. Ortogonal diziler deneysel taşanının bir parçası olmakla beraber, biraz farklı bir yapıya sahiptirler. Normal iki kademeli bir deneysel tasarım kurulacaksa Tam (Full) faktöriyel tasarımın gereği  $2^k$  adet denemenin gerçekleştirilmesi beklenir. Fakat Taguchi uzun çalışmalar sonucu standart deneme planları geliştirmiş ve bu planların vereceği sonuçla,  $2^k$  denemenin sonuçları arasında bir fark olmayacağını iddia etmiştir. Bu iddiasında haklı olduğunu pratikte göstermiştir. Söz konusu standart deneme planlarının esası, eşzamanlı olarak birkaç faktörün kademelerini değiştirerek deneme sayısında oldukça fazla bir azalma meydana getirilmesidir. Örneğin yedi faktörün tesbit edildiği bir deney için  $2^7 = 128$  adet denemeyi gerçekleştirmek gerekir. Taguchi ise bu deney için 8 denemeyi yeterli görmektedir.

Deneyin yapılması (Verilerin toplanması): Deney, ortogonal dizinin ön gördüğü denemelerden oluşur. Bu denemelerin her biri, faktörlerin değişik şartlarına göre ayarlanmıştır. Hangi şartın karakteristik üzerinde nasıl bir etki yaptığı Ortogonal dizi sayesinde belirlenir. Her deneme sonucunda elimize, bir takım veriler geçmiş olur. Bu verilerin niteliği ve niceliği hakkında deneyi yapmadan önce, bir takım kararlar verilir. Bunların önemli olanlarını şöyle sıralamak mümkündür:

- 1- Etkin bir ölçüm sistemi
- 2- Denemelerde yapılması gereken tekrar sayıları.
- 3- Denemelerin bir rastgele sıralanması

Ölçüm sistemi, verilerin toplanması için çok önemlidir. Zira faktör etkilerinin ölçümü için mecburen bir ölçü sistemi gerekmektedir. Bir deney yapılmadan önce elde edilmesi beklenen numunelerin ölçülüp veri haline getirilmesi için, ölçümün sistematik ve mümkün olduğunca kolay olması beklenir. Ayrıca deneylerden iyi sonuç alınabilmesi için, ölçüm aletlerinin hassas olması sağlanmalıdır. Zira ifade ettiğimiz gibi ölçüm sisteminin mümkün olduğunca basit, kolay ve kısa zamanda sonuç vermesi istenir.

Deney boyunca faktör şartları değiştirildikçe, ya da denemeler gerçekleştirilirken hatanın minimize edilmesi için, denemelerin tekrar edilmesi gerekir. Tek deneme söz konusu olursa, hata payının yüksek olması mümkün olduğu gibi, bilinmeyen faktörlerin etkilerinin de ölçülmesine fırsat verilmemiş olur. Ancak deneme maliyeti yüksekse o zaman tek değer veya mümkünse iki değerle yetinmek gerekeceği için, denemeleri titizlikle yapmak önem kazanır. Normal şartlarda tekrar sayısı 5 ve 10 arasında değişirse deneyin tatmin ediciliği yüksek olur.

Denemelerin yapılış sırasının numara sırasına göre değil de bir rastgelelikle belirlenmesi gerekmektedir. Bir deneyi dizinin öngördüğü numara sırasına göre yapmak bazı bilinmeyen faktörlerin denemeyi etkilemesine sebep olabilir. Bu tür bilinmesi çok zor veya imkansız olan ya da henüz bilinmeyen faktör etkilerine fırsat vermemek için rastgele bir sıra oluşturmak faydalı olmaktadır. Ancak, bazı faktörlerin kademelerini sık sık değiştirmek, ortaya aşırı maliyet çıkarabilir. Bu durumda faktör şartlarının durumuna uygun bir sıralama yapılabilir.

Rassallaştırma için rastgele sayılar tablosu veya sayıların yazılıp atıldığı bir yığından çekme metodu kullanılabilir. Rastgele sıra sağlandıktan sonra sıra denemelerin yapılmasına gelir.

Deneyin yapılması, faktör şartlarının sağlanması ile başlar. Faktörler her denemeye tek bir kademelerindeki değerleri ile katılırlar. Her deneme faktörlerin değişik kombinasyonlarının denenmesidir. Örneğin 7 faktörlü deneyde 6.deneme, faktörlerin  $A_2, B_1, C_2, D_2, E_1, F_2, G_1$  kombinasyonundan oluşmaktadır. Bir deneyde etkileşim varsa daha önce belirtildiği üzere bir faktör gibi işleme sokulur. Ancak etkileşimin kademeleri, ana faktörlerin kademeleri değiştirildikçe değişir. Bizzat müdahale ile değiştirmek, ana faktörlerden bağımsız olarak mümkün değildir. Deney esnasında sadece ana faktörlerin kademelerine müdahale etmek mümkün olmaktadır.

Verilerin analizi ve yorumlanması: Elde ettiğimiz gözlem değerleri, belirlediğimiz hedefe ulaşabilmemiz için tercih edeceğimiz faktör kombinasyonunu tesbit etmemizi sağlayacaktır. Bunun için faktörlerin hangilerinin etkin olduğunu tesbit etmemiz gerekecektir. Faktörlerin etkinlikleri de sahip olduğumuz verilerin çeşitli metodlarla analiz edilmesi ile tesbit edilebilir. Analizin yapıldığı metodları şöyle sıralayabiliriz.

- Varyans Analizi
- Sütun Farkları Metodu
- Gözleme Metodu
- Ranking Metodu
- Grafik Metodu

Doğrulama deneyinin yapılması ve sonuçlandırma: Tahmini değerler güven aralıklarıyla belirlendikten sonra işlemlerin sağlanması olarak optimal şartlarda bir deney gerçekleştirilir. Deneyden elde edilen verilerin ortalaması ve standart sapmaları, hata oranları bulunur. Gözlenen değerler daha önceki çalışmalar neticesinde elde edilen tahmini değerlere yakınsa (sağlama deneyi için öngörülen güven aralığının içinde ise) deney gerçeğe yaklaşmış demektir. Bu durumda bulunan değerleri bu çalışmanın en iyi değerleri olarak kabul eder ve deneyi sonlandırırız. Gözlenen değerler, öngörülen değerlerden uzaksa o zaman modelde bir başarısızlık, bir hata söz konusudur. Geri besleme tekniği ile önceki adımlara dönerek, modelin kuruluşundan itibaren tekrar ele alınır ve yeni modelin kuruluş aşamalarına başlanır. Yapılacak çalışmalar, öncelikle hatanın tesbitine yönelik olmalıdır. Başarısızlığın nedenleri: hedef fonksiyonun yanlış seçimi, yanlış faktörlerin seçimi, karakteristiğinin



yapısına uygun olmayan S/G oranının seçilmiş olması, ortogonal dizinin seçiminde hata yapılmış olması vb. aşamalardan biri veya birkaçıdır.

Sonuç safhasına kadar gelindiğinde, yapılan çalışma başarılı olmuş demektir. Çalışma neticesinde elde edilen değerlere göre değişiklikler yapılması ve bu çalışma verilerinin üretime katılması gerekmektedir. Bu çalışmada istenilen seviyeye ulaşılamadı. Y.S.A., tolerans tasarımından yararlanır. Tolerans aralığı daraltılarak, kaliteyi geliştirme çalışmalarına başlanır.

### **3.4.3.3 Tolerans tasarımı**

Tolerans tasarımının amacı parametre tasarımında belirlenen nominal değerler civarında değişkenlerin, kabul edilebilir aralıklarda belirlenmesidir. Bu aşamaya her problemin çözümünden sonra başvurulabileceği gibi, parametre tasarımını güçlendirmek için de kullanılması öngörülmektedir. Toleransın kullanımı, yararın yanısıra zarar boyutunu da çalışma koşullarına yansıtılabilmektedir. Hatta Taguchi toleransların etken kullanımı konusunda “Şayet toleranslarla çalışırsanız, montajınızda sapmalar birikip ciddi bir başarısızlık ortaya çıkabileceği halde, onu toleranslar içinde diye kabul etmiş olacaksınız.” demekte ve konunun önemini vurgulamaktadır. Tolerans kavramım iki boyutta inceleyelim.

1. Parametrelerin analizinden elde edilen optimal değerlerin iyileştirilmesi, ekonomik kayıpların azaltılması ve maliyetlerin dengelenmesi tolerans tasarımı çalışması ile gerçekleştirilebilir.

2. Hedef değerden sapmaları azaltsak da sonucu tek bir noktaya bağlamak oldukça zor bir ihtimaldir. Bu nedenle ekonomik dengeyi sağlamak maksadıyla tolerans tasarımı safhasını gerçekleştirmek gerekmektedir.

İncelenen maddelerden ilki Taguchi felsefesine uymaktadır ve çalışmalarımızda da tercih ettiğimiz düşünce bu doğrultudadır. Bu nedenle dar toleranslar seçilmesi öngörülmektedir. Zira sapmalar arasındaki fark büyüdükçe ürün spesifik değerden

sapar, bu da işletmenin kayba uğramasına neden olur. Uzun dönemde müşteri boyutundaki kayıplar genellikle geniş toleranslarla çalışma sonucunda doğar.

Tolerans tasarımı kalite geliştirme sürecinin bir adımı olmasının yanısıra kalite değerlendirme faaliyetidir. Bazı yayınlar kalite çalışmaları çerçevesini iki parça halinde sunarlar. Bunlar:

1. Kaliteyi nasıl geliştirelim
2. Kaliteyi nasıl değerleyelim

Sorulardan ilki sistem ve parametre tasarımı ile ikincisi ise tolerans tasarımı ile yanıtlanabilmektedir. Bu çalışmada kalite geliştirmek üzere parametre tasarımı üzerine yoğunlaşıldığından tolerans tasarımı konusunun ayrıntılarına girilmemektedir.

#### **3.4.4 Ortogonal diziler**

Ortogonal dizi kavramı, İngiltere’de Sir Ronald Fisher tarafından ortaya çıkarılmıştır. Bu konudaki ilk çalışmalar deneylerdeki hataları kontrol etmek için kullanılmıştır. Taguchi, ortogonal dizilerle sadece ortalama sonuçlar üzerine faktörlerin etkisini ölçmekle kalmamış, aynı zamanda ortalama sonuçlardan değişimi de incelemiştir.

Ortogonalite, denge olarak tanımlanırsa; deneysel matriste ortogonal matrisin anlamı istatistiki olarak bağımsızlıktır. Aşağıdaki şekilde klasik tasarım ve Taguchi tasarımı aralarındaki fark daha iyi görülmektedir.

Tablo 3.3’te 2 deneme planı görülmektedir. Buna göre 1 ilk seviyeyi, 2 ise ikinci seviyeyi göstermektedir. İlk faktör sabit iken 7. faktörde seviye değişikliği yapılmaktadır. Bu yolla bütün faktörler teker teker denenmektedir. Sonuçta 128 deneme gerçekleşmiş olmaktadır. Halbuki Taguchi tasarımına göre ilk denemeden ikinciye geçilince 7 faktörden dördü değiştirilmektedir. Daha sonraki denemeler için de 4’ü 2. seviyede, 3’ü 1 seviyede olmak üzere her seferinde değişiklik yapılmaktadır. Bunda da toplam 8 deneme yeterli bilgi vermektedir.

Tablo 3.3: Teklif edilen deney tasarımları

Deneme No	Faktör No						
	1	2	3	4	5	6	7
1	1	1	1	1	1	1	1
2	1	1	1	1	1	1	2
3	1	1	1	1	1	1	1
4	1	1	1	1	1	1	2
5	1	1	1	1	1	2	1
6	1	1	1	1	1	2	2
.	.	.	.	.	.	.	.
128	2	2	2	2	2	2	2

Deneme No	Faktör No						
	1	2	3	4	5	6	7
1	1	1	1	1	1	1	1
2	1	1	1	2	2	2	2
3	1	2	2	1	1	2	2
4	1	2	2	2	2	1	1
5	2	1	2	1	2	1	2
6	2	1	2	2	1	2	1
7	2	2	1	1	2	2	1
8	2	2	1	2	1	1	2

a)  $2^k$  tasarımı

b) Taguchi Tasarımı

Bu dizilere, ortogonal dizi denmesinin sebebi, her faktörde eşit miktarda farklı kademelerin bulunmasıdır. Bunun testini yapmak istediğimizde 1'lere (-1), 2'lere de (1) değerlerini vererek her faktöre ait sütunu toplarsak sonucun 0 olduğunu görürüz. Bu da eşit miktarda farklı kademelerin bulunduğuya eşittir. Örnek olarak L8 dizideki 6. faktörü ele alalım. Toplam = (-1) + (1) + (1) + (-1) + (-1) + (1) + (1) + (-1) = 0

Bu işlem herhangi bir ortogonal dizinin herhangi bir sütunu için de aynı sonucu verecektir. Ortogonal diziler 2 kademeli, 3 kademeli ve, 2 ve 3 kademeli olmak üzere üç türlü belirlenmişlerdir. Belirlenen bu diziler standart olup Taguchi deneysel tasarım metodunun temel taşlarını oluşturmaktadır. En çok kullanılan diziler 2 seviyeliler için  $L_4$ ,  $L_8$ ,  $L_{12}$ , ve  $L_{32}$  iken 3 seviyeliler için  $L_9$ ,  $L_{18}$ ,  $L_{27}$  dizileridir. Her iki seviyenin karışık olarak kullanıldığı dizilerden bazıları  $L_{18}$ ,  $L_{36}$  ve  $L_{54}$  dizileridir. Burada ortogonal dizi latin kareden türetildiği için L latin kareyi, bitişiğindeki rakamsa dizinin öngördüğü deneme sayısını gösterir.

Genel gösterimi  $L_A(B^C)$  şeklinde olup; A deneylerin sayısını veya deneyde kullanılan faktörlerin kombinasyonunu, B her kolondaki seviyelerin sayısını, C ise ortogonal dizideki kolonların sayısını göstermektedir.

Dizilerin seçimi kademe sayısı ve toplam serbestlik derecesi yardımıyla yapılır. Kademe sayısı dizileri sınıflandırmada belirleyicidir. Bu bakımdan 2 kademeli bir faktör grubuna 3 kademeli bir diziyi önermek yanlış olur. Bir sonraki aşama serbestlik derecesinin bulunmasıdır.

İki seviyeden beş seviyeye kadar değişen seviyelerde ortogonal diziler bulunmaktadır. Yapılan tasarımın parametrelerine ve amaca göre, genellikle iki veya üç seviyeli diziler kullanılabilir. Zaman zaman iki ve üç seviyenin birlikte kullanıldığı diziler de tercih edilmektedir.

### 3.4.5 Serbestlik derecesi

Bir dizinin serbestlik derecesi her bir faktörün ayrı ayrı serbestlik derecelerinin toplamına eşittir.

$v_A$  : A faktörünün serbestlik derecesi

$v_{A \times B}$  : A ile B interaksyonu( etkileşimi) serbestlik derecesi

$k_A$  : A faktörünün kademe sayısı

$$v_A = k_A - 1 \quad v_{A \times B} = v_A \times v_B \quad (3.2)$$

Faktör grubunun serbestlik derecesi ise tüm faktör ve etkileşimlerin serbestlik dereceleri toplamına eşittir. Bu aynı zamanda toplam veri sayısından bir çıkarmakla bulunur.

$v_T$  : Dizinin toplam serbestlik derecesi

$N$  : Dizinin toplam veri sayısı

$$v_T = N - 1 \quad (3.3)$$

Serbestlik derecesi belli faktörler grubunun ortogonal dizi seçimi kolaylıkla yapılabilir. Serbestlik derecesinin uygun düştüğü, deneme sayısına sahip olan dizi seçilir. Serbestlik derecesi maksimum; seçilecek olan dizinin deneme sayısından bir eksik olabilir. Eşit olursa bir üst düzeyin seçilmesi gerekmektedir. Bu sayı iki dizi sayısı arasındaki bir sayıya denk geliyorsa bir üstteki dizi tercih edilmelidir. Seçilen dizinin sütunlarına faktörler atanır.

### 3.4.6 Analiz yöntemi

Bu bölümde daha kolay, anlaşılır olması ve etkin sonuçlar vermesi nedeniyle sütun farkları yöntemine değinilecektir.

Sütun farkları metodu:

Basitleştirilmiş varyans analizidir. Bu yöntemde seçilen ortogonal diziye ait cevap değişkenleri tablosu öncelikle oluşturulur. Tablodaki sütun sayıları faktörlerin kademelerinin sayıları ile belirlenir.

Örneğin  $L_8$  kullanılacaksa  $7 \times 2 = 14$  tane sütun açmak gerekmektedir. Tablo çizildikten sonra her bir faktöre ait sütunlara numara verilir.(2'li ise 1,2; 3'lü ise 1,2,3) Sonra her sütunun, hangi denemede açık, hangi denemede kapalı olacağını ifade etmek için. kapalı olması gereken yerler taranır. Böylece tablo oluşmuş olur. Bir denemeye ait değer satır boyunca tüm açık kutucuklara yazılır. Yazım bittikten sonra kolonlar teker teker toplanarak toplam bölümüne, ortalamaları alınarak da ortalama bölümüne kaydedilir. Bu işlemden sonra, her bir faktöre ait kolonların farkları alınır. Farklar büyüklük sırasına göre dizilir. Varyans analizindeki gibi burada da en büyük fark değeri, etkin olan faktörü gösterir. Bu değerler daha sonra bir grafik üzerinde gösterilir. [28]

Sonuç değişkenleri tablosunda elde edilen değerlerin grafik üzerinde gösterimi ise aşağıdaki algoritmaya göre yapılır.

1. Tablo sonucunda en büyük ve en küçük değerleri belirle,
2. Bütün bu ortalamaları içerecek biçimde bir dikey skala çiz,
3. Bu dikey skalanın tüm değerler ortalamasına denk olan noktasından yatay bir eksen çiz,
4. Her bir faktör için yüksek ve düşük seviye değerlerinin noktasını grafikte işaretle (seviye numaraları noktanın yukarıda veya aşağıda olmasını etkilemez, büyüklüğü önemlidir)
5. Her bir faktöre ait noktaları doğru bir çizgi ile birleştir.

Grafik tekniğinde etkin faktörlerin seviyeleri arasındaki çizgi büyük olur. Eğer problem maksimum hedefli ise büyük değeri veren seviye, eğer minimum ise küçük değeri veren seviye tercih edilmelidir.

Bu tekniğin sonucunda bir de Normal Dağılım grafik kağıdı kullanılarak etkinlik belirlenir.

1. Tahmini faktör etkilerini küçükten büyüğe doğru sırala,
2.  $(E_i, P_i)$  noktalarını normal dağılım kağıdında işaretle

m : Tahmini etken sayısı

$E_i$  : i. tahmini faktör değerinin en küçük değeri

$$P_i = \frac{100(1-0.5)}{m} \quad (3.4)$$

$E_i$  değeri yatayda ,  $P_i$  değeri ise dikey ekseninde yer alır. 2 seviyeli deneylerde skala 7 veya 15 üzerinde alınabilir. Skala daima kağıdın yanında yer alır.

3. Doğru bir çizgiyi noktaların yoğunluk kazandığı bölgeden geçirin. Çok büyük  $E_i$ 'lerle çok küçük  $E_i$ 'leri ihmal ediniz. Diğer noktalar gerçek etkiye sahiptirler.

### 3.4.7 Kalite karakteristikleri

Müşteri istek ve ihtiyaçları temel alındığında; kalite kavramı ile maliyet kavramını birarada almak gerekmektedir. Bu amaçla her ürün için tasarımdan imalata kadar belirlenmiş en iyi kalite karakteristiklerine ulaşılmaya çalışılmaktadır.

Kalite karakteristikleri, deneylerde sonuç değişken veya performans karakteristiği olarak isimlendirilirler. İstenilen sonucun seviyesine göre S/G oranının ve kayıp fonksiyonunun hesaplanmasında söz sahibidirler.

Her ürün için belirli kalite karakteristikleri mevcuttur. Tüm kalite karakteristikleri eşit olarak önem taşımadıklarından, kalite karakteristiklerinin tümünü geliştirmek

gerekli değildir. Ürün kalite karakteristikleri içinden seçilen performans karakteristikleri müşteri ihtiyaçlarını yeteri derecede karşıladıklarından birincil derecede önemlidirler. Televizyondaki görüntünün niteliği, performans karakteristiklerine örnektir. Gerek tasarım ve imalat aşamalarında değişik işlemler esnasında ve kullanım ömrü süresince ürünün performans karakteristiklerinin ideali olan hedef değere yakın performans göstermesi istenmektedir. Hedef değer civarındaki değişim azaldıkça kalite yükselmektedir.

Üretilmiş ürünün kalitesi ve maliyeti, ürünün mühendislik tasarımı ve imalat prosesi tarafından kontrol edilir. Ürün geliştirmenin ürün tasarımı, proses tasarımı ve imalat aşamalarından oluştuğu kabul edilmektedir. Bir adımın çıktısının, diğer adımın girdisi olacağı düşünülürse, tüm adımlar ve aşamalar arasındaki geçişler ürün kalite ve maliyetini etkilerler. Bu amaçla ürün tasarımı yapılmadan önce üründen beklenen kalite karakteristikleri belirlenmeli ve malzeme seçimi iyi yapılmalıdır.

Ölçüm yeteneklerine göre kalite karakteristikleri :

Ölçülebilen karakteristikler: Sürekli skalada ölçülebilen karakteristiklerdir. Boyut, ağırlık örnek olarak verilebilir. Ölçülebilen kalite karakteristikleri çerçevesinde bu sınıflandırma nominal en iyi, küçük değer iyidir ve büyük değer iyidir karakteristiklerine ayrılır.

- a- Büyük Olan İyidir
- b- Küçük Olan İyidir
- c- Nominal En İyisidir

Sembolik karakteristikler: Sürekli skalada ölçülemezler. Sembol verilerinin en önemlileri Git/Gitme veya Geçer/Geçmez olanıdır. Döküm ürünlerinin sevkıyattan önce incelenmesi sonucunda sevk edilmesi (Git) ve hurdaya ayrılan veya tamire gönderilmesi (Gitme) örnek olarak alınabilir. Hurda oranı ve kazanç kalite ölçümünde yaygın olarak kullanılır. Sembolik karakteristikler diğerlerinden daha fazla tercih edilirler. Çünkü bu tür veriler daha basit ve anlaşılırdırlar.

Sembolik karakteristiklerin en önemli dezavantajı, ölçülebilir karakteristiklerden alınan aynı düzeydeki bilginin elde edilebilmesi için daha büyük bir örnek kitlesine gerek olmasıdır. Sembolik karakteristiklerin sonuca katkısı da problem yaratabilir. Her bir faktörün etkisi 1 ise iki faktörün birlikte etkisi yine 1 olabilir. Diğer bir dezavantaj ise sembolik veri temelinde deney faktörlerinin her bir deneysel çalışma için aynı sonuçları üretmesidir. Bu yanlış bir yaklaşım olup her bir deneysel çalışmanın farklı sonuçlar vermesi gerekmektedir.

**Dinamik karakteristikler:** Dinamik karakteristikler biraz daha karmaşık yapıya sahiptirler. Bu araç anlaşılacak bir konu üzerinde proses bilgisini kolaylaştırmak için güçlü ve etkilidir. Dinamik karakteristikler çalışılan prosesin fonksiyonel gösterimidir. Bu anlayışta proses sistem olarak düşünülüp, girdi ve çıktının sistemin enerji transferi olduğu varsayılmalıdır.

Dinamik karakteristikler prosesin bileşenleri arasındaki ilişkilerin daha iyi anlaşılmasına yardımcı olur. Giriş ve çıkış değerlerinin belirlenmesi özellikle sistem açısından çıkış değerinin bilinmesi ve aralarındaki lineer ilişkinin varlığı girişte ayarlama yaparak çıkış değeri elde etme şansını verir.

### **3.4.8 Faktörlerin sınıflandırılması**

Deneylerde prosesi veya ürün kalite karakteristiklerini etkileyen ve kontrol edilebilen parametrelere faktör adı verilir. Taguchi tarafından proses ve ürün performansına etkileyen iki tür faktör tanımlanmıştır. Bunlara Taguchi sistem girdileri de denilmektedir.

- Kontrol Faktörleri (Kontrol Edilebilen Faktörler, Tasarım\Parametreleri)
- Gürültü Faktörleri (Kontrol Edilemeyen Faktörler)



### **3.4.8.1 Kontrol faktörleri**

Kontrol faktörleri, imalat ve tasarım proseslerinde kararlılık için en iyi şartların seçiminde kullanılır. Bağ mukavemetini geliştirmek için, bağlayıcı malzeme tipi veya malzemenin kaplamasının tabaka sayısı kontrol faktörlerine örnektir.

Kontrol faktörleri imalatçı tarafından belirlenen ve müşteri tarafından direkt olarak değiştirilemeyen faktörlerdir. Kontrol faktörleri kontrol edilebilen faktörlerdir ve iki temel gruba ayrılır. [26]

Belirtici faktörler (Değişken kontrol faktörleri): Sonucu doğrudan etkileyen faktörlerdir. Ürün çeşitliliği ve boyut değişikliği örnek olarak verilebilir. S/G oranının yüksek değerleri ürün kullanım şartları tarafından ürün fonksiyonlarının kolayca etkilenmeyeceğini gösterir. Bu durumda belirtici faktörler gürültü faktörleri gibi davranırlar.

Sinyal faktörleri (Hedef kontrol faktörleri): Bu faktörler sonucun sadece ortalamasını etkilerler. Sinyal faktörü giriş sinyal değerlendirilmesinde kullanılırlar ve S ile gösterilirler. Dinamik karakteristikler için çıkışın gereksinimlerini gerçekleştirmekte kullanılan sinyal karakteristikleri aktif sinyal faktörleri olarak isimlendirilir.

### **3.4.8.2 Gürültü faktörleri**

Değişime sebep olan tüm faktörlere gürültü faktörleri denilir, iç gürültü faktörleri bileşenlerin hedef değerden sapmasına veya kullanım esnasında bozulmasına sebep olur. Dış gürültü faktörleri ürünün kullandığı çevre şartlarını içerir.

Dış gürültü faktörleri doğrudan imalatçının kontrolünde olmayıp kullanımla ve müşterinin kullanım ortamı ile ilgilidir. İç gürültü faktörleri imalat ve operasyon esnasında kalite karakteristiklerinde ve ölçülen sistemin performansındaki değişime sebep olan ve kontrol edilmesi pahalı veya imkansız olan faktörlerdir

### 3.4.8.3 Sinyal/Gürültü (S/G) oranı

Taguchi metodunda iki önemli amaç vardır.

1. Ürün karakteristik değerini hedefe mümkün olduğunca yaklaştırmak
2. Minimum sapmayı sağlamak


Maddelerden ilkini Taguchi şimdiye kadar açıklanan metodlarla gerçekleştirmiştir. İkinci madde ise bir değişim ölçüsü gerektirmektedir. Veri noktaları arasındaki farklılığı minimize etmek için S/G oranı Taguchi tarafından geliştirilmiştir.

Taguchi tekniğinde S/G oranı incelenen sistemde faktörlerin sonuç değişken olarak belirlenmiş kalite karakteristiğinin öngörülen büyüklüğü (en küçük iyidir, en büyük iyidir ve nominal en iyisidir) hedef alınarak hesaplanmış oranıdır. S/G, S/G (Signal to Noise) diye de anılmaktadır.


Taguchi kırktan fazla S/G oranı önermiştir. Bunlardan üçü kalite karakteristikleri statik olduğu zaman kullanılmaktadır.

1. Küçük olan iyidir.
2. Büyük olan iyidir.
3. Nominal en iyisidir.

Taguchi gürültü faktörlerinin azaltılmasına dikkat çekmiştir. Ona göre bu durum ürün performansında değişime sebep olmaktadır. Çıkış karakteristiklerinin saptması veya fonksiyonel değişimlerin sebepleri üç sınıfta ele alınan gürültü faktörlerinden kaynaklanmaktadır. Bu durum Şekil 3.4'te gösterilmiştir.



a) Gürültü Faktörlerinin Etkisi



b) Ürünler Arası Gürültü

Şekil 3.4: Fonksiyonel değişimlerin sebepleri


Taguchi kayıp fonksiyonu kalite mühendisliği kapsamında yer alan tolerans tasarımında kullanıldığı gibi parametre tasarım safhasında S/G oranına bağlı olarak kaliteyi güçlendirmek amacıyla da kullanılır. S/G oranı kalitenin güçlendirilmesi için bir göstergedir. Bu anlamda kayıp fonksiyonu ile S/G oranının bileşenleri arasındaki ilişki Şekil 3.5’de görülmektedir.

Küçük olan iyidir: Ölçüm değeri küçüldükçe iyileşmenin arttığı karakteristik tipidir. LB ile gösterilir. Bu karakteristikte hedef değer sıfırdır ve negatif tolerans da yoktur. Eğer sapma varsa pozitif yöndedir. Bu karakteristiğin hesaplama formülü ;

n : Bir denemedeki test sayısı

$y_i$  : Gözlem Değeri

$$S/G_{LB} = -10 \log \left( \frac{1}{n} \sum_{i=1}^n y_i^2 \right) \quad (3.5)$$



- \*İşlem Koşullarındaki Değişim
- \*Bozunma
- \*İnsan Hataları
- \*Bozunma
- \*İmalat Hataları

Şekil 3.5: Kayıp fonksiyonu ile gürültü arasındaki ilişki [24]

Nominal en iyisidir: Nominal değere ne kadar yaklaşırsa iyileşme o kadar gerçekleşir. NB ile gösterilir. İdeal değer nominal değer olduğu durumdur. Sapma sağda veya solda gerçekleşebilir. Varyans analizi kullanılarak S/G oranı şöyle hesaplanır:

- $\bar{y}$  : Veri grubunun ortalaması
- s : Veri grubunun standart sapması

$$S/G_{NB} = -10 \log \left( \frac{s_i}{\bar{y}_i} \right)^2 \quad (3.6)$$

Büyük olan iyidir :Ölçüm değeri büyüdükçe iyileşmenin arttığı karakteristik tipidir. HB ile gösterilir. İyileşme için üst sınır yoktur. Ne kadar artış olursa, aynı oranda iyileşme olur. Bu karakteristiğin hesaplanması için gerekli formül aşağıda verilmiştir.

$$S/G_{NB} = -10 \log \left( \frac{1}{n} \sum_{i=1}^n \frac{1}{y_i^2} \right) \quad (3.7)$$

S/G oranı varyans analizine ya da sütun farkları metoduna tabi tutulur. Yapılan işlem sonucunda etkin faktörler belirlenir. Çoğunlukla ortalamayı optimize eden faktörler değişkenliği de minimize ederler.

## BÖLÜM 4. YAPAY SINİR AĞIYLA İŞLEM SÜRESİ TAHMİN MODELİ

Yapay sinir ağıyla işlem süresi tahmin modeli için yapılması gereken işlem adımları Şekil 4.1’de verilmiştir.



Şekil 4.1: Y.S.A işlem süresi tahmin modeli

### 4.1 İşlem Süresine Etki Eden Faktörlerin Belirlenmesi

İşlem sürelerinin tahmini için yapay sinir ağı yöntemi iyi bir seçenektir. Yapay sinir ağındaki girdiler için, makineler ve bu makinelerde çalışan işçilerin yaptıkları faaliyetler kameraya alınarak, bu konuda uzman kişilerle birlikte beyin fırtınası yöntemi uygulanarak işlem süresine etki eden faktörler belirlenmelidir. İşlem

süresine etki eden faktör sayısı yapay sinir ağının giriş neuron sayısını oluşturacaktır.

#### **4.2 Veri Toplama**

Belirlenen faktörler göz önünde tutularak yapay sinir ağının hem eğitimi hem de yapay sinir ağının performansının ölçülmesi için işlem süreleri toplanmalıdır. Yine faktörler göz önünde tutularak işlem süreleri doğrudan ölçülebilir ya da faktörler eldeki teknik resimlerden, işlem süreleri ise varsa işletme kayıtlarından alınabilir.

#### **4.3 Yapay Sinir Ağı Parametrelerinin Belirlenmesi**

Yapay sinir ağında kullanılan parametrelere ilişkin literatür çalışmaları incelenmiş ve aşağıda verilmiştir.

Gizli katman sayısı: Giriş ve Çıkış katmanı arasına gizli tabaka konması veya gizli tabaka sayısının artırılmasının verimi artırıp artırmayacağı konusunda kesin bir cevap vermek yanlış olur. Tabaka sayısı hakkında bir genelleme yapmak her ne kadar yanlış ise de, tek bir gizli tabakanın kullanıldığı üç katmanlı bir Y.S.A.'nın bir çok doğrusal olmayan tasviri başarı ile gerçekleştirdiğini görmüştür. Bu yüzden bu çalışmada da gizli katman sayısı fazla alınmamıştır.[17]

Neuron (Hücre sayısı): Saklı tabaka içerisinde kaç tane hücre bulunması gerektiğine dair karar verilmelidir. Bunun için de kesin bir bilgi yoktur. Ama tavsiye olarak başlangıçta en azından üç tane hücreye yer vermenin uygun olacağına dair görüşler vardır. [18]

Öğrenme katsayısı: Öğrenme katsayısı, ağırlıkların değişim miktarıyla ilgilidir. Eğer büyük değerler seçilirse o zaman yerel çözümler arasında ağın dolaşması ve osilasyon yaşaması söz konusu olmaktadır. Küçük değerler seçilmesi ise öğrenme zamanını artırmaktadır. Tecrübeler genellikle 0.2-0.4 arasındaki değerlerin kullanıldığını göstermektedir. Bazı uygulamalarda ise öğrenme katsayısının 0.6 değerini aldığı zaman en başarılı sonuçları verdiği görülmektedir. [14]

Momentum katsayısı: Yine öğrenme katsayısında olduğu gibi öğrenmenin performansını etkilemektedir. Momentum katsayısı bir önceki iterasyondaki değişimin belirli bir oranının yeni değişim miktarına eklenmesi olarak görülmektedir. Bu özellikle yerel çözümlere takılan ağların bir sıçrama ile daha iyi sonuçlar bulmasını sağlamak amacı ile önerilmiştir. Bu değer küçük olması yerel çözümlerden kurtulmayı zorlaştırabilir. Çok büyük değerler ise tek bir çözüme ulaşmada sorunlar yaşanmasına neden olmaktadır. Tecrübeler bu değer 0.6-0.8 arasında seçilmesinin uygun olacağını göstermektedir. Fakat bu da öğrenme katsayısında olduğu gibi kesindir diyemeyiz. Daha küçük değerlerle de daha başarılı sonuçların alındığı görülmektedir. [14]

Yukarıdaki açıklamalar doğrultusunda Yapay sinir ağına kullanılmak üzere deneyde gizli katman sayısı, neuron (hücre) sayısı, öğrenme katsayısı ve momentum katsayısı olmak üzere 4 adet faktör (parametre) belirlenmiştir. Her bir faktör için ise 2 adet seviye kullanılabilir.

- Ağ yapısında geri beslemeli hata yayma modeli (geriye yayılım algoritması) kullanılabilir.
- Belirlenen Faktör sayısı kadar giriş bulunmalıdır.
- Ağırlıkları ve eşik değerlerini, momentum değerine bağlı olarak değiştiren bir eğitim fonksiyonu olan TRAINGDM; öğrenme fonksiyonu olarak LEARNGDM; saklı katmanlar için işlemci (aktivasyon fonksiyonu) yani iç işleyiş tetikleme işlemcisi olarak LOGSIGMOID ( $\text{logsig}(n)=1/(1+\exp(-n))$ ) fonksiyonu; çıkış fonksiyonunun aktivasyon fonksiyonu PURELIN ( $\text{purelin}(n)=n$ ) (Linear Transfer Function) kullanılması uygundur. Bu fonksiyonların kullanılma sebebi; literatürde, tahminleme amacıyla kullanılan yapay sinir ağı modellerinde sıkça rastlanılıyor olmasındandır.[35,36,37,38,39,40].
- Çıkış sadece işlem süresi olduğu için çıkış sayısı 1 olmalıdır.

#### 4.4 En İyi Ağ Topolojisi

Yapay sinir ağından elde edilecek olan verilerin gerçek verilere yakınsamasını artırmak için en iyi ağ topolojisinin bulunması gerekmektedir. İlk olarak



etkileşimlerinin var olup olmadığını araştırmak gerekir. Bu yüzden tam faktöriyel deney yapılmalıdır. Tam faktöriyel deney sonucunda etkileşimlerin var olup olmadığı ve en önemli faktörler görülerek belirlenen bu en önemli faktörlere göre arama alanı artırılarak daha iyi sonuçlara gitme şansı artırılabilir yada etkileşim söz konusu değilse diğer makineler için deney sayısı azaltılabilir.

Bu 4 faktör (parametre) ve literatür araştırması (Bölüm 4.3) sonucunda en iyi sonuç veren 2 seviye kullanıldığı zaman tam faktöriyel deney için  $2^4$  (16 tane) (Tablo 4.1) deney yapılmalıdır. Aşağıdaki Tablo 4.1'de  $S_1$  1.seviyeyi,  $S_2$  2.seviyeyi göstermektedir.

Tablo 4.1: L16 tam faktöriyel deney

	Gizli Katman Sayısı	Neuron Hücre Sayısı	Öğrenme Katsayısı	Momentum Katsayısı
1	$S_1$	$S_1$	$S_1$	$S_1$
2	$S_2$	$S_1$	$S_1$	$S_1$
3	$S_1$	$S_2$	$S_1$	$S_1$
4	$S_2$	$S_2$	$S_1$	$S_1$
5	$S_1$	$S_1$	$S_2$	$S_1$
6	$S_2$	$S_1$	$S_2$	$S_1$
7	$S_1$	$S_2$	$S_2$	$S_1$
8	$S_2$	$S_2$	$S_2$	$S_1$
9	$S_1$	$S_1$	$S_1$	$S_2$
10	$S_2$	$S_1$	$S_1$	$S_2$
11	$S_1$	$S_2$	$S_1$	$S_2$
12	$S_2$	$S_2$	$S_1$	$S_2$
13	$S_1$	$S_1$	$S_2$	$S_2$
14	$S_2$	$S_1$	$S_2$	$S_2$
15	$S_1$	$S_2$	$S_2$	$S_2$
16	$S_2$	$S_2$	$S_2$	$S_2$

Her bir makine için çok sayıda örnek kullanılmalıdır. Ama eldeki bütün örnekler de eğitime için kullanılmamalı, mesela 1/3'ü test aşaması için saklanmalıdır. (Bölüm 2.9) Her bir kombinasyon için denemeler tekrarlanmalıdır. Etkileşim olmadığı ortaya çıktıktan sonra deney sayısı azaltılabilir.

#### 4.5 Yapay Sinir Ağının Performansının Ölçülmesi

Çeşitli performans ölçütleri yapay sinir ağının performansını ölçmekte kullanılır.

Aşağıda kullanılan çeşitli performans ölçütleri ve formülleri verilmektedir.

P(Predicted value) ile gösterilen sembol yapay sinir ağı ile tahminlenen işlem süresini, A (Actual Value) ile gösterilen ise gerçek işlem süresini vermektedir.

$$RMSE = \sqrt{\sum_{i=1}^n (P_i - A_i)^2 / n} \quad (4.1)$$

$$MAE = \sum_{i=1}^n |P_i - A_i| \quad (4.2)$$

$$MAPE = \sum_{i=1}^n |(P_i - A_i) / A_i| * 100 \quad (4.3)$$

Bu performans ölçütlerinin yanı sıra elde edilen değerlerin istatistiksel olarak anlamlı olup olmadığı araştırmak için z testi yada t testi kullanılabilir.

Test verileriyle denenerek sonuçların doğruluğunun (Çalışmanın sonucunda elde edilen yapay sinir ağı çıktıları ile gerçek veriler arasındaki sapmanın tutarlılığının) test edilmesi gerekmektedir. Bunun için çalışmadaki iki yığın (yapay sinir ağının verdiği çıktılar ile gerçek veriler) karşılaştırılmalı, iki yığın orta değeri arasındaki fark tahmin edilmeli ya da bu fark için hipotez testi yapılmalıdır.

Bu iki isteğin birisini yapmak için her bir yığından gerekli bilgiler, örnekleme ile elde edilmelidir. Örnek verilerden yararlanarak iki yığın orta değeri ile ilgili tümevarım yapılabilir. İki yığın karşılaştırıldığında yığın özelliklerini birbirinden farklı kılacak notasyonların kullanılması gerekir. Çalışmada  $\mu$  (söz konusu tek yığının orta değeri)  $\sigma$  (yığının standart sapması)  $\bar{x}$  (ortalama) ve s (örneğin standart sapması) gibi yığın ve örnek istatistikleri farklı notasyonlar ile gösterilmiştir. Bu durum Tablo 4.2’de özetlenmiştir.

Tablo 4.2:  $\mu_1 - \mu_2$  için büyük örnek Z testi

<b>Boş Hipotez</b>	<b>H<sub>0</sub>: <math>\mu_1 - \mu_2 =</math> Hipotez Değeri</b>
<b>Test İstatistiği</b>	$z = \frac{\bar{x}_1 - \bar{x}_2 - (\mu_1 - \mu_2)}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}}$
<b>Alternatif Hipotez</b>	<b>Ret Bölgesi</b>
Ha: $\mu_1 - \mu_2 >$ hipotez değeri	$z > z$ kritik değeri ise H <sub>0</sub> ret (sağ kuyruk testi)
Ha: $\mu_1 - \mu_2 <$ hipotez değeri	$-z < -z$ kritik değeri ise H <sub>0</sub> ret (sol kuyruk testi)
Ha: $\mu_1 - \mu_2 \neq$ hipotez değeri	$z > z$ kritik değeri veya $-z < -z$ kritik değeri ise H <sub>0</sub> ret
z kritik değerleri seçilen önem düzeyine göre belirlenir.	

## **BÖLÜM 5. UYGULAMA: SİPARİŞE GÖRE PEÇETE MAKİNESİ İMALATI YAPAN İŞLETMEDE MAKİNE İŞLEME SÜRESİNİN YAPAY SİNİR AĞI YAKLAŞIMIYLA TAHMİN EDİLMESİ**

### **5.1 İşletme Tanıtımı**

Bu çalışma I.C.M. Makine ve Mühendislik Ltd. Şirketinde yapılmıştır. Firma temizlik kağıtları üretimi ve ambalaj sanayine mühendislik hizmeti veren, çeşitli makineler üreten, bir işletmedir. Bu gün dinamik yapısı içerisinde kendi dizaynı olan kağıt peçete, otomatik peçete paketleme, tuvalet kağıdı makineleri, sarıcı ve aktarıcılar, sekiz renge kadar flexo ve gravür baskı makineleri, hot-melt uygulama makineleri, solventsiz laminasyon makineleri, kağıt gofraj silindirleri üretmekte ve tüm dünyaya pazarlamaktadır. Makine üretiminin yanısıra ICM, proje üretimi ve teknik destek sağlayarak hassas iş talep eden endüstriyel tesislere talaşlı parça imalatı, makine imalatı gibi mühendislik, müteahhitlik hizmetleri de vermektedir.

#### **5.1.1 Ürünler**





İşletme müşterinin istekleri doğrultusunda 3 farklı ürün grubu üretmektedir.

1. Ambalaj Sanayi İçin Makineler
2. Peçete Makineleri
3. Tuvalet Kağıdı Makineleri

Ambalaj sanayi ve tuvalet kağıdı için makineler;

- Hot - Melt Makinesi-Genişlik 2500 mm e kadar
- Rewinder
- Solventsiz Laminasyon Makinesi
- Flexo Baskı Makinesi-Max: 8 renk
- Embosin Machine for Aliminium
- TK 160

Tablo 5.1: Üretilen peçete makineleri

S serisi	Restaurant tipi kağıt peçete, lüks ebat ve/veya bar peçetesi üreten peçete makineleri.	 "S" SERİSİ
SP Serisi	Lüks, renkli, baskılı peçete üretimi için makineler.	 "SP" serisi
ICM400	Otomatik peçete paketlenme makinesi	 ICM400
U Serisi	Otomatik	 "U" SERİSİ

### 5.1.2 Organizasyon şeması

I.C.M. Makine ve Mühendislik Ltd. Şirketinin organizasyon şeması Şekil 5.1'de ki gibidir.



Şekil 5.1: I.C.M. organizasyon şeması



İşlem sürelerinin tahmini için optimizasyon, görüntü tanıma, tahminleme gibi birçok alanda başarılı sonuçlar veren yapay sinir ağı kullanılmıştır.

Yapay sinir ağının gerçek sonuçlara yakınsamasını artırmak için yapay sinir ağı topolojisinin en iyisinin seçilmesi gerekmektedir. En iyi ağ topolojisinin seçimi (parametre optimizasyonu) ve yapay sinir ağında kullanılan parametrelerin etki ve etkileşimlerini öğrenebilmek amacıyla deney tasarımı yöntemi kullanılmıştır.

Deney tasarımı sonucunda elde edilen en iyi sonuç istatistiksel olarak %95 güven aralığında analiz edilmiştir.

Sonuç olarak; işletme için en uzun aşamalardan biri olan işlem sürelerinin toplanması aşaması tamamlanmıştır. Böylelikle işletme elde edilen tahmini işlem sürelerini kullanarak kapasite planlama ve çizelgeleme yapabilecektir.

Bundan sonraki bölümlerde uygulanacak adımlar aşağıdaki gibidir.

1. Bu Çalışmanın Niçin Yapıldığı (Çalışmanın Amacı)
2. Çalışma Metodolojisi
3. Matkap Tezgahı için parametre etkileşimlerinin belirlenmesi, yapay sinir ağının kullanımı ve sonuçların analizi
4. Freze Tezgahı için parametre etkileşimlerinin belirlenmesi, yapay sinir ağının kullanımı ve sonuçların analizi
5. Torna Tezgahı için taguchi deney tasarımı yöntemi, yapay sinir ağının kullanımı ve sonuçların analizi

### **5.3 Çalışmanın Yapılış Nedeni**

Uygulamanın makine üreten bir işletmede yapılmasından dolayı müşteri istekleri daha da önem kazanmıştır. Müşterinin isteği üzerine, revizyona uğrayan ya da işletmede daha önce üretilmemiş makinelerin imalatı söz konusudur. Bu durum ürün çeşidinin, süreçlerin sürekli değişmesine neden olmaktadır. Bir peçete makinesinin yaklaşık 600 teknik resim ve her bir teknik resimin de çok sayıda işlem adımından

oluştugu düşünöldüğünde sürecin karmaşıklığı daha da ortaya çıkmaktadır. Sürecin karmaşıklığı ve işletmenin spesifik ürün üretmemesi veri toplama aşamasını zorlaştırmaktadır. Dolayısıyla revizyona uğramış peçete makineleri için teslim süresindeki gecikme süreleri artmakta, tamamıyla yeni ürün için ise teslim aşaması daha da uzamaktadır. Bu gecikmeler müşteri ile işletme arasında yapılan anlaşma dahilinde işletmeye parasal anlamda külfet getirmektedir.

Tablo 5.2'de işletmenin ürettiği makineler ve bu makineler için müşteriyle yapılan sözleşme tarihleri, gerçekleşen tarihler ve bunun sonucunda ortaya çıkan gecikmeler ele alınmıştır. Tablodan da anlaşıldığı üzere işletmenin 12 makineden sadece 4 makineyi zamanında teslim etmesi, işletmenin düşük bir performansla çalıştığını göstermektedir.

Tablo 5.2: Sipariş edilen makineler için sözleşme, teslim tarihleri ve gecikmeler

Makine Tipi	Sözleşme Tarihi	Teslim Tarihi	Gerçekleşen Teslim Tarihi	Planlanan Gün	Gerçekleşen Gün	Geciken gün	Gecikme
Non-Wowen Bez Katlama Makinesi	16.09.2005	26.12.2005	17.01.2006	101	123	22	22%
En-Motion Havlu Makinesi	22.08.2005	31.10.2005	25.02.2006	70	187	117	167%
SDE Serisi 25x25 Peçete Makinesi (1 Adet)	17.11.2005	31.01.2006	18.03.2006	75	121	46	61%
TKL 160 Otomatik Tuv.Kağ.Mak. ve Nested Havlu ve Lam.Ünt.-Tek Gofrajlı (1 adet)	16.03.2006	31.03.2006	31.03.2006	15	15	0	0%
S Serisi 26,5x26,5 Peçete Makinesi (1 Adet)	16.01.2006	10.04.2006	10.04.2006	84	84	0	0%
SDE Serisi 30x30 Peçete Makinesi (1 Adet)	01.02.2006	28.04.2006	24.04.2006	86	82	0	-5%
Dispencer Havlu Makinesi (1 Adet)	24.11.2005	15.05.2006	25.05.2006	172	182	10	6%
SDE Serisi 25x25 Peçete Makinesi (1 Adet)	12.12.2005	10.04.2006	25.05.2006	119	164	45	38%
S Serisi 30x30 Peçete Makinesi (1 Adet)	27.02.2006	10.04.2006	12.06.2006	42	105	63	150%
ICM 400 Otomatik Paketleme Makinesi 330x330 Tekli Paket Yük. 40-50,80-90 (1 Adet)	23.07.2005	14.04.2006	02.06.2006	265	314	49	18%
SDE Serisi 33x33 Peçete Makinesi (1 Adet)	01.05.2006	30.06.2006	30.06.2006	60	60	0	0%
ICM 400 Otomatik Paketleme Makinesi 24 ve 30 luk Tekli Paket Yük.40-50 ve 80-90 ( 1 adet) 460	29.03.2006	21.07.2006	01.09.2006	112	150	38	34%



Performansın düşük olmasının ve siparişin zamanında teslim edilmemesinin en önemli nedeni ise, müşterinin istediği spesifikasyondaki peçete makinesinin üretimi için gerekli olan parçaların, makinelerdeki işlem süresinin bilinmemesinden kaynaklanmaktadır. Özellikle diğer peçete makinelerinden farklılık gösteren makinelerin tamamlanma süresini sezgisel olarak hesaplamak daha da zordur. İşletme sahibinin deneyimi sayesinde tahminlenen işlem sürelerinin yerine, verilerin bilimsel olarak toplanarak eksik işlem sürelerinin tamamlanması sağlanmalıdır.

## **5.4 Çalışma Metodolojisi**

### **5.4.1 İşlem süresine etki eden faktörlerin belirlenmesi**

Yapay sinir ağındaki girdiler için, makineler ve bu makinelerde çalışan işçilerin yaptıkları faaliyetler kameraya alınarak, bu konuda uzman kişilerle birlikte beyin fırtınası yöntemi uygulanarak işlem süresine etki eden faktörler belirlenmiştir. Her bir makine için toplam sekiz tane faktör belirlenmiştir. Sekiz faktör, sekiz giriş anlamına gelmektedir.

### **5.4.2 Veri toplama**

Verilerin bir kısmı beyin fırtınası sonucunda elde edilen faktörlere göre zaman etüdü çalışması yapılarak toplanmış, diğer kısmı ise teknik resimlerden ve işletme kayıtlarında bulunan işlem sürelerinden elde edilmiştir.

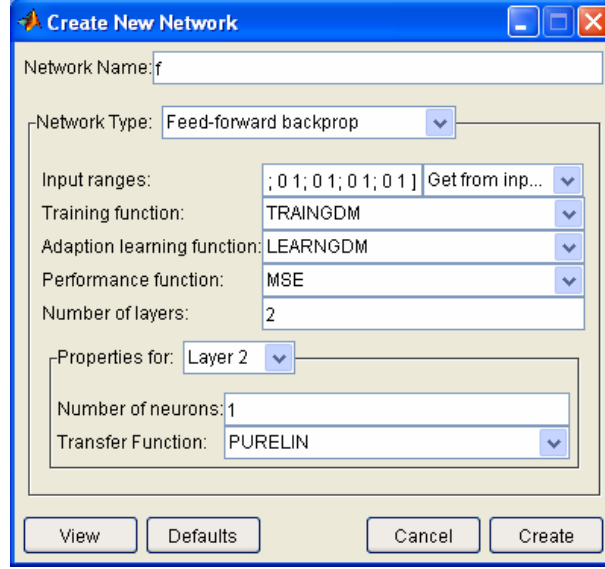
### **5.4.3 Yapay sinir ağı parametrelerinin belirlenmesi**

Bölüm 4.3'teki açıklamalar doğrultusunda Yapay sinir ağında kullanılmak üzere deneyde gizli katman sayısı, neuron (hücre) sayısı, öğrenme katsayısı ve momentum katsayısı olmak üzere 4 adet faktör (parametre) belirlenmiştir. Her bir faktör için ise 2 adet seviye belirlenmiştir. Özetle deneyde kullanılan faktör ve seviyeleri Tablo 5.3'de görülmektedir.

Tablo 5.3: Deneide kullanılan faktör ve seviyeler

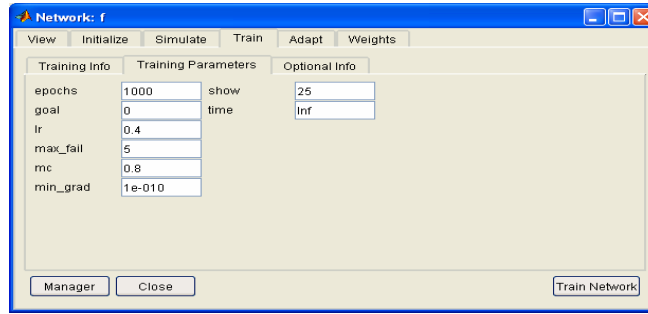
<b>FAKTÖR</b>	<b>SEVİYE 1</b>	<b>SEVİYE 2</b>
<b>Gizli katman sayısı</b>	1	3
<b>Neuron Hücre Sayısı</b>	1	3
<b>Öğrenme katsayısı</b>	0.2	0.4
<b>Momentum katsayısı</b>	0.6	0.8

- Yapay sinir ağı MATLAB (6.5) toolbox kullanılarak oluşturulmuştur
- Şekil 5.3'de görüldüğü üzere ağ yapısında geri beslemeli hata yayma modeli (geriye yayılım algoritması) kullanılmıştır. 8 tane giriş bulunmaktadır. Bu 8 giriş normalize edilerek yapay sinir ağına giriş verisi olarak girilmiştir.
- Ağırlıkları ve eşik değerlerini, momentum değerine bağlı olarak değiştiren bir eğitim fonksiyonu olan TRAINGDM kullanılmıştır, Öğrenme fonksiyonu olarakta LEARNGDM kullanılmıştır.
- Programdaki katman sayısı ise gizli katman ve çıkış katmanının toplam sayısını vermektedir.
- Saklı katmanlar için işlemci (aktivasyon fonksiyonu) yani iç işleyiş tetikleme işlemcisi olarak LOGSIGMOID ( $\text{logsig}(n)=1/(1+\exp(-n))$ ) fonksiyonu kullanılmıştır.
- Çıkış fonksiyonunun aktivasyon fonksiyonu PURELIN ( $\text{purelin}(n)=n$ ) (Linear Transfer Function) kullanılmıştır.
- Çıkış hücre katmanındaki hücre sayısı 1'dir.



Şekil 5.3: Ağ yapısı ve kullanılan fonksiyonlar

Şekil 5.4’de eğitim verileri ile ilgili bilgiler bulunmaktadır. İterasyon sayısı 1000, hedef 0 (sıfır) olarak hedeflenmiştir. Tablo 5.3’te gösterilmiş olan düzeylere göre öğrenme katsayısı, momentum katsayısı Y.S.A.’ya girdi olarak verilecektir. 25 iterasyonda bir sonuçlar ekranda görüntülenecektir.



Şekil 5.4: Kullanılan eğitim parametreleri

#### 5.4.4 En iyi ağ topolojisi

Yapay sinir ağında kullanılan en uygun parametrelerin bulunması, parametrelerin etkileri ve etkileşimlerinin belirlenmelidir. İlk aşamada belirlenen faktörler arasında etkileşim olup olmadığını karar vermek için tam faktöriyel deney yapılmıştır.

Bu 4 faktör (parametre) ve 2 düzey kullanıldığı zaman tam faktöriyel deney için  $2^4$  (16 tane) (Tablo 5.4) deney yapılmalıdır..

Tablo 5.4: Tam faktöriyel deneyde kullanılan parametre kombinasyonları

	<b>Gizli Katman Sayısı</b>	<b>Neuron Hücre Sayısı</b>	<b>Öğrenme Katsayısı</b>	<b>Momentum Katsayısı</b>
<b>1</b>	1	1	0.2	0.6
<b>2</b>	3	1	0.2	0.6
<b>3</b>	1	3	0.2	0.6
<b>4</b>	3	3	0.2	0.6
<b>5</b>	1	1	0.4	0.6
<b>6</b>	3	1	0.4	0.6
<b>7</b>	1	3	0.4	0.6
<b>8</b>	3	3	0.4	0.6
<b>9</b>	1	1	0.2	0.8
<b>10</b>	3	1	0.2	0.8
<b>11</b>	1	3	0.2	0.8
<b>12</b>	3	3	0.2	0.8
<b>13</b>	1	1	0.4	0.8
<b>14</b>	3	1	0.4	0.8
<b>15</b>	1	3	0.4	0.8
<b>16</b>	3	3	0.4	0.8

Örneğin; birinci denemede tüm parametrelerin birinci seviyeleri için deney yapılmıştır. Gizli katman sayısı parametresi için ilk seviye 1 tane gizli katman, gizli katmandaki neuron sayısı için ilk seviye 1 neuron (hücre), öğrenme katsayısı için ilk seviye 0.2, momentum terimi için ilk seviye de 0.6'dır. Onbeşinci deneme için ise sadece birinci parametre seviyesi 1, diğerler parametrelerin seviyesi 2'dir. Birinci parametrenin (Gizli Katman Sayısı) birinci seviyesi (1 gizli katman), ikinci parametre (gizli katmandaki neuron sayısı) için ikinci seviye (3 tane hücre), üçüncü parametre (öğrenme katsayısı) için ikinci seviye (0.4), dördüncü parametre olan momentum katsayısı için de birinci seviye yani 0.8 değeri kullanılmıştır.

Her bir makine için 100'den fazla örnek (ölçüm) alınmıştır. Bir kısmı eğitim verisi olarak bir kısmı ise test verisi olarak yapay sinir ağına girilmiştir. Her bir kombinasyon için beşer deneme yapılmıştır. Gerçekleştirilen toplam 80 deney yapılmıştır. (Matkap ve Freze Tezgahları için tam faktöriyel deney yapılmıştır. Etkileşim olmadığı ortaya çıktıktan sonra torna tezgahı için L8 deseni kullanılmıştır.)

#### **5.4.5 Yapay sinir ađının performansının ölçülmesi**

Performans fonksiyonu olarak hem test verileri hem de eğitim verileri için RMSE, MAPE, MAE değerleri hesaplanmıştır. Elde edilen sonuçların güvenilirliğinin ölçülmesi için %95 güven aralığında Z testi yapılmıştır.

### **5.5 Matkap Tezgahı İçin Parametre Etkileşimlerinin Belirlenmesi, Yapay Sinir Ağının Kullanımı ve Sonuçların Analizi**

#### **5.5.1 Matkap için belirlenen faktörler**

Malzeme cinsi: Malzeme cinsinin sert ve yumuşak olması durumu işlem süresini etkilemektedir. Toplam 7 tane malzeme türü ile çalışılmıştır. St 37, St 47, Ç 1030, Ç 1040, Ç 1045, Ç 4140, Alüminyum.

Malzeme boyutları: Malzeme boyutunun küçük ya da büyük olması işlem süresini etkilemektedir.

Yüzey hassasiyeti: Toleransın küçük olması işlem süresini artırmaktadır. Buna bađlı olarak kesme hızı düşürülecek, bu durum işlem süresini artıracaktır.

Delik sayısı: Parçada açılacak olan delik sayısı işlem süresini etkilemektedir. Sayının çok olması işlem süresini artırır.

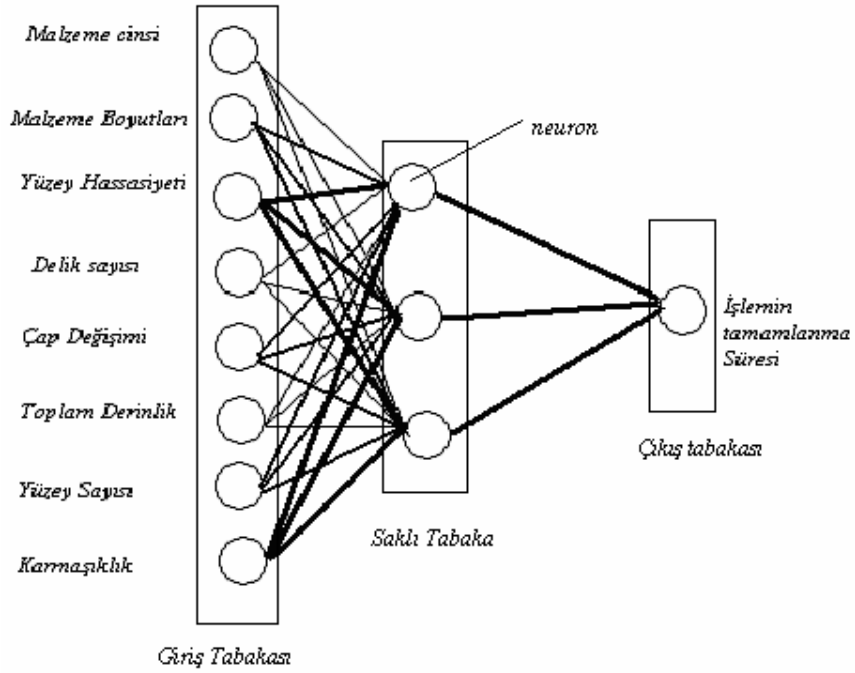
Çap deđişimi: Açılması gereken delik boyutlarının farklılık göstermesi hazırlık süresini artıracakđ için işlem süresini etkiler.

Toplam derinlik: Matkapın parçadan kaldıracakđ talaş miktarının artması işlem süresini de artırır.

Yüzey sayısı: Parçanın kaç yüzeyinde işlem yapılacađının bilinmesi gerekir. Eđer parçanın birden çok yüzeyinde işlem yapılacaksa parça mengeneden çıkartılır. Bu yüzden hazırlık süresi artacaktır.

Karmaşıklık: Parçanın şeklinin işleme açısından zor olması işlem süresini artırır.

Her bir makine için 8 tane faktör belirlenmiştir. (Bu sekiz faktör yapay sinir ağının girişlerini oluşturmaktadır.) Verilerin bir kısmı işletme tarafından kayıt altına alınmış süreler, bir kısmı ise bizzat ölçülerek elde edilmiştir. (Bu işlemlerin tamamlanma süreleri yapay sinir ağının çıktısını oluşturmaktadır.) Yapay Sinir Ağında kullanılan girişler ve çıkış Şekil 5.5'te gösterilmektedir.



Şekil 5.5: Yapay sinir ağında kullanılan girişler ve çıkış

### 5.5.2 Matkap tezgahı için parametre etkileşimleri ve optimizasyonu

En uygun ağ topolojisinin bulunması için deney tasarımı yapılmalıdır. İlk olarak etkileşimin olup olmadığının belirlenmesi gerekir. Bunun için tam faktöriyel deney yapılması uygundur.

#### 5.5.2.1 Matkap tezgahı için elde edilen sonuçlar

Tablo 5.5'de yapay sinir ağının eğitimi için kullanılan gerçek verilerle yapay sinir ağının ürettiği sonuçlar arasındaki fark dakika cinsinden hesaplanmıştır.

Tablo 5.5: Eğitim verilerinin sonuçları

Deneyler	Denemeler					Toplam	Ortalama
	1	2	3	4	5		
1	1425	1813	2380	1958	2399	9974	1994.81
2	1929	1895	1862	2155	2440	10282	2056.35
3	1869	2013	1869	2173	1512	9436	1887.23
4	1871	2118	2360	2434	2182	10965	2193.03
5	1863	2084	2424	2408	2375	11153	2230.61
6	1933	2160	2379	2114	2182	10768	2153.63
7	1666	1335	2052	1282	1335	7669	1533.83
8	2193	2373	1966	1911	1774	10216	2043.21
9	2428	2338	2148	1663	2367	10944	2188.87
10	2428	2328	1988	2405	2265	11414	2282.84
11	1394	1678	2393	1734	2100	9298	1859.70
12	2149	2247	2328	2008	2129	10862	2172.34
13	2176	2193	2366	2384	2427	11546	2309.18
14	2306	2242	2243	2400	2068	11260	2252.01
15	1300	2099	1835	1320	1995	8637	1727.41
16	2424	1500	1649	2091	2267	9931	1986.16

Test için kullanılan gerçek verilerle yapay sinir ağının ürettiği sonuçlar arasındaki fark dakika cinsinden hesaplanmıştır. Bu sonuçlar da Tablo 5.6’da verilmiştir.

Tablo 5.6: Test verileri sonuçları


Deneyler	Denemeler					Toplam	Ortalama
	1	2	3	4	5		
1	341	456	612	538	557	2503	500.69
2	558	743	423	734	580	3039	607.74
3	346	530	569	681	523	2649	529.72
4	565	548	635	636	618	3002	600.44
5	491	582	639	681	628	3022	604.44
6	561	583	634	489	545	2811	562.27
7	329	376	553	389	447	2094	418.76
8	673	655	655	511	434	2927	585.50
9	631	607	483	551	658	2930	585.96
10	628	691	513	651	663	3146	629.25
11	296	454	542	373	538	2203	440.67
12	575	636	643	462	541	2856	571.12
13	525	523	559	628	597	2832	566.30
14	654	567	643	613	660	3136	627.30
15	269	546	421	332	552	2120	423.96
16	617	417	487	544	622	2687	537.34

### 5.5.2.2 Matkap tezgahı için belirlenen en önemli faktörler

Tablo 5.5 ve Tablo 5.6’deki sonuçlardan yola çıkarak MINITAB 13 programında deney tasarımı yöntemi uygulanmıştır. Elde edilen sonuçlar aşağıdaki gibidir.


Parametre MINITAB’ın çıktısı olarak elde edilen Şekil 5.6’dan  $\alpha = 0.05$  değerinde en önemli etkilerin sırasıyla A ile gösterilen gizli katman sayısının ve B ile gösterilen

neuron sayısının olduğu ortaya çıkmıştır. Gizli katman sayısının etkisinin sayısal değeri 81.40, neuron sayısının etkisinin sayısal değeri ise -72.05'dir.(Ek 1'de gösterilmiştir)



Şekil 5.6: Matkap tezgahı için  $\alpha = 0.05$  düzeyindeki en önemli etki

Aşağıda bulunan Şekil 5.7'de tüm ana faktörler ve etkileşimlerin önem sıraları görülmektedir. Daha önceden de belirtildiği gibi gizli katman sayısı (A) en önemli etkiye sahiptir. Gizli katmandaki neuron sayısı (B) ikinci öneme sahip parametredir. En az etkiye sahip olan ise momentum ve öğrenme katsayısı etkileşimidir.

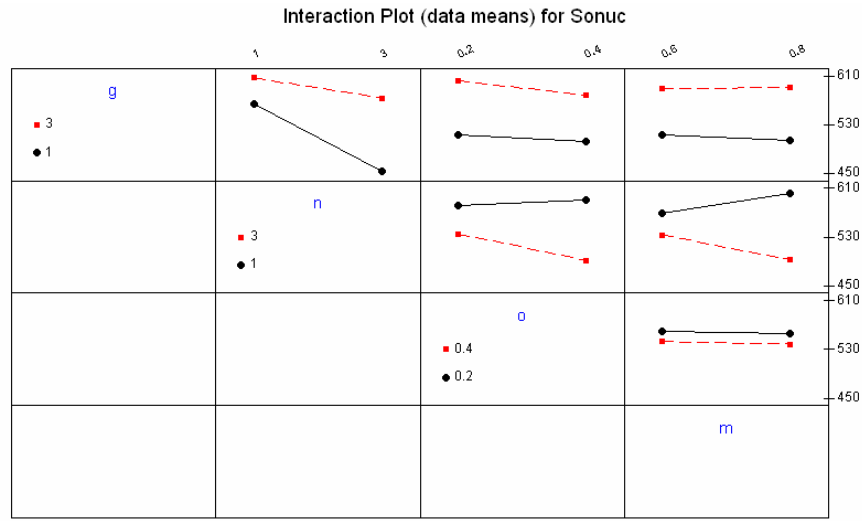


Şekil 5.7: Matkap tezgahı için pareto diyagramı



### 5.5.2.3 Matkap tezgahı için parametrelerin etkileşimlerinin analizi

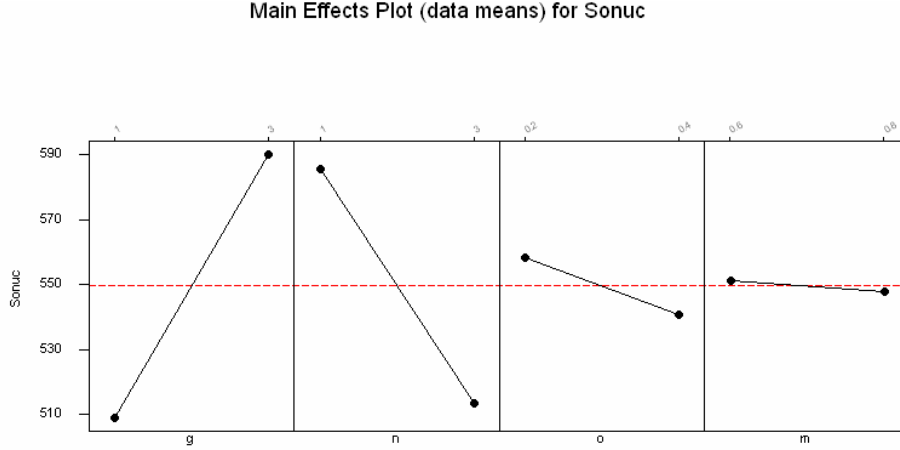
Aşağıdaki Şekil 5.8’de görüldüğü üzere gizli katman sayısı-öğrenme katsayısı etkileşimi, gizli katman sayısı-momentum katsayısı arasındaki etkileşimi, neuron sayısı-öğrenme katsayısı etkileşimi, öğrenme katsayısı-momentum katsayısı etkileşimi için gösterilen doğruların aşağı yukarı paralel oldukları görülmektedir. Bu, etkileşimin olmadığı anlamına gelir. Neuron sayısı-momentum katsayısı, gizli katman sayısı-neuron sayısı arasında etkileşim var gözükse de  $\alpha=0.05$  seviyesinde (Şekil 5.7’de görüldüğü üzere) etkileşimin önemli olmadığı görülmüştür.



Şekil 5.8: Matkap tezgahı için faktörlerin etkileşimleri

### 5.5.2.4 Matkap tezgahı için en iyi faktör seviyeleri kombinasyonu

Parametre optimizasyonundaki amaç hatayı azaltmaktır. Yapay sinir ağından elde edilen sonuçlarla gerçek veriler arasındaki farkın en az olması istenir. Dolayısıyla en düşük değeri sağlayan seviyeler bizim için en iyi değerlerdir. Deney tasarımı sonuçlarından ortaya çıkan (Şekil 5.9) gizli katman sayısı olarak 1, neuron sayısı olarak 3, öğrenme katsayısı olarak 0.4, momentum katsayısı 0.8, bizim için en iyi seviyelerdir.



Şekil 5.9: Matkap tezgahı için ana etkiler için en iyi düzeyler


### 5.5.3 Matkap tezgahı için elde edilen en iyi sonuç:

Onbeşinci kombinasyon olan gizli katman sayısı 1 gizli katmandaki neuron sayısı 3 öğrenme katsayısı 0.4 ve momentum katsayısı 0.8 en iyi sonucu sağlamıştır. Bu sonuç deney tasarımı sonucunda elde ettiğimiz sonuçlar (Şekil 5.9 Ana etkiler için en iyi düzeyler) ile aynıdır. 80 tane deney sonucunda, en düşük değer;

Test için yapılan denemeler arasında 269 dakika (Tablo 5.6) bulunmuştur.


Beş denemenin ortalaması olarak test için en düşük değer 423.96'dır.

Şekil 5.10'da görüldüğü gibi veriler 1000 iterasyonluk eğitime tabi tutulmuş ve toplam karesel hata değeri 100'üncü iterasyona gelmeden önce kararlı duruma gelmiştir ve azalarak devam etmiştir.



Şekil 5.10: Toplam karesel hatanın iterasyona bağlı değişimi

Y.S.A. 'nın eğitilmesi için kurulan ağ yapısı Şekil 5.11'de verilmiştir.



Şekil 5.11: Matkap tezgahı için en iyi sonuç veren ağ yapısı

Eğitim sonucunda elde edilen vektörler

Giriş katmanı ağırlık vektörü:

$$IW\{1,1\} = \begin{bmatrix} -0.78327 & 3.85781 & 0.0753 & 3.7224 & -2.4706 & -1.5507 & 1.1426 & -0.85855, \\ 2.8725 & 3.4366 & 2.7976 & 0.86024 & 0.61716 & 1.6773 & 2.3342 & 1.5925, \\ 2.5096 & -1.282 & -2.7398 & 1.1267 & 3.7643 & -0.99323 & -0.97043 & 2.8628 \end{bmatrix} \quad (4.1)$$

Çıkış katmanı ağırlık vektörü:

$$IW\{2,1\} = [0.022654 \ 0.35104 \ 0.077845] \quad (4.2)$$


Giriş katmanı eşik vektörleri:

$$b\{1\} = \begin{bmatrix} 0.93567, \\ -8.1363, \\ 0.63573 \end{bmatrix} \quad (4.3)$$

Çıkış katmanı eşik vektörü:

$$b\{2\} = [0.1972] \quad (4.4)$$

olarak belirlenmiştir.



Şekil 5.12: Matkap tezgahı için elde edilen en iyi eğitim sonuçları


100 tane veri eğitim için kullanılmıştır ve Şekil 5.12’de gerçek verilerle yapay sinir ağından elde edilen sonuçları aynı alana Matlab 6.5’te çizdirilmiştir. Gerçek veriler kırmızı, Y.S.A.’nın verdiği sonuçlar mavi renkle gösterilmiştir. Böylelikle yapay sinir ağı olaylar arasındaki ilişkileri eğitim verileriyle öğrenmiştir.

Eğitim için toplam 100 adet örnek alınmıştır. Matkap tezgahı için 80 deneme içerisinde gerçek verilere en yakın olan tahmini değerlerle gerçek veriler Tablo 5.7’de gösterilmiştir.

Tablo 5.7: Matkap tezgahı için elde edilen en iyi eğitim sonuçları

	Eğitim Verisi Çıktı	Eğitim Verisi Çıktı (Y.S.A.)	Sapma	Mutlak sapma										
1	200	130	70	70	35	80	83	-3	3	68	50	80	-30	30
2	20	53	-33	33	36	110	96	14	14	69	40	57	-17	17
3	120	94	26	26	37	120	113	7	7	70	70	58	12	12
4	65	63	2	2	38	70	67	3	3	71	55	65	-10	10
5	50	60	-10	10	39	65	69	-4	4	72	55	71	-16	16
6	72	69	3	3	40	80	78	2	2	73	100	116	-16	16
7	100	116	-16	16	41	100	84	16	16	74	80	75	5	5
8	70	73	-3	3	42	70	71	-1	1	75	80	78	2	2
9	45	99	-54	54	43	100	72	28	28	76	20	52	-32	32
10	130	123	7	7	44	120	104	16	16	77	100	96	4	4
11	65	119	-54	54	45	90	71	19	19	78	130	83	47	47
12	65	66	-1	1	46	85	107	-22	22	79	90	111	-21	21
13	100	83	17	17	47	65	62	3	3	80	120	125	-5	5
14	90	98	-8	8	48	100	103	-3	3	81	100	126	-26	26
15	140	123	17	17	49	80	79	1	1	82	140	115	25	25
16	130	123	7	7	50	70	65	5	5	83	55	70	-15	15
17	135	119	16	16	51	65	61	4	4	84	80	75	5	5
18	120	120	0	0	52	100	103	-3	3	85	120	118	2	2
19	90	84	6	6	53	90	102	-12	12	86	80	83	-3	3
20	45	61	-16	16	54	75	70	5	5	87	70	61	9	9
21	70	64	6	6	55	150	129	21	21	88	90	86	4	4
22	100	53	47	47	56	120	115	5	5	89	60	76	-16	16
23	65	67	-2	2	57	70	85	-15	15	90	60	62	-2	2
24	80	95	-15	15	58	55	57	-2	2	91	120	122	-2	2
25	90	89	1	1	59	85	72	13	13	92	140	123	17	17
26	120	126	-6	6	60	70	63	7	7	93	55	68	-13	13
27	135	128	7	7	61	80	67	13	13	94	70	64	6	6
28	90	122	-32	32	62	110	118	-8	8	95	80	70	10	10
29	145	107	38	38	63	70	68	2	2	96	40	56	-16	16
30	55	58	-3	3	64	85	113	-28	28	97	70	65	5	5
31	80	70	10	10	65	120	123	-3	3	98	120	111	9	9
32	100	111	-11	11	66	140	128	12	12	99	90	84	6	6
33	80	80	0	0	67	120	117	3	3	100	105	123	-18	18
34	90	116	-26	26										1300

1000 iterasyon sonucunda performans, minimum kareler ortalaması 0.00881626 (normalize edilmiş veriler üzerinden) ve 100 tane veri için mutlak sapma 1300 dakika olarak hesaplanmıştır. Her bir işlem süresi için ortalama olarak 13 dakikadır.



Şekil 5.13: Matkap tezgahı için elde edilen en iyi test sonuçları

Yapay sinir ağı olaylar arasındaki ilişkileri öğrendikten sonra daha sonra hiç görmediği örnekler hakkında öğrendikleri bilgileri kullanarak tahminde bulunmuştur. Yine Y.S.A.'na verilen test örnekleri ve gerçek veriler Şekil 5.13'de verilmiştir. Gerçek veriler kırmızı, Y.S.A.'nın verdiği sonuçlar mavi renkle gösterilmiştir.

Tablo 5.8: Matkap tezgahı için elde edilen en iyi test sonuçları

	Test Verisi Çıktı	Test Verisi Çıktı (Y.S.A.)	Sapma	Mutlak Sapma										
1	73	60	13	13	14	84	73	11	11	27	104	102	2	2
2	91	93	-2	2	15	85	71	14	14	28	72	64	8	8
3	108	116	-8	8	16	99	91	8	8	29	67	64	3	3
4	75	69	6	6	17	99	98	0	0	30	94	83	11	11
5	77	72	5	5	18	109	120	-10	10	31	98	96	2	2
6	112	122	-10	10	19	125	112	12	12	32	125	125	0	0
7	99	107	-7	7	20	127	124	3	3	33	84	95	-11	11
8	86	67	19	19	21	87	85	2	2	34	113	97	15	15
9	113	101	13	13	22	53	57	-4	4	35	100	111	-11	11
10	66	68	-2	2	23	89	85	4	4	36	94	101	-7	7
11	67	68	-2	2	24	120	122	-3	3	37	72	68	4	4
12	104	114	-11	11	25	58	60	-2	2	38	88	84	4	4
13	81	72	8	8	26	44	56	-12	12	<b>Toplam</b>				269

Tablo 5.8'de görüldüğü üzere test için uygulanan yapay sinir ağı ve gerçek veriler arasında mutlak sapma 269 dakika olarak hesaplanmıştır. Bu da yaklaşık olarak her bir işlem süresi için 7 dakikadır. (Yapay sinir ağından elde edilen sonuçların ortalaması 89 dakikadır.)

#### 5.5.4 Matkap tezgahı için istatistiksel analiz

Tablo 5.9’da matkap tezgahı için elde edilmiş olan veriler istatistiksel olarak analiz edilmiştir.

Tablo 5.9: Matkap tezgahı için test verilerinin istatistiksel analizi

	Test Verisi Çıktı	Sapma $\sigma$	Sapmanın karesi	Test Verisi Çıktı (Y.S.A.)	Sapma	Sapmanın Karesi
1	73	-18	318	60	-29	833
2	91	1	0	93	5	21
3	108	18	307	116	27	727
4	75	-15	227	69	-19	373
5	77	-14	184	72	-17	275
6	112	21	460	122	34	1124
7	99	9	78	107	18	316
8	86	-4	18	67	-21	457
9	113	23	528	101	12	141
10	66	-24	589	68	-21	423
11	67	-24	574	68	-21	423
12	104	13	173	114	26	660
13	81	-10	96	72	-17	275
14	84	-7	45	73	-16	260
15	85	-6	36	71	-18	320
16	99	9	80	91	2	6
17	99	8	66	98	10	92
18	109	19	354	120	31	945
19	125	34	1172	112	24	559
20	127	37	1335	124	35	1245
21	87	-4	12	85	-4	15
22	53	-38	1414	57	-32	1001
23	89	-2	3	85	-4	15
24	120	29	847	122	33	1114
25	58	-33	1059	60	-29	816
26	44	-47	2168	56	-33	1073
27	104	13	180	102	13	165
28	72	-18	341	64	-24	595
29	67	-24	572	64	-25	618
30	94	3	11	83	-6	36
31	98	7	54	96	7	46
32	125	34	1169	125	36	1291
33	84	-7	47	95	6	33
34	113	22	499	97	9	76
35	100	9	88	111	22	478
36	94	3	11	101	12	139
37	72	-19	344	68	-20	417
38	88	-3	6	84	-5	23
<b>Toplam</b>	<b>3438</b>		<b>15464</b>	<b>3373</b>		<b>17425</b>
<b>Ortalama</b>	<b>90</b>		<b>407</b>	<b>89</b>		<b>459</b>

$$z = \frac{\bar{x}_1 - \bar{x}_2 - (\mu_1 - \mu_2)}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}} \quad (5.5)$$

$$z = ((90 - 89 - 0) / \sqrt{(15464/38) + (17425/38)}) = 0.058 \quad (5.6)$$

Test istatistiđi=0.058

% 95 güven düzeyinde(z=1.645) Yapay sinir ađının verdiđi sonuçlar ile gerçek veriler arasında fark olmadıđı yani  $H_0$  ( $H_0: \mu_1 - \mu_2 =$  hipotez deđeri = 0) boş hipotezinin kabul edildiđi görölmektedir. Sonuç olarak istatistiksel olarak farkın görölmediđi ortaya çıkmıştır.

## 5.6 Freze Tezgahı İçin Parametre Etkileşimlerinin Belirlenmesi, Yapay Sinir Ađının Kullanımı ve Sonuçların Analizi

Daha önceki kısımda matkap tezgahı için tam faktöriyel deney tasarımı yapılmış, yapay sinir ađı yaklaşımıyla işlem süreleri ve işlem süreleri %95 güven aralığında hipotez testi ile tutarlılıđı belirlenerek tahmin edilmiştir. Tam faktöriyel deney tasarımının yapılmasının nedeni parametreler arasında etkileşiminin olup olmadıđının tespiti içindir. Tam faktöriyel deney tasarımı sonucundan parametreler arasında etkileşiminin görölmediđi ortaya çıkmıştır. Ancak %95 güven aralıđı %90 veya daha düşük güven aralıkları için etkileşim olduđu ortaya çıkmıştır. Bu yüzden freze tezgahı için de tam faktöriyel deney yapılması uygundur.

### 5.6.1 Freze ve torna tezgahı için belirlenen faktörler

Malzeme cinsi: Malzeme cinsinin sert ve yumuşak olması durumu işlem süresini etkilemektedir. Toplam 7 tane malzeme türü ile çalışılmıştır. St 37, St 47, Ç1030, Ç1040, Ç1045, Ç4140, Alüminyum.



Malzeme boyutları: Malzeme boyutunun küçük ya da büyük olması işlem süresini etkilemektedir.

Yüzey hassasiyeti: Toleransın küçük olması işlem süresini artırmaktadır. Buna bağlı olarak kesme hızı düşürülecek, bu durum işlem süresini artıracaktır.

Toplam ilerleme: Parçanın uzunluğundan alınacak olan talaş miktarı işlem süresini etkilemektedir. Toplam ilerleme miktarının artması işlem süresini artırır.

Toplam derinlik: Frezenin, Parçanın boyundan kaldıracığı talaş miktarı işlem süresini etkiler. freze ucunun parçanın içine girdiği derinlik arttıkça talaş kaldırma zorlaşacak, zaman uzayacaktır.

Toplam genişlik: Malzemenin üzerinde açılacak olan kanalın genişliği elimizdeki uygun olan ucun çapından daha büyük olabilir. Bu durumda ucun farklı eksenlerde hareket etmesi de gerekecektir. Bu nedenle süre uzayacaktır.

İşlem sayısı: Parçada kaç tane işlem yapılacağıın bilinmesi gerekir. Eğer parçanın birden çok işlem yapılacaksa parça mendenen çıkartılır. Kısacası hazırlık süresi artacaktır.

Karmaşıklık: Parçanın şeklinin işleme açısından zor olması işlem süresini artırır.

## **5.6.2 Freze tezgahı için parametre etkileşimleri ve optimizasyonu**

%95 güven aralığı %90 veya daha düşük güven aralıkları için etkileşim olduğu ortaya çıkmıştır. Bu yüzden freze tezgahı içinde tam faktöriyel deney yapılmıştır.

### **5.6.2.1 Freze tezgahı için elde edilen sonuçlar**

Yapay sinir ağının eğitimi için kullanılan gerçek verilerle yapay sinir ağının ürettiği sonuçlar arasındaki fark dakika cinsinden hesaplanmıştır. Bu sonuçlar da Tablo 5.10'da verilmiştir.

Tablo 5.10: Eğitim verilerinin sonuçları

Deneyler	Denemeler					Toplam	Ortalama
	1	2	3	4	5		
1	1 871	2 069	2 409	2 345	2 392	11 085	2 217
2	2 447	2 221	2 535	2 309	2 549	12 061	2 412
3	1 977	1 987	2 436	2 093	1 845	10 338	2 068
4	2 020	2 498	2 260	2 312	2 432	11 522	2 304
5	2 465	1 909	2 491	2 528	2 354	11 747	2 349
6	2 262	2 276	2 375	2 543	2 084	11 540	2 308
7	2 352	2 060	1 800	2 320	1 693	10 226	2 045
8	2 273	2 409	2 035	2 093	1 998	10 809	2 162
9	2 003	2 176	2 172	2 257	2 533	11 140	2 228
10	2 273	2 275	1 861	2 459	2 550	11 417	2 283
11	2 028	2 522	1 819	1 853	2 444	10 665	2 133
12	2 470	2 346	2 520	2 391	2 087	11 814	2 363
13	2 502	2 026	2 086	2 328	2 383	11 326	2 265
14	2 534	2 192	2 529	2 232	2 352	11 839	2 368
15	2 032	1 498	1 840	2 266	1 877	9 512	1 902
16	1 927	2 117	2 175	2 426	2 129	10 774	2 155

Test için kullanılan gerçek verilerle yapay sinir ağının ürettiği sonuçlar arasındaki fark dakika cinsinden hesaplanmıştır. Bu sonuçlar da Tablo 5.11’de verilmiştir.


Tablo 5.11: Test verileri sonuçları

Deneyler	Denemeler					Toplam	Ortalama
	1	2	3	4	5		
1	521	487	631	563	554	2 755	551
2	522	614	592	573	604	2 906	581
3	486	546	625	678	430	2 764	553
4	450	632	581	618	577	2 857	571
5	538	491	569	580	635	2 812	562
6	556	634	643	652	567	3 053	611
7	546	565	536	700	535	2 882	576
8	589	623	578	559	572	2 921	584
9	496	578	584	566	571	2 796	559
10	600	724	468	606	676	3 075	615
11	516	596	495	479	666	2 753	551
12	572	595	578	527	597	2 869	574
13	620	566	540	503	719	2 948	590
14	584	569	585	660	572	2 969	594
15	611	368	505	638	443	2 564	513
16	514	528	661	550	632	2 885	577

Tablo 5.10 ve Tablo 5.11’deki sonuçlardan yola çıkarak MINITAB 13 programında deney tasarımı yöntemi uygulanmıştır. Elde edilen sonuçlar aşağıdaki gibidir.

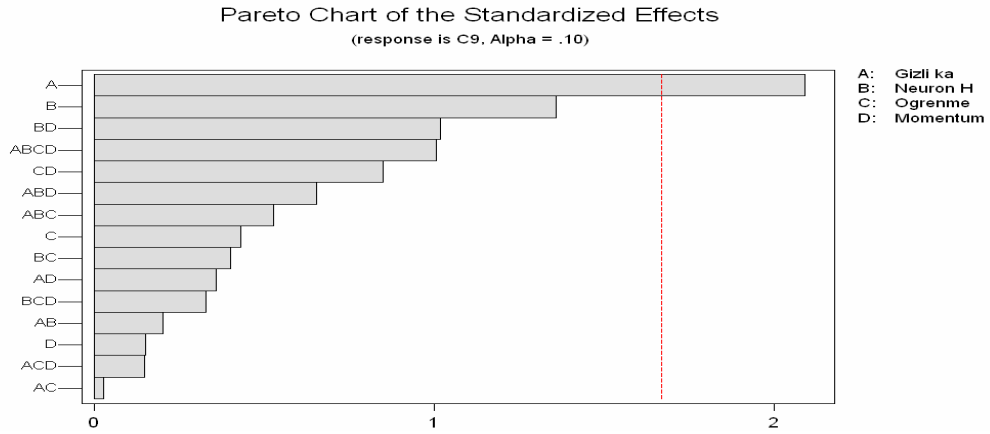
### 5.6.2.2 Freze tezgahı için belirlenen en önemli faktörler

Şekil 5.14’den  $\alpha=0.10$  değerinde en önemli etkinin A ile gösterilen gizli katman sayısının olduğu ortaya çıkmıştır. Gizli katman sayısının etkisinin sayısal değeri 31.56’dır. (Ek 2) Bu değer diğer ana etkiler ve etkileşimler arasındaki en büyük sayıdır.



Şekil 5.14: Freze tezgahı için  $\alpha = 0.10$  düzeyindeki en önemli etki


Aşağıda bulunan Şekil 5.15’de tüm ana faktörler ve etkileşimlerin önem sıraları görülmektedir. Daha önceden de belirtildiği gibi gizli katman sayısı (A) en önemli etkiye sahiptir. En az etkiye sahip olan ise gizli katman ve öğrenme katsayısı etkileşimidir.



Şekil 5.15: Freze tezgahı için Pareto diyagramı

### 5.6.2.3 Freze tezgahı için parametreler etkileşimlerinin analizi:


Aşağıdaki Şekil 5.16’da görüldüğü üzere gizli katman-neuron sayısı etkileşimi, gizli katman-öğrenme katsayısı arasındaki etkileşim, gizli katman-momentum katsayısı etkileşimi, neuron sayısı-öğrenme katsayısı etkileşimi için gösterilen doğruların aşağı yukarı paralel oldukları görülmektedir. Bu, etkileşimin olmadığı anlamına gelir. Öğrenme katsayısı-momentum katsayısı ve neuron sayısı-momentum katsayısı arasında etkileşim var gözükse de  $\alpha = 0.10$  seviyesinde (Şekil 5.15’de görüldüğü üzere) etkileşimin önemli olmadığı görünmüştür.



Şekil 5.16: Freze tezgahı için faktörlerin etkileşimleri

#### 5.6.2.4 Freze tezgahı için en iyi faktör seviyeleri kombinasyonu

Deney tasarımı sonuçlarından ortaya çıkan (Şekil 5.17) gizli katman sayısı olarak 1, neuron sayısı olarak 3, öğrenme katsayısı olarak 0.2, momentum katsayısı 0.8, bizim için en iyi seviyelerdir.



Şekil 5.17: Freze tezgahı için ana etkiler için en iyi düzeyler


#### 5.6.3 Freze tezgahı için elde edilen en iyi sonuç

Onbeşinci kombinasyon olan gizli katman sayısı 1 gizli katmandaki neuron sayısı 3 öğrenme katsayısı 0.2 ve momentum katsayısı 0.8 en iyi sonucu sağlamıştır. Bu sonuç deney tasarımı sonucunda elde ettiğimiz sonuçlar (Şekil 5.17 Freze tezgahı için ana etkiler için en iyi düzeyler) ile aynıdır. 80 tane deney sonucunda, en düşük değer;

Test için yapılan denemeler arasında 368 (Tablo 5.11) bulunmuştur.


Beş denemenin ortalaması olarak test için en düşük değer 513'dir.

Şekil 5.18’de görüldüğü gibi veriler 1000 iterasyonluk eğitime tabi tutulmuş ve toplam karesel hata değeri 100’üncü iterasyona gelmeden önce kararlı duruma gelmiştir ve azalarak devam etmiştir.



Şekil 5.18: Toplam karesel hatanın iterasyona bağlı değişimi

Y.S.A. ‘nın eğitilmesi için kurulan ağ yapısı Şekil 5.19’da verilmiştir.



Şekil 5.19: Freze tezgahı için en iyi sonuç veren ağ yapısı

Giriş katmanı ağırlık vektörü:

$$IW\{1,1\} = \begin{bmatrix} -2.573 & 1.7653 & 2.0677 & -2.9542 & -2.6497 & 1.4374 & -1.2689 & 2.9607 \\ -2.7268 & -0.59428 & -3.299 & -1.5749 & -1.9879 & -2.6827 & -2.512 & -0.34736 \\ 0.17033 & 2.8873 & 1.13 & 3.522 & 3.043 & 2.711 & 0.2735 & 0.28654 \end{bmatrix} \quad (5.7)$$

Çıkış katmanı ağırlık vektörü:

$$LW\{2,1\} = \begin{bmatrix} 0.0087846 \\ -0.36129 \\ 0.086282 \end{bmatrix} \quad (5.8)$$

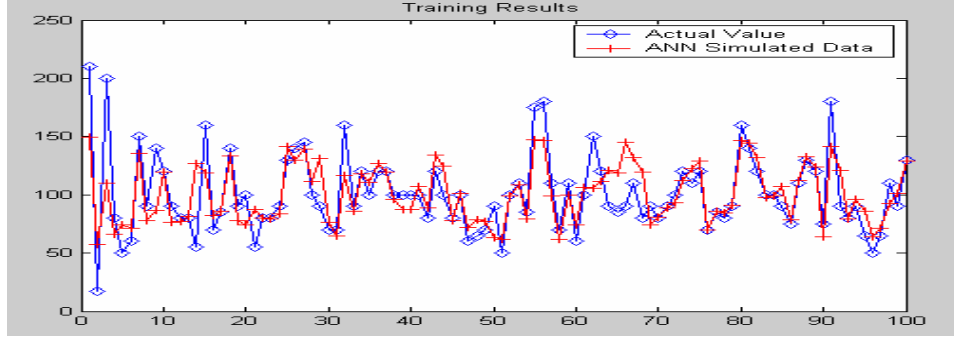
Giriş katmanı eşik vektörleri:

$$b\{1\} = \begin{bmatrix} 3.0571 \\ 8.2228 \\ -4.3881 \end{bmatrix} \quad (5.9)$$

Çıkış katmanı eşik vektörü:

$$b\{2\} = [0.61991] \quad (5.10)$$

olarak belirlenmiştir.



Şekil 5.20: Freze tezgahı için elde edilen en iyi eğitim sonuçları


100 tane veri eğitim için kullanılmıştır ve şekil 5.20’de gerçek verilerle yapay sinir ağından elde edilen sonuçlar görülmektedir. Gerçek veriler kırmızı, Y.S.A.’nın verdiği sonuçlar mavi renkle gösterilmiştir. Böylelikle yapay sinir ağı olaylar arasındaki ilişkileri eğitim verileriyle öğrenmiştir.

Eğitim için toplam 100 adet örnek alınmıştır. Freze tezgahı için 80 deneme içerisinde gerçek verilere en yakın olan tahmini değerlerle gerçek veriler Tablo 5.12’de gösterilmiştir.

Tablo 5.12 Freze tezgahı için elde edilen en iyi eğitim sonuçları

	Eğitim Verisi Çıktı	Eğitim Verisi Çıktı (Y.S.A.)	Sapma	Mutlak sapma										
1	210	150	60	60	35	100	111	-11	11	68	80	120	-40	40
2	17	57	-40	40	36	120	127	-7	7	69	90	75	15	15
3	200	110	90	90	37	120	120	0	0	70	80	81	-1	1
4	80	66	14	14	38	100	96	4	4	71	90	89	1	1
5	50	74	-24	24	39	100	87	13	13	72	100	93	7	7
6	60	71	-11	11	40	100	87	13	13	73	120	113	7	7
7	150	136	14	14	41	100	107	-7	7	74	110	122	-12	12
8	90	78	12	12	42	80	89	-9	9	75	120	129	-9	9
9	140	87	53	53	43	120	134	-14	14	76	70	70	0	0
10	120	120	0	0	44	100	124	-24	24	77	85	86	-1	1
11	90	76	14	14	45	80	78	2	2	78	80	84	-4	4
12	80	77	3	3	46	100	101	-1	1	79	90	91	-1	1
13	80	82	-2	2	47	60	72	-12	12	80	160	147	13	13
14	55	127	-72	72	48	65	78	-13	13	81	140	144	-4	4
15	160	118	42	42	49	70	77	-7	7	82	120	132	-12	12
16	70	82	-12	12	50	90	63	27	27	83	100	98	2	2
17	85	86	-1	1	51	50	62	-12	12	84	100	99	1	1
18	140	134	6	6	52	100	99	1	1	85	90	107	-17	17
19	90	78	12	12	53	110	109	1	1	86	75	79	-4	4
20	100	74	26	26	54	85	80	5	5	87	110	112	-2	2
21	55	87	-32	32	55	175	147	28	28	88	130	132	-2	2
22	80	80	0	0	56	180	146	34	34	89	120	124	-4	4
23	80	79	1	1	57	110	99	11	11	90	75	64	11	11
24	90	84	6	6	58	70	62	8	8	91	180	141	39	39
25	130	142	-12	12	59	110	100	10	10	92	90	121	-31	31
26	140	129	11	11	60	60	74	-14	14	93	80	79	1	1
27	145	139	6	6	61	100	106	-6	6	94	90	96	-6	6
28	100	111	-11	11	62	150	106	44	44	95	65	86	-21	21
29	90	131	-41	41	63	120	111	9	9	96	50	64	-14	14
30	70	76	-6	6	64	90	121	-31	31	97	65	72	-7	7
31	70	65	5	5	65	85	118	-33	33	98	110	93	17	17
32	160	117	43	43	66	90	145	-55	55	99	90	101	-11	11
33	90	86	4	4	67	110	132	-22	22	100	130	129	1	1
34	120	118	2	2										1498

1000 iterasyon sonucunda performans, minimum kareler ortalaması 0.0153441 (normalize edilmiş veriler üzerinden) ve 100 tane veri için mutlak hata 1498 dakika olarak hesaplanmıştır. Bu yaklaşık olarak her bir işlem süresi için 15 dakikadır.



Şekil 5.21: Freze tezgahı için elde edilen en iyi test sonuçları

Yapay sinir ağı olaylar arasındaki ilişkileri öğrendikten sonra daha sonra hiç görmediği örnekler hakkında öğrendikleri bilgileri kullanarak tahminde bulunmuştur. Yine Y.S.A.'na verilen test örnekleri ve gerçek veriler Şekil 5.21'de verilmiştir. Gerçek veriler kırmızı, Y.S.A.'nın verdiği sonuçlar mavi renkle gösterilmiştir.

Tablo 5.13: Freze tezgahı için elde edilen en iyi eğitim sonuçları

	test verisi çıktı	test verisi çıktı (Y.S.A.)	Sapma	mutlak sapma										
1	100	86	14	14	12	125	135	-10	10	23	120	120	0	0
2	111	104	7	7	13	90	85	5	5	24	90	76	14	14
3	105	98	7	7	14	90	85	5	5	25	80	77	3	3
4	80	89	-9	9	15	115	128	-13	13	26	80	82	-2	2
5	95	73	22	22	16	75	64	11	11	27	55	127	-72	72
6	120	133	-13	13	17	80	71	9	9	28	160	118	42	42
7	130	139	-9	9	18	98	98	0	0	29	70	82	-12	12
8	105	107	-2	2	19	116	133	-17	17	30	85	86	-1	1
9	110	114	-4	4	20	100	108	-8	8	31	140	134	6	6
10	87	81	6	6	21	85	81	4	4	32	90	78	12	12
11	85	80	5	5	22	66	64	2	2	33	100	74	26	26
														368

Test için uygulanan yapay sinir ağı ve gerçek veriler arasında mutlak hata 368 dakika (Tablo 5.13) olarak hesaplanmıştır. Bu da yaklaşık olarak her bir işlem süresi için 11 dakikadır. (Yapay sinir ağından elde edilen sonuçların ortalaması 85 dakikadır.)

#### 5.6.4 Freze tezgahı için istatistiksel analiz

Freze tezgahından elde edilen sonuçlar istatistiksel olarak analiz edilmiştir.(Tablo 5.14)



Tablo 5.14: Freze tezgahı için test verilerinin istatistiksel analizi

	Test Verisi Çıktı	Sapma $\sigma$	Sapmanın karesi	Test Verisi Çıktı (Y.S.A.)	Sapma	Sapmanın Karesi
1	100	2	4	86	2	2
2	111	13	166	104	20	396
3	105	7	47	98	13	179
4	80	-18	328	89	5	22
5	95	-3	10	73	-11	129
6	120	22	479	133	48	2327
7	130	32	1016	139	55	2996
8	105	7	47	107	23	518
9	110	12	141	114	30	871
10	87	-11	124	81	-3	10
11	85	-13	172	80	-4	18
12	125	27	722	135	50	2507
13	90	-8	66	85	1	1
14	90	-8	66	85	0	0
15	115	17	285	128	43	1861
16	75	-23	535	64	-20	403
17	80	-18	328	71	-13	177
18	98	0	0	98	13	182
19	116	18	320	133	48	2324
20	100	2	4	108	23	541
21	85	-13	172	81	-4	15
22	66	-32	1032	64	-21	430
23	120	22	479	120	35	1249
24	90	-8	66	76	-8	66
25	80	-18	328	77	-7	51
26	80	-18	328	82	-3	9
27	55	-43	1860	127	42	1779
28	160	62	3829	118	34	1154
29	70	-28	791	82	-2	6
30	85	-13	172	86	2	2
31	140	42	1754	134	49	2425
32	90	-8	66	78	-6	40
33	100	2	4	74	-10	102
<b>Toplam</b>	<b>3238</b>		<b>15740</b>	<b>3211</b>		<b>22792</b>
<b>Ortalama</b>	<b>98</b>		<b>414</b>	<b>85</b>		<b>600</b>

$$z = \frac{\bar{x}_1 - \bar{x}_2 - (\mu_1 - \mu_2)}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}} \quad (5.11)$$

$$z = ((98 - 85) - 0) / \sqrt{(15740/33) + (22792/33)} = 0.428 \quad (5.12)$$

Test istatistiđi=0.428

% 95 güven düzeyinde ( $z=1.645$ ) Yapay sinir ađının verdiđi sonuçlar ile gerçek veriler arasında fark olmadığı yani  $H_0$  ( $H_0: \mu_1 - \mu_2 = \text{hipotez deđeri}=0$ ) boş hipotezinin kabul edildiđi görölmektedir sonuç olarak istatistiksel olarak farkın görülmediđi ortaya çıkmıştır.

### **5.7 Torna Tezgahı İçin Taguchi Deney Tasarımı, Yapay Sinir Ađının Kullanımı ve Sonuçların Analizi**

Matkap ve Freze Tezgahı için yapılan deney tasarımı sonucunda etkileşim olmadığı ortaya çıkmıştır.Bu varsayımla etkileşimler göz önüne alınmayarak Taguchi deney tasarımı yöntemi torna tezgahı için uygulanmıştır.

Taguchi metodunun aşamaları ve Y.S.A. dan en iyi sonuçların bulunması için dört faktörlü-iki seviyeli kombinasyonun aşamaları aşağıdaki gibidir:

#### **5.7.1.Taguchi deney tasarımı aşamaları**

##### **5.7.1.1 Problemlerin tanımlanması**

Y.S.A.'dan elde edilen verilerle gerçek veriler arasında sapmalar mevcut problem olarak tespit edilmiştir.Bu sapmaların en düşük seviyede sağlanabilmesi için kalite karakteristiklerinden küçük deđerin en iyi olması hedeflenmektedir.

##### **5.7.1.2 Faktör ve seviyelerinin belirlenmesi**

Deneyde gizli katman sayısı,(hücre) neuron sayısı,öğrenme katsayısı ve momentum katsayısı olmak üzere 4 adet faktör belirlenmiştir. Her bir faktör için ise 2 adet seviye belirlenmiştir.

### 5.7.1.3 Ortogonal diziler ve seçimleri

Faktörsel deneyler, olası tüm faktör-seviye kombinasyonlarını açıklamayı gerektirdiği için yüzlerce hatta binlerce deney gerektirir. Bu deney sayılarını azaltan Taguchi tarafından geliştirilen Ortogonal diziler kullanılır. Matkap ve freze tezgahlarında yapılan tam faktöriyel deneyler sonucunda etkileşim olmadığı ortaya çıkmıştır. Bu yüzden deneyde iki seviyeli dört faktörlü L8 Ortogonal tablosu (Tablo 5.15) kullanılmıştır.

Tablo 5.15: L8 ortogonal tablosu

PROVA	FAKTÖRLER			
	gizli	neuron	öğrenme	momentum
1	1	1	0,2	0,6
2	1	1	0,2	0,8
3	1	3	0,4	0,6
4	1	3	0,4	0,8
5	3	1	0,4	0,6
6	3	1	0,4	0,8
7	3	3	0,2	0,6
8	3	3	0,2	0,8

### 5.7.1.4 Faktörlerin kolonlara atanması

Bir deneysel dizayn matrisi tüm plandaki her bir deneyi tanımlayan deneysel şartların bir özetidir. Faktörler Ortogonal dizi sütunlarına atanırken öncelikle seviye durumuna ve faktörler arasındaki etkileşim olup olmadığına bakılır. Eğer faktörler birbirinden bağımsız ise her hangi bir faktör her hangi bir sütuna atanabilir. Eğer faktörler arasında tespit edilmiş bir etkileşim var ise, o zaman belli kurallar gereği atama sütunlara zorunlu olarak yapılır.

### 5.7.1.5 Deneylerin gerçekleştirilmesi ve verilerin toplanması

Seçilen L8 Ortogonal dizisine uygun olarak gerçekleştirilen sekiz deney sonucu aşağıdaki değerler elde edilmiştir. Yine her bir kombinasyon için 5'er deneme yapılmıştır. Sonuçlar Tablo 5.16'da görülmektedir.

### 5.7.1.6 Torna tezgahı için elde edilen sonuçlar

Sapmaların minimum olması istenilen durum olduğundan dolayı sinyal Gürültü oranının en küçüğü en iyidir olarak belirlenir. Aşağıda amaca göre sinyal gürültü oranları ve formülleri verilmiştir.

Signal to Noise Ratio:	Formula
<input type="radio"/> Larger is better	$-10 \cdot \log(\sum(1/Y^{**2})/n)$
<input type="radio"/> Nominal is best	$-10 \cdot \log(s^{**2})$
<input type="radio"/> Nominal is best	$10 \cdot \log([\bar{Y}^{**2}]/s^{**2})$
<input checked="" type="radio"/> Smaller is better	$-10 \cdot \log(\sum[Y^{**2}]/n)$

En küçük en iyidir amacına göre ( $S/G_{ij} = -10 \log(\frac{1}{n_i} \sum_{k=1}^{n_i} y_{ijk}^2)$ ) sinyal gürültü oranı belirlenmiştir.

Tablo 5.16: Torna tezgahı için elde edilen sonuçlar ve sinyal/gürültü oranları

Deney No	SAPMA					S/N
	1	2	3	4	5	
1	934	856	708	1086	937	-59.20
2	934	828	810	862	952	-58.88
3	995	743	904	1105	998	-59.62
4	851	667	640	1047	965	-58.58
5	996	966	868	959	1005	-59.65
6	938	968	921	943	924	-59.45
7	958	1030	940	1137	708	-59.69
8	713	1182	742	879	925	-59.12

Tablo 5.17: Sütun farkları yöntemine göre belirlenmiş faktör etkileri

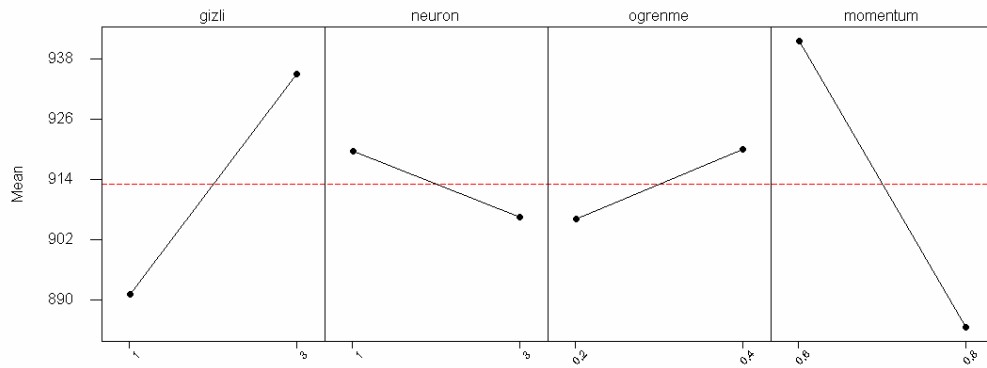
En Küçük En İyi									
	A	B	C	D	S/N	FAKTÖRLER	S1	S2	Maks-Min
1	1	1	0,2	0,6	-59.20				
2	1	1	0,2	0,8	-58.88	A	-59.0694	-59.4778	0.408
3	1	3	0,4	0,6	-59.62	B	-59.2956	-59.2517	0.044
4	1	3	0,4	0,8	-58.58	C	-59.2241	-59.3231	0.099
5	3	1	0,4	0,6	-59.65	D	-59.5392	-59.0080	0.531
6	3	1	0,4	0,8	-59.45				
7	3	3	0,2	0,6	-59.69				
8	3	3	0,2	0,8	-59.12				

Birinci faktörün ilk seviyesi için ortalama, A faktörünün (Gizli Katman Sayısı) ilk seviyesi ile gerçekleştirilen ilk dört denemenin ortalamasıdır. Benzer şekilde, A faktörünün ikinci seviyesi için ortalama, A faktörünün ikinci seviyesi ile gerçekleştirilen son dört denemenin ortalamasıdır. B (neuron sayısı) faktörünün ilk seviyesi için ortalama; birinci, ikinci, beşinci ve altıncı denemelerin ortalamasıdır. Bu faktörün ikinci seviyesi için ortalama; üç, dört, yedinci ve sekizinci denemelerin ortalamasıdır. (Tablo 5.17) Öğrenme ve Momentum katsayısı içinde benzer şekilde hesaplanır.

### 5.7.1.7 Freze tezgahı için en iyi faktör seviyeleri kombinasyonu (Optimum faktör seviyelerinin seçimi)

Bu deney sonucunda gizli katman faktörü için en büyük S/N oranına sahip birinci seviye, neuron sayısı için ikinci seviye, öğrenme katsayısı için ise birinci seviye, momentum terimi için de ikinci seviye optimum faktör seviyesi olarak belirlenmiştir. Momentum faktörünün seviyeler arasındaki S/N oran değişimi diğer üç faktöre göre daha yüksek olduğu için bu deneyde en önemli faktör neuron sayısı faktörüdür.

Main Effects Plot for Means



Şekil 5.22: Sinyal gürültü oranlarına göre en iyi etmenler

Sonuç olarak Yapılan deney sonucunda gizli katman sayısı 1, neuron sayısı 3 öğrenme katsayısı 0.2 ve momentum terimi 0.8 olan parametrelerin seçilmesi gerektiği bulunmuştur. (Şekil 5.22) Bu parametrelerin sapmaları minimize ettiğinin belirlenmesi için doğrulama testi yapılmalıdır.

### 5.7.1.8 Doğrulama deneyi (Torna tezgahı için elde edilen en iyi sonuç)

Şekil 5.22’de görüldüğü üzere;

Gizli katman sayısı=1


Neuron Sayısı=3

Öğrenme Katsayısı=0.2

Momentum Katsayısı=0.8 bulunmuştur.


Bu parametrelere göre denemeler yapılmıştır. Toplam 5 deneme yapılmıştır. Test verileri için mutlak sapma değerleri sırasıyla 759, 735, 495, 845, 670 bulunmuştur. Bu beş sonuçtan en iyisi olan 495 şuna kadar yapılan tüm denemelerin en iyisidir.

Şekil 5.23’de görüldüğü gibi veriler 1000 iterasyonluk eğitime tabi tutulmuş ve toplam karesel hata değeri 100’üncü iterasyona gelmeden önce kararlı duruma gelmiştir ve azalarak devam etmiştir.



Şekil 5.23: Toplam karesel hatanın iterasyona bağlı değişimi

Y.S.A.’nın eğitilmesi için kurulan ağ yapısı Şekil 5.24’de verilmiştir.



Şekil 5.24: Torna tezgahı için en iyi sonuç veren ağ yapısı

Eđitim sonucunda elde edilen vektörler

Giriş katmanı ağırlık vektörü:

$$IW\{1,1\} = \begin{bmatrix} 1.7374 - 0.0690973.9426 - 0.09356 - 1.0878 2.6145 3.71150.40225, \\ 0.052208 - 2.3181 2.171 - 2.8545 - 2.67121.2872 - 3.3056 - 1.7953, \\ 2.54841.7947 1.90681.4953 0.60395 4.6515 - 1.3141 0.89812 \end{bmatrix} \quad (5.13)$$

Çıkış katmanı ağırlık vektörü:

$$IW\{2,1\} = \begin{bmatrix} 0.35572 \\ - 0.1441 \\ 0.25503 \end{bmatrix} \quad (5.14)$$

Giriş katmanı eşik vektörleri:

$$b\{1\} = \begin{bmatrix} - 8.821 \\ 4.5787 \\ - 3.3403 \end{bmatrix} \quad (5.15)$$

Çıkış katmanı eşik vektörü:

$$b\{2\} = [0.28513] \quad (5.16)$$

olarak belirlenmiştir.

### 5.7.2 Torna tezgahı için istatistiksel analiz

$$z = \frac{\bar{x}_1 - \bar{x}_2 - (\mu_1 - \mu_2)}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}} \quad (5.17)$$

$$\bar{X}_1 \text{ (1.yığının ortalaması(gerçek veriler))} = 171$$

$$\bar{X}_2 \text{ (2.yığının ortalaması(gerçek veriler))} = 163$$

$$z = ((171 - 163) - 0) / \sqrt{(30100./39) + (32639/39)} \\ = 0.199$$

Test istatistiđi=0.199

% 95 güven düzeyinde ( $z=1.645$ ) Yapay sinir ağının verdiği sonuçlar ile gerçek veriler arasında fark olmadığı yani  $H_0$  ( $H_0: \mu_1 - \mu_2 = \text{hipotez değeri}=0$ ) boş hipotezinin kabul edildiği görülmektedir. Sonuç olarak istatistiksel olarak farkın görülmediği ortaya çıkmıştır. Böylelikle işletme belirlenen faktörleri göz önüne alarak tasarımı yapılmış olan yeni makinelerin çizimlerinden bu faktörleri belirleyerek işlem süresini tahmin edebilecektir böylelikle işletmeler için en uzun aşamalardan biri olan veri toplama aşaması tamamlanmış olacaktır.

## 5.8 Uygulama Sonuçları

Matkap, freze ve torna tezgahı için elde edilen çeşitli performans ölçütlerine göre (Bölüm 4.5) sonuçlar Tablo 5.18’de verilmiştir.

Tablo 5.18: Her makine için elde edilen sonuçların değerleri

	Eğitim Verileri			Test Verileri		
	Matkap	Freze	Torna	Matkap	Freze	Torna
<b>Normalize edilmiş değerlerin Min. kareler ort.(RMSE)</b>	0.0881626	0.0113243	0.00491286	-	-	-
<b>RMSE</b>	29.891	37.246	42.055	8.494	17.463	15.312
<b>Mutlak Hata</b>	1300	1498	2005	269	368	495
<b>N(sayı)</b>	100	100	100	38	33	39
<b>MAE</b>	130	150	200	7	11	13
<b>MAPE</b>	18.01	17.33	13.86	3.11	4.21	2.97
<b>Ort.(gerçek)</b>	-	-	-	90	98	171
<b>Ort.(Y.S.A.)</b>	-	-	-	89	85	163
<b>Z değeri</b>	-	-	-	0.058	0.428	0.199

Yapay sinir ağının performansının ölçülmesi için Ortalama Mutlak Hata (MAE), Ortalama Karesel hata (RMSE), Ortalama Mutlak Yüzelik Hata (MAPE) değerleri hesaplanmıştır ve elde edilen sonuçların gerçek verileri ne ölçüde temsil ettiğini belirlemek için %95 güven aralığında Z testi yapılarak istatistiksel olarak ölçülmüştür. Sonuç olarak her üç tezgah için  $H_0$  hipotezinin kabul edilmiş ve gerçek verilerle yapay sinir ağı çıktılarının istatistiksel olarak aynı olduğu sonucu ortaya çıkmıştır.



## SONUÇ

İşletmeler arasındaki artan rekabet müşterinin istediği özelliklerde ürün üretmek (müşteri memnuniyeti), tam zamanında teslim ve maliyetlerin düşürülmesi tüm işletmeler için önem arz etmektedir. İşletmeler müşterilerinin istedikleri özellikleri, spesifikasyonları taşıyan ürünleri, istedikleri zamanda yada işletmenin öngördüğü zaman dilimi içersinde teslim etmeleri çok önemlidir. Zamanında teslim edilemeyen geciken ürünler işletmenin prestijini olumsuz yönde etkilemektedir. İşletmeler zamanında teslimi gerçekleştirebilmeleri için ilk olarak yapılan işlerin işlem sürelerini bilinmesi gerekmektedir.

Çalışmada işlem sürelerinin tespiti için yapay sinir ağı kullanılmaktadır. Yapay sinir ağları örneklerden olaylar arasındaki ilişkileri öğrenerek daha sonra hiç görmediği örnekler hakkında öğrendikleri bilgileri kullanarak karar veren sistemlerdir. Doğal sinir sisteminden esinlenerek oluşturulmuştur. İnsan beyninin fonksiyonel özelliklerine benzer şekilde öğrenme, ilişkilendirme, sınıflandırma, genelleme, özellik belirleme ve optimizasyon konularında başarılı örnekler vardır. Finansla ilgili konulardan mühendisliğe kadar pek çok alanda uygulanmaktadır. Bu çalışmada da yapay sinir ağı ile tahmin yapılmıştır.

Uygulama, siparişe göre peçete makinesi imalatı yapan işletmede yapılmıştır. İşletmenin en önemli sorunu müşteriden gelen siparişleri yetiştirememesi ve dolayısıyla zamanında teslimin gerçekleşmemesidir. Teslim süresindeki gecikme 117 günü bulmaktadır (işletme kayıtları). Bunun en önemli nedeni ise müşterinin istediği spesifikasyondaki peçete makinesinin üretimi için gerekli olan parçaların makinelerdeki işlem süresinin bilinmemesinden kaynaklanmaktadır. Özellikle diğer peçete makinelerden farklılık gösteren makinelerdeki parçaların tamamlanma süresini sezgisel olarak hesaplamak daha da zordur.

Çalışmada makineler ve bu makinelerde çalışan işçilerin yaptıkları faaliyetler kameraya alınarak bu konuda uzman kişilerle birlikte beyin fırtınası yöntemi uygulanarak işlem süresine etki eden faktörler belirlenmiştir. Bu faktörler göz önünde tutularak zaman etüdü çalışması yapılmıştır. Her bir makine için 100 den fazla örnek alınarak yapay sinir ağına örnek verisi olarak girilmiştir.

Yüksek doğrulukta cevap veren yapay sinir ağı yapısı oluşturulması için yapay sinir ağının öğrenme katsayısı, momentum katsayısı, gizli katman sayısı ve her gizli katmandaki hücre (neuron) sayısı olmak üzere bu dört parametre değerleri deney tasarımıyla belirlenmiştir. Üç makine için en iyi kombinasyon sırasıyla öğrenme katsayısı için 0.4, 0.2, 0.2, momentum katsayısı için 0.8, 0.8, 0.8, saklı katman sayısı için 1, 1, 1 ve her bir katmandaki hücre (neuron) sayısı için 3, 3, 3 olarak bulunmuştur. Aktivasyon fonksiyonu olarak logsigmoid fonksiyonu ( $y=1/(1+e^{-x})$ ) kullanılmıştır. Sonuç olarak sırasıyla en iyi ağ yapısı (8,1,1) (8,1,1) (8,1,1) dır.

Elde edilen en iyi ağ yapısı kullanılarak çıkan sonuçların doğruluğunun (Çalışmanın sonunda elde edilen yapay sinir ağı çıktıları ile gerçek veriler arasındaki sapmanın tutarlılığının) test edilmesi gerekmektedir. Yapay sinir ağı çıktıları ile gerçek veriler %95 güven aralığında hipotez testi ile test edilmiştir ve istatistiksel olarak gerçek verilerle yapay sinir ağı çıktıları arasında farkın görülmediği ortaya çıkmıştır.

Böylelikle işletme belirlenen faktörleri göz önüne alarak tasarımı yapılmış olan yeni makinelerin teknik resimlerinden bu faktörleri belirleyerek işlem süresini ve ellerinde olmayan işlemler için tamamlanma sürelerini tahmin edebilecektir. Sonuç olarak işletmeler için en uzun aşamalardan biri olan veri toplama aşaması tamamlanmış olacaktır. Yapay sinir ağı yöntemiyle elde edilen veriler, işletmenin en büyük sorunu olan teslim sürelerinin gecikmesi sorununa çözüm getirmesi hedeflenen çizelgeleme aşamasında kullanılabilir. İşlem süresinin tahmini için yapay sinir ağı kullanımı literatüre ek olarak farklı bir uygulama alanında kullanılmıştır.

## KAYNAKLAR

1. M. Hulusi Demir, Şevkinaz Gümüőođlu, “Üretim Yönetimi”, 6.b., *Beta Yayınları*,(1999)
2. Uluslararası Çalışma Örgütü, “İş Etüdü”, *Milli Productivite Yayınları*,Ankara(2003)
3. Erasmo Cadenasa, Wilfrido Rivera, “Wind speed forecasting in the South Coast of Oaxaca, Mexico”, *Renewable Energy* 32 2116–2128, (2007)
4. Raul Pino, Jose Parreno, Alberto Gomez, Paolo Priore “Forecasting next-day price of electricity in the Spanish energy market using artificial neural Networks”, *Engineering Applications of Artificial Intelligence*, (2007)
5. Qing Wang , “Artificial neural networks as cost engineering methods in a collaborative manufacturing environment”, *Int. J. Production Economics*
6. Hsiao-Tien Pao, “Comparing linear and nonlinear forecasts for Taiwan’s electricity consumption” *Energy* 31 2129–2141, (2006)
7. Parag C. Pendharkar “ Scale economies and production function estimation for object-oriented software component and source code documentation size” *European Journal of Operational Research* 172 1040–1050, (2006)
8. Philip Doganis, Alex Alexandridis, Panagiotis Patrinos, Haralambos Sarimveis, “Time series sales forecasting for short shelf-life food products based on artificial neural networks and evolutionary computing”, *Journal of Food Engineering* 75 196–204, (2006)
9. Bahman Kermanshahi,Hiroshi Iwamiya, “Up to year 2020 load forecasting using neural nets”,*Electrical power and energy systems*, 24 789-797, (2002)
10. Soteris A. Kalogirou, “Artificial neural networks in renewable energy systems applications: a review”, *Renewable and Sustainable Energy Reviews* 5 373–401, (2001)
11. Louis Sanzogni , Don Kerr, “Milk production estimates using feed forward artificial neural networks” *Computers and Electronics in Agriculture* 32 21–30, (2001)
12. Soteris A. Kalogirou “Applications of Artificial neural-networks for energy systems”, *Applied Energy* 67 17-35, (2000)

13. Yurtođlu H., “Yapay Sinirađları Metodolojisi İle Öngörü Modellemesi: Bazı Makroekonomik Deđişkenler İin Türkiye Örneđi”, Yayın No: Dpt: 2683,*Uzmanlık Tezi*, Şubat (2005)
14. Öztemel Ercan, “Yapay Sinir Ađları”,İstanbul:*Papatya Yayıncılık* , (2003)
15. Cihan KARAKUZU, “Yapay Sinir Ađları ile Bir Kontrol Uygulaması”, Yüksek Lisans Tezi, *Kocaeli Üniversitesi Fen Bilimleri Enstitüsü*, İzmit, (1998)
16. Altug, S. “İstanbul Menkul Kıymetler Borsası’nda Yapay Sinir Ađları Kullanılarak Fiyat Öngörüsü”, Yüksek Lisan Tezi, *Bilkent Üniversitesi Fen Bilimleri Enstitüsü*, (1994)
17. Elmas,Ç, “Yapay Sinir Ađları”,*Sekin Kitabevi*,(2003)
18. Şen Z, “Yapay Sinir Ađları” ,*Su Vakfı Yayınları*,İstanbul, (2004)
19. ROSS, P. J., “Taguchi Techniques for Quality Engineering” *McGraw-Hill Book Company*, p. 1-277, Singapore (1989)
20. ÇELİK, C. ve BURNAK N., “Kalite Geliştirmede Taguchi Yöntemlerinin Rolü ve Bir Uygulama” *Endüstri Mühendisliđi Dergisi*, Cilt:5, Sayı:5, 9-17, Ankara. 1994.
21. FERAH, M., “Çok Yanıtlı Taguchi Tasarım Metodu ve Alüminyum Sanayinde Bir Uygulama” Yüksek Lisans Tezi, *Sakarya Üniversitesi Fen Bilimleri Enstitüsü*, Sakarya,(2003)
22. ŞİRVANCI, M., “Kalite İin Deney Tasarımı Taguchi Yaklaşımı”, *Literatür Yayınları*, s 11. İstanbul. (1997)
23. TAPTIK, Y., KELEŞ, Ö., “Kalite Savaş Araları”, *Kalder Yayınları*, İstanbul, (1998)
24. Altınbilek Ü, “Şanzıman Giriş Mili İmalatındaki Proses Parametrelerine Taguchi Metodunun Uygulanması” Yüksek Lisans Tezi, *Marmara Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul, (2001)
25. TAGUCHI, G., and JUGULUM, R.,. The Mahalanobis “Taguchi Strategy: A Pattern Technology System” *John Wiley and Sons Inc.*, U.S.A .( 2002 )
26. KELEŞ, Ö., “Matkap Ularının Ark Pvd ve Tin Kaplanmasında Proses Parametrelerinin Taguchi Metodları ile Optimizasyonu”, Yüksek Lisans Tezi. *İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul,(1996)
27. ANTONY, J., “Simultaneous Optimisation of Multiple Quality Characteristics in Manufacturing Processes Using Taguchi’s Loss Function” *Int.J.of Adv. Manuf. Technology*, ,17:134-138. (2001)

28. JARAYAM, J.S.R., IBRAHİM, Y., “Multiple Response Robust Design and Yield Maximization”, *Int. Journal of Quality and Reliability Management*, Vol.16, No.9, 826-837, (1999)
29. BAYNAL, K., “Çok Yanıtlı Problemlerin Taguchi Yöntemi ile En İyilenmesi ve Bir Uygulama”, Doktora Tezi, *İstanbul Üniversitesi Sosyal Bilimler Enstitüsü*, İstanbul. (2003)
30. ÖZTÜRKCAN M, “İstatistik” , *Kocaeli Üniversitesi Yayınları* ,syf 1, (2002)
31. AKDENİZ F, “Olasılık ve İstatistik” ,*Baki Kitabevi*,syf 3, (1998)
32. ÖZER Serper, “İstatistik” ,*Filiz Kitabevi*,Syf 4-5, (1980)
33. İstatistiğin Doğuşu, Gelişimi ve Devlet İstatistik Enstitüsü, <http://www.die.gov.tr/istDogusu.htm> (Ziyaret Tarihi:15.04.2007)
34. Bircan H., Karagöz Y. ve Kasapoğlu Y., “Ki-Kare ve Kolmogorov Smirnov Uygunluk Testlerinin Simulasyon ile Elde Edilen Veriler Üzerinde Karşılaştırılması”, *C.Ü. İktisadi ve İdari Bilimler Dergisi*, cilt 4, sayı 1, 2003
35. K. ERMİS, A. MİDİLLİ, I. DİNCER, M.A. ROSEN, “Artificial neural network analysis of world green energy use”, *Energy Policy* Vol. 35, sayfa 1731–1743, (2007)
36. HSIAO-TİEN PAO, “Forecasting electricity market pricing using artificial neural Networks”, *Energy Conversion and Management* 48 907–912 (2007)
37. COŞKUN HAMZAÇEBİ, “Forecasting of Turkey’s net electricity energy consumption on sectoral bases”, *Energy Policy* 35 2009–2016 (2007)
38. s.g. li , x. kuo “the Inventory Management System for Automobile Spare Parts in a Central Warehouse”, *Expert Systems with Applications* (2007)
39. J.P.S. Catalão , S.J.P.S. Mariano , V.M.F. Mendes, L.A.F.M. Ferreira, “Short-Term Electricity Prices Forecasting in a Competitive Market: A Neural Network Approach”, *Electric Power Systems Research* , (2006)
40. Alfonso P., Jose J., Montano, Sese S, “Designing an artificial neural network for forecasting tourism time series”, *Tourism Management* 27 781–790, (2006)

## EKLER

### EK-A. MATKAP TEZGAHI İÇİN MINITAB ÇIKTISI

#### Factorial Design

Full Factorial Design

Factors: 4 Base Design : 4; 16  
Runs : 80 Replicates : 5  
Blocks : none Center pts (total) : 0

All terms are free from aliasing

#### Fractional Factorial Fit: Sonuc versus g; n; o; m

Estimated Effects and Coefficients for Sonuc (coded units)

Term	Effect	Coef	SE Coef	T	P
Constant		549.48	9.921	55.38	0.000
g	81.40	40.70	9.921	4.10	0.000
n	-72.05	-36.02	9.921	-3.63	0.001
o	-17.50	-8.75	9.921	-0.88	0.381
m	-3.45	-1.72	9.921	-0.17	0.863
g*n	39.10	19.55	9.921	1.97	0.053
g*o	-6.45	-3.22	9.921	-0.33	0.746
g*m	5.80	2.90	9.921	0.29	0.771
n*o	-26.70	-13.35	9.921	-1.35	0.183
n*m	-36.95	-18.48	9.921	-1.86	0.067
o*m	-0.60	-0.30	9.921	-0.03	0.976
g*n*o	26.25	13.12	9.921	1.32	0.191
g*n*m	-4.00	-2.00	9.921	-0.20	0.841
g*o*m	6.65	3.33	9.921	0.34	0.739
n*o*m	19.30	9.65	9.921	0.97	0.334
g*n*o*m	-34.95	-17.47	9.921	-1.76	0.083

Analysis of Variance for Sonuc (coded units)

Source	DF	Seq SS	Adj SS	Adj MS	F	P
Main Effects	4	242706	242706	60677	7.71	0.000
2-Way Interactions	6	73652	73652	12275	1.56	0.174
3-Way Interactions	4	22436	22436	5609	0.71	0.587
4-Way Interactions	1	24430	24430	24430	3.10	0.083
Residual Error	64	503966	503966	7874		
Pure Error	64	503966	503966	7874		
Total	79	867190				

## EK-B. FREZE TEZGAHI İÇİN MINITAB ÇIKTISI

### Factorial Design

Full Factorial Design

Factors	: 4	Base Design	: 4; 16
Runs	: 80	Replicates	: 5
Blocks	: none	Center pts (total)	: 0

All terms are free from aliasing

### Fractional Factorial Fit: C9 versus Gizli katman; Neuron Hucre;

Estimated Effects and Coefficients for C9 (coded units)

Term	Effect	Coef	SE Coef	T	P
Constant		572.60	7.552	75.83	0.000
Gizli ka (Gk)	31.56	15.78	7.552	2.09	0.041
Neuron H (NH)	-20.51	-10.25	7.552	-1.36	0.179
Ogrenme (O)	6.49	3.24	7.552	0.43	0.669
Momentum (M)	-2.29	-1.15	7.552	-0.15	0.880
Gk*NH	-3.03	-1.52	7.552	-0.20	0.841
Gk*O	-0.43	-0.21	7.552	-0.03	0.977
Gk*M	5.40	2.70	7.552	0.36	0.722
NH*O	-6.05	-3.02	7.552	-0.40	0.690
NH*M	-15.35	-7.68	7.552	-1.02	0.313
O*M	-12.82	-6.41	7.552	-0.85	0.399
Gk*NH*O	7.95	3.98	7.552	0.53	0.600
Gk*NH*M	9.87	4.94	7.552	0.65	0.516
Gk*O*M	-2.23	-1.12	7.552	-0.15	0.883
NH*O*M	-4.94	-2.47	7.552	-0.33	0.745
Gk*NH*O*M	15.18	7.59	7.552	1.01	0.319



Analysis of Variance for C9 (coded units)

Source	DF	Seq SS	Adj SS	Adj MS	F	P
Main Effects	4	29274	29274	7318.5	1.60	0.184
2-Way Interactions	6	9506	9506	1584.3	0.35	0.909
3-Way Interactions	4	3802	3802	950.6	0.21	0.933
4-Way Interactions	1	4611	4611	4610.9	1.01	0.319
Residual Error	64	291969	291969	4562.0		
Pure Error	64	291969	291969	4562.0		
Total	79	339163				

## EK-C. TORNA TEZGAHI İÇİN MINITAB ÇIKTISI

### Taguchi Design

Taguchi Orthogonal Array Design

L8(2\*\*4)

Factors: 4

Runs: 8

### Response Table for Signal to Noise Ratios

Smaller is better

Level	gizli	neuron	ogrenme	momentum
1	-59.0703	-59.2959	-59.2243	-59.5392
2	-59.4777	-59.2521	-59.3237	-59.0088
Delta	0.4074	0.0438	0.0994	0.5305
Rank	2	4	3	1

### Response Table for Means

Level	gizli	neuron	ogrenme	momentum
1	891.1	919.75	906.05	941.65
2	935.1	906.45	920.15	884.55
Delta	44.0	13.30	14.10	57.10
Rank	2	4	3	1

## **ÖZGEÇMİŞ**

1983 yılında Bolu'da doğdu 1994 yılında ilkokulu Sakarya İlköğretim İlkokulunda, ortaokul ve liseyi İzzet Baysal Anadolu Lisesinde 2001 yılında tamamladı. Lisans eğitimini 2005 yılında mezun olduğu Kocaeli Üniversitesi Mühendislik Fakültesi Endüstri Mühendisliği Bölümü'nde aldı. Eylül 2005'de Kocaeli Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı'nda Yüksek Lisans Eğitimine başladı.

2005 Aralık ayından beri Kocaeli Üniversitesi Endüstri Mühendisliği Bölümü Endüstri Mühendisliği Anabilim Dalı'nda Araştırma Görevlisi olarak görev yapmaktadır.

Burcu ÖZCAN