


**KALIP ÜRETİM AŞAMALARININ STANDART
ZAMANLARININ BELİRLENMESİ**

Gizem GÖKLÜ



T.C.

ULUDAĞ ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

**KALIP ÜRETİM AŞAMALARININ STANDART ZAMANLARININ
BELİRLENMESİ**

Gizem GÖKLÜ

Prof. Dr. Seda ÖZMUTLU

(Danışman)

YÜKSEK LİSANS TEZİ

ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI

BURSA – 2013

Her Hakkı Saklıdır

TEZ ONAYI

Gizem GÖKLÜ tarafından hazırlanan “Kalıp Üretim Aşamalarının Standart Zamanlarının Belirlenmesi” adlı tez çalışması, aşağıdaki jüri tarafından oy birliği/oy çokluğu ile Uludağ Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı’nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Danışman: Prof. Dr. Seda ÖZMUTLU

Başkan :

İmza

.....Fakültesi,

.....Anabilim Dalı

Üye :

İmza

..Fakültesi,

.....Anabilim Dalı

Üye :

İmza

.....Fakültesi,

.....Anabilim Dalı

Yukarıdaki sonucu onaylarım

Prof. Dr. Ali Osman DEMİR

Enstitü Müdürü

.././....

U.Ü. Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

.../.../...

Gizem GÖKLÜ

ÖZET

Yüksek Lisans Tezi

KALIP ÜRETİM AŞAMALARININ STANDART ZAMANLARININ BELİRLENMESİ

Gizem GÖKLÜ

Uludağ Üniversitesi
Fen Bilimleri Enstitüsü
Endüstri Anabilim Dalı

Danışman: Prof. Dr. Seda ÖZMUTLU

Üretim planlamanın başarılı şekilde gerçekleştirilebilmesi, üretim aşamalarının sürelerinin doğru şekilde tahmin edilebilmesine bağlıdır. Kalıpcılık sektöründe, üretilen ürün karmaşık ve üretim süreci uzun olduğu için üretim sürelerinin tahmin edilmesi özellikle zordur. Bu çalışma, kalıp üretim aşamalarının sürelerinin tespiti ve tahmini ile ilgilidir. Kalıp üretim aşamaları sürelerinin belirlenebilmesi için üretim süresini etkileyen kalıp teknik parametre değerlerinin tahmin edilebilmesi gereklidir. Bu sebeple bu çalışmada, kalıp üretim aşamalarının sürelerinin belirlenmesi amacıyla yönelik olarak kalıp teknik parametre değerlerinin tahmini için regresyon analizi ve yapay sinir ağları yaklaşımı olmak üzere iki farklı yaklaşım uygulanmıştır. Çalışmada, öncelikle kalıpların üretim süresine etki eden teknik parametreler belirlenmiş, parametrelerle ilgili veri analizine uygun bağımsız ve bağımlı değişkenlerin bir arada olduğu veri setleri hazırlanmıştır. Daha sonra bu veri setleri kullanılarak, regresyon analizi ve yapay sinir ağları metotları ile teknik parametre değerlerini tahmin etmek üzere tahmin modelleri geliştirilmiştir. Bu tahmin modelleri ile örnek bir uygulama yapılmış ve elde edilen süreler gerçek sürelerle karşılaştırılmıştır.

Anahtar Kelimeler: kalıp üretimi, üretim süreleri tahmini, regresyon analizi, yapay sinir ağları.

2013, vi + 91 sayfa

ABSTRACT

MSc Thesis

DETERMINATION OF STANDART TIME IN DIE MANUFACTURING STAGES

Gizem GÖKLÜ

Uludağ University
Graduate School of Natural and Applied Sciences
Department of Industiral Engineering

Supervisor: Prof. Dr. Seda ÖZMUTLU

The succesful realization of production planning depends on the correct time estimation of the stages of production. In die industry, the manufactured product is complicated and the manufacturing process is a long period of time, because of that, estimated of production time is especially difficult. This study is about the detection and prediction of the duration of the production stages of the die. For determining the duration of the stages of production die, prediction of the values of technique parameters which affects the duration of production time is required. Thus, in this study, for the purposes of determination of the duration time of die manufacturing stages, two different approaches which are regression analysis and artificial neural network were applied. In the study, firstly the technique parameters which affects the duration time of the die manufacturing were determined and then, about these parameters, the data sets which have the dependent and also independent variables were prepared in accordance with te data analysis. Thereafter, with these data sets, the prediction models were developed using the regression analysis and artificial neural network methods for the prediction of the technique parameters values. An application is implemented with the prediction models and the times which were obtained from the prediciton models and the real-times are compared.

Key words: die manufacturing, estimating of manufacturing time, regression analysis, artificial neural networks.

2013, vi + 91 sayfa.

TEŐEKKÜR

Bu tez alıőmasında beni yönlendiren ve araőtırmalarımnda desteęini esirgemeyen tez danıőmanım Sayın Prof. Dr. Seda ÖZMUTLU' ya, ayırmıő olduęu zaman, görüő ve deęerli katkıları için Prof. Dr. H. Cenk ÖZMUTLU' ya ve her an yanımda olan aileme verdikleri destek ve gösterdikleri özveri için teőekkür ederim.

.../.../...

Gizem GÖKLÜ

İÇİNDEKİLER

Sayfa

ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
İÇİNDEKİLER.....	iv
ŞEKİLLER DİZİNİ	v
ÇİZELGELER DİZİNİ	vi
1. GİRİŞ	1
2. KONU İLE İLGİLİ ÇALIŞMALAR	4
2.1. Kuramsal Bilgiler	4
2.2. Kaynak Araştırması.....	8
3. MATERYAL VE YÖNTEM.....	13
3.1. Materyal.....	13
3.1.1. Regresyon Analizi	13
3.1.1.1. Genel Bilgiler	13
3.1.1.2. Basit Doğrusal Regresyon Analizi	15
3.1.1.3. Çoklu Doğrusal Regresyon Analizi.....	16
3.1.1.4. Regresyon Modelinin Oluşturulması.....	18
3.1.2. Yapay Sinir Ağları	21
3.1.2.1. Yapay Sinir Ağı Tanım ve Özellikleri	21
3.1.2.2. Yapay Nöron Modeli	23
3.1.2.3. Yapay Sinir Ağı Yapısı.....	30
3.1.2.4. Yapay Sinir Ağlarının Sınıflandırılması.....	32
3.1.2.5. Yapay Sinir Ağlarında Öğrenme.....	37
3.1.2.6. Yapay Sinir Ağlarının Geliştirilmesi.....	45
3.2. Yöntem	51
3.2.1. Genel Bilgiler	51
3.2.2. Regresyon Analizi	55
3.2.3. Yapay Sinir Ağı Uygulaması.....	63
4. ARAŞTIRMA SONUÇLARI.....	71
5. TARTIŞMA.....	84
KAYNAKLAR.....	86
ÖZGEÇMİŞ.....	91

ŞEKİLLER DİZİNİ

Sayfa

Şekil 2.1. Farklı geometriye sahip parçalar	7
Şekil 3.1. Biyolojik sinir hücresi	24
Şekil 3.2. Matematiksel nöron modeli	25
Şekil 3.3. Eşik aktivasyon fonksiyonu	27
Şekil 3.4. Doğrusal aktivasyon fonksiyonu.....	28
Şekil 3.5. Logaritma sigmoid aktivasyon fonksiyonu	29
Şekil 3.6. Hiperbolik tanjant aktivasyon fonksiyonu.....	30
Şekil 3.7. Yapay sinir ağı modeli	31
Şekil 3.8. İleri beslemeli ağ.....	33
Şekil 3.9. Geri beslemeli ağ.....	34
Şekil 3.10. Danışmanlı öğrenme modeli blok diyagramı	35
Şekil 3.11. Danışmansız öğrenme modeli blok diyagramı	36
Şekil 3.12. Destekleyici öğrenme modeli blok diyagramı	37
Şekil 3.13. Hızlı ve performansı yüksek geri yayımlı öğrenme algoritmaları	44
Şekil 3.14. (Bağımsız değişken B) 'ÇK-P-4' hataların normal dağılım grafiği	58
Şekil 3.15. (Bağımsız değişken E) 'ÇK-P-4' hataların normal dağılım grafiği	59
Şekil 3.16. (Bağımsız değişken G) 'ÇK-P-4' hataların normal dağılım grafiği	59
Şekil 3.17. (Bağımsız değişken K) 'ÇK-P-4' hataların normal dağılım grafiği	60
Şekil 3.18. Model 1 için hataların normal dağılım grafiği	62
Şekil 3.19. Model 2 için hataların normal dağılım grafiği	62
Şekil 3.20. Kullanılan yapay sinir ağı yapısı.....	67

ÇİZELGELER DİZİNİ

Sayfa

Çizelge 3.1. Biyolojik sinir hücresi ile yapay sinir hücresi arasındaki benzerlikler	24
Çizelge 3.2. Ağ Çeşitleri ve başarılı oldukları alanlar	47
Çizelge 3.3. Uygulama alanlarına göre ağ çeşitleri	49
Çizelge 3.4. (a) Çekme kalıbı teknik parametreler	52
Çizelge 3.4. (b) Çevre kesme kalıbı teknik parametreler	53
Çizelge 3.4. (c) Ütüleme kalıbı teknik parametreler	53
Çizelge 3.5. Kalıp tiplerine göre alt parametreler	54
Çizelge 3.6. ‘ÇK-P-4’ teknik parametresi tekli regresyon analizi sonuçları	56
Çizelge 3.7. ‘ÇK-P-4’ teknik parametresi basit doğrusal regresyon modelleri	57
Çizelge 3.8. (Bağımsız Değişken B) ‘ÇK-P-4’ için ANOVA Tablosu	57
Çizelge 3.9. (Bağımsız Değişken E) ‘ÇK-P-4’ için ANOVA Tablosu	57
Çizelge 3.10. (Bağımsız Değişken G) ‘ÇK-P-4’ için ANOVA Tablosu	58
Çizelge 3.11. (Bağımsız Değişken K) ‘ÇK-P-4’ için ANOVA Tablosu	58
Çizelge 3.12. Adımsal Regresyon Analizi için test sonuçları	61
Çizelge 3.13. Adımsal regresyon analizi sonrası ANOVA Tablosu	61
Çizelge 3.14. Araştırılan yapay sinir ağı ara katman sayısı ve nöron sayısı	65
Çizelge 3.15. Katman sayılarına göre araştırılan aktivasyon fonksiyonları	65
Çizelge 3.16. Çekme kalıbı için YSA sonuçları hata yüzdeleri	68
Çizelge 3.17. Çevre kesme kalıbı için YSA sonuçları hata yüzdeleri	68
Çizelge 3.18. Ütüleme kalıbı için YSA sonuçları hata yüzdeleri	69
Çizelge 4.1. Çekme kalıbı regresyon ve YSA MAPE değerleri	71
Çizelge 4.2. Çevre kesme kalıbı regresyon ve YSA MAPE değerleri	72
Çizelge 4.3. Ütüleme kalıbı regresyon ve YSA MAPE değerleri	72
Çizelge 4.4. (a) Çekme Kalıbı toplam üretim süresinin hesaplanması	73
Çizelge 4.4. (b) Çevre kesme kalıbı toplam üretim süresinin hesaplanması	76
Çizelge 4.4. (c) Ütüleme kalıbı toplam üretim süresinin hesaplanması	79
Çizelge 4.5. Toplam kalıp üretim sürelerinin karşılaştırılması	83

1. GİRİŞ

Gelişen teknoloji, küreselleşme ve değişen pazar şartları beraberinde yoğun bir rekabet ortamı getirmiştir. Bu yoğun rekabet ortamında işletmeler devamlılıklarını sürdürebilmek için maliyetlerini düşürmek, ürün kalitesini yükseltmek ve verimliliklerini arttırmak zorundadırlar. Rekabet ortamında, kaynaklarını en verimli şekilde kullananlar rakiplerinden daha üstün duruma gelecektir.

Tüm sektörlerde üreticiler, rekabet avantajı kazanabilmek için verimliliklerini arttırmak durumundadır. Verimliliği arttırmanın en önemli yollarından biri ise üretim planlama faaliyetlerinin doğru şekilde yürütülmesidir. Üretim planlamanın, başarılı bir şekilde gerçekleştirilebilmesi için üretim aşamalarının standart zamanlarının doğru şekilde ve gerçeğe yakın olarak tahmin edilmesi gereklidir. Bu çalışma, kalıp üretim aşamalarının standart zamanlarının tahmini ile ilgilidir.

Planlama faaliyetlerinin yapıtaşları, üretim planının zaman boyutunu oluşturan standart işlem süreleridir. Bu işlem sürelerinin üretim öncesinde tahmin ediliyor olması gerekmektedir. Kalıp üretim süreleri doğru şekilde tahmin edilebilmesi, planlama faaliyetlerinin daha başarılı olarak gerçekleştirilebilmesi için önemlidir. Kalıp üretim aşamalarının standart zamanlarının doğru olarak belirlenmesi, üretim zamanlarının bilimsel şekilde modellenerek tahmin edilmesi bu çalışmanın konusunu oluşturmaktadır.

Otomotiv endüstrisi sac kalıpçılığında kullanılan kalıp tipleri (çekme kalıbı, çevre kesme kalıbı ve ütüleme kalıbı) için üretim sürelerinin tahminine yönelik olan bu çalışmada, öncelikli olarak kalıpların üretim süresine etki edebilecek teknik parametreler belirlenmiştir. Sürelerin belirlenmesinde etkili olan bu teknik parametrelerin tahmini için bu parametrelere etki eden alt parametreler belirlenmeye çalışılmıştır. Bu alt parametreleri girdi (bağımsız değişken) olarak alarak teknik parametreleri (bağımlı değişken) tahmin eden tahmin modelleri geliştirilmiştir. Çalışmada, kalıp üretim aşamalarının standart zamanlarını tespit etmek amacıyla temel olarak iki farklı yaklaşım uygulanmıştır. Bu yaklaşımlar, çalışmanın gerçekleştirildiği işletme tarafından sağlanan, veri analizine uygun bağımlı ve bağımsız değişkenlerin bir

arada olduđu veri setleri üzerinde uygulanmıřtır. Veri setleri, her kalıp tipi için 30'ar adet olmak üzere toplamda 90 adet kalıp için bağımlı ve bağımsız deęişken verilerden oluřmaktadır. Bu örnek veriler, her üç kalıp için de, 25 ve 5 adet örnek içerecek řekilde iki kısma ayrılmıř ve verilerin 25 adet örnek içeren kısmı yöntemlerin uygulanabilir hale gelmeleri için bazı deęerlerin belirlenmesi ve 5 adet örnek içeren ikinci kısmı da test amacıyla kullanılmıřtır.

Yukarıda da belirtildięi gibi, bu çalıřmada, kalıp üretim sürelerini etkileyen teknik parametre ve alt parametre bilgilerini kullanarak, kalıp üretim ařamalarının standart zamanlarını tahmin etmek amacıyla, iki farklı yaklařım uygulanmıř olup bunlar regresyon analizi yaklařımı ve yapay sinir aęları yaklařımıdır. Bu yaklařımların bařarısı, uygulanan yöntemlerin, test verilerindeki tahmin sonularını gereęe en yakın olarak belirleyebilmeleridir. Bařka bir deyiřle, bir yaklařımın dięerine göre daha bařarılı olabilmesi için bu yaklařımın test verileri için elde ettięi tahmin sonularının dięerine göre gereęe daha yakın olması gerekmektedir.

İlk yaklařımda, regresyon analizi için öncelikle, üretim süresinde etkili olduęu öngörülen teknik parametreler ile alt parametreler arasındaki iliřkiler öncelikle tek faktör bazında incelenmiřtir. Analizde, kalıp üretim sürelerini etkileyen teknik parametreler üzerinde etkin olan olmayan bağımsız deęişkenler ANOVA çalıřmalarıyla tespit edilmiř ve ANOVA çalıřmasında etkin çıkan faktörler ile regresyon denklemleri geliřtirilmiřtir. Derlenen veriler ile oluřturulan regresyon modelleri yeni üretim için geerli olan teknik parametrelerin belirlenmesi için ilgili deęerler girilerek, test edilmiř ve tahmin edici olma özellięi kazandırılmıřtır.

İkinci yaklařımda, kalıp üretim sürelerini belirlemek için bir yapay sinir aęı kullanılmıřtır. Uygulamada kullanılan yapay sinir aęının giriş sayıları her kalıp tipine göre farklı olup çekme, çevre kesme ve ütüleme kalıpları için sırasıyla 10,12 ve 11'dir. Tek çıkıřa sahip olan yapay sinir aęı, her kalıp tipi için farklı çıkıřlar için uygulanmakta olup çekme kalıbı için 10, çevre kesme kalıbı için 11, ütüleme kalıbı için 9 farklı çıkıř söz konusudur.

Yapay sinir ađı, ayrı olarak her kalıp tipi için derlenen 30 adet veriden 25 adedi kullanarak eđitilmiřtir. Bu amala, yapay sinir ađına, kalıp tipine bađlı olarak ıkıřlar verilmiřtir. Yapay sinir ađı, eđitiminin tamamlanmasının ardından, 5 adet test verisi üzerinde alıřtırılmıřtır. Bu řekilde, eđitim ve test iřlemleri yapılarak, elde edilen sonuların tahmin performansları incelenmiřtir.

Bu iki yaklařım ile yapılan uygulama sonuları karřılařtırmalı olarak deđerlendirilmiřtir.

Bu alıřma ařađıdaki blmlerden oluřmaktadır:

İkinci kısımda sac kalıpılıđı, otomotiv endstrisi sac kalıpları, kalıp retimi zorlukları ile ilgili genel bilgiler ve kalıp retim ařamalarının standart zamanlarının belirlenmesi ile ilgili olarak literatrdeki alıřmalardan bahsedilmiřtir. nc kısımda materyal blmnde sırasıyla regresyon analizi ve yapay sinir ađı metotları hakkında bilgi verilmiřtir. Yntem kısmında ise yapılan uygulama yapısı, ařamaları, uygulama sonuları ile birlikte aktarılmıřtır. Drdnc kısımda ise geliřtirilen tahmin metotları, uygulama sonularına gre deđerlendirilmiřtir. Beřinci blm tartıřmada ise alıřmanın genel sonucu ve ilerleme yn incelenmiřtir.

2. KONU İLE İLGİLİ ÇALIŞMALAR

Bu bölümde çalışmaya konu edilen sac metal kalıpları hakkında genel bilgiler ile literatür araştırmaları özetine yer verilmiştir.

2.1. Kuramsal Bilgiler

Kalıp, talaş kaldırmadan metal veya metal olmayan malzemelere, uygun preslerde kesme, basma, eğme, bükme, vurma, çekme vs. operasyonlarla, şekil veren komple aparatlardır (Ataşımşek 2002).

Günümüzde, kalıplarla üretilen parçalar, yaşantımızın neredeyse her bölümüne girmiş durumdadır. Mutfak malzemelerinden elektrik-elektronik endüstrisine, özellikle otomotiv endüstrisi ve birçok diğer endüstri kollarında kalıplarla üretilen parçalar yaygın olarak kullanılmaktadır.

Kalıpçılık sektörü, ülkemizde otomotiv sektörünün gelişmesiyle birlikte bir ivme kazanmış ve sektörde hızlı gelişmeler yaşanmıştır. Kalıpçılığın gelişmesiyle kalıplar birtakım avantajları da beraberinde getirmiştir. Bu avantajlar aşağıdaki gibi özetlenebilir:

- Kalıplanan parçaların üretim oranı yüksektir.
- Seri üretimi kolaydır.
- Her parça için sarf edilecek insan gücü azdır.
- Üretimin otomatik olarak yapılması mümkündür.
- Üretilen parçaların, çoğu zaman yeniden işlenmesine gerek yoktur.
- Üretilen parçalar ölçü tamlığı içinde özdeştir.
- Diğer metotlar ile üretilemeyen çok küçük parçaların üretimi mümkündür.
- Değişik biçimdeki parçaların üretimi ekonomiktir.
- Bazı hallerde kalıplama tezgâhını ve kalıbı değiştirmeden farklı malzemelerden aynı parça kalıplanabilmektedir.
- Üretim süresince, kalıplanan parça ölçüleri istenilen sınırlar içerisinde kontrol edilir.

Bunun yanı sıra kalıpların kullanılmasının getirdiği zorluklar da söz konusudur. Kalıpların bazı dezavantajları ise aşağıda sıralanmıştır:

- Kalıp maliyeti yüksektir.
- Kalıp yapımında kullanılan tezgâh ve avadanlıkları çok pahalıdır.
- Bazı hallerde üretimin kontrolü zordur.
- İyi bir kalıpcının yetiştirilmesi zordur.
- Kalite kontrolü kısa zamanda yapılamayabilir.
- Probleme esas olabilecek bilgiler yetersiz kalabilir.
- Kalıp ömrünü istenilen sınırlar içerisinde tutmak zor olabilir.

Kalıpçılığın ana bölümlerinden biri sac metal kalıpcılığıdır. Özdeş parçaları, istenen ölçü sınırları içerisinde ve en kısa zamanda talaş kaldırmadan üreten, malzeme sarfiyatı ve insan gücünün asgari düzeyde tutulmasına yardımcı olan, takım tezgâhları ile çalışan aygıtlar, sac metal kalıpları olarak isimlendirilmektedir (Anonim 2011). Sac metal kalıpcılığında, seri halde sac metal malzemelerden talaş kaldırmaksızın parça üretilmesi esastır.

Otomotiv endüstrisi sac metal kalıpcılığında kullanılan çeşitli kalıp tipleri mevcuttur. Bunlara örnek olarak açınım kalıpları, derin çekme kalıpları, kesme ve delme kalıpları, çekme kalıpları, bükme ve ütüleme kalıpları verilebilir. Bu çalışmada, üretim aşamalarının süre tahmin çalışmaları, otomotiv endüstrisi sac metal kalıpcılığında yaygın olarak kullanılan çekme kalıpları, çevre kesme kalıpları ve ütüleme kalıpları için gerçekleştirilmiştir.

Kalıp sektöründe, üretim planlama büyük bir önem taşımaktadır. Kalıp üretimi uzun süreli ve birçok aşamadan oluşan karmaşık bir süreç olması sebebiyle üretim planlama faaliyetleri özellikle zorlayıcı olmaktadır. Üretim sürelerinin doğru olarak tahmin edilememesi verimlilik düşmesine ve planlama sıkıntılarına yol açmaktadır. Yüksek maliyetli makinelere ihtiyaç duyan yapıdaki üretim sürecinde, yapılan bir yanlış ya da hatalı süre tahmini durumu üretim planlarında ciddi sapmalara neden olabilmektedir. Kalıpcılık sektöründe, kalıp üretim aşamalarının standart zamanlarının belirlenmesi ile ilgili sıkıntı uzun zamandır var olan bir sorundur.

Dođru şekilde yapılan üretim planlama, işletmelerde üretim sürecinde akışın düzgün olması ve verimlilik açısından oldukça önemlidir. Kalıp üretim faaliyetlerinin planlanmasında, kalıp teslim süresinin tahmin edilmesi, kalıp elemanlarının iş emirlerinin takibi, tezgahların kapasite planlaması ve çizelgelenmesi, gerçekleşen maliyetin kontrolü, gerçekleşen ve planlanan faaliyetlerin farklılaşması dikkat edilmesi gereken noktalardandır.

Üretim planlama faaliyetleri, işletmelerin en yüksek verimlilikte düşük maliyet ile çalışmasını hedefler. Bunu gerçekleştirirken, süre hesaplamaları için, üretim sürecinin standart zamanlarının belirlenmesi üretim planlamanın en önemli aşamalarından birini oluşturmaktadır. Çünkü doğru planlama yapabilmenin önemli unsurlarından biri, öngörülen standart zamanların doğru şekilde tahmin ediliyor olmasıdır. Planlama faaliyetinin ana elemanı olan işlem sürelerinin üretim öncesinde tahmin edilmesi gerekmektedir.

Kalıpçılık sektöründeki bir işletmede, kalıp üretim aşamalarının standart zamanlarının doğru olarak tahmin ediliyor olması, kalıp için doğru üretim planlama yapabilmeyi sağlayacaktır. Gerçekleştirilen bu planlama ile yüksek maliyetli makineler daha verimli kullanılabilir ve işletme makine kapasitelerini daha doğru şekilde planlayabilecektir. Kapasite miktarlarının gerçeğe yakın olarak öngörülebilmesiyle, daha fazla üretim yapılabilecektir. Bu sayede işletmenin maliyetleri düşerken, verimliliği ve karlılığı artacaktır. Bu kazanımların yanı sıra, doğru belirlenmiş standart zamanlar ile gerçekleştirilen doğru planlama faaliyetleri ile yeni kalıp siparişleri için daha doğru teslim zamanları belirlenebilirken maliyet tahminleri de daha iyi şekilde yapılabilecektir. Ayrıca, teslim zamanları rakiplere göre daha avantajlı olarak tespit edilebilmesi işletmeye rekabet gücü de kazandıracaktır.


Kalıp üretiminde doğru üretim planlama faaliyetleri için temel oluşturan kalıp üretim sürelerinin belirlenmesini zorlaştıran birtakım etkenler söz konusudur. Bu zorluğu oluşturan başlıca etkenler aşağıda sıralanmıştır:

- *Farklı Kalıp Tipleri*


Parçaların üretileceği kalıp tipleri, kalıp üretim sürelerinin farklı olmasının önemli nedenlerinden biridir. Her bir kalıp tipi sahip olduğu özelliklere göre farklı kalıp üretim sürelerine sahiptir. Farklı kalıp tiplerine örnek olarak çalışmada konu edilen çekme kalıbı, çevre kesme kalıbı ve ütüleme kalıbı verilebilir.

- *Parça Geometrilerindeki Farklılıklar*

Parça geometrilerindeki farklılıklar, üretim sürelerinin belirlenmesini zorlaştıran diğer bir etken olarak sıralanabilir. Parçaların yüzey ve kesme hattı geometrilerindeki farklılıkları, kalıp ebadını, tasarım, CNC, montaj, tesviye & alıştırma sürelerini etkilemektedir. Şekil 2.1’ de görüldüğü gibi benzer büyüklükteki iki parçanın geometrik farklılıkları, toplam üretim saatlerini etkilemektedir.



Toplam Üretim Saati: 2100 Saat



Toplam Üretim Saati: 1425

Şekil 2.1. Farklı geometriye sahip parçalar

- *Parça Üzerindeki Farklı Tolerans Değerlerine Sahip Bölgeler*

Parça üzerindeki farklı tolerans değerine sahip olan bölgelerin yer alması kalıp üretim sürelerini etkileyebilmektedir. Parça üretiminin istenen toleranslarda üretilmesi için çeşitli imalat işlemleri gerçekleştirilir. Parça üzerinde düşük

toleranslı bölgelerin fazla olması, daha çok işlem ve hassas çalışma gerektirebilmektedir. Bu da parça üzerine daha uzun süre çalışılmasını gerektirmektedir. Örneğin, tolerans değerlerinin sağlanması için, CNC, tesviye & alıştırma işlemlerinin birkaç defa tekrarlanması gerekebilir. Parçanın özelliğine göre değişen bu durum üretim süresinin öngörülebilmesini zorlaştıran faktörlerdendir.

2.2. Kaynak Araştırması

Çalışmada, kalıp üretim aşamaları, bu aşamaların süre tahmini, ilgili kalıp parametreleri ve standart zamanların belirlenmesi konuları öncelikli odak seçilerek literatür araştırmaları gerçekleştirilmiştir.

Kang, Kim ve Rhee (1994), çalışmalarında kalıp üretim proseslerinde standart zamanların belirlenmesi üzerinde durmuşlardır. Kalıp üretiminde çok fazla ve farklı formda üretim işleminin olduğunu belirterek standart zamanların farklı üretim süreçlerine, çalışma metotlarına göre değişiklik göstereceğine dikkat çekmişlerdir. Bu durumun standart zamanların belirlenmesini zorlaştırdığını çalışmalarında vurgulamışlardır. Bu nedenle, metotlar ve iş durumları sınırlandırılarak her bir proses çalışması için standart verinin kuralı belirlenmiştir. Çalışmada, standart veriler kullanılarak çoklu doğrusal regresyon analizi ile standart zamanlar belirlenmiştir.

Standart zamanların girdi olarak kullanıldığı bir çalışma Lee ve arkadaşları (1995) tarafından gerçekleştirilmiştir. Makalelerinde, kalıp üretim fabrikalarının makul bir değerlendirme yapmaksızın siparişleri kabul ettiğini belirtmiş ve bu durumun üretim çizelgesinin kontrolünü zorlaştırdığını aktarmışlardır. Çalışmada, kalıp üretiminin bazı karakteristikleri belirlenerek ve gerçek ve potansiyel yüklemeler göz önüne alınarak hızlı sipariş kabul değerlendirmesi için sezgisel bir metot önerilmiştir. Bu metodun uygulanabilmesi için tüm operasyonların standart zamanları ve makinelerin kapasite bilgilerinin bulunması gerektiği belirtilmiştir.

Pilani, Narasimhan, Maiti, Singh ve Date (2000) ise tasarım süresinin ve toplam kalıp üretim süresinin azaltılması odaklı bir çalışma gerçekleştirmişlerdir. Çalışmada, sac metal şekillendirme kalıp tasarımı için hibrid akıllı sistemler yaklaşımı geliştirmişlerdir.

Kalıp tasarımının karmaşık bir prosedür olduğunu ve ayrıca kalıp tasarım faaliyetinin kalıbın üretimin süresinin yaklaşık %20'sini kapladığı belirtilmiştir. Ayrıca tasarım sürecinde alınan kararların üretim verimliliğini %70 - %80 etkilediği aktarılmıştır. Geliştirilen hibrit akıllı sistem yaklaşımı ile çeşitli tasarım parametreleri ile proses parametreleri (katman kalınlığı, matkap hızı vb.) değerlendirilerek kalıba en uygun tasarım parametrelerinin seçilmesini sağlayarak kalıp tasarım süresini ve toplam kalıp üretim süresini azaltıldığı belirtilmiştir. Sistemde çeşitli tasarım ve süreç parametrelerinin otomatik seçimi sezgisel kurallara dayanarak yapılandırıldığı çalışmada aktarılmıştır.

Toplam kalıp üretim zamanının önemine vurgu yapan Altan ve Lillg ve Yen (2001), makalelerinde kalıpların birçok üretim sürecinde kullanıldığını belirterek kalıpların üretim sektöründeki önemini vurgulamışlardır. Kalıpların kalitesi, maliyeti ve toplam üretim zamanının özellikle otomotiv sektöründe büyük miktardaki parçaların üretim ekonomisini etkilediği belirtilmiştir. Buna bağlı olarak kalıp üreticilerinin kalıp üretim süreçlerindeki teknolojilerini ve yöntemlerini geliştirmeleri gerektiğine dikkat çekilmiş, sektördeki önemli gelişmelere ve tasarım, şekillendirme gibi alanlarda pratik uygulamalar hakkında bilgiler verilmiştir.

Boujelbene, Moisan, Tounsi ve Brenier (2004) çalışmalarında kalıp üretim aşamalarından biri olan yüzey işleme prosesi üzerine eğilmiş ve yüzey işleme prosesinde farklı metotlar denemişlerdir. Belirlenen metotlar uygulanmış yüzeylerin kaliteleri gözlemlenmiş ve metotların yüzey kalitesine olan etkileri incelenmiştir. Yüzey kalitelerinin seçilen metotlarla iyileştirilmesiyle yüzey perdahlama işlem zamanlarının %30'dan daha fazla oranda azaltılabildiği çalışmada belirtilmiştir. Bu nedenle çalışmanın kalıp üretim sektörü için önemli bir verimlilik adımı olarak yorumlandığı aktarılmıştır.

Kuzman ve Nardin (2004), çalışmalarında kalıp üreticisi firmalarının yaşadığı kalıp boşluğu yapımı için teknoloji seçim zorluğu ve önemi üzerinde durmuşlardır. Kalıp boşlukları için teknoloji tercihinin genellikle çalışanların deneyimlerine dayandığını belirterek optimal olmayan tercihlerin yapıldığını aktarmışlardır. Çalışmalarında, kalıp üretiminde kullanılan iki ana üretim teknolojisinden hangisinin kullanımının optimal

olacağı kararını ortaya koyabilen bir model geliştirmişlerdir. Bu model, biçimlendirilen her kalıp parçası için optimal üretim teknolojisinin seçilmesine yardımcı olmaktadır. Kuzman ve Nardin, teknoloji tercihi ile asıl amaçlarının kalıbı mümkün olan en kısa sürede, en az maliyetle ve istenen kalite ile üretebilmek olduğunu belirtmişlerdir. Geliştirdikleri model, 13 farklı parametreye dayanmakta olup dinamik özellik taşımaktadır. Bu özelliği ile yeni teknolojiler ile ilgili verilerin tanımlanarak modelin geliştirilmesinin mümkün olduğu aktarılmıştır.

Schützer, Helleno ve Pereira' da (2006) seçilen üretim metotlarına göre değişen üretim süreleri ile ilgilenmişlerdir. Ürün partilerinin düşmesi, çeşitliliğin artması ve yeni ürünlerin hızla ortaya çıkması ile dünya ekonomisinde öne çıkan kalıp üretimi üzerinde çalışmalarını yoğunlaştırmışlardır. Belirlenen değişkenler içerisinde geometrik hassasiyet, ürün özelliklerini oluşturan yüzey işleme parametreleri temel olarak zaman bakımından sorumlu tutulmuştur. Deneysel bir çalışma olan makalelerinde, kesme stratejileri ile işleme zamanı ve parça yüzey kalitesinin ilişkisi araştırılmıştır. Seçilmiş olan malzeme ve farklı kesme stratejileri (paralel hat, zig-zag vb.) kullanılarak gerçekleştirilen deneysel çalışmada işleme zamanı ve yüzey kaliteleri karşılaştırılmıştır. Bu çalışma ile kesme stratejilerinin üretilen kalıp geometrisine bağlantılı olarak etki ettiği sonucu ortaya çıkarılmıştır. Bu etkilerin, hazırlık sürelerinde, yüzey bitirme ve CAM programlama sürelerinde gözlemlenebileceği belirtilmiştir.

Literatür araştırmalarında, kalıp üretim aşamalarında standart zamanların belirlenmesinden farklı olarak toplam kalıp üretim süresinin çeşitli teknolojiler kullanılarak düşürülmesi, değişik metotlarla kalıp yüzey kalitesinin artırılması gibi benzeri yöntem ile süre ya da yöntem ile kalite ilişkisinin araştırıldığı çalışmalarla ağırlıklı olarak karşılaşılmıştır.

Araştırmalara, tahmin çalışmalarına yönelik olarak farklı çalışma alanlarında son yıllarda yapılan çalışmalar incelenerek devam edilmiştir. Özellikle regresyon analizi ve yapay sinir ağları metotlarının tahmin için kullanımları araştırılmıştır.

Erzin ve Çetin (2013) çalışmalarında, homojen sonlu şevleri güvenlik değerinin kritik faktörünün tahmini için yapay sinir ağları ve çoklu regresyon modellerinin geliştirilebileceği ile ilgilenmişlerdir. Bu amaçla çalışmada, farklı toprak ve şev

parametrelerine sahip 675 homojen sonlu şev kritik faktör değerleri basitleştirilmiş Bishop metodu ile hesaplanmış, her şev için kritik (minimum) güvenlik değeri belirlenmiş ve yapay sinir ağları ve çoklu regresyon modellerinde kullanılmıştır. Her iki modelden alınan sonuçlar, hesaplamalardan elde edilen bu değerlerle karşılaştırılmıştır. Çalışma sonucunda yapay sinir ağı modelinin tahmin değerlerinin çoklu regresyon tahmin sonuçlarına göre hesaplanmış olan kritik faktör değerleriyle daha iyi eşleştiği görülmüştür. Buna ek olarak, geliştirilen tahmin modellerinin tahmin kapasitelerini incelemek üzere belirtme katsayıları (R^2), ortalama karesel hata (RMSE) gibi bazı performans göstergeleri hesaplanmıştır. Bu performans kriterlerine göre yapay sinir ağı modelleri regresyon modellerine göre daha yüksek bir tahmin performansı gösterdiği çalışma sonuçlarında aktarılmıştır. Elde edilen sonuçlar, yapay sinir ağı modellerinin homojen sonlu şev tasarımında başlangıç aşamasında kullanılabileceğini kanıtı olarak yorumlanmıştır.

Rodriguez, Borroto, Lpuerta, Perez ve Verhelst (2013) tarafından gerçekleştirilen bir başka çalışmada ise biyodizel yakıtın setan sayısının tahmini için yapay sinir ağları ve çoklu lineer regresyon yöntemleri kullanılmıştır. Dizel yakıtın en önemli kalite göstergesi olarak setan sayısı, yanma bölümüne enjekte edilen yakıtın tutuşmaya yatkınlığını ölçmektedir. Çalışmada, biyodizel yakıtların yağlı ester metil kompozisyon bilgilerinden yola çıkarak setan sayılarını tahmin etmek üzere yapay sinir ağları ve çoklu doğrusal regresyon metotlarıyla tahmin modelleri geliştirilmiştir. Modellerin oluşturulmasında literatür raporlarından alınan modelleme-eğitim aşaması ve validasyon aşaması için 48 ve 15 biyodizel yakıtın verisinin yer aldığı deneysel verilerin kullanıldığı çalışmada aktarılmıştır. Çalışmada 2 temel topoloji ve ikinci eğitim aşaması için farklı algoritmalar kullanan 24 farklı yapay sinir ağı değerlendirildiği aktarılmıştır. Geliştirilen çoklu doğrusal regresyon modeli sonuçları, literatürdeki diğer iki model ile karşılaştırılmıştır. Regresyon modeli, setan sayısını %89 doğrulukla tahmin edebildiği belirtilmiştir. Yapay sinir ağı modeli ise %92 doğrulukla setan sayısını tahmin edebilmiştir.

Asiltürk (2012) ise yapay sinir ağları ve çoklu doğrusal regresyon metotları ile AISI 1040 çelik malzemenin yüzey pürüzlülüğünü tahmin etmek üzere bir çalışma yapmıştır. Modeller, kesme parametreleri girdi, bunlara karşılık gelen yüzey pürüzlülüğü değerleri

ise çıktı olarak kullanılarak optimize edilmiştir. Çalışmada kesme parametreleri içinde kesme hızı, ilerleme hızı, kesme derinliği ve köşe radyüsü yer almaktadır. Yüzey pürüzlülüğü, yüzeydeki farklı noktalardan alınan pürüzlülük ölçümlerinin ortalaması ve toplamı olarak karakterize edilmiştir. Toplamda 81 farklı deney gerçekleştirilmiş ve her farklı kesme parametre değerlerinde yapılan bu deney sonuçları kayıt edilmiştir. Bu deneylerden alınan girdi-çıkı değerlerine göre geliştirilen modellerden alınan sonuçlar değerlendirilmiş ve yapay sinir ağı modellerinin çoklu doğrusal regresyona göre daha iyi sonuçlar alındığı aktarılmıştır. Sonuçlara göre, yüzey pürüzlülüğünde ilerleme hızının en baskın faktör olduğu tanımlanmıştır. Gelecek araştırmalar için bir üretim tesisinde tornalama süreci boyunca yüzey pürüzlülüğünün tahmininde maliyet, gerçek zamanlı uygulama bakımından yapay sinir ağları kullanımının uygulanabilirliği üzerinde durulacağı çalışmada aktarılmıştır.

Literatürde son yıllarda yapılan araştırmalarda, yapay sinir ağları ve regresyon metotlarının tahmin çalışmalarında birlikte incelenerek sonuçlarının karşılaştırıldığı görülmüştür.

3. MATERYAL VE YÖNTEM

Kalıp üretim aşamalarının standart zamanlarını belirlemek üzere kullanılan materyal ve yöntem ile ilgili açıklamalar bu bölümde aktarılmıştır.

3.1. Materyal

Çalışmada kullanılan materyal ile ilgili bilgilere bu bölümde yer verilmiştir.

3.1.1. Regresyon Analizi

Çalışmada kullanılan tekniklerden regresyon analizi ile ilgili genel bilgiler bu bölümde sunulmuştur.

3.1.1.1. Genel Bilgiler

Nicel değişkenlerin bulunduğu her türlü ortamda, değişkenler arasında basit ya da karmaşık işlevsel ilişkiler olabilir. Bu durumda, bazı değişkenlerin diğer değişkenler üzerinde etkilerini incelemek gerekmektedir. Birçok deneysel çalışmada, bir değişkenin aynı nesne üzerinde yapılan bir veya daha çok ölçmeyle ilişkili olduğu durumlarda, diğer değişkenleri nasıl etkilediği ve aralarındaki ilişkinin şeklini tahmin için matematiksel işlevler ve ilişkilerden yararlanır (Öztürkcan 2009).

İki (veya daha çok sayıda) değişken arasında bir ilişki bulunup bulunmadığı, eğer varsa bu ilişkinin derecesinin saptanması sıkça araştırılan bir konudur (Serper 2000). Değişkenler arasındaki ilişki yeterince kuvvetli ise ve bu ilişki matematiksel fonksiyonla ifade edilebiliyorsa, değişkenlerden birine ilişkin veriler mevcutsa, diğer değişkenin verileri yaklaşık olarak tahmin edilebilir.

Değişkenler arasındaki ilişkilerin araştırılması genel olarak iki tür sorun için gerekli olur. Bunlardan ilki, bir değişkene ilişkin gözlem sonuçları yardımıyla diğer değişkenin alabileceği değerleri tahmin etmekle ilgilidir. Diğer bir sorun ise, değişken değerlerinde gözlenen farklılıkların ne ölçüde belirleyici bazı etmenlere bağlanabileceği ile ilgilidir (Serper 2000).

Regresyon analizi, değişkenler arasındaki sebep sonuç ilişkisini araştırır ve modelleyen bir istatistik tekniğidir. Regresyon uygulamaları günümüzde giderek yaygınlaşmaktadır.

Mühendislikten fizik ve kimyaya, ekonomiden yönetim ve sosyal bilimlere kadar pek çok alanda regresyon uygulamaları görülebilir. Regresyon analizinin, en geniş kullanımı olan istatistiksel teknik olduğu söylenebilir (Montgomery ve ark. 2001).

Regresyon analizi, ölçülebilen bir veya daha fazla değişkenin üzerinde etkili olduğu düşünülen başka bir değişkenle arasındaki ilişkilerin bir matematiksel eşitlik ile açıklanması ya da modellenmesidir. Değişkenler arasındaki ilişki bir neden-sonuç ilişkisidir. Regresyon analizi, aralarında neden-sonuç ilişkisi bulunan iki veya daha fazla değişken arasındaki ilişkiyi belirlemek ve bu ilişkiyi kullanarak o konu ile ilgili tahminler ya da kestirimler yapabilmek amacıyla yapılır. Ancak değişkenler arasında istatistiksel açıdan bir ilişkinin bulunması, neden-sonuç ilişkisinin varlığına bir kanıt değildir. Bu durum, sadece böyle bir ilişkinin var olabileceğine işaret etmektedir. Diğer yönden, değişkenler arasında istatistiksel açıdan herhangi bir ilişki bulunmadığında neden-sonuç ilişkisinin olmadığı yorumlanmaktadır.

Değişkenler arasındaki ilişki doğrusal olabileceği gibi, doğrusal olmayan bir ilişki de olabilir. Korelasyon, değişkenler arasındaki ilişkinin yönünü ve derecesini gösterir. İlişkinin derecesi ise oransal bir ölçü olan korelasyon katsayısı ile belirtilir. Regresyon, bağımlı ve bağımsız değişkenler arasındaki ilişkinin yönünü ve kuvvetini göstermemektedir (Serper 2000). Bu nedenle, regresyon analizi öncesinde değişkenler arasında korelasyon varlığı araştırılması gerekir.

İki değişken arasındaki ilişkinin derecesinin ve yönünün belirlenmesi için kullanılan istatistiksel yöntem ise korelasyon analizidir. Analizde, değişkenlerin bağımlı veya bağımsız olması dikkate alınmaz. Değişkenler arasındaki doğrusal ilişkinin derecesini ölçerken hiçbir şekilde neden-sonuç ilişkisi kurulmaz (Serper 2000).

Bilinen bulgulardan, gelecekteki olaylarla ilgili tahminler yapılmasını sağlayan regresyon modelinde, etkilenen değişken **bağımlı değişken** olup bağımlı değişken modelde açıklanan ya da tahmin edilen değişkendir. Buradaki varsayım, bu değişkenin bağımsız değişken ile ilişkili olduğudur. Regresyonda etkileyen değişkenler ise **bağımsız değişkenler**dir. Bağımlı değişkenin değerini tahmin etmek için bu değişkenler kullanılır.

Bu çalışmada, bağımlı değişken ile bir veya daha çok bağımsız değişken arasındaki ilişkiyi araştırmak amacıyla uygulanan yöntemlerden biri doğrusal regresyon analizidir. Bu yöntemde, bir tek bağımsız değişkenin kullanıldığı regresyon analizi basit regresyon, birden fazla bağımsız değişkenin kullanıldığı regresyon analizi ise çoklu regresyon analizi olarak adlandırılmaktadır.

3.1.1.2. Basit Doğrusal Regresyon Analizi

Basit doğrusal regresyon analizi bir bağımlı değişken ve bir bağımsız değişken arasındaki ilişkiyi inceleyen analiz tekniğidir. Bu analizle bağımlı ve bağımsız değişkenler arasındaki doğrusal (lineer) ilişkiyi temsil eden bir doğru denklemi formüle edilmektedir. Tekli doğrusal regresyon analizi olarak da adlandırılan bu regresyon analizi normal dağılıma sahip, hakkında aralıklı/oranlı ölçekle veri toplanmış iki değişken arasında doğrusal ilişki olup olmadığını test etme olanağı verir.

Bir bağımlı değişken ile bir bağımsız değişken arasındaki doğrusal ilişkiyi açıklayan basit regresyon modelinin genel formu aşağıdaki gibidir (Montgomery ve ark. 2001):

$$y = \beta_0 + \beta_1 x + \varepsilon \quad (3.1)$$

Eşitlikte,

y : bağımlı değişkendir.

x : bağımsız değişkendir, hatasız ölçüldüğü varsayılır.

β_0 : sabit değerdir.

β_1 : regresyon katsayısıdır. x 'in kendi birim cinsinden 1 birim değişimine karşılık y 'de kendi birimi cinsinden oluşacak değişim miktarıdır.

ε : tesadüfi hata terimidir. Ortalaması sıfır (0), varyansı σ^2 olmak üzere normal dağılım gösterdiği varsayılmaktadır. Bu varsayım, katsayıların önem kontrolü için gerekli olmaktadır.

Doğrusal regresyon analizi aşağıda yer alan bazı varsayımlara dayanmaktadır (Montgomery ve ark. 2001):

- Bağımlı değişken ile bağımsız değişkenler arasındaki ilişki doğrusaldır.

- Hata terimleri (ε_i), ortalaması sıfır olan deęişkenlerdir.
- Hata terimleri (ε_i), varyansları aynı olan deęişkenlerdir.
- Hata terimleri birbirinden baęımsızdır.
- Hatalar tesadüfidir ve normal daęılmaktadır.

Bu varsayımlar, genel olarak doğrusal regresyon analizinin kabulleri olup tekli ve çoklu regresyon analizinin her ikisi için de geçerlidir.

3.1.1.3. Çoklu Doğrusal Regresyon Analizi

Herhangi bir baęımlı deęişkeni tek bir baęımsız deęişken ile açıklamak gerçek hayatta birçok model için yeterli deęildir. Bu tür modeller için iki veya daha fazla açıklayıcı (baęımsız) deęişkene ihtiyaç duyulmaktadır. Örneęin, ekonomik modeller, genellikle birden fazla sebebin sonucudur. Bu modellerde çok fazla sayıda deęişken bir araya gelerek bir dięer deęişkeni etkileyebilmektedirler. Bu deęişkenler aynı zamanda kendi aralarında da birbirlerini etkileyebilmektedir. Bu sebeple, bu duruma benzer olarak birden fazla deęişkenin kullanılması gereken durumlarda basit doğrusal regresyon analizi yapılması yetersiz olmaktadır.

Bir baęımlı deęişken ve birden fazla baęımsız deęişkenin yer aldığı doğrusal regresyon modelleri çoklu doğrusal regresyon analizi olarak adlandırılır. Birden çok baęımsız deęişkenli çoklu regresyon analizi bir baęımsız deęişken içeren basit regresyon analizinin doğal bir uzantısıdır. Çoklu deęişken regresyon analizinde baęımsız deęişkenler eş zamanlı olarak (aynı anda) baęımlı deęişkendeki deęişimi açıklamaya çalışmaktadır.

Baęımlı deęişken ile baęımsız deęişkenler arasındaki ilişkiyi matematiksel bir modelle istatistik temellere oturarak açıklamak ve baęımsız deęişkenler yardımıyla baęımlı deęişken için kestirimde bulunabilmek çoklu regresyon analizinin amaçlarındandır (Alpar 2003). Birden fazla baęımsız deęişkenle açıklanabilen model için de, baęımsız deęişkenlerin sayılarını azaltarak az sayıda parametre ile baęımsız deęişkeni açıklamak da başka bir amacdır (Bayazıt 2006).

Çoklu doğrusal regresyon modelinin genel formu aşağıdaki gibidir (Montgomery ve ark. 2001):

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \varepsilon \quad (3.2)$$

Eşitlikte, basit doğrusal regresyona benzer olarak;

y : bağımlı değişkendir, belli bir hataya sahip olduğu varsayılır.

x : bağımsız değişkenlerdir, hatasız ölçüldüğü varsayılır.

k : bağımsız değişken sayısıdır.

β_j : regresyon katsayılarıdır. Bu değer, diğer bağımsız değişkenler ($x_i (i \neq j)$) sabit olmak üzere x_j 'deki bir birim değişiminin y değişkeninde oluşturduğu değişim miktardır ($j = 0, 1, \dots, k$). Bu nedenle, kısmi regresyon katsayıları olarak da adlandırılır.

ε : tesadüfi hata terimidir.

Birden fazla bağımsız değişkenin yer aldığı çoklu regresyon denklemlerinde, mevcut bağımsız değişkenlerin, bağımlı değişkendeki toplam değişimi açıklamada yetersiz kaldığı durumlarla karşılaşılabilir. Böyle bir durumda, oluşturulan regresyon modeline yeni bir ya da birden fazla bağımsız değişken eklenebilir. Karşılaşılan başka bir durum ise, denklemdeki mevcut bağımsız değişkenlerden bazıları bağımlı değişkendeki toplam değişimi açıklamada istatistiksel olarak etkileri bulunmamasıdır. Bu bağımsız değişkenler çoklu regresyon modelinden çıkarılabilir.

Doğrusal regresyon modelinin varsayımlarından biri, bağımsız değişkenler arasında tam veya kuvvetli doğrusal bağlılığın olmamasıdır. Bağımsız değişkenler arasında doğrusal ya da doğrusala yakın ilişkilerin varlığı durumunda çoklu doğrusal bağlılıktan söz edilir (Serper 2000). Tam bir doğrusal bağlılık olduğu durumda parametreler belirlenemez hale gelir. Bu nedenle, çoklu regresyon analizinde, bağımsız değişken seçiminde kendi aralarında yüksek korelasyona sahip bağımsız değişkenlerden sadece biri seçilmelidir. Bu sebeple, regresyon analizi öncesinde tüm değişkenlerin korelasyon matrisleri incelenmeli ve aralarında yüksek korelasyon alanlardan biri seçilerek model oluşturulmalıdır.

Çoklu regresyon modelinde bağımsız değişken sayısının artması durumunda, oluşturulan birçok model arasında amaca uygun en iyi regresyon denkleminin seçiminin

yapılması gereği ortaya çıkar. Bağımsız değişkenler arasında oluşabilecek çoklu doğrusal bağıllık sorununu aşmak ve isteğe en uygun gelen regresyon modelini belirleyebilmek için ileriye doğru seçim, geriye doğru ayıklama ya da adımsal regresyon gibi yöntemler uygulanabilir (Montgomery ve ark. 2001). Bu çalışmada bu konuda adımsal regresyon analizi yönteminden yararlanılmıştır.

Adımsal regresyon analizi, tamamen matematiksel ölçütlere göre girilmektedir. Bağımlı değişkendeki değişimi en fazla açıklayan tahmin değişkeni bulunur, sonra geri kalan değişimi en fazla açıklayan tahmin değişkeni bulunarak bu şekilde ilerletilir. Başka bir deyişle, bağımlı değişkene en fazla etki eden bağımsız değişkenler denkleme alınırken diğer değişkenleri denklemden çıkarmaktadır.

Çoklu regresyonun iki yaygın kullanım amacı, tahmin ve nedensellik analizidir. Tahmin analizinde hedef, bağımsız değişkenlerden elde edilen verilere dayanarak bağımlı değişken üzerinde tahmin yapabilmek için formül geliştirmektir (Çelik 2010).

3.1.1.4. Regresyon Modelinin Oluşturulması

Bir regresyon modeli oluşturulurken kullanılan genel yaklaşım en küçük kareler yöntemidir. Bu yöntem, parametrelerin (regresyon katsayılarının) tahmin edilmesinde hata teriminin dağılışı ile ilgili herhangi bir varsayım söz konusu değilse kullanılır (Öztürkcan 2009). En küçük kareler yöntemi, gözlenen değerlerin beklenen değerler ile arasındaki farkların karelerinin toplamını en az yapacak şekilde parametreleri tahmin eder.

Regresyon denklemleri oluşturulurken kullanılan en küçük kareler yöntemi çoklu doğrusal regresyon modeli için bu kısımda detaylandırılmıştır. Çoklu doğrusal regresyon modeli için, her bir gözlem içinde yer alan bağımlı değişken y , bağımsız değişken x ve rassal hata ε 'nin toplamının doğrusal bir fonksiyonu olarak yazılmaktadır. Buna bağlı olarak, çoklu doğrusal regresyon denklemi, n gözlem sayısı, k bağımsız değişken sayısı, β regresyon katsayıları olmak üzere (3.3) nolu denklem ile ifade edilebilir (Montgomery ve ark. 2001).

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_k x_{ik} + \varepsilon_i \quad (i = 1, \dots, n) \quad (3.3)$$

(3.3) nolu denkleme göre, y değerlerinin tahminini gösteren ifade;

$$E(y_i) = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_k x_{ik} \quad (3.4)$$

şeklindedir. Yöntemde, β regresyon katsayıları buna bağlı olarak $E(y)$ değeri bulunması hedeflenmektedir. Burada, β ' ların tahmini $\hat{\beta}$ ile ifade edilirse, denklemin yeni ifadesi;

$$\hat{E}(y_i) = \hat{\beta}_0 + \hat{\beta}_1 x_{i1} + \hat{\beta}_2 x_{i2} + \dots + \hat{\beta}_k x_{ik} \quad (3.5)$$

şeklinde olur. $\hat{E}(y_i)$ arařtırmalarda genellikle \hat{y}_i olarak atanmaktadır. Dolayısıyla, burada dikkat edilmesi gereken nokta, \hat{y}_i 'nin y_i 'yi deęil $\hat{E}(y_i)$ 'yi tahmin etmekte olduęudur.

\hat{y}_i 'lerin en küçük kareler tahminleri, y 'lerin modelden sapmalarının karelerinin toplamını minimize etmektedir. Burada,

$$S(\beta_0, \beta_1, \dots, \beta_k) = \sum_{i=1}^n \hat{e}_i^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \sum_{i=1}^n \left(y_i - \beta_0 - \sum_{j=1}^k \beta_j x_{ij} \right)^2,$$

$$j = 1, \dots, k \quad (3.6)$$

denklemini minimum deęere ulařtıracak $\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_k$ deęerleri bulunmaya çalıřılmaktadır. (3.7) nolu denklemi minimize eden $\hat{\beta} = (\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_k)$ deęerleri, matris formundaki,

$$\hat{\beta} = (X'X)^{-1}(X'y) \quad (3.7)$$

denklemini ile elde edilmiřtir (Montgomery ve ark. 2001). Oluřturulan regresyon denklemini, $x' = [1, x_1, x_2, \dots, x_k]$ olmak üzere;

$$\hat{y} = x' \hat{\beta} = \hat{\beta}_0 + \sum_{j=1}^k \hat{\beta}_j x_j \quad (3.8)$$

şeklinde ifade edilir.

Regresyon modellerinin oluşturulması sonrasında, hazırlanan modelin gerçeğe uygunluğunu yansıtan gösterge, tanım aralığı 0-1 arasında olan determinasyon katsayısı (R^2) olarak adlandırılan ölçüttür. Bu katsayı bağımlı değişkenin gözlenen değeri ile modelde tahminlenen değeri arasındaki korelasyon katsayısının karesidir. Değer, bağımlı değişkendeki değişmelerin yüzde kaçının bağımsız değişkendeki farklılaşmalardan kaynaklandığını yansıtmakta ve nedensellik hakkında belirgin fikir vermektedir (Okkan ve Mollamahmutoğlu 2010).

R^2 , 0'a yaklaşırsa modelin verilere uygun olmadığı yani modelin verileri açıklamadığı anlaşılır. R^2 değerini analizinin yorumlanması önemlidir. Çünkü bağımsız bir değişkenin eklenmesi bile R^2 de artış meydana getirebilir. Bir bağımsız değişkenin modele eklenmesiyle artarak değişen R^2 , serbestlik derecesi dikkate alınarak belli bir miktar azaltılması ile düzeltilir ve düzeltilmiş \bar{R}^2 elde edilir. Bir modeli analiz ederken R^2 ile \bar{R}^2 arasındaki fark belirli bir dereceden fazla ise \bar{R}^2 değerine bakılması gerekir (Alpar 2003).

Determinasyon katsayısı,

y_i : bağımlı değişkenin orijinal hali,

\bar{y} : tahmin serisi,

n : ölçüm sayısı olmak üzere,

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3.9)$$

şeklinde ifade edilir.

Modelin istatistiksel olarak uygunluğunun test etmek için uygulanan bir diğer yöntem ise varyans analizi (ANOVA)'dir. Bağımsız değişkenlerin kendi aralarında nasıl etkileşime girdiklerini ve bu etkileşimlerin bağımlı değişken üzerindeki etkilerini analiz etmek için kullanılır. F testine göre karar vermeyi sağlayan bu teknik ile regresyon modelinin istatistiksel olarak anlamlılığı analiz edilmektedir. Yapılan ANOVA

sonuçlarına göre model için hesaplanan F değeri, F tablo değerinden büyük ise, modelin genel olarak uygun olduğu kabul edilir (Bayata ve Hattatoğlu 2010).

3.1.2. Yapay Sinir Ağları

Yapay sinir ağları ile ilgili genel bilgiler bu bölümde sunulmuştur.

3.1.2.1. Yapay Sinir Ağı Tanım ve Özellikleri

Yapay sinir ağları (YSA), insan beyninin çalışma sisteminin yapay olarak benzetimi çabalarının bir sonucu olarak ortaya çıkmış ve beynin çalışma yöntemini modellemek için tasarlanmış olan sistemlerdir (Takçı 2010). En genel anlamda bir YSA insan beynindeki birçok sinir hücresinin (nöronun) veya yapay olarak basit işlemcilerin birbirlerine değişik etki seviyeleri ile bağlanması sonucu oluşan karmaşık bir sistem olarak düşünülebilir.

Beynin çalışma ilkelerinin sayısal bilgisayarlar üzerinde taklit edilmesi fikri ile ortaya çıkan yapay sinir ağlarına ilişkin ilk çalışmalar beyni oluşturan biyolojik hücrelerin, literatürdeki ismiyle nöronların matematiksel olarak modellenmesi üzerinde yoğunlaşmıştır (Elmas 2003). Bu çalışmalar, her bir nöronun komşu nöronlardan birtakım bilgiler aldığını ve aldığı bu bilgilerin biyolojik nöron dinamiğinin öngördüğü biçimde bir çıktıya dönüştürüldüğünü ortaya çıkarmıştır.

Yapay sinir ağları; yapısı, bilgi işleme yöntemindeki farklılık ve uygulama alanları nedeniyle çeşitli bilim dallarının da kapsam alanına girmektedir (Elmas 2003). Günümüzde YSA fizik, matematik, elektrik ve bilgisayar mühendisliği gibi çok farklı bilim dallarında araştırma konusu haline gelmiştir. İnsan beyninin çalışma sistemini taklit etmeye çalışan yapay sinir ağları, karar hızı açısından insan beyni ile yarışabilecek aşamaya henüz gelmemiş olmalarına rağmen, karmaşık eşleştirmelerin hassas bir biçimde gerçekleştirilebilmesi ve yapısal gelişmişliğe sahip olmaları nedeniyle, her geçen gün uygulama alanları genişlemektedir (Çavdur 2005).

Sinir sisteminin modellenmesi için yapılan çalışmalar sonucu oluşturulan yapay sinir ağları, biyolojik sinir sisteminin üstünlüklerine de sahiptir. Yapay sinir ağları, günümüzde birçok bilim alanında sahip olduğu üstün özellikleri nedeniyle etkin olmuş

ve uygulama yeri bulmuştur (Elmas 2003). Bu özellikler ve getirdiği avantajlara aşağıda yer verilmiştir (Haykin 1999):

- *Doğrusallık:* Yapay sinir ağlarının temel işlem elemanı hücre doğrusal olmayabilir ve bu durumdaki hücrelerin birleşmesi ile oluşan yapay sinir ağıda doğrusal olmaz. Aynı katmanlar arasında zaman bağımlılığı da bulunmamaktadır. Bu, tüm sistemin eş zamanlı çalışabilmesine olanak vermekte ve hızı çok artırmaktadır. Bu özelliği ile YSA doğrusal olmayan karmaşık problemlerin çözümlenmesine olanak sağlar.
- *Öğrenebilirlik:* Yapay sinir ağlarının istenilen davranışı sergileyebilmesi için amaca uygun girilen bilgiler kullanılarak hücreler arasında doğru bağlantıların yapılması ve bağlantıların uygun ağırlıklara sahip olması gerekir. Yapay sinir ağının karmaşık yapısı nedeniyle önceden bağlantılar ve ağırlıkları verilemez. Ancak yapay sinir ağının örneklerle kendini eğitmesi ve gerekli verileri oluşturması bu sorunu ortadan kaldırmaktadır.
- *Genelleme:* Yapay sinir ağları eğitimi sonrasında, eğitim için ağına verilmemiş test örnekleri de değerlendirip, istenen tepkileri üretebilir. Örneğin, bir sistemin eğitilmiş yapay sinir ağı modeli, eğitim sürecinde verilmeyen girdi sinyalleri için de sistemle aynı davranışı göstermesi mümkündür.
- *Hata Toleransı:* Çok sayıda hücrenin çeşitli şekillerle bağlanmasından oluşan yapay sinir ağlarındaki paralel yapı, ağıdaki bilginin tüm bağlantılara yayılmasını sağlamaktadır. Bu sebeple, bazı bağlantıların veya hücrelerin etkisiz hale gelmesi ağın doğru bilgiyi üretmesini önemli derecede etkilemez ve bununla birlikte yapay sinir ağlarının klasik yöntemlere göre hatayı tolere etme yetenekleri son derece yüksektir.
- *Uyarlanabilirlik:* Yapay sinir ağlarında ağırlıklar, ilgilenilen probleme göre yeniden yapılandırılabilir olması belirli bir problemi çözmek için eğitilen yapay sinir ağının, problemdeki değişikliklere göre yeniden eğitilebilmesi ve farklı koşullara uyarlanabilmesini sağlamaktadır. Bu özelliği ile yapay sinir ağları,

örnek tanıma, sinyal işleme, sistem tanılama ve denetim gibi alanlarda etkin olarak kullanılır.

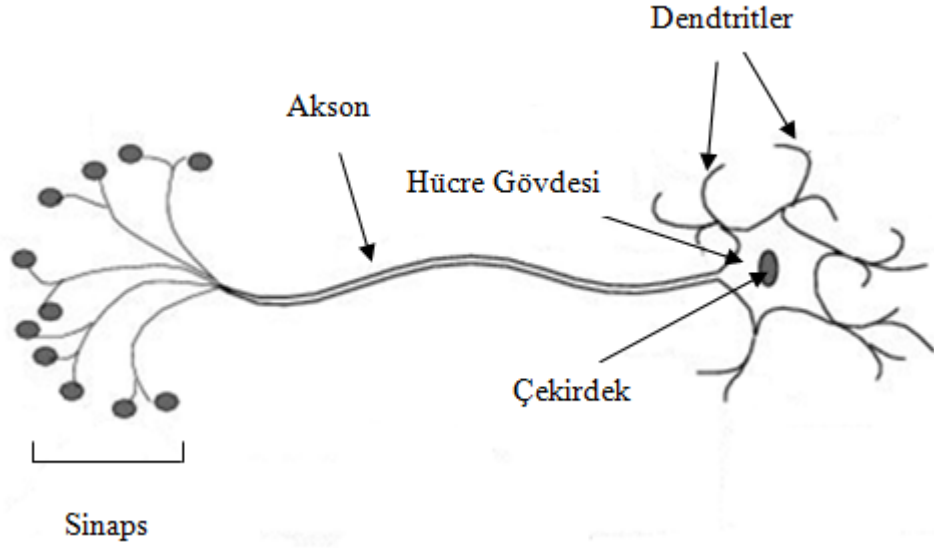
- *Donanım ve Hız:* Yapay sinir ağları, paralel yapısı sayesinde entegre devre teknolojisi ile gerçekleştirilebilir. Bu özellik, hızlı bilgi işleme yeteneğini artırmaktadır.
- *Analiz ve Tasarım Kolaylığı:* YSA'nın temel işlem elemanı olan hücrenin yapısı ve modeli, bütün YSA yapılarında çoğunlukla aynıdır (Ergezer ve ark. 2003). Bu nedenle, farklı uygulama alanlarında kullanılan yapay sinir ağları benzer öğrenme algoritmalarını ve teorilerini paylaşabilirler. Bu özellik, problemlerin YSA ile çözümünde önemli bir kolaylık getirmektedir.

Bu üstün özelliklerinin yanı sıra yapay sinir ağları, mühendislik açısından bakıldığında bir kara kutu özelliği de taşımaktadır. Dışarıdan bilgileri alıp çıktılar üreten sistemin çalışması analiz edilememektedir (Elmas 2003). Diğer bir deyişle, ağların sonuçları nasıl oluşturduğunu açıklama yeteneği yoktur. Bu durum, uygulamalarda risk oluşturmakla birlikte başarılı uygulamalar yapay sinir ağlarına olan ilgiyi arttırmaktadır.

3.1.2.2. Yapay Nöron Modeli

İnsan beyninin çalışma fonksiyonlarının örnek alınarak geliştirilen yapay sinir ağları, birbiriyle bağlantılı birçok yapay sinir hücresinden meydana gelmektedir. Yapay sinir hücreleri, biyolojik sinir hücrelerinin basit bir modelidir. Bu yüzden aralarında yapısal olarak bazı benzerlikler vardır (Öztemel 2003).

Yapay sinir hücresi, gerçek biyolojik hücreyle aynı ilkelere dayandırılmaya çalışılmıştır (Fausett 1994). Şekil 3.1' de görülen gerçek sinir hücrelerinin genel yapısı ile yapay sinir hücrelerinin yapısı arasındaki benzerlikler Çizelge 3.1' de verilmiştir.



Şekil 3.1. Biyolojik sinir hücresi

Biyolojik bir sinir hücresi; bir gövde, bir akson, çok sayıda sinir ucu (dendrit) ve akson ile diğer sinir hücresinin sinir ucu arasında kalan ince uzantılar (sinaps) olmak üzere dört kısımdan oluşmaktadır. Dendritler, gelen sinyalleri çekirdeğe iletirken çekirdek dendritten gelen sinyalleri bir araya toplar ve aksona iletir. Toplanan bu sinyaller, akson tarafından işlenerek sinapslara gönderilir. Sinapslar da yeni üretilen sinyalleri diğer sinir hücrelerine iletir.


Yapay sinir hücreleri, biyolojik sinirlere göre daha basit bir yapıda olsa da, biyolojik sinirlerin yukarıda aktarılmış olan temel işlevlerini taklit ederler. Yapay bir sinir hücresinde girdiler (x_1, x_2, \dots, x_n) kendilerine ait ağırlıklarla çarpılarak toplandıktan sonra aktivasyon fonksiyonuna gönderilirler. Aktivasyon fonksiyonuna gelen sinyal, burada işlenerek çıktıya dönüştürülür (Öztemel 2003).

Çizelge 3.1. Biyolojik sinir hücresi ile yapay sinir hücresi arasındaki benzerlikler

Biyolojik Sinir Hücresi	Yapay Sinir Hücresi
Dendrit	Toplama fonksiyonu
Hücre Gövdesi	Transfer fonksiyonu
Aksonlar	Eleman çıkışı
Sinapslar	Ağırlıklar

Bir YSA modelinin temel birimi, Şekil 3.2' de gösterilen işlem elemanıdır. Bu eleman yapay nöron olarak adlandırılır. Nöron modelinin üç temel elemanı vardır (Çavdur 2005):

- Her biri kendine ait bir ağırlıkla karakterize edilen, sinapsisler (synapses veya connecting links) kümesi. Özel olarak, j sinapsisindeki k nöronuna bağlı olan x_j sinyali, w_{kj} ağırlığıyla çarpılır. w_{kj} ağırlığında indislerinin yazım şekli önemlidir. İlk indis incelenen nörona, ikinci indis de sinapsisin giriş tarafındaki nörona karşılık gelmektedir. Literatürde bu gösterimin tersi de kullanılmaktadır. İlgili sinapsis yükseltici ise w_{kj} ağırlığı pozitif, indirgeyici ise negatiftir.
- Sırasıyla nöronun sinapsisleri tarafından ağırlıklandırılmış giriş sinyallerini toplamak için bir toplayıcı, burada açıklanan işlemler bir doğrusal birleştirici oluşturmaktadır.
- Nöron çıkışının büyümesini sınırlandırmak için bir aktivasyon fonksiyonu (activation veya squashing function). Tipik olarak, normalize edilmiş bir nöron çıktısı $[0,1]$ veya $[-1,+1]$ aralıklarındadır.



Şekil 3.2. Matematiksel nöron modeli

x_1, x_2, \dots, x_p	: giriş sinyalleri,
$w_{k1}, w_{k2}, \dots, w_{kp}$: sinaptik ağırlıklar,
u_k	: doğrusal birleştirici çıktısı,
θ_k	: eşik değeri,
$\varphi(\cdot)$: aktivasyon fonksiyonu
y_k	: çıkış sinyali olmak üzere,

k nöronu,

$$U_k = \sum_{j=1}^p w_{kj}x_j \quad (3.10)$$

ve

$$y_k = \varphi(u_k - \theta_k) \quad (3.11)$$

denklemleriyle tanımlanabilir.

θ_k eşik değeri uygulanmasıyla, doğrusal birleştiricinin u_k çıkışında,

$$v_k = u_k - \theta_k \quad (3.12)$$

şeklinde bir dönüşüm olmaktadır.

Yapay sinir ağları, bu temel yapıdan türetilmiştir. Ağların farklı sınıflandırılması, bu yapıdaki farklılıklardan kaynaklanmaktadır (Elmas 2003).

Aktivasyon Fonksiyonları

Nöron davranışının belirleyen önemli etmenlerden biri nöronun aktivasyon fonksiyonudur. Biyolojik nöronlarda v ile gösterilen toplam, belli bir değeri aştığında nöronun kısa süreli bir darbe gönderdiği bilinmektedir. Bu davranışa benzer bir davranışı yapay nöronlarla da elde etmek için aktivasyon fonksiyonları kullanılır (Efe ve Kaynak 2000). Aktivasyon fonksiyonu, yapay sinir hücresinin çıktısının büyüklüğünü sınırlandıran fonksiyondur (Mandic ve Chambers 2001). Sıklıkla transfer fonksiyonu olarak da isimlendirilen bu fonksiyon, hücrelere gelen net girdiyi bir


işlemden geçirerek hücre çıktısını oluşturur. Yapay nöron modelinde $\varphi(\cdot)$ olarak ifade edilmekte olan aktivasyon fonksiyonları doğrusal ve doğrusal olmayan özellikte olabilmektedir. Nöron modellerinde, hücrenin gerçekleştireceği işleve göre çeşitli tipte aktivasyon fonksiyonları kullanılabilir (Elmas 2003).

Hücre çıktısı, aktivasyon fonksiyonuna bağlı olarak değiştiği için bu fonksiyon seçimleri yapay sinir ağı modelleri için önemlidir (Hagan ve ark. 1996). Yapay sinir ağlarında, ağı gerçekleştireceği işleve ya da probleme göre kullanılan aktivasyon fonksiyonları değişim göstermektedir. Bununla birlikte, aşağıda yaygın olarak kullanılan bu aktivasyon fonksiyonları tanıtılmıştır:

- a) Eşik aktivasyon fonksiyonu: Eşik aktivasyon fonksiyonu, nöron net çıkışı için eğer net değer sıfırdan küçükse sıfır (0), sıfırdan daha büyük bir değer ise +1 değeri verir. Eşik aktivasyon fonksiyonunun -1 ile +1 değerleri arasında değişen versiyonu ise signum aktivasyon fonksiyonu olarak adlandırılır. Signum aktivasyon fonksiyonu, nöron net girdi değeri sıfırdan büyükse +1, sıfırdan küçükse -1, sıfıra eşit olduğu durumlarda sıfır değerini verir. Şekil 3.3'te eşik aktivasyon fonksiyonunun grafiği görülmektedir. Eşik aktivasyon fonksiyonu;

$$f(x) = \begin{cases} 1, & \text{eğer } x \geq 0 \\ 0, & \text{eğer } x < 0 \end{cases} \quad (3.13)$$

şeklinde ifade edilir.




Şekil 3.3. Eşik aktivasyon fonksiyonu

b) Doğrusal (Linear) aktivasyon fonksiyonu: Bu aktivasyon fonksiyonunda, nöron girişlerinin değişimine göre nöron çıkışları doğrusal olarak değişim gösterir. Diğer bir deyişle, hücrenin net girdisini doğrudan hücre çıkışı olarak vermektedir. Şekil 3.4'te görülmekte olan doğrusal aktivasyon fonksiyonu genellikle ağıncı katmanında kullanılmaktadır. Bu aktivasyon fonksiyonu;

$$f(x) = x \quad (3.14)$$

şeklinde ifade edilir.




Şekil 3.4. Doğrusal aktivasyon fonksiyonu

c) Lojistik fonksiyon: Sigmoid aktivasyon fonksiyonu, yapay sinir ağı yapılarında en yaygın olarak kullanılan aktivasyon fonksiyonudur. Sigmoid fonksiyonunun örneklerinden biri lojistik fonksiyondur (Haykin 1999). Lojistik aktivasyon fonksiyonunun türevi alınabilir, sürekli ve doğrusal olmayan bir fonksiyon olması nedeniyle en çok kullanılan aktivasyon fonksiyonudur. Lojistik aktivasyon fonksiyonu genellikle geri yayımlı öğrenme algoritmasının kullanıldığı çok katmanlı yapay sinir ağlarında kullanılır (Hagan ve ark. 1996). Fonksiyonun lineer olmamasından dolayı türevinin alınması özelliği ile geri yayımlı ağlarda kullanmak mümkün olabilmektedir (Aynekin 2006). Değişim aralığı [0 1] olan fonksiyon, bu aralıkta lineer olmayan bir değişim sergiler. Şekil 3.5' te logaritma sigmoid aktivasyon fonksiyonu görülebilir. Lojistik fonksiyon,

$$f(x) = \frac{1}{1+\exp(-ax)} \quad (3.15)$$

şeklinde ifade edilir. Buradaki a eğim sabitidir. Eğim sabitinin farklı değerler almasıyla, farklı eğimlerde sigmod fonksiyonları oluşmakla birlikte genellikle bu değer 1 olarak alınmaktadır (Haykin 1999, Aynekin 2006).




Şekil 3.5. Logaritma sigmoid aktivasyon fonksiyonu

- d) Hiperbolik tanjant aktivasyon fonksiyonu: Bu fonksiyon, sigmoid fonksiyonunun bir başka formudur (Haykin 1999). Lojistik fonksiyona benzer olarak lineer olmayan ve türevi alınabilir bir fonksiyondur. Hiperbolik tanjant fonksiyonu, giriş uzayının genişletilmesinde etkili olan bir aktivasyon fonksiyonudur. Bu fonksiyonunun çıktısı +1 ile -1 aralığında oluşmaktadır. Fonksiyon, Şekil 3.6'da görülmektedir. Hiperbolik tanjant fonksiyonu;

$$f(x) = \tanh(vx) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.16)$$

şeklinde ifade edilir.



Şekil 3.6. Hiperbolik tanjant aktivasyon fonksiyonu

Uygulamalarda nöron cevabının, girdilerin sürekli bir fonksiyonu olmasını gerektiren durumlarda sigmoid aktivasyon fonksiyonları kullanılırken, ikili karar mekanizması gerektiren durumlarda eşik aktivasyon fonksiyonları tercih edilmektedir (Efe ve Kaynak 2000).

3.1.2.3. Yapay Sinir Ağı Yapısı

Biyolojik sinir ağlarının sinir hücrelerinden oluşmasına benzer olarak yapay sinir ağları da yapay sinir hücrelerinden oluşmaktadır. Sinir hücreleri bir grup halinde işlev gördüklerinde ağ olarak adlandırılırlar ve böyle bir grupta binlerce nöron bulunur. Yapay nöronların birbirleriyle bağlantılar aracılığıyla bir araya gelmeleri yapay sinir ağını oluşturmaktadır. Yapay sinir ağıyla aslında biyolojik sinir ağının bir modeli oluşturulmak istenmektedir. Nöronların aynı doğrultu üzerinde bir araya gelmeleriyle katmanlar oluşmaktadır (Haykin 1994).

Bir yapay sinir ağı, birbirleriyle bağlantılı sinirlerin yer aldığı temelde üç katmandan oluşmaktadır. Bu katmanlar sırasıyla, girdi katmanı, gizli katman ve çıktı katmanıdır (Şekil 3.7):

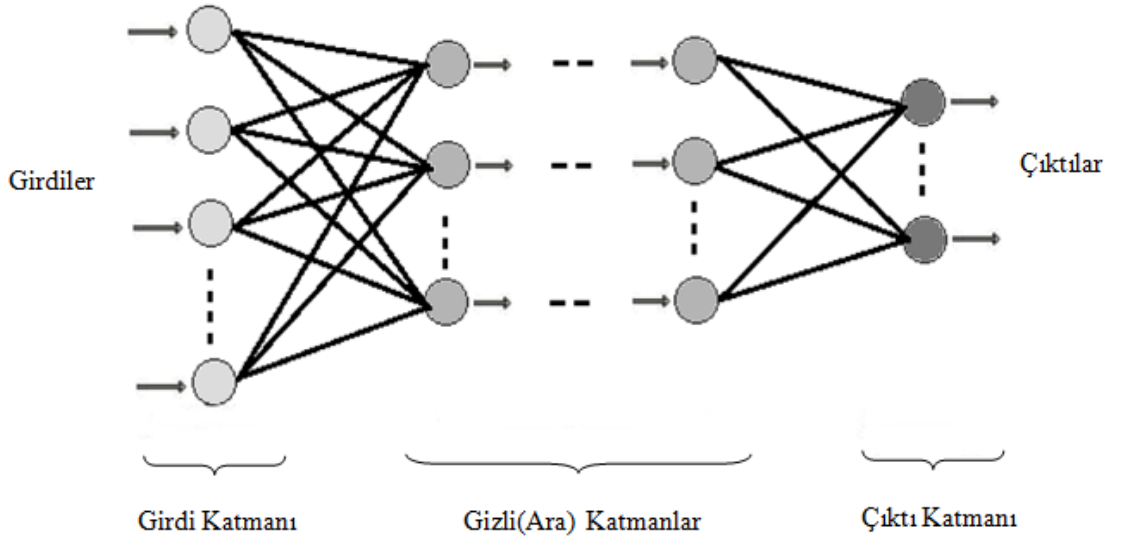
a) Girdi Katmanı:

Bu katman ağın ilk katmanıdır. Yapay sinir ağına dış dünyadan gelen bilgileri olarak ara katmanlara transfer eden işlem elemanlarını içerir. Dışarıdan alınan bu bilgiler istatistikte bağımsız değişkenlere karşılık gelir. Girdi katmanında, girdi

sayısı kadar hücre bulunmaktadır. Ağa alınan bilgiler herhangi bir işleme olmaksızın ara katmanlara iletilirler.

b) *Gizli Katman (Ara Katman)*: Girdi katmanı ile çıktı katmanı arasında yer alan bu katman, girdi katmanından gelen bilgileri işleyerek bir sonraki katmana iletir. Bilgilerin işlenmesi gizli katmanlarda gerçekleştirilir. Ağ içinde birden fazla gizli katman yer alabilir. Gizli katmanlarda hücre sayıları, girdi ve çıktı sayılarından bağımsızdır.

c) *Çıktı Katmanı*: Bu katman bilgilerin dışarıya iletilmesi görevini üstlenir. Gizli katmandan gelen bilgileri işleyerek girdi katmanına gelen girdiye uygun olarak üretmesi gereken çıktıyı üretir. Üretilen çıktı dış dünyaya bu katmandan gönderilir. Bu çıktı değişkenleri istatistikte bağımlı değişkenlere karşılık gelir. Çıktı katmanındaki hücre sayısı, birden büyük olabilir. Her bir çıkış hücresi, bir adet çıktıya sahiptir. Her bir hücre bir önceki katmanda yer alan bütün hücelere bağlıdır.



Şekil 3.7. Yapay sinir ağı modeli

3.1.2.4. Yapay Sinir Ağlarının Sınıflandırılması

Bir YSA, basit işlem elemanlarının (nöron) birbiriyle bağlanmış halidir ve çalışma sistemi olarak hayvan nöronunu temel alır. Ağın işlem kabiliyeti, birtakım eğitim örneği ile elde edilmiş olan birimler arası bağlantıların kuvvetinde veya ağırlığında saklıdır (Gurney 1997). Her bir sinir hücresi arasındaki bağlantıların yapısı ağın yapısını belirler. İstenilen hedefe ulaşmak için bağlantıların nasıl değiştirileceği öğrenme algoritması tarafından belirlenir. YSA'lar yapılarına ve öğrenme algoritmalarına göre sınıflandırılırlar (Haykin 1994). Hücrelerin bağlantı şekillerine, öğrenme kurallarına göre geliştirilen YSA yapıları bu bölümde tanıtılmıştır.

Yapılarına göre yapay sinir ağları

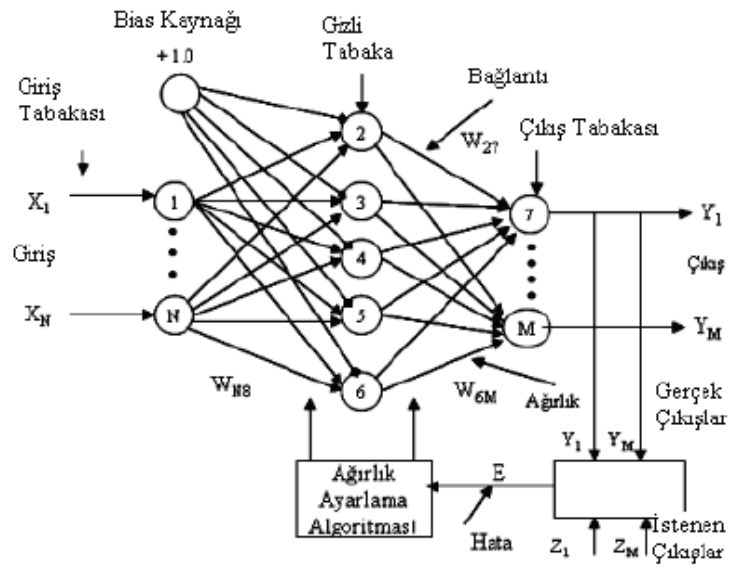
Yapay sinir ağlarında yer alan sinir hücreleri ve bağlantılar, farklı şekillerde bir araya gelerek farklı ağ mimarileri oluşturabilmektedir. Yapay sinir ağı mimarileri, sinirler arası bağlantıların yönlerine göre veya ağ içindeki işaretlerin akış yönlerine göre sınıflandırılabilirler. Buna göre, yapıları bakımından ağlar, ileri beslemeli (feedforward) ve geri beslemeli (feedback) ağlar olmak üzere iki şekilde sınıflandırılırlar.

- İleri beslemeli ağlar


İleri beslemeli yapay sinir ağlarında bilgi sadece ileri yönde gizli ve çıkış katmanına doğru hareket eder. Sistem belleksizdir. Bu yapay sinir ağı yapısına statik ağlarda denilmektedir (Nguyen 2007). İleri beslemeli ağlarda, sinirler yalnızca bir sonraki katmanda bulunan sinirlerle bağlantıya sahiptir. Bu modellerde ağın çıktısı, tamamen ağa giren girdilere bağlıdır. Bu ağlar, herhangi bir dinamiklik özelliği taşımazlar ve bu özellikleri ile doğrusal ve doğrusal olmayan kararlı problem alanlarında uygulanmaları mümkündür (Güneri ve Apaydın 2004). En çok bilinen geriye yayma öğrenme (Backpropagation) algoritması, bu tür yapay sinir ağların eğitiminde etkin olarak kullanılmaktadır. Şekil 3.8'de çok katmanlı ileri beslemeli yapay sinir ağı yapısı görülmektedir. İleri beslemeli ağlara örnek olarak çok katmanlı persepton (Multi Layer Perceptron-MLP) ve LQV (Learning Vector Quantization) ağları verilebilir (Aynekin 2006).

- Geri beslemeli ağlar

Geri beslemeli ağlarda bir tür geri besleme işlemi mevcuttur. Bu ağlarda, bir hücrenin çıktısı sadece bir sonraki katmana girdi olarak verilmez. Kendinden önceki katmanda veya kendi katmanında bulunan herhangi bir hücreye girdi olarak verilebilir. Geri beslemeli sinir ağı çıkış ve ara katlardaki çıkışlardan giriş birimlerine veya önceki ara katmanlara geri beslenmenin yapıldığı bir ağ yapısıdır (Aşkın ve ark. 2011). Bu sayede, girişler hem ileri yönde hem de geri yönde aktarılmış olur. Bu çeşit sinir ağlarının dinamik hafızaları vardır. Bu yapıdaki nöronların çıkışı sadece o anki giriş değerlerine bağlı değildir ayrıca önceki giriş değerlerine de bağlı olarak değişir. Bu ağlar çeşitli tipteki zaman-serilerinin tahmininde oldukça başarı sağlamışlardır (Mackay 1992). Bu ağlara örnek olarak Hopfield, SOM (Self Organizing Map), Elman ve Jordan ağları verilebilir (Aynekin 2006). Şekil 3.9'da bir geri beslemeli ağ yapısı görülmektedir.



Şekil 3.8. İleri beslemeli ağ (Aşkın ve ark. 2011)



Şekil 3.9. Geri beslemeli ağ (Aşkın ve ark. 2011)


Öğrenme modellerine göre yapay sinir ağları

Yapay sinir ağlarında bilgi, ağdaki bağlantıların ağırlıklarında depolanır. Bir ağda öğrenme, istenen bir işlevi yerine getirecek şekilde ağırlıkların ayarlanması sürecidir. Yapay sinir ağlarında öğrenme, sinirler arasındaki ağırlıkların değiştirilmesi ile gerçekleşmektedir. Buna göre sinirler arası bağlantılar üzerindeki ağırlıkları belirli bir yöntem ile dinamik olarak değiştirilebilen ağlar eğitilebilir. Öğrenebilen ağlar, yeni şekilleri tanıyabilir ya da verilen bir girişin hangi sınıfa ait olduğuna karar verebilir. Yapay sinir ağlarında öğrenme düğümler arasındaki ağırlıkların, düğümlerdeki etkinlik ya da aktarım işlevlerinin değişkenlerinin ayarlanmasıyla yapılmaktadır (Elmas 2003). Bu nedenle, ağın öğrenebilmesi için birtakım metot, gözlem ve eğitime göre ağdaki ağırlıkların değiştirilmesi sağlanmalıdır. Bunun için öğrenme metot ve kurallarından yararlanılmaktadır.

Yapay sinir ağları kullanılarak yapılan araştırmalarda en sık kullanılan üç öğrenme metodu ve bu metotların uygulandığı değişik öğrenme kurallarından söz edilebilir. Bu öğrenme metotları aşağıda açıklanmaktadır.

- Danışmanlı (Denetimli) Öğrenme Modeli


Bu tip öğrenmede, yapay sinir ağının kullanılmadan dışarıdan etki ile eğitilmesi söz konusudur. Eğitim sırasında, yapay sinir ağına hem girdi değerleri hem de bu girdi değerleri için doğru çıktı değerleri verilir. İstenilen çıktı ile ağın ürettiği çıktı karşılaştırılarak hata hesabı yapılır ve en uygun çıktıyı elde etmek üzere bağlantıların ağırlıkları yeniden düzenlenebilir. Bu sebeple danışmanlı öğrenme algoritmasında bir “öğretmene” veya “danışmana” ihtiyaç duyulur. Şekil 3.10’da danışmanlı öğrenme yapısı görülebilir. Danışmanlı öğrenme yöntemi, ileri beslemeli ağlarda daha sıklıkla kullanılan bir yöntemdir. Danışmanlı öğrenme yönteminde çalışma seti, verinin özellikleri ve gözlemlenebilir çıktılar hakkında bütün bilgileri içerir. Modeller, girdilerle çıktılarının ilişkisi öğrenilerek oluşturulabilir (Smith ve Gupta 2002). Bu öğrenme modelinde, sistemin performans fonksiyonu olarak karesel ortalama hata ya da toplam karesel hata seçilebilir (Haykin 1999). Widrow-Hoff tarafından geliştirilen delta kuralı ve Rumelhart ve McClelland tarafından geliştirilen genelleştirilmiş delta kuralı veya geri yayılım algoritması danışmanlı öğrenme algoritmalarına örnek olarak verilebilir.



Şekil 3.10. Danışmanlı öğrenme modeli blok diyagramı (Haykin 1999)

- Danışmansız Öğrenme Modeli

Danışmansız öğrenmede sistemin doğru çıkış hakkında bilgisi yoktur (Elmas 2003). Bir başka deyişle girdi değişkenlerine karşılık istenen çıktılar belirtilmez. Sisteme sadece girdiler verilir. Danışmansız öğrenmede amaç, veri setindeki modelin ortaya çıkarılmasıdır. Danışmansız olarak eğitilebilen ağlar, istenen ya da hedef çıkış olmadan giriş bilgilerinin özelliklerine göre ağırlık değerlerini ayarlar. Burada ağ istenen dış verilerle değil, girilen bilgilerle çalışır. Bu yaklaşımda, verilen giriş vektörleri için önceden bilinebilen performansını ölçebilecek ağ için hiçbir çıkış örneği sağlanmaz, yani ağ yaparak öğrenmektedir (Hanssens ve ark. 2001, Elmas 2003). Girişe verilen örneklerdeki parametreler arasındaki ilişkileri sistemin kendi kendine öğrenmesi beklenir. Girdi olarak verilen bilgilerden elde edilen çıkış bilgisine göre ağ, bağlantı ağırlıklarını aynı özellikleri gösteren desenler oluşturmak üzere ayarlar. Katmanlar arasındaki ağırlıkların ayarlanması ağ tarafından kendiliğinden gerçekleştirilir (Güneri ve Apaydın 2004). Şekil 3.11’de danışmansız öğrenme yapısı görülmektedir. Grossberg tarafından geliştirilen ART (Adaptive Resonance Theory) veya Kohonen tarafından geliştirilen SOM (Self Organizing Map) öğrenme kuralı danışmansız öğrenmeye örnek olarak verilebilir.

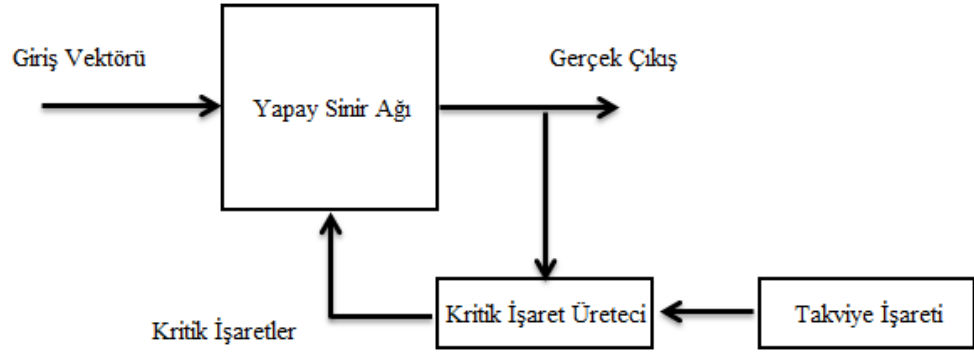


Şekil 3.11. Danışmansız öğrenme modeli blok diyagramı (Haykin 1999)

- Destekleyicili Öğrenme Modeli

Destekleyicili öğrenme, destek sinyali olarak adlandırılan bir performans ölçüsünü enbüyükleyecek şekilde tasarlanmış bir deneme ve hata sürecinde, giriş-çıkış haritalama şeklindeki bir bağlantılı öğrenmedir (Haykin 1999). Destekleyicili öğrenme modeli danışmanlı öğrenmeye benzer bir metottur. Bu

modelde farklı olarak, hedef çıktıyı vermek için bir “danışman” yerine, yapay sinir ağına bir çıkış verilmemekte fakat elde edilen çıkışın verilen girişe karşılık iyiliğinin danışman tarafından değerlendirilmesi istenir. Yapılan değerlendirme, ağın performansının ölçümü olarak düşünebilir. Bu değerlendirmeye bağlı olarak ödüllendirme ve cezalandırma yöntemiyle ağın ağırlıkları güncellenir. Şekil 3.12’de bu öğrenme yapısı gösterilmiştir. Bu öğrenme modeli danışmanlı öğrenme modeline göre daha az kullanılmakla birlikte kontrol sistemleri uygulamaları için daha uygundur (Hagan ve ark. 1996). Optimizasyon problemlerini çözmek için Hinton ve Sejnowski’nin geliştirdiği Boltzmann kuralı veya GA takviyeli öğrenmeye örnek olarak verilebilir.



Şekil 3.12. Destekleyici öğrenme modeli blok diyagramı

3.1.2.5. Yapay Sinir Ağlarında Öğrenme

Yapay sinir ağlarının gerçekleştirdiği temel fonksiyonlardan biri öğrenmedir. Ağların diğer bir önemli fonksiyonu ise performansını geliştirme yetenekleridir. Öğrenme işlemi, ağdaki ağırlık değerlerinin, bir giriş vektörüne karşılık istenen çıkış vektörünü sağlamak üzere uygulanan iteratif bir ayarlama sürecidir (Haykin 1999). Diğer bir deyişle, yapay sinir ağları mevcut örnek veri kümesi üzerinde girdi ile çıktı arasındaki sinaptik ağırlıkların değiştirilmesiyle eğitilirler.

Öğrenme, bir yapay sinir ağının bağımsız parametrelerinin, ağın bulunduğu çevre tarafından oluşturulan etkilerle ayarlandığı, sürekli bir süreçtir. Öğrenme tipi, parametre değişimlerinin nasıl gerçekleştiği ile ilgilidir (Haykin 1999). Buna göre, öğrenme

sürecinde, yapay sinir ađında çevreden etkilenmesi sebebiyle meydana gelen birtakım deęişiklikler dolayısıyla, çevreye farklı bir şekilde cevap verdiği söylenebilir.

Haykin (1999)'e göre öğrenme süreci, öğrenme algoritmaları (learning algorithms) ve öğrenme modelleri (learning paradigms) olmak üzere iki kısımda incelenmiştir. Genel olarak kullanılan öğrenme modelleri ile ilgili açıklamalar bir önceki kısımda yer almaktadır. Yapay sinir ađının eğitimi için birçok deęişik optimizasyon yöntemi bulunmaktadır. Ancak bu yöntemlerin içerisinde optimum sonucu garanti eden genel bir algoritma yoktur. Çeşitli problemlerin çözümünde kullanılan birçok farklı öğrenme algoritması bulunmaktadır. Yapay sinir ađlarında yaygın olarak kullanılan başlıca öğrenme algoritmaları aşağıda yer almaktadır:

- Geri Yayılım Öğrenme Algoritması
- Hebb Öğrenme Kuralı
- Hopfield Öğrenme Kuralı
- Kohonen Öğrenme Kuralı.

Bu kısımda, yapay sinir ađının mimarisine, karşılaşılan sorunun niteliğine göre farklılık gösteren bu öğrenme algoritmalarından en çok kullanılan öğrenme algoritması Geri Yayılım Algoritması tanıtılmıştır.

Geri Yayılım(Backpropagation) Algoritması

Geri yayılım algoritması, 1970'lerin başında geliştirilmiş, en etkili ve karmaşık, tanımlanamamış problemlere doğrusal olmayan çözümler getirebilen bir algoritmadır (Elmas 2003). Bu açıdan algoritma, yapay sinir ađları açısından en önemli tarihsel gelişmelerden biridir. Danışmanlı öğrenme algoritmalarından geri yayılım (backpropagation - BP) algoritması, yapay sinir ađlarının parametrelerinin güncellenmesi için literatürde en çok kullanılan yöntemdir (Fırat ve Güngör 2004). Geri yayımlı yapay sinir ađ sistemleri mükemmel tahmin yetenekleri nedeniyle tahmin problemlerinde sıkça kullanılmaktadır (Zheng ve ark. 2009).

Geri yayılım algoritması ileri beslemeli ve çok katmanlı bir ađ mimarisini gerektirmektedir (Haykin 1999). Çok katmanlı ađlar, bir girdi katmanı, bir veya daha

fazla sayıda gizli katman ve çıkış katmanından oluşmaktadır. Giriş sinyali ağda, ileri yönde katmanlar boyunca, yayılır.

Bir çok katmanlı ağın sahip olduğu ayırt edici karakteristikler aşağıda sıralanmıştır (Haykin 1999):

- Ağdaki her nöron modeli çıkışta doğrusal olmayan bir yapı içerir. Buradaki önemli nokta, doğrusal olmayan yapının sürekli olmasıdır. Bu gereksinimi karşılayan ve çok kullanılan bir doğrusal olmayan yapı şekli, $y_j = \frac{1}{1+\exp(-v_j)}$ sigmoid fonksiyonuyla tanımlanmaktadır. Formülasyondaki, v_j , j nöronunun net içsel aktivite düzeyi ve y_j de nöron çıkışıdır. Doğrusal olmayan yapıların bulunması önemlidir, çünkü diğer durumda, ağın giriş-çıkış ilişkisi bir katmanlı ağa dönüşebilmektedir. Bu fonksiyonun kullanımı, gerçek nöronlara benzerlik gösterdiği için biyolojik açıdan da önemlidir.
- Ağ, giriş ve çıkışın parçası olmayan ve gizli nöronlardan oluşan, bir veya daha fazla sayıda katman içermektedir. Bu gizli nöronlar, giriş vektöründen daha anlamlı özellikleri çıkararak, daha karmaşık görevlerin öğrenilmelerini sağlamaktadır.
- Ağ sinapsisleri tarafından belirlenen yüksek bir bağlantı yapısı göstermektedir. Ağın bağlantı yapısında meydana gelen bir değişiklik, sinaptik bağlantılar veya ağırlıklarının değiştirilmesini gerektirmektedir.

Çok katmanlı ağlara hesaplama gücü sağlayan bu karakteristikler, aynı zamanda ağın davranışı hakkında bilgi eksikliğine de sebep olmaktadır. Çünkü doğrusal olmamanın dağıtılmış yapısı ile ağın yüksek bağlantı yapısı çok katmanlı ağların teorik olarak incelenmesini zorlaştırmaktadır. Ayrıca, gizli nöronların kullanılması, öğrenme sürecini görmeyi güçleştirir. Öğrenme sürecinin, giriş örüntüsündeki hangi özelliklerinin gizli nöronlar tarafından gösterileceğine karar vereceği bir yapı daha belirleyici olabilir. Bu durumda, öğrenme süreci daha zor olmaktadır, çünkü arama, çok daha büyük bir olası fonksiyonlar uzayında yapılacak ve giriş örüntüsünün alternatif gösterimleri arasında seçim yapmak gerekecektir.

Çok katmanlı ağlar, geri yayımlı öğrenme algoritması ile eğitilip, çeşitli zor problemlerin çözümünde başarıyla kullanılmaktadırlar.

Geri yayımlı algoritma, ağdaki ağırlıkların bir fonksiyonu olarak görülen hata hedef fonksiyonu seçildiği ve hataların kareleri ortalaması dereceli azaltma yöntemi kullanılarak hedef fonksiyonunu minimize etmek üzere tasarlanmış optimizasyon tekniğidir. Bu algoritma, hataları çıkıştan girişe geriye doğru azaltmaya çalışmasından dolayı geri yayılım ismini almıştır (Haykin 1999).

Geri yayılım algoritmasının işlem adımları aşağıdaki gibi özetlenebilir (Nabiyev 2005):

- Girişler ve gizli katmanlar için ağırlıklar rassal olarak belirlenir.
- Öğretilecek vektör girişe uygulanır.
- Doğrusal olmayan sigmoid fonksiyonu kullanılarak değerler giriş seviyesinden gizli seviyeye ve yine aynı fonksiyon ile bu değerler (aktivasyonlar) çıkış seviyesine yayılır.
- Hedef çıkış ile gerçek çıkış karşılaştırılarak hata değeri hesaplanır. Bu değer önceden belirlenmiş sınır değerini aştığında; çıkış tabakasından gizli tabakaya ve gizli tabakadan giriş tabakasına geriye doğru yayılır.
- Ağırlıklar hata değerine göre yeniden düzenlenir ve tekrar eğitim işlemine geçilir.

Geri yayılım algoritmasının matematiksel gösteriminde kullanılan notasyonlar aşağıdaki gibidir (Haykin 1999):

- i, j ve k , ağ boyunca soldan sağa doğru yayılan farklı nöronları göstermektedir. j nöronu i nöronunun sağındaki katmanda ve k nöronu j nöronunun sağındaki katmanda bulunmaktadır.
- n iterasyonu, ağa verilen n . eğitim örneğini göstermektedir.
- $\varepsilon(n)$, n . iterasyondaki hata kareleri toplamını göstermektedir. Tüm n değerleri için $\varepsilon(n)$ ortalaması, ε_{av} ortalama karesel hatasını göstermektedir.
- $e_j(n)$, n . iterasyonda, j nöronu çıkışındaki hata sinyalini göstermektedir.
- $d_j(n)$, n . iterasyonda, j nöronu çıkışındaki istenen cevabı göstermektedir.
- $y_j(n)$, n . iterasyonda, j nöronu çıkışındaki fonksiyon sinyalini göstermektedir.

- $w_{ji}(n)$, n . iterasyonda, i nöronu çıkışı, j nöronu girişine bağlayan sinaptik ağırlığı göstermektedir. Bu ağırlığa n . iterasyonda uygulanan düzeltme $\Delta W_{ji}(n)$ ile gösterilmektedir.
- $v_j(n)$, n . iterasyonda, j nöronunun net içsel aktivite düzeyini göstermektedir. Bu değer, j nöronundaki doğrusal olmayan yapıya uygulanan sinyali göstermektedir.
- $\varphi_j(\cdot)$, j nöronunun giriş çıkış arasındaki doğrusal olmayan yapının fonksiyonel ilişkisini tanımlayan aktivasyon fonksiyonunu göstermektedir.
- θ_j , j nöronuna uygulanan eşik değerini göstermektedir. Eşik değerinin etkisi, -1 değerine eşit olan bir $w_{j0} = \theta_j$ ağırlık sinapsi ile gösterilmektedir.
- $x_i(n)$, giriş vektörünün, n . iterasyondaki, i . elemanını göstermektedir.
- $o_k(n)$, çıkış vektörünün, n . iterasyondaki, k . elemanını göstermektedir.
- η , öğrenme katsayısını göstermektedir.

n . iterasyonda, j nöronu çıkışındaki hata sinyali,

$$e_j(n) = d_j(n) - y_j(n) \quad (3.17)$$

j nöronu bir çıkış düğümü olmak üzere yukarıdaki şekilde tanımlanmaktadır. Buna göre, ağırlık hata kareleri toplamı,

$$\varepsilon(n) = \frac{1}{2} \sum_{j \in c} e_j^2(n) \quad (3.18)$$

şeklinde ifade edilmektedir. Verilen bir eğitim kümesi için ε_{av} , eğitim kümesi öğrenme performansının ölçüsü olarak maliyet fonksiyonunu göstermektedir. Öğrenme sürecinin amacı, ε_{av} değerini en küçükleyecek şekilde ağ parametrelerinin ayarlanmasıdır.

Solundaki nöron katmanı tarafından üretilen fonksiyon sinyali kümesini girdi olarak alan bir j nöronu ele alınsın, j nöronunun net içsel aktivite düzeyi,

$$v_j(n) = \sum_{i=0}^p w_{ji}(n)y_i(n) \quad (3.19)$$

olarak tanımlanmaktadır. Buna göre, n . iterasyonda, j nöronuna uygulanan fonksiyon sinyali,

$$y_j(n) = \varphi_j(v_j(n)) \quad (3.20)$$

ve $w_{ji}(n)$ sinaptik ağırlığına uygulanan, $\Delta W_{ji}(n)$ düzeltme değeri (3.21) nolu denklemdeki gibidir.

$$\Delta W_{ji}(n) = \eta \delta_j(n) y_i(n) \quad (3.21)$$

elde edilir. Burada yerel eğim,

$$\delta_j(n) = e_j(n) \varphi'_j(v_j(n)) \quad (3.22)$$

şeklinde tanımlanmaktadır. Denkleme göre, j nöronu için yerel eğim $e_j(n)$ hata sinyali ile $\varphi'_j(v_j(n))$ aktivasyon fonksiyonunun türevinin çarpımıdır. $\delta_j(n)$ 'nin değeri hesaplanırken, j nöronunun konumuna bağlı olarak iki farklı durum oluşmaktadır. Bunlar;

- j nöronunun çıkış düğümü olması durumunda, kendisine ait bir istenen cevabı bulunmaktadır. Bu nedenle, $e_j(n)$ hata sinyali ve $\delta_j(n)$ doğrudan hesaplanabilmektedir.
- j nöronunun ara düğüm olması durumunda ise hata sinyali, j nöronuna, doğrudan bağlı olan, sonraki gizli katman veya çıkış katmanındaki nöronlara ait δ değerlerinin ağırlıklarının çarpılmasıyla

$$\delta_j(n) = \varphi'_j(v_j(n)) \sum_k \delta_k(n) w_{kj}(n) \quad (3.23)$$

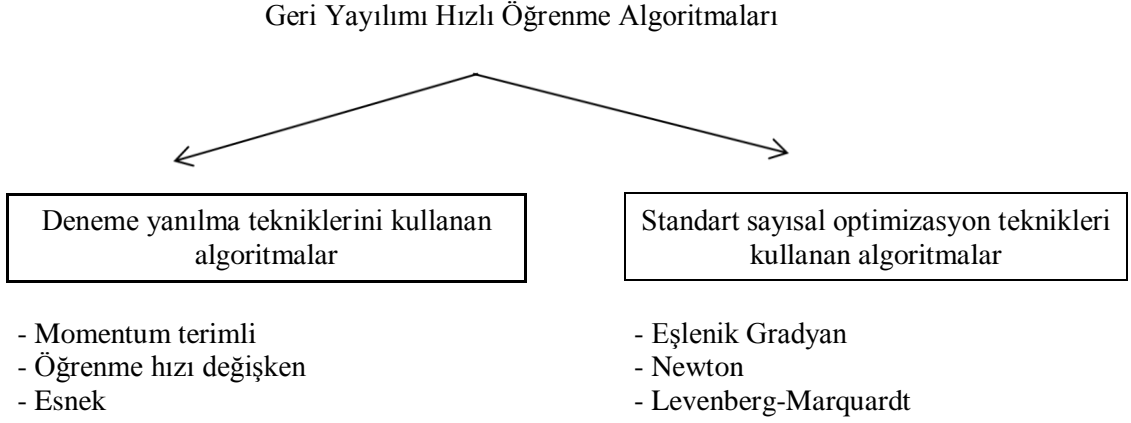
denklemleri ile elde edilmektedir.

(3.24) nolu denklemdeki gibi ağırlıklar revize edilir. Bu çevrim ε_{av} 'nin değeri istenen minimum seviyeye gelinceye kadar devam eder (Aynekin 2006).

$$w_{ji}(Yeni) = w_{ji}(Eski) + \Delta w_{ji}(n) \quad (3.24)$$

Yapay sinir ağlarında eğitim genellikle bir optimizasyon problemi olarak görülür. Özellikle yapay sinir ağlarında eğitimin amacı, ağdaki ağırlıkları ayarlayarak hata değerini minimize etmektir. $\varepsilon(n)$ 'yi mümkün olduğu kadar hızlı azaltmak için $\Delta W_{ji}(n)$ değeri ayarlanır. $\Delta W_{ji}(n)$ 'nin hesaplanması ise kullanılan öğrenme algoritmasına göre farklılık göstermektedir (Aşkın ve ark. 2011).

Standart geri yayılım algoritması, birçok pratik uygulamada, hata fonksiyonunu minimize ederken iterasyon sürecinin oldukça yavaş işlemesi sebebiyle çok geri kalmıştır. Bu sebeple algoritmada yakınsamayı hızlandırmak için farklı optimizasyon tekniklerini temel alan bazı yöntemler geliştirilmiştir (Hagan ve ark. 1996). Standart geri yayılım algoritmasının geliştirilmesi ile hızlı ve yüksek performanslı algoritmalar ikiye ayrılmaktadır: deneme yanılma tekniklerini kullanan algoritmalar ve standart sayısal optimizasyon yöntemlerini kullanan algoritmalar. Şekil 3.13'te bu algoritmalar görülmektedir. Sayısal optimizasyon yöntemlerinden kullanan Levenberg-Marquardt öğrenme algoritması da sıklıkla tercih edilir hale gelmiştir (Hagan 1994, Foo ve Ghosh 2002). Bu çalışmada da, öğrenme algoritması olarak Levenberg-Marquardt algoritması kullanılmıştır. Hızlı yakınsama sağlayan algoritmaların gelişmiş bir çeşidi olan Levenberg-Marquardt algoritması, Gauss-Newton algoritmasının bir kombinasyonudur. Bu algoritma, Gauss-Newton ve eğimli düşüş algoritmalarının en iyi özelliklerinden oluşur ve bu iki algoritmanın kısıtlamalarını kaldırır. Levenberg-Marquardt algoritması ayrıca daha hızlıdır (Aşkın ve ark. 2011).



Şekil 3.13. Hızlı ve performansı yüksek geri yayımlı öğrenme algoritmaları

Eşlenik gradyan öğrenme algoritmasına alternatif olarak sunulan Newton yöntemlerinde temel adım Hessian matrisini ($H(w)$) elde etmektir. Hessian matrisi, performans fonksiyonunun ağırlıklara göre ikinci dereceden türevlerinden oluşan bir matristir. Hessian matrisi, ağırlık uzayının farklı doğrultularındaki gradyan değişimini gösterir.

Hessian matrisi hesaplandıktan sonra, tersi bulunarak ağırlıklar yenilenebilir. Ancak Hessian matrisi çözümü karmaşık ve ileri beslemeli yapay sinir ağı için hesaplanması zor bir matristir (Doğan 2010). Bu algoritma, Hessian matrisinin yaklaşık değerini kullanmaktadır (Marquardt 1963, Okan ve Mollamahmutoğlu 2010). Bu yaklaşık değer (3.25) nolu denklem yardımıyla yapılabilmektedir.

$$H(w) \cong J^T(w)J(w) + \mu I \quad (3.25)$$

Burada; μ , Marquardt parametresini, I ise birim matrisi ifade etmektedir. J matrisi ise, Jakobien matrisi ifade etmekte olup öğrenim sürecindeki hataların, ağıdaki ağırlıklara ve eğitime göre türevini ifade eder. Ağın hatasının geri yayılması aşamasında, öncelikle Jakobien matrisin transpozu ve ağ hataları kullanılarak ağın gradyeni hesaplanmaktadır. Denklem 3.26'da verilen bu denklem ile ağın gradyeninin hesaplanmasının sonrasında, ağın ağırlıklarındaki vektörel değişim (3.27) nolu denklemde olduğu üzere, Hessian matrisinin tersi ile ağın gradyeninin çarpılmasıyla belirlenir. Ağın ağırlıkları ise (3.28)

nolu denklemde gösterildiği gibi güncellenmektedir (Okan ve Mollamahmutoğlu 2010, Hagan 1994).

$$\nabla E(w) = J^T(w)e(w) \quad (3.26)$$

$$\Delta w = -[H(w)]^{-1}\nabla E(w) \quad (3.27)$$

$$w_{yeni} = w_{eski} + \Delta w \quad (3.28)$$

Her performans fonksiyonunun azaltılmasında μ değeri azalırken, hataların karelerinin toplamının arttığı adımlarda μ değerinin artırılır. Bu yöntemde μ parametresi hesaplama süresince otomatik olarak güncellenmekte ve böylece yavaş yakınsama probleminden etkilenmediği için hızlı bir yaklaşım elde edilmektedir. Yaklaşım oranının hızlanması ile eğitim kısa sürmektedir. Ancak fazla işlem yapmakta ve sonucunda çok fazla hafıza kullanmayı gerektirmektedir (Haykin 1999).

3.1.2.6. Yapay Sinir Ağlarının Geliştirilmesi

Bir yapay sinir ağı uygulamasının başarısında, uygun metodolojiyi belirlemek büyük önem taşımaktadır. Bir sinir ağı modeli oluşturmak için nöronların bağlantı şekli, işlemci elemanların kullandıkları fonksiyonlar, öğrenme metodu ve öğrenme algoritması belirlenmelidir (Aşkın ve ark. 2011). Eldeki veriye göre tasarlanması gereken modelin başarısı, doğru bir ağ mimarisinin oluşturulması ile yakından ilgilidir. Bu nedenle, yapay sinir ağının geliştirilmesi sürecinde, ağın yapısına ve işleyişine ilişkin aşağıdaki kararların verilmesi gerekmektedir:

- Ağ mimarisinin seçimi ve ağın yapısal özelliklerinin belirlenmesi (katman sayısı, katmandaki nöron sayısı gibi)
- İşlemci elemanların (nöronların) kullanacağı fonksiyonların karakteristik özelliklerinin belirlenmesi
- Öğrenme algoritmasının seçimi ve ilgili parametrelerin belirlenmesi
- Eğitim verisi ile test verisinin oluşturulması.

Söz konusu kararlarda yapılabilecek olası hatalar sistem karmaşıklığını arttıracaktır. Bir yapay sinir ağı uygun parametrelerle tasarlanması durumunda ise yapay sinir ağları sürekli olarak kararlı ve istikrarlı sonuçlar üretecektir. Probleme uygun olarak en doğru kararı verebilmek için literatürdeki benzer çalışmalar gözden geçirilerek problemler için belirlenmiş olan parametrelerle yapıyı tasarlamaya ve eğitmeye başlamak akılcı bir yaklaşım olacaktır (Aşkın ve ark. 2011). Sistem tasarımında göz önünde bulundurulması gereken diğer noktalar ise uygulamanın süresi ve hafızadaki kaplayacağı yerdir.

Ağ Mimarisinin Seçimi ve Ağın Yapısal Özelliklerinin Belirlenmesi

Ağ yapısının seçimi, uygulama problemine bağlı olarak yapılmalıdır. Hangi ağ yapısının hangi problem için uygun olduğunun bilinmesi önemlidir. Kullanılacak öğrenme algoritmasına bağlı olarak da uygun yapay sinir ağ yapısının seçimi değişebilir. Seçilen öğrenme algoritmasının gerektirdiği mimarinin seçimi zorunlu olarak gerçekleştirilecektir. Geri yayılım algoritmasının ileri beslemeli ve çok katmanlı bir ağ mimarisini gerektirmesi bu duruma bir örnek olarak verilebilir.

Günümüzde yaygın olarak kullanılan çok katmanlı ağların, özellikle sınıflama, tahmin etme, tanıma, yorumlama ve teşhis etmede başarılı sonuçlar verdiği çalışmalardan gözlenebilmektedir (Dreyfus 2005). Kullanım amacına göre o alanda başarılı sonuçlar üreten diğer ağ çeşitleri Çizelge 3.2’de verilmiştir. YSA’nın karmaşıklığını azaltmak için en etkin araç ağ yapısının değiştirilmesidir. Ağda fazla işlem elemanlarının bulunması ağın genelleme yeteneğini düşürür. Nöronların aynı doğrultu üzerinde bir araya gelmeleriyle oluşan katmanların farklı şekilde birbiriyle bağlanmaları değişik ağ yapılarının oluşmasına neden olur. Problemin yapısına göre değişen katman sayılarının belirlenmenin en iyi yolu, denemeler yaparak probleme en uygun yapıya ve yapının ne olduğuna karar vermektir (Dreyfus 2005). Genelde kesin sonuç beklenmeyen ancak bir değere yaklaşması istenen problemlerde iki katmanlı çözümler kullanılmaktadır.

Çizelge 3.2. Ağ Çeşitleri ve Başarılı oldukları alanlar (Saraç 2004)

Kullanım amacı	Ağ türü	Ağın kullanımı
Tahmin	- Çok katmanlı ağlar	Ağın girdilerinden bir çıktı değerinin tahmin edilmesi
Sınıflandırma	- LVQ - ART - Counterpropagation - Olasılıklı Sinir Ağları	Girdilerin hangi sınıfa ait olduklarının belirlenmesi
Veri İlişkilendirme	- Hopfield - Boltzman Machine - Bidirectional Associative Memory	Girdilerin içindeki hatalı bilgilerin bulunması ve eksik bilgilerin tamamlanması

Nöron Sayısı ve Nörondaki Fonksiyonların Özelliklerinin Belirlenmesi

Her bir katmanda bulunan nöronların sayıları da ağın yapısal özellikleri arasında önemli bir özelliktir. Girdi ve çıktı katmanlarındaki nöron sayıları genellikle problemin gereklerine göre belirlenmektedir. Girdi katmanındaki nöron sayısı, girdi veri sayısı kadardır. Her bir girdi nöronu bir veri alır ve işlemeden bir sonraki katman olan gizli katmana geçer. Gizli katman sayısı ve bu katmandaki nöron sayısı probleme göre farklılık gösterir. Gizli katman sayısı ve bu katmanlardaki nöron sayıları için deneme yanılma yöntemi kullanılabilir (Asilkan ve Irmak 2009). Nöron sayısını belirlemek üzere, başlangıçtaki nöron sayısını istenilen performansa ulaşıncaya kadar arttırma veya istenen performansın altına inmeden azaltma yolu izlenebilir. Bir katmandaki nöron sayısının mümkün olduğunca az olmasına önem verilmesi, ağın genelleme yeteneği açısından kritiktir. Az nöron sayısı ağın bu yeteneğini arttırır ancak gereğinden fazla nöron olması ağın verileri ezberlemesine neden olacaktır. Ancak nöron sayısının gereğinden az olması verilerdeki ilişkinin ağ tarafından öğrenilememesi sorununu ortaya çıkarabilir. Bu sebeple, gizli katman ve nöron sayısının belirlenmesi önemli bir kararı oluşturur. Gizli katmandaki nöron sayısının belirlenmesi için uygulamalarda az

sayıda nörondan (2 veya 3) başlayarak daha sonra bu sayıyı artırmakla (örneğin 5, 10, 20) başarı değerlendirilmesi yapılması önerilmektedir (Nabiyev 2005).

Diğer bir önemli karar ise nörondaki fonksiyonların karakteristik özellikleridir. Nöron geçiş fonksiyonunun seçimi büyük ölçüde ağırlıkların verilerine bağlıdır. Aktivasyon fonksiyonları içerisinde en çok kullanılan fonksiyonları sigmoid ve hiperbolik tanjant fonksiyonlarıdır. Aktivasyon fonksiyon seçimi büyük ölçüde YSA verilerine ve ağırlıkların öğrenmesi istendiğine bağlıdır. En uygun aktivasyon fonksiyon seçimi tasarımcının deneyimleri sonucu belli olur.

Bir problemdeki gizli katman ile nöron sayısının ve aktivasyon fonksiyon etkisini değerlendirmek için test verilerinin performansına bakılmaktadır. Ağ mimarisinin belirlenmesinde değerlendirilen çeşitli performans ölçütleri bulunmaktadır (Aladağ ve ark. 2009). Yapay sinir ağlarında genellikle performans ölçütü olarak hata kareler ortalaması (H.K.O) ve hata kareler ortalaması karekökü (H.K.O.K) kullanılmaktadır. Bu istatistiksel kriterler sırasıyla (3.29) ve (3.30) nolu denklemler ile hesaplanmaktadır. Buna göre, mutlak hata ortalaması ve hata kareler ortalamasının en küçük olduğu değer, alınması gereken gizli katman sayısını, nöron sayısı ve aktivasyon fonksiyonunu belirlemektedir (Küçükkoçaoğlu ve ark. 2005). Diğer performans ölçütleri; ortalama mutlak hata (OMH) ve ortalama mutlak yüzde hata (OMYH) ise (3.31) ve (3.32) nolu denklemlerde verilmiştir.

$$HKO = \frac{1}{N} \sum_{i=1}^N (b_i - y_i)^2 \quad (3.29)$$

$$HKOK = \sqrt{\frac{1}{N} \sum_{i=1}^N (b_i - y_i)^2} \quad (3.30)$$

$$OMH = \sum_{i=1}^N \frac{|b_i - y_i|}{N} \quad (3.31)$$

$$OMYH = \left(\frac{1}{N}\right) \sum_{i=1}^N \left| \frac{b_i - y_i}{b_i} \right| (100) \quad (3.32)$$

Burada,

N test kümesi büyüklüğü, b_i gerçek gözlem değeri, y_i tahmin edilen değerdir.

Öğrenme Algoritması Seçimi

Öğrenme algoritması, bir yapay sinir ağı uygulamasında önemli bir karar noktasıdır. Genellikle seçilen ağ yapısı, öğrenme algoritmasının seçiminde etkilidir. Bu sebeple, öğrenme algoritması seçimi ağ yapısına bağlı olarak gerçekleştirilir. Yapay sinir ağlarının eğitimi ve geliştirilmesinde kullanılan birçok öğrenme algoritması bulunmaktadır. Bazı algoritmaların bazı tip uygulamalar için daha uygun olduğu ve başarılı sonuçlar verdiği bilinmektedir. Bu algoritmalar uygulama alanlarına göre daha önceki bölümlerde yer alan Çizelge 3.3'te özetlenmiştir.

Çizelge 3.3. Uygulama alanlarına göre ağ çeşitleri

Uygulama Çeşidi	Yapay Sinir Ağı
Öngörü Tanıma	<ul style="list-style-type: none">- Geri Yayılım- Delta Bar Delta- Geliştirilmiş Delta Bar Delta- Yönlendirilmiş Rassal Tarama- Geri Yayılım İçinde Self Organizing Map- Higher Order Neural Networks
Sınıflandırma	<ul style="list-style-type: none">- Learning Vector Quantization- Counter-Propagation- Olasılıklı Yapay Sinir Ağları
Veri İlişkilendirme	<ul style="list-style-type: none">- Hopfield- Boltmann Makinesi- Bidirectional Associative Memory- Spantion-Temproal Pattern Recognition
Veri Kavramlaştırma	<ul style="list-style-type: none">- Adaptive Resonance Network- Self Organizing

Eđitim - Test Verisinin Oluřturulması ve Normalizasyon

Yapay sinir ađı modellerinde ađın genelleyebilme yeteneđinin deđerlendirilebilmesi aısından ađın girdi ve ıktı deđerlerinin hepsi kullanılmamakta, belli bir kısmı eđitim, belli bir kısmı ise test safhalarında deđerlendirilmektedir (Haykin 1999, ztemel 2003). Literatürde eđitim ve test veri setlerinin belirlenmesine ynelik olarak az da olsa neriler vardır. Birok arařtırmacının %90-%10, %80-%20 veya %70-%30 kuralını temel alan bir yntem izlediđi grlmektedir (Zhang ve ark. 1998). Yapay sinir ađı yapısı ve zelliklerinin belirlenmesinin yanı sıra uygulama ncesinde eđitim ve test verilerinin hazırlanması ayrıca nemlidir.

Yapay sinir ađı tasarım srecinde, verilerle ilgili olarak yapılan bir bařka alıřma da verilerin normalizasyona tabii tutulmasıdır. Veriler karar ya da nerilere eřit katkıda bulunduđundan l biriminin etkisinden arındırılmak iin standartlařtırılır (Kkkocaođlu ve ark. 2006). Girdi ve ıktı verilerinin normalleřtirilmesinin, yakınsama ve đrenme iřlemi aısından nemlidir (Saritas 2008). Normalizasyon ile veriler boyutsuz hale getirilir.

Verilerin normalizasyonu iin seilen yntem, yapay sinir ađı performansını dođrudan etkileyeceđi iin nemlidir. Normalizasyon ile leklenen veriler geerli eksen sisteminde sıkıřtırılması anlamı tařır. Verilerinde ařırı salınımlar ieren problemlerde, oluřturulan ađ modelleri olumsuz ynde etkileyebilir. Bir veri kmesi [0 1] arasında bir leklendirme yapılacaksa: F ; boyutsuz deđer, F_i ; lm deđer, F_{min} ve F_{maks} olmak zere;

$$F = \frac{(F_i - F_{min})}{(F_{maks} - F_{min})} \quad (3.33)$$

forml kullanılabilir.

3.2. Yöntem

Bu bölümde uygulanan yöntem ile ilgili bilgiler aktarılmıştır.

3.2.1. Genel Bilgiler

Kalıp üretim süreci zor ve oldukça karmaşıktır. Bu nedenle, üretim aşamalarının sürelerini belirlemek zor olmaktadır. Kalıp üretim sürelerini belirlemeye yönelik olarak bu çalışmada tahmin modelleri geliştirilmiştir. Çalışmada, öncelikle modellerin kullanacağı veri setleri ve verilerle ilgili gerekli kabuller oluşturulmuştur.

Kalıp üretim aşamalarının standart zamanlarını belirleyebilmek için öncelikle üretim sürelerine etki eden teknik parametrelerin belirlenmesi gerekir. Kalıp üretim sürelerine etki eden teknik parametrelerin belirlenmesi sürecinde kalıpcılık sektöründe deneyim sahibi, konusunda uzman personelin (çalışmanın gerçekleştirildiği firmadaki teknik personelin) görüşlerinden yararlanılmıştır. Uzman personelin, parametrelerin belirlenmesi için gerçekleştirilen çalışmalarda beyin fırtınası metodu kullandığı bilinmektedir. Beyin fırtınası, bireylerde eleştirilme endişesi olmadan yaratıcı fikirlerin ortaya çıkmasını ve problem çözme gücünü geliştirmeyi amaçlayan bir tartışma yöntemidir. Serbest tartışma yöntemi ve eleştirilmeme rahatlığı fikirlerin çoğalmasını sağlamaktadır (Nakiboğlu 2003). Uzman personelin gerçekleştirildiği çalışmalar sonucunda, üretim süresine etki edebilecek teknik parametreler, hangi kriterin parametre olarak seçileceği, hangisinin bir parametre olarak değerlendirilmeyeceğinin belirlenmiş ve ortaya çıkarılan bilgiler bu çalışma için firma tarafından sağlanmıştır.

Kalıp üretim sürelerini etkileyen çok sayıda parametre mevcuttur. Bu sebeple, kalıp üretim sürelerinin belirlenmesi için birçok parametre göz önüne alınmaktadır. Parametre belirleme sürecinde, ilk adım olarak kalıp tipleri belirlenmiştir. Kalıp tiplerinin belirlenmesinin devamında kalıp çeşitlerine göre birçok parametre ortaya çıkarılmıştır. Çalışma için, firma tarafından en çok üretimin olduğu 3 tip kalıp belirlenmiş olup bu kalıplar; çekme kalıbı, çevre kesme kalıbı ve ütüleme kalıbıdır.

Firmadan sağlanan bilgilere göre, kalıp üretim süresinin etkileyebileceği öngörülen çekme kalıbı için 119 parametre, çevre kesme kalıbı için 110 adet parametre, ütüleme kalıbı için 112 adet parametre belirlenmiştir. Belirlenmiş bu parametreler sabit ve değişken yapıda olabileceği görülmüştür. Örneğin, vidalamak, sabit yapıda olan

parametre olarak tespit edilmiştir. Her bir vidayı vidalamak işleminin 2 dk sürüyor ise, 10 adet vidayı vidalamak, 20 dk sürecektir. Bu parametre ile ilgili olarak herhangi bir değişkenlik bulunmamaktadır. Ancak kimi süreler, kalıbın yapısına göre değişebilmektedir. Bu sebeple bu yapıdaki parametreler değişken parametreler olarak belirlenmiştir. Belirlenen bu parametreler firma bilgi birikimi olması ve gizlilik sebebiyle çalışma kapsamında paylaşılamamıştır.

Kalıp üretim sürelerinin hesaplanabilmesi için belirlenmesi gereken teknik parametrelerin üzerinde etkin olan olmayan bağımsız değişkenler (alt parametreler) tespit edilmeye çalışılmıştır. Kalıp üretim sürelerinin üzerinde etkili olabileceği öngörülen teknik parametrelerin bu alt parametrelerden etkilenmesi sebebiyle, kalıp üretim sürelerinin hesaplanabilmesi için teknik parametreler ile alt parametreler arasındaki ilişki araştırılmıştır.

Kalıp üretim sürelerini etkileyebileceği öngörülen teknik parametreler Çizelge 3.4 (a), (b) ve (c)'de ve alt parametreler kalıp tipine göre Çizelge 3.5'te verilmiştir. Kalıp tiplerine göre bütün parametreler firma bilgi gizliliği sebebiyle çeşitli notasyonlarla temsil edilmiştir. Veriler, kalıp tiplerine göre bu teknik parametre ve tahmin değişkenlere göre toplanarak derlenmiştir.

Çizelge 3.4.(a) Çekme kalıbı teknik parametreler

Kalıp Elemanı	Çekme Kalıbı Teknik Parametreler
Pot	ÇK-P-1
	ÇK-P-2
	ÇK-P-3
	ÇK-P-4
	ÇK-P-5
	ÇK-P-6
Erkek	ÇK-E
Dişi	ÇK-D
Alt Tabla	ÇK-AT-1
	ÇK-AT-2

Çizelge 3.4.(b) Çevre kesme kalıbı teknik parametreler

Kalıp Elemanı	Çevre Kesme Kalıbı Teknik Parametreler
Kontur	KK-K-1
	KK-K-2
Sıyırıcı	KK-S-1
	KK-S-2
	KK-S-3
Erkek	KK-E
Dişi	KK-D-1
	KK-D-2
	KK-D-3
Alt Tabla	KK-AT-1
	KK-AT-2

Çizelge 3.4.(c) Ütüleme kalıbı teknik parametreler

Kalıp Elemanı	Ütüleme Kalıbı Teknik Parametreler
Baskı	ÜK-B-1
	ÜK-B-2
	ÜK-B-3
Erkek	ÜK-E
Dişi	ÜK-D-1
	ÜK-D-2
	ÜK-D-3
Alt Tabla	ÜK-AT-1
	ÜK-AT-2

Herhangi bir çalışmada, sonuçlar ancak verilerin kalitesi ve miktarı kadar iyidir. Bu nedenle, çalışma için mümkün olduğu kadar çok veri toplayabilmek firma tarafından ideal bir yaklaşım olarak benimsenmiştir. Ancak sonuca ulaşmak için belli bir süre dâhilinde çalışmanın sonlandırılması gerektiğinden ve veri toplama çalışması özellikle kalıp sektörü için oldukça zor bir süreç olması sebebiyle, veri miktarı için bir minimum sayı belirlenmiştir. Belirlenen bütün parametreler göz önüne alınarak, çekme, çevre kesme ve ütüleme kalıbı olmak üzere tespit edilen 3 kalıp tipinden 30’ar adet veri toplanmıştır. 30 adet veri toplanması ile toplanan verilerin normal dağılıma uyması hedeflenmiştir. Verinin normal dağılıma uyması sağlanarak, gerçekleştirilecek istatistiksel analizlerin de teorik varsayımlarının sağlanması hedeflenmiştir.

Çizelge 3.5. Kalıp tiplerine göre alt parametreler

Alt Parametreler		
Çekme Kalıbı	Çevre Kesme Kalıbı	Ütüleme Kalıbı
A	A	A
B	B	B
C	C	C
D	D	D
E	E	E
F	F	F
G	G	G
H	H	H
I	I	I
K	K	K
	L	N
	M	

Kalıp üretim aşamaları standart zamanlarının hesaplanmasını etkileyen teknik parametreler bağımlı değişken, üretilen parça ile ilgili diğer parametreler de bağımsız değişken olarak yer almaktadır. Firma tarafından oluşturulan veri setlerinde hem bağımlı hem de bağımsız değişken için gerekli değerlerin yer almasına dikkat edilmiştir. Bu şekilde, bu çalışma için gerekli veri bütünlüğü sağlanarak ilgili analiz faaliyetlerinde kullanılabilir olan veri seti firma tarafından sağlanmıştır. Veri seti firma gizliliği sebebiyle çalışmada paylaşılmamıştır.

Çalışmada, MINITAB ve MATLAB Neural Network Toolbox yazılımları kullanılmıştır. Regresyon analizinde veriler MINITAB programında düzenlenerek girdiler ile çıktı arasındaki ilişkiyi temsil eden model denklemleri oluşturulmuştur. Tahminleme çalışmaları için kullanılan diğer yöntem olan yapay sinir ağı modelleri ise MATLAB Neural Network Toolbox yazılımı yardımıyla geliştirilmiştir.

3.2.2. Regresyon Analizi

Çalışmada yaklaşık bir yıl süreyle toplanmış olan 3 kalıp tipi için 30' ar adet veri yardımıyla regresyon analizi gerçekleştirilmiştir. Kalıp tipine göre ilgili teknik parametreler ve bağımsız değişkenlerin (alt parametreler) değerleri bu veri setinde yer almaktadır. Regresyon analizi, her kalıp tipi için ayrıca uygulanmıştır.

Her kalıp tipi için toplanan veri setleri 30 adet kalıp verisini içermektedir. Regresyon analizinde bu 30 adet verinin 25 adedi regresyon analizinde, 5 adedi ise oluşturulan regresyon modelinin testi için kullanılmıştır.

Veriler arasındaki ilişkiyi açıklayabilen, istatistiksel açıdan anlamlı bir regresyon denklemi bulmak üzere yapılan çalışmalarda, normal dağılıma uygunluk için grafiksel görüntüler incelenmiş ve istatistiksel testler yapılmıştır. Tekli ve çoklu regresyon modelleriyle yapılan her parametre analizinde, hata dağılımının normal dağılıma uyumu kontrol edilmiştir. İstatistiksel testlere göre normal dağılıma uymayan veri analizlerinde, normal dağılımı sağlamak için dağılımda dışa düşen verilerden birkaçı veri setinden çıkarılmak suretiyle, analizler tekrarlanmıştır.

Çalışmada ilk adım olarak, tüm bağımsız değişkenler tek tek bağımlı değişkenler ile regresyon analizi yapılmıştır. Bu sayede her bir bağımsız değişkenin hata oluşum

miktarı üzerindeki etkisi tespit edilmeye çalışılmıştır. Tekli regresyon analizleri için, β_1 , regresyon denklemi katsayısını göstermek üzere,

$$H_0 : \beta_1 = 0$$

$$H_1 : \beta_1 \neq 0$$

Her bir bağımsız değişkenin tek tek bağımlı değişken ile gerçekleştirilen regresyon analizi sonuçları, çekme kalıbının teknik parametresi olan ‘ÇK-P-4’ için Çizelge 3.6’da verilmiştir. Çalışmada uygulanan regresyon analizi adımları tüm bağımlı değişkenler yani teknik parametreler için ayrıca gerçekleştirilmiş olup uygulanan aşamalar teknik parametreler arasından seçilen ‘ÇK-P-4’ bilgileri üzerinden bu kısımda açıklanmıştır. Aralarında korelasyon yakalanmayan bağımsız değişkenlere çizelgede yer verilmemiştir.

Çizelge 3.6. ‘ÇK-P-4’ teknik parametresi tekli regresyon analizi sonuçları

	B	E	G	K
$R^2(\%)$	90,2	56,9	89,3	72
$R^2(\%)$ düzeltilmiş	89,6	55	88,8	70,5
F	165,24	30,36	150,97	48,77
p	0,00	0,00	0,00	0,00
MAPE	19,53	28,09	18,57	24,35

Elde edilen regresyon sonuçları irdelenerek, verilerin regresyon modeline uyumunun anlamı araştırılmıştır. Regresyon analizlerinin ANOVA tabloları incelenerek F ve p değerleri incelenmiş ve teknik parametreler üzerinde etkili olan bağımsız değişkenler ayırt edilmiştir. Çekme kalıbı teknik parametresi ‘ÇK-P-4’ için $F_{hesap} > F$ ve p değerinin 0,05 ten küçük olduğu istatistiksel açıdan anlamlı regresyon denklemleriyle etkileşimin olduğu bağımsız değişkenler Çizelge 3.7’ de görülmektedir. Bulunan bu

regresyon denklemleri için elde edilen ANOVA tabloları ise Çizelge 3.8 – Çizelge 3.11’deki gibidir.

Çizelge 3.7. ‘ÇK-P-4’ teknik parametresi basit doğrusal regresyon modelleri

		Basit doğrusal regresyon modeli
Bağımsız değişken	B	$(\text{ÇK-P-4}) = 598,5 + 3,12 * B$
	E	$(\text{ÇK-P-4}) = 2748 + 3672 * E$
	G	$(\text{ÇK-P-4}) = 354 + 3,045 * G$
	K	$(\text{ÇK-P-4}) = 1773 + 3942 * K$

Çizelge 3.8. (Bağımsız Değişken B) ‘ÇK-P-4’ için ANOVA Tablosu

Değişkenlik	Kareler	Serbestlik	Kareler	F	p
Regresyon	9678899	1	9678899	165,24	0,00
Hata	1054318	18	58573		
Toplam	10733217	19			

Çizelge 3.9. (Bağımsız Değişken E) ‘ÇK-P-4’ için ANOVA Tablosu

Değişkenlik	Kareler	Serbestlik	Kareler	F	p
Regresyon	19852659	1	19852659	30,36	0,00
Hata	15039757	23	653902		
Toplam	34892416	24			


Çizelge 3.10. (Bağımsız Değişken G) ‘ÇK-P-4’ için ANOVA Tablosu

Değişkenlik	Kareler	Serbestlik	Kareler	F	p
Regresyon	9589817	1	9589817	150,97	0,00
Hata	1143400	18	63522		
Toplam	10733217	19			


Çizelge 3.11. (Bağımsız Değişken K) ‘ÇK-P-4’ için ANOVA Tablosu

Değişkenlik	Kareler	Serbestlik	Kareler	F	p
Regresyon	9316378	1	9316378	48,77	0,00
Hata	3629621	19	191033		
Toplam	12945999	20			


Hataların normal dağılım grafikleri ise Şekil 3.14 – Şekil 3.17’ deki gibi bulunmuştur.




Şekil 3.14. (Bağımsız değişken B)
ÇK-P-4 için hataların normal dağılım grafiği



Şekil 3.15. (Bağımsız değişken E)
ÇK-P-4 için hataların normal dağılım grafiği



Şekil 3.16. (Bağımsız değişken G)
ÇK-P-4 için hataların normal dağılım grafiği



Şekil 3.17. (Bağımsız değişken K)
ÇK-P-4 için hataların normal dağılım grafiği

Teknik parametre değerlerinin tahmini için aynı zamanda çoklu regresyon modelleri de geliştirilmiştir. Bağımlı değişkenlerin her biri ilgili olduğu kalıbın bağımsız değişkenlerine bağlı olarak tahmin edilmeye çalışılmaktadır.

Birçok tahmin değişkeni olan karmaşık modeller için hangi tahmin modellerinin seçildiği önemlidir. Çalışmada, çoklu regresyon analizinde, değişken sayısına bağlı olarak olası regresyon model sayıları da artmaktadır. Bu durum, çekme kalıbında yer alan 'ÇK-P-4' teknik parametresi için ele alınırsa, 10 adet bağımsız değişken olduğu için olası tüm regresyon modelleri sayısı 2^{10} olacaktır. Böyle bir durumda, hesaplamalar giderek zorlaşmaktadır. Bu nedenle, çalışmada, adımsal regresyon analizi uygulanmıştır. Adımsal regresyon analizi sonuçları 'ÇK-P-4' teknik parametresi için Çizelge 3.12 ve Çizelge 3.13'te görülmektedir.

Çizelge 3.12. Adımsal Regresyon Analizi için test sonuçları

Model		$R^2(\%)$	$R^2(\%)$ (düzeltilmiş)	MAPE
1	(sabit)	87,4	86,8	19,03
	B			
2	(sabit)	95,1	94,6	18,14
	B			
	F			


Çizelge 3.13. Adımsal regresyon analizi sonrası ANOVA Tablosu

Değişkenlik Kaynağı		Kareler Toplamı	Serbestlik Derecesi	Kareler Ortalaması	F	p
1	Regresyon	10408684	1	10408684	131,94	0,000
	Hata	1498860	19	78887		
	Toplam	11907544	20			
2	Regresyon	14302970	2	7151485	175,58	0,000
	Hata	733152	18	40731		
	Toplam	15036122	20			


Analiz sonrasında, hesaplanan F değerlerine göre regresyon doğrusuna uyumun anlamlı olduğu söylenir. Ayrıca p değeri de 0,05'ten küçük olduğu için regresyon doğrusuna olan uyumun anlamlı olduğunu desteklemektedir. Adımsal regresyon analizi sonrasında, uyumluluğu test edilen regresyon denklemleri arasında en yüksek belirlilik katsayısı (R^2) değerine sahip olan modelin 2. model olduğu belirlenmiştir. Bu modele ait regresyon denklemi bağımlı değişken 'ÇK-P-4' teknik parametresi y , bağımsız değişkenler B ve F alt parametreleri sırasıyla x_1 ve x_2 ile gösterilmiş olarak aşağıda görülmektedir.

$$y = -768 + 3.315 x_1 + 2.955 x_2 \quad (3.34)$$

Her iki model için hataların normal dağılım grafiği Şekil 3.18 ve Şekil 3.19’da verilmiştir.



Şekil 3.18. Model 1 için hataların normal dağılım grafiği



Şekil 3.19. Model 2 için hataların normal dağılım grafiği

Çalışmanın bu bölümünde adımsal regresyon analizi ile ele alınan 10 bağımsız değişkenden hangilerinin ‘ÇK-P-4’ bağımlı değişkenindeki değişim üzerinde anlamlı oldukları belirlenmeye çalışılmıştır.

Regresyon analizleri ile tüm bağımlı değişkenler için tekli ve çoklu regresyon denklemleri oluşturulmuştur. Oluşturulan regresyon modelleri, test veri seti ile her

bağımlı deęişken için test edilerek ortalama mutlak yüzde hata oranları (MAPE) hesaplanmıştır. Alternatif regresyon denklemleri arasından R^2 deęeri yüksek ve test verilerindeki hata miktarı düşük olan denklemler tahminleme çalışmalarında kullanılmak üzere seçilmiştir. Bu seçimlerde firmanın da görüşü alınmış olup denklemler birlikte deęerlendirilmiştir.

3.2.3. Yapay Sinir Aęı Uygulaması

Kalıp üretim aşamalarının standart zamanlarının belirlenmesi için gerekli teknik parametre deęerlerinin tahminine yönelik olarak çalışmada kullanılan dięer bir yöntem yapay sinir aęlarıdır. Yapay sinir aęı yöntemiyle teknik parametre deęerlerini tahmin etmek üzere yapay sinir aęı uygulaması tasarlanmıştır.

Bu çalışma ile girdi olan parça ile ilgili deęişken veriler ile çıktı olan teknik parametreler arasındaki ilişkiyi modellemek üzere bir yapay sinir aęı uygulaması yapılmıştır. Yapay sinir aęı tasarımı, MATLAB yazılımının yapay sinir aęları ile ilgili araç setinden faydalanılarak kurulmuştur.

Yapay sinir aęı uygulaması için veriler, eğitim ve test veri seti olmak üzere iki kısma ayrılmıştır. Regresyon analizine benzer olarak modellemede, her kalıp tipi için 30 adet veri kullanılmıştır. Verilerin 25 adeti yapay sinir aęı modelini eğitmek için, 5 adeti ise yapay sinir aęı modelini test etmek için kullanılmıştır. Veri seti birçok teknik parametre ve deęişken bilgilerini içermekte olduğundan bu veriler farklı tiplerde ve deęişik ölçeklerde dir. Bu sebeple, (3.35) nolu denklem ile bu deęerler normalize edilmiştir. Yapay sinir aęı modellemesinde, veriler 0 ile 1 arasında ölçeklendirilerek aęa sunulmuştur. Bu sayede, veriler arasındaki uzaklık ortadan kaldırılarak aęın eğitim sürecinde daha hızlı yakınsaması sağlanmıştır. Eğitim işleminin tamamlanmasının ardından elde edilen ölçeklendirilmiş çıktılar ise ters işlem ile orijinal ölçeğine dönüştürülmüştür.

$$\frac{x_i - x_{maks}}{x_{maks} - x_{min}} \quad (3.35)$$

Burada; x_i , gözlem değerini, x_{maks} , gözlem değerleri için maksimum değeri, x_{min} , gözlem değerleri için minimum değeri ifade etmektedir.

Oluşturulan modelde kalıp tiplerine göre tüm alt parametreler girdi ve ayrı ayrı her bir teknik parametre ise çıktı olmak üzere yapay sinir ağı modeli tasarlanmıştır. Bir başka deyişle, yapay sinir ağı kalıp tipine göre tüm alt parametreleri girdi olarak bir çıktı üretmek üzere modellenmiştir.

Çalışmada, kullanılan ağ ileri beslemeli, çok katmanlı bir ağıdır. Ağın eğitiminde geriye yayılım algoritması kullanılmıştır. Çalışmanın amacı, kalıp üretim zamanlarının belirlenmesi için kalıp teknik parametre değerlerini doğru şekilde tahmin etmektir. Tahmin problemlerinde çoğunlukla geri yayılım öğrenme algoritması tercih edilmektedir (Aynekin 2006). Yapay sinir ağında, Levenberg-Marquardt eğitim yöntemi kullanılmıştır.

Gerçeğe en yakın tahmini bulmak üzere, ağ üzerinde farklı nöron sayıları, farklı gizli katman adedi, fonksiyonlar ve öğrenme algoritmaları denenmiştir. Modelde, 3 farklı gizli tabaka değerlerinin her biri için 3 farklı formülasyon kullanılarak gerçek sonuçlar ile uyumu en iyi olan gizli tabaka nöron sayısı belirlenmiştir. Kullanılan aktivasyon fonksiyonu, sigmoid aktivasyon fonksiyonu olup katmanlara göre gerçek sonuçlarla en iyi uyumu sağlayan fonksiyon kullanımı ise deneme-yanılma yöntemi ile belirlenmiştir. Araştırılan ara katman sayı ve hücreleri ile katmanlara göre aktivasyon fonksiyonları Çizelge 3.14 ve Çizelge 3.15'te görülmektedir.

Çizelge 3.14. Araştırılan yapay sinir ağı ara katman sayısı ve nöron sayısı

Ara Katman Hücre Sayısı		
1. katman	2. katman	3. katman
5	-	-
8	-	-
10	-	-
4	5	-
5	10	-
10	15	-
2	3	5
3	5	10
10	15	20

Çizelge 3.15. Katman sayılarına göre araştırılan aktivasyon fonksiyonları

Ara katman sayısı	Ara katman aktivasyon fonksiyonları	Çıkış aktivasyon fonksiyonu
1	Tansig	Tansig
	Tansig	Logsig
	Tansig	Purelin
	Logsig	Logsig
	Logsig	Tansig
	Purelin	Logsig
2	Logsig- Logsig	Purelin
	Logsig- Logsig	Logsig
	Tansig- Tansig	Purelin
	Tansig- Tansig	Logsig
	Tansig- Logsig	Logsig
	Tansig- Logsig	Purelin
	Logsig- Logsig	Tansig
	Purelin- Purelin	Logsig

Çizelge 3.15. Katman sayılarına göre araştırılan aktivasyon fonksiyonları (devam)

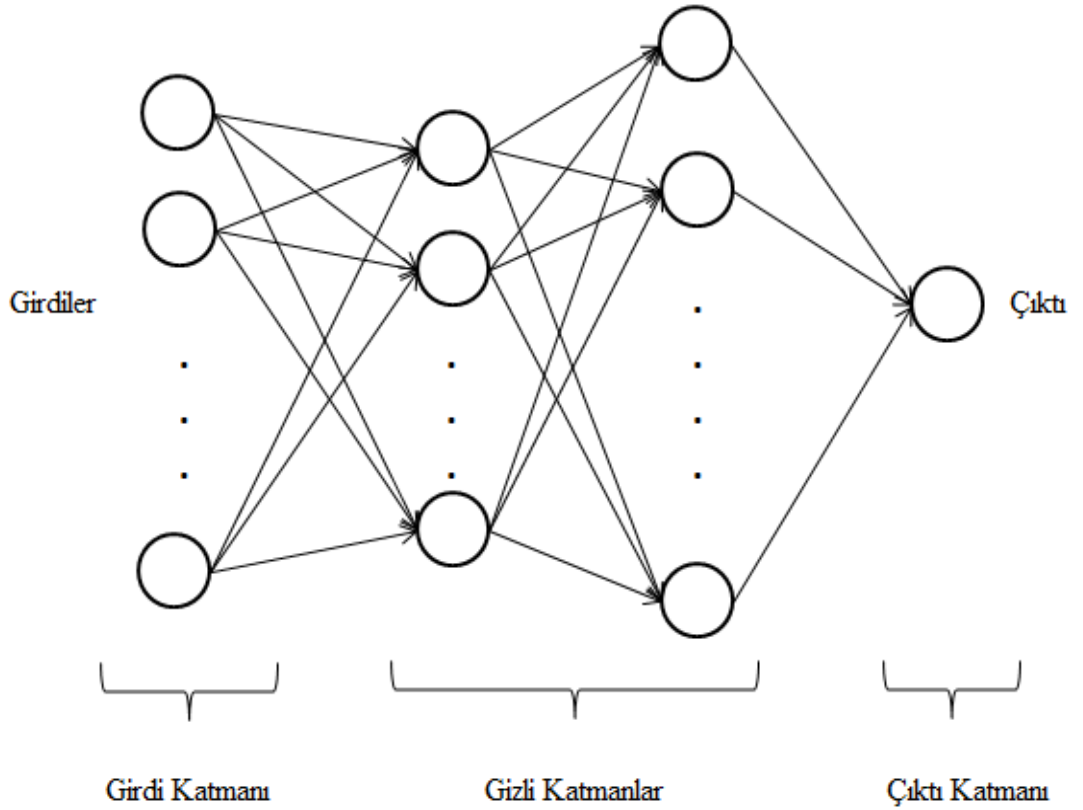
2	Purelin-Logsig	Logsig
	Purelin-Tansig	Logsig
3	Tansig- Tansig- Tansig	Logsig
	Tansig- Tansig -Logsig	Logsig
	Tansig- Logsig -Logsig	Logsig
	Logsig- Logsig- Logsig	Logsig
	Purelin- Logsig- Logsig	Logsig
	Tansig- Purelin- Logsig	Logsig
	Tansig-Logsig-Purelin	Logsig
	Logsig- Tansig- Tansig	Logsig
	Logsig- Logsig- Tansig	Logsig
	Logsig- Tansig- Tansig	Tansig

Her değişik nöron ve gizli katman sayılarına sahip ağ için 10 adet tahmin değeri hesaplanmış olup ağın performansı bu 10 adet tahmin değerinin ortalaması olarak hesaplanmıştır. Yapılan çalışmalar sonucunda, ağlar test edilmiş ve tahminde ortalama mutlak yüzde hatası en düşük olan yapay sinir ağı tahmin çalışmalarında kullanılmak üzere seçilmiştir. En iyi YSA modelini tespit ederken her bir model için iterasyon sayısı 10.000 ile sınırlandırılmıştır. Çalışmada, tasarlanmış olan ağ yapısı Şekil 3.20’de gösterilmektedir. Ağdaki gizli katman sayısı 2 olup aktivasyon fonksiyonları sırasıyla tanjant tipi sigmoid ve logaritma sigmoid aktivasyon fonksiyonudur. Çıkış katmanında da logaritma sigmoid aktivasyon fonksiyonu bulunmaktadır. Yapay sinir ağı eğitimi, belirlenen hata düzeyi altına düşüncüye dek sürdürülmüştür. Bu çalışmadaki, hata düzeyi, ortalama karesel hata (mean squared error-MSE) performans ölçüsüdür. MATLAB programında kabul edilebilir hata oranı $1e-2$ olarak seçilmiştir.

Yapay sinir ağlarının eğitimi tamamlandığında, istenen hata düzeyine ulaşıldığında, ağ veri kümesinde test için ayrılan 5 adet veri kullanılarak test edilmiştir. Test çalışmasında, yapay sinir ağına tahmin edilecek teknik parametre ile ilgili olarak girişler verilmiş, ağın bu girişlere cevap vermesi beklenmiştir. Ağın test aşamasında, ağın

vermiş olduğu değerler tersine normalizasyon yapıldıktan sonra, gerçek çıkışlarla karşılaştırılmıştır. Yapay sinir ağının vermiş olduğu değerler ile gerçek çıkış değerleri karşılaştırılarak tahminlerin ortalama mutlak yüzde hata (MAPE) oranları hesaplanmıştır. Böylece gerçek değerler ile tahmin değerleri arasındaki yanılma payı yüzdesel olarak gözlemlenebilmiştir.

Oluşturulan yapay sinir ağı modelinin kalıp tiplerine göre teknik parametre tahmin sonuçlarının gerçek değerlere göre ortalama mutlak yüzde hata (MAPE) değerleri Çizelge 3.16, Çizelge 3.17 ve Çizelge 3.18’de verilmiştir.



Şekil 3.20. Kullanılan yapay sinir ağı yapısı

Çizelge 3.16. Çekme kalıbı için YSA sonuçları hata yüzdeleri

Çekme Kalıbı	
Teknik Parametre	MAPE
ÇK-P-1	16,18
ÇK-P-2	10,47
ÇK-P-3	30,60
ÇK-P-4	19,49
ÇK-P-5	29,07
ÇK-P-6	11,52
ÇK-E	85,36
ÇK-D	27,55
ÇK-AT-1	15,19
ÇK-AT-1	17,75

Çizelge 3.17. Çevre kesme kalıbı için YSA sonuçları hata yüzdeleri

Çevre Kesme Kalıbı	
Teknik Parametre	MAPE
KK-K-1	28,97
KK-K-2	19,38
KK-S-1	23,05
KK-S-2	8,55
KK-S-3	17,17
KK-E	18,36
KK-D-1	36,73

Çizelge 3.17. Çevre kesme kalıbı için YSA sonuçları hata yüzdeleri (devam)

Çevre Kesme Kalıbı	
Teknik Parametre	MAPE
KK-D-2	33,86
KK-D-3	21,41
KK-AT-1	9,05
KK-AT-1	8,29

Çizelge 3.18. Ütüleme kalıbı için YSA sonuçları hata yüzdeleri

Ütüleme Kalıbı	
Teknik Parametre	MAPE
ÜK-B-1	23,67
ÜK-B-2	19,94
ÜK-B-3	39,68
ÜK-E	20,86
ÜK-D-1	24,83
ÜK-D-2	107,70
ÜK-D-3	22,17
ÜK-AT-1	20,16
ÜK-AT-2	11,27

Yapay sinir ağı sonuçlarına göre genel olarak hata oranlarının yüksek olduğu gözlemlenmiştir. Ayrıca hata değerlerinin bazı parametreler için diğer parametrelere oranla daha yüksek olduğu görülmüştür. Bu durumun ağı eğitim için verilen verilerin yapısından kaynakladığı düşünülmüştür. Daha öncede belirtilmiş olduğu gibi, yapay sinir ağlarının örneklerle eğitilmesi ile ağın kendi için gerekli bilgileri oluşturması ve

sistem davranışını öğrenmesi sağlanmaktadır. Eğitimi sonrasında ağ, kendisine verilen farklı verileri değerlendirerek sistem davranışını yansıtan tepkileri üretebilmektedir. Bu açıdan, veri kalitesi oldukça önemlidir.

Kalıp sektöründe, oldukça farklı geometride kalıp üretimleri yapılabilmekte ve bazı durumlar için özel kalıp üretimleri de gerçekleştirilebilmektedir. Bu kalıplar, diğer kalıplara göre boyutlarında ve işlemlerinde farklılıklara sahip olduklarından ilgili parametre değerleri ve süreleri farklı olabilmektedir. Çalışma için, her üç kalıp tipi için toplanan veri kümelerinde benzer durumdaki kalıp verileri de yer almaktadır. Bu sebeple, normal kalıp değerlerinden farklı olan bu kalıp verileri yapay sinir ağının sistem davranışını tam olarak öğrenmesini engellemiş olabileceği ve dolayısıyla test verileri için hata değeri yüksek sonuçlar ürettiği düşünülmektedir.

4. ARAŞTIRMA SONUÇLARI

Çalışmada, kalıp üretim aşamalarının standart zamanlarının belirlenmesi için kalıp teknik parametre değerlerini tahmin etmek üzere regresyon analizi ve yapay sinir ağları metotlarıyla tahmin modelleri geliştirilmiştir. Bu modellerin başarısı, test verilerindeki tahmin sonuçlarını gerçeğe en yakın olarak belirleyebilmeleridir. Diğer bir açıdan, test verilerinde alınan tahminlerin gerçek değerden yanılma payını analiz etmek üzere hesaplanan ortalama mutlak yüzde hata (MAPE) oranlarının düşük olması tahmin modelinin başarısını göstermektedir.

Her bir teknik parametre için seçilmiş olan regresyon modeline göre ve yapay sinir ağı uygulamasına göre test verilerindeki tahmin başarısı kalıp tiplerine göre Çizelge 4.1, Çizelge 4.2 ve Çizelge 4.3'te görülmektedir.

Çizelge 4.1. Çekme kalıbı regresyon ve YSA MAPE değerleri

ÇEKME KALIBI		
Teknik Parametreler	MAPE	
	Regresyon	YSA
ÇK-P-1	16,63	16,18
ÇK-P-2	8,52	10,47
ÇK-P-3	26,05	30,60
ÇK-P-4	16,00	19,49
ÇK-P-5	22	29,07
ÇK-P-6	4,97	11,52
ÇK-E	15,19	85,36
ÇK-D	19,19	27,55
ÇK-AT-1	9,16	15,19
ÇK-AT-2	13,57	17,75

Çizelge 4.2. Çevre kesme kalıbı regresyon ve YSA MAPE değerleri

ÇEVRE KESME		
Teknik Parametreler	MAPE	
	Regresyon	YSA
KK-K-1	18,86	28,97
KK-K-2	11,82	19,38
KK-S-1	16,15	23,05
KK-S-2	5,86	8,55
KK-S-3	32,68	17,17
KK-E	13,92	18,36
KK-D-1	9,42	36,73
KK-D-2	23,10	33,86
KK-D-3	13,48	21,41
KK-AT-1	17,07	9,05
KK-AT-2	13,25	8,29

Çizelge 4.3. Ütüleme kalıbı regresyon ve YSA MAPE değerleri

ÜTÜLEME KALIBI		
Teknik Parametreler	MAPE	
	Regresyon	YSA
ÜK-B-1	3,74	23,67
ÜK-B-2	7,11	10,94
ÜK-B-3	13,69	39,68
ÜK-E	5,93	20,86
ÜK-D-1	77,69	107,70
ÜK-D-2	5,73	24,83
ÜK-D-3	11,06	22,17
ÜK-AT-1	17,09	20,16
ÜK-AT-2	8,04	11,27

Tahmin modellerinin her bir teknik parametreyi tahmin etme başarısının yanı sıra çalışmanın toplam üretim süresini tahmin etmedeki başarısı da önemlidir. Bu sebeple, elde edilen tahmin modelleri ile teknik parametreler tahmin edilerek toplam kalıp üretim süresi, her üç tip kalıp için hesaplanmış olup gerçek değerler ile karşılaştırılmıştır. Seçilen regresyon denklemlerine ve yapay sinir ağı modeline göre tahmin edilen teknik parametrelerle çekme, çevre kesme ve ütüleme kalıp tiplerinden seçilen birer kalıp için

toplam üretim süresi hesaplanmıştır. Hesaplamalarda, üretim aşamalarında sabit olan parametrelerle ilgili süreler direkt olarak hesaplamaya katılmıştır. Parametre değerlerine bağlı olarak değişen hesaplamalar için öncelikle teknik parametre değerleri regresyon ve yapay sinir ağı modelleri ile tahmin edilmiştir. Çekme, çevre kesme ve ütüleme kalıpları için toplam üretim sürelerinin hesaplanması, ilgili işlem adımlarına göre sabit ve tahmin edilen dakika zaman biriminden süreler sırasıyla Çizelge 4.4 (a), (b) ve (c)'de görülmektedir. İşlem adımları ve süre hesaplamalarıyla ilgili işlem adları, hesaplama formülleri gibi detay bilgiler işletme bilgi gizliliği sebebiyle çalışmada paylaşılamamıştır. Toplam kalıp üretim süre hesaplamalarının sonuçları gerçek kalıp üretim süreleriyle karşılaştırılmış ve Çizelge 4.5'te yansıtılmıştır.

Çizelge 4.4 (a). Çekme Kalıbı toplam üretim süresinin hesaplanması

KALIP İŞLEM ADIMLARI	İstatistiksel Model	Yapay Sinir Ağı
1	45	45
2	45	45
3	1736	1736
4	4314	4314
5	450	450
6	4860	4860
7	243	243
8	194	194
9	972	972
10	1458	1458
11	648	648
12	0	0
13	269	342
14	78	78
15	324	324
16	384	384
17	66	66
18	138	138
19	420	420
20	90	118

Çizelge 4.4 (a). Çekme Kalıbı toplam üretim süresinin hesaplanması (devam)

KALIP İŞLEM ADIMLARI	İstatistiksel Model	Yapay Sinir Ağı
21	45	45
22	384	384
23	116	116
24	53	53
25	24	24
26	378	378
27	0	0
28	90	90
29	0	0
30	13	13
31	18	18
32	269	342
33	324	324
34	384	384
35	66	66
36	50	50
37	138	138
38	184	197
39	116	116
40	378	378
41	18	18
42	184	197
43	120	120
44	50	50
45	384	384
46	384	384
47	18	18
48	420	420
49	62	62
50	53	53
51	21	21
52	108	108
53	36	36
54	45	45
55	18	18
56	0	0
57	90	118
58	0	0
59	36	36

Çizelge 4.4 (a). Çekme Kalıbı toplam üretim süresinin hesaplanması (devam)

KALIP İŞLEM ADIMLARI	İstatistiksel Model	Yapay Sinir Ağı
60	18	18
61	184	197
62	36	36
63	134	134
64	62	62
65	18	18
66	116	116
67	18	18
68	150	150
69	20	20
70	0	0
71	2091	1698
72	1180	913
73	139	139
74	2738	1178
75	3851	3083
76	2380	1856
77	145	157
78	145	157
79	144	144
80	84	84
81	84	84
82	96	96
83	3120	3120
84	825	825
85	450	450
86	45	45
87	30	30
88	120	120
89	90	90
90	672	672
91	120	120
92	144	144
93	132	132
94	450	450
95	156	156
96	0	0
97	0	0
98	3120	3120

Çizelge 4.4 (a). Çekme Kalıbı toplam üretim süresinin hesaplanması (devam)

KALIP İŞLEM ADIMLARI	İstatistiksel Model	Yapay Sinir Ağı
99	120	120
100	120	120
101	180	180
102	0	0
103	0	0
104	39	39
105	2162	743
106	3173	2475
107	1573	1217
108	75	75
109	1967	1521
110	1967	1521
111	3173	2475
112	9720	9720
113	3967	3094
114	675	675
115	868	868
116	2025	2025
117	1736	1736
118	5181	3326
119	1875	1875
Toplam süre(dk)	85712	75674

Çizelge 4.4 (b). Çevre kesme kalıbı toplam üretim süresinin hesaplanması

KALIP İŞLEM ADIMLARI	İstatistiksel Model	Yapay Sinir Ağı
1	45	45
2	45	45
3	1123	1099
4	4314	4314
5	2245	2197
6	8100	8190
7	482	482
8	385	385
9	1926	1926

Çizelge 4.4 (b). Çevre kesme kalıbı toplam üretim süresinin hesaplanması (devam)

KALIP İŞLEM ADIMLARI	İstatistiksel Model	Yapay Sinir Ağı
10	3852	3852
11	648	648
12	4860	4860
13	216	229
14	78	78
15	324	324
16	384	384
17	54	54
18	66	66
19	96	104
20	116	116
21	720	720
22	0	0
23	53	53
24	419	410
25	24	24
26	18	18
27	413	413
28	216	229
29	324	324
30	384	384
31	66	66
32	53	53
33	108	108
34	53	53
35	66	66
36	378	378
37	21	21
38	378	378
39	72	72
40	720	720
41	255	255
42	169	171
43	18	18
44	96	104
45	375	375
46	18	18
47	116	116
48	36	36

Çizelge 4.4 (b). Çevre kesme kalıbı toplam üretim süresinin hesaplanması (devam)

KALIP İŞLEM ADIMLARI	İstatistiksel Model	Yapay Sinir Ağı
49	18	18
50	180	180
51	413	413
52	2095	2051
53	39	39
54	10	10
55	53	53
56	24	24
57	62	62
58	108	108
59	300	300
60	18	18
61	285	285
62	18	18
63	1572	1538
64	18	18
65	331	331
66	2326	2110
67	0	0
68	7711	7711
69	2095	2051
70	0	0
71	1162	1148
72	900	900
73	144	144
74	84	84
75	84	84
76	3120	3120
77	186	186
78	90	90
79	672	672
80	0	0
81	615	615
82	540	540
83	90	90
84	3780	3960
85	1890	1980
86	0	0
87	435	435

Çizelge 4.4 (b). Çevre kesme kalıbı toplam üretim süresinin hesaplanması (devam)

KALIP İŞLEM ADIMLARI	İstatistiksel Model	Yapay Sinir Ağı
88	120	120
89	90	90
90	120	120
91	3120	3120
92	615	615
93	90	90
94	0	0
95	38	38
96	180	180
97	45	45
98	90	90
99	435	435
100	1800	1800
101	1787	1591
102	729	716
103	427	479
104	1123	1099
105	900	900
106	998	977
107	3679	3483
108	2207	2090
109	900	900
110	1875	1875
Toplam süre(dk)	87762	87218

Çizelge 4.4 (c). Ütuleme kalıbı toplam üretim süresinin hesaplanması

KALIP İŞLEM ADIMLARI	İstatistiksel Model	Yapay Sinir Ağı
1	45	45
2	45	45
3	2083	2083
4	4972	4972
5	450	450
6	5760	5760

Çizelge 4.4 (c). Ütuleme kalıbı toplam üretim süresinin hesaplanması(devam)

KALIP İŞLEM ADIMLARI	İstatistiksel Model	Yapay Sinir Ağı
7	288	288
8	230	230
9	1152	1152
10	2304	2304
11	648	648
12	2880	2880
13	177	150
14	78	78
15	324	324
16	384	384
17	54	54
18	66	66
19	84	90
20	53	53
21	0	0
22	384	384
23	116	116
24	360	360
25	53	53
26	21	21
27	24	24
28	108	108
29	72	72
30	84	84
31	18	18
32	177	150
33	324	324
34	384	384
35	36	36
36	53	53
37	0	0
38	216	216
39	105	105
40	768	768
41	66	66
42	24	24
43	144	144
44	0	0
45	360	360

Çizelge 4.4 (c). Ütuleme kalıbı toplam üretim süresinin hesaplanması(devam)

KALIP İŞLEM ADIMLARI	İstatistiksel Model	Yapay Sinir Ağı
46	18	18
47	168	168
48	133	133
49	84	90
50	18	18
51	116	116
52	36	36
53	18	18
54	180	180
55	413	413
56	66	66
57	53	53
58	384	384
59	62	62
60	108	108
61	15	19
62	0	0
63	42	42
64	132	132
65	18	18
66	20	20
67	162	162
68	325	325
69	359	359
70	1725	2229
71	1495	816
72	665	665
73	59	74
74	144	144
75	84	84
76	84	84
77	3120	3120
78	90	90
79	120	120
80	120	120
81	465	465
82	465	465
83	3120	3120
84	672	672

Çizelge 4.4 (c). Ütuleme kalıbı toplam üretim süresinin hesaplanması(devam)

KALIP İŞLEM ADIMLARI	İstatistiksel Model	Yapay Sinir Ağı
85	308	308
86	0	0
87	240	240
88	30	30
89	0	0
90	3120	3120
91	90	90
92	240	240
93	240	240
94	930	930
95	930	930
96	7800	7800
97	672	672
98	308	308
99	480	480
100	60	60
101	60	60
102	36	36
103	1568	2027
104	1359	742
105	450	450
106	900	900
107	1699	927
108	5636	5376
109	2352	3040
110	1350	1350
111	675	675
112	1875	1875
Toplam süre(dk)	74738	74041

Çizelge 4.5. Toplam kalıp üretim sürelerinin karşılaştırılması

		Toplam Kalıp Üretim Süreleri				
		Gerçek (sa)	İstatistiksel Model(sa)	Hata (%)	Yapay Sinir Ağı(sa)	Hata (%)
Kalıp Tipi	Çekme	1383,75	1429	0,03	1261	0,09
	Çevre Kesme	1634,25	1463	0,11	1454	0,11
	Ütüleme	1326	1246	0,06	1234	0,07

Tahmin için geliştirilen istatistiksel modeller yani regresyon modelleri ile yapay sinir ağı modellerinin karşılaştırmasında istatistiksel model daha başarılı bulunmuştur. Bu çalışma ile kalıp üretim zamanları, yaklaşık % 10-15 hata oranı ile tahmin edilebilmiştir.

5. TARTIŞMA

Bu tez çalışmasında, kalıp üretim aşamalarının standart zamanlarının, kalıp teknik parametreleri yardımıyla belirlenmesine alternatif yaklaşımlar olarak regresyon analizi ve yapay sinir ağları yöntemi ile tahmin modelleri geliştirilmiştir. Bu amaçla, kalıp teknik parametrelerinin tahmini için hazırlanan veri setinde her bir kalıp tipi için yer alan 30 veriden 25 adedi tahmin modellerinin geliştirilmesinde 5 tanesi ise geliştirilen bu tahmin modellerinin testinde kullanılmıştır.

Çalışma sonucunda, kalıp üretim zamanlarının tahmin edilen kalıp teknik parametrelere bağlı olarak belirlenebileceği ortaya konmuştur. Test işlemi sonrasında elde edilen tahmin değerlerinin gerçek değerlere göre ortalama mutlak yüzde hata (MAPE) değerleri incelendiğinde regresyon tekniğinin yapay sinir ağı yöntemine göre kalıp teknik parametrelerini dolayısıyla kalıp üretim aşamalarının zamanlarını daha başarılı olarak tahmin ettiği görülmüştür.

Yapay sinir ağlarının model oluşturmada sağladığı esneklik regresyon yönteminde kullanılamamakta ve regresyon tekniği sadece mevcut sonuçları temel alarak tek bir model denklemini vermekte olduğundan YSA ile veri tahmini daha güçlü bir şekilde yapılabilmektedir. Ancak, bu çalışmada regresyon tekniğinden alınan sonuçların daha iyi olmasının sebebinin, yapay sinir ağlarını eğitmek için daha fazla verinin gerekli olması olabileceği yorumlanmıştır. Rutin yapay sinir ağları uygulamalarında veri büyüklüğü binler veya milyonlarla ifade edilmektedir. Veri büyüklüğü ve kalitesi, değişkenler arasındaki ilişkinin (örüntünün) ortaya çıkarılmasında önemli rol oynamaktadır. Daha fazla veri ile eğitilen ve test edilen yapay sinir ağının gerçek ilişkileri daha iyi öğrenmesine ve gerçeğe daha yakın çıktılar (sonuçlar) üretmesi mümkün olacaktır. Ancak az adette veri ile gerçekleştirilen yapay sinir ağı uygulaması bu çalışmada başarılı sonuçlar vermemiştir.

Bazı teknik parametre tahminlerinde başarı performans ölçüsü olarak belirtilmiş olan MAPE değerlerinin oldukça yüksek olduğu görülebilir. Bu duruma veri miktarının yetersizliği ve dolayısıyla geliştirilen tahmin modellerinin bazı kalıp parametre değerlerini tahmin etmede başarısızlığı neden olmaktadır. Veri yetersizliğinin yanı sıra rastlanılan diğer bir durum ise; test verisinde olağan dışı bir kalıp verisinin yer

almasıdır. Genel temsil etmeyen bu örnek, ortalama mutlak yüzde hata değerlerini de etkilemektedir.

Geliştirilen tahmin modelleri ile kalıp tipine göre teknik parametreler tahmin edilebilmekte, tahmin edilen teknik parametre değerleri kullanılarak kalıp üretim aşamalarının süreleri hesaplanabilmektedir. Elde edilen bu kazanımla işletme, üretim planlamalarını doğru ve başarılı şekilde yürütebilecek, siparişlerini attırabilecek ve verimliliğini arttırabilecektir.

Literatür araştırmalarında, çalışmada konu edilen kalıp üretim aşamalarının zamanlarının belirlenmesine yönelik olarak çalışmalara pek rastlanmamıştır. Bu açıdan çalışmanın, kalıp üretim sürelerinin tahmini için önemli olduğu söylenebilir. Bu çalışmadan hareketle problemin çözümüne yönelik olarak tahmin çalışmaları daha fazla veri ile aynı yaklaşımlarla tekrarlanabilir. Böylece, veri miktarının yetersizliği sebebiyle oluşan sapmalar en aza indirgenebilir. Regresyon yaklaşımında, doğrusal analizlerin yanı sıra parametreler arasında doğrusal olmayan bağlantılar araştırılabileceği; yapay sinir ağı yaklaşımında ise farklı ağ tasarımları ve farklı öğrenme yapıları benzer çalışmalar için denenebileceği düşünülmektedir.

KAYNAKLAR

- Aladağ, Ç.H. Eğrioğlu, E. Kadılar, C. 2009.** Forecasting nonlinear time series with a hybrid methodology. *Applied Mathematics Letters*, 22: 1467-1470.
- Alpar, C.R. 2003.** Uygulamalı çok değişkenli istatistiksel yöntemlere giriş-1. Nobel Yayınları, Ankara, 412 s.
- Altan, T. Lilly, B. Yen, Y.C. 2001.** Manufacturing of dies and molds. *CIRP Annals – Manufacturing Technology*, 50: 404-422 p.
- Anonim, 2011.** Makine teknolojisi: Sac metal kalıp ve mekanizmalar resmi. Milli Eğitim Bakanlığı, 2011, Ankara.
- Asilkan, Dr. Ö. Irmak, S. 2009.** İkinci el otomobillerin gelecekteki fiyatlarının yapay sinir ağları ile tahmin edilmesi. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 14(2): 375-391.
- Asiltürk, İ. 2012.** Predicting surface roughness of hardened AISI 1040 based on cutting parameters using neural networks and multiple regression. *Int J Adv Manuf Technol*, 63: 249-257 p.
- Aşkın, D. İskender, İ. Mamızadeh A. 2011.** Farklı yapay sinir ağları yöntemlerini kullanarak kuru tip transformatör sargısının termal analizi. *Gazi Üniversitesi Mühendislik ve Mimarlık Fakültesi Dergisi*, 26(4): 905-913.
- Ataşımşek, S. 2002.** Plastik ve metal kalıpcılık teknikleri. Birsen Yayınevi, İstanbul, 298 s.
- Aynekin, G. 2006.** İnternet İçerik Madenciliğinde Yapay Sinir Ağları ve Bir Uygulama. *Yüksek Lisans Tezi*, UÜ Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, Bursa.
- Bayata, H.F. Hattatoğlu, F., 2010.** Yapay sinir ağları ve çok değişkenli istatistik yöntemlerle trafik kaza modellemesi. *Erzincan Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 3(2): 207-219.
- Bayazıt, M. 2006.** Çok değişkenli istatistik analiz ve hidrolojide uygulamaları. Su Vakfı Yayınları, İstanbul, 166 s.
- Boujelbene, M. Moisan, A. Tounsi, N. Brenier, B. 2004.** Productivity enhancement in dies and molds manufacturing bu the use of C^1 continuous tool path. *International Joournal of Machine Tools & Manudacture*, 44: 101-107.
- Çavdur, F. 2005.** Arama Motorları Kullanıcı Oturumlarındaki Konu Değişikliklerinin Tespit ve Tahmin Yöntemleri. *Yüksek Lisans Tezi*, UÜ Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, Bursa.

- Çelik, M. 2010.** Bir otomotiv yan sanayi kuruluşunda veri madenciliği uygulaması. *Yüksek Lisans Tezi*, UÜ Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, Bursa.
- Demuth H., Beale M. 2000.** Neural Network Toolbox for Use with Matlab. MathWorks Inc., 847 pp.
- Doğan, G. 2010.** Yapay sinir ağları kullanılarak Türkiye’deki özel bir sigorta şirketinde portföy değerlendirilmesi. *Yüksek Lisans Tezi*, Hacettepe Üniversitesi İstatistik Anabilim Dalı, Ankara.
- Dreyfus, G. 2005.** Neural Networks: Methodology and Applications. Springer –Verlag, USA, 510 pp.
- Efe, M. Ö. Kaynak, O. 2000.** Yapay sinir ağları ve uygulamaları. Boğaziçi Üniversitesi Yayınları, 141 s.
- Elmas, Ç. 2003.** Yapay Sinir Ağları(Kuram, Mimari, Eğitim, Uygulama). Seçkin Yayıncılık, Ankara, 192 s.
- Ergezer, H. Dikmen, M. Özdemir, E. 2003.** Yapay sinir ağları ve tanıma sistemleri. *Pivolka*, 2(6): 14-17.
- Erzin, Y. Çetin, T. 2013.** The prediction of the critical factor of safety of homogeneous finite slopes using neural Networks and multiple regressions. *Computers & Geosciences*, 51: 305-313.
- Fausett, L. 1994.** Fundamentals of neural networks. architectures, algorithms and application. Prentice-Hall, New Jersey, 476 p.
- Foo, J.S. Ghosh, P.S. 2002.** Artificial neural network modelling of partial discharge parameters for transformer oil diagnosis. Electrical Insulation and Dielectric Phenomena, 2002 Annual Report Conference on, Mexico.
- Gurney, K. 1997.** An Introduction to Neural Networks. CRC Press, USA, 135 pp.
- Gültekin, F. 2011.** Regresyon analizi, <http://turkistatistik.net/upload/dosya/reganaliz.pdf> (Erişim tarihi: 23.12.2012)
- Güneri, N. Apaydın, A. 2004.** Öğrenci başarılarının sınıflandırılmasında lojistik regresyon analizi ve sinir ağları yaklaşımı. *Ticaret ve Turizm Eğitim Fakültesi Dergisi*, (1): 170 – 188.
- Hagan, M.T. Demuth, H. B. Beale M. H. 1996.** Neural network design. Colorada University Bookstore, (değişik sayfalama).
- Hagan, M.T. Menhaj, M.B. 1994.** Training feedforward networks with the Marquardt Algorithm. *IEEE Transactions on Neural Networks*, 5(6): 989-993.

- Hanssens D. M., Parsons L.J. Schultz R.L. 2001.** Market Response Models Econometric and Time Series Analysis. Kluwer Academic Publishers, New York, 520 pp.
- Haykin, S. 1994.** Neural networks: a comprehensive foundation. Macmillan College Publishing Company, USA. 696 s.
- Haykin, S. 1999.** Neural networks: a comprehensive foundation. Prentice Hall, New Jersey. 842 s.
- Kalaycı, Ş. 2006.** SPSS uygulamalı çok değişkenli istatistik teknikleri. Asil Yayınları, Ankara, 426 s.
- Kang, K.S. Kim, T.H. Rhee, I.K. 1994.** The establishment of standard time in die manufacturing process using standard data. *Computers & Industrial Engineering*, 27: 539-542.
- Küçükkocaoğlu, G. Benli, Y.K. Küçüksözen, C. 2005.** Finansal bilgi manipülasyonunun tespitinde yapay sinir ağı modelinin kullanımı. *İstanbul Menkul Kıymetler Borsası Dergisi*, 36: 1-30.
- Kuzman, K. Nardin, B. 2004.** Determination of manufacturing Technologies in mould manufacturing. *Journal of Materials Processing Technology*, 157-158: 573-577.
- Lee, M. S. Rho, H. M. Kang, M. J. 1995.** An evaluation system of order acceptability under consideration of machine loading in die manufacturing, *Annals of the CIRP*, 44(1): 413-416.
- Mackay, D.J.C. 1992.** Bayesian interpolation. *Neural Computation*, 4(3): 415-447.
- Mandic D. P., Chambers J. A. 2001.** Recurrent Neural Networks for Prediction - Learning Algorithms Architectures and Stability. John Wiley & Sons Ltd, New York, 308 pp.
- Marquardt, D. 1963.** An algorithm for least squares estimation of non-linear parameters. *Journal of the Society for Industrial and Applied Mathematics*, 11(2): 431-441.
- Montgomery, D.C. Peck, E.A. Vining, G.G. 2001.** Introduction to linear regression analysis. John Wiley & Sons, New York, 641 p.
- Nabiyev, V.V. 2005.** Yapay Zeka: problemler, yöntemler, algoritma. Seçkin Yayıncılık, 764 s.
- Nakiboğlu, M. 2003.** Kuramdan uygulamaya beyin fırtınası yöntemi. *Türk Eğitim Bilimleri Dergisi*, 1(3): 343.

Nguyen, H.H. 2007. A neural fuzzy approach to modeling the thermal behaviour of power transformers. *Ph.D. Thesis.*, Victory University School of Electrical Engineering Faculty of Health, Engineering&Science, USA.

Okkan, U. Mollamahmutođlu, A. 2010. Yiđitler ayı gnlk akımlarının yapay sinir ađları ve regresyon analizi ile modellenmesi. *Dumlupınar niversitesi Fen Bilimleri Enstits Dergisi*, (23): 33-48.

ztemel, E. 2012. Yapay sinir ađları. Papatya Yayıncılık, İstanbul, 232 s.

ztrkcan, Prof. Dr. M. 2009. Regresyon Analizi. T.C. Maltepe niversitesi Yayınları, İstanbul, 119 s.

Pilani, R. Narasimhan, K. Maiti, S. K., Singh, U. P., Date, P.P. 2000. A hybrid intelligent systems approach for die design in sheet metal forming. *Int J Adv Manuf Technol*, 16: 370-375.

Rodriguez, R.P. Borroto, Y.S. Lapuerta, M. Perez, L.G. 2013. Prediction of the cetane number of biodiesel using artificial neural Networks and multiple linear regression. *Energy Conversion and Management*, 65: 255-261.

Sara, T. 2004. Yapay sinir ađları. *Seminer Projesi*. Gazi niversitesi Endstri Mhendisliđi Blm Anabilim Dalı, Ankara.

Saritas, G. 2008. The design of magnetic filter for cleaning industrial liquids and adaptive control of filter by artificial intelligence methods. *Phd Thesis*, Selcuk University, Institute of the Natural and Applied Sciences, Konya.

Schtzer, K. Helleno, A.L. Pereira, S.C. 2006. The influence of the manufacturing strategy on the production of molds and dies. *Journal of Materials Processing Technology*, 179: 172-177.

Serper, . 2000. Uygulamalı istatistik II. Ezgi Kitabevi, Bursa, 409 s.

Smith, K. A., Gupta J.N.D. 2002. Neural Networks in Business: Techniques and Applications. IRM Pres, United Kingdom, 272 p.

Ően, Z. 2004. Yapay sinir ađları ilkeleri. Su Vakfı Yayınları, İstanbul, 183 s.

Takı, Dr. H. 2010. Yapay Sinir Ađlarına GiriŐ Ders Notları, GYTE Bilgisayar Mhendisliđi Blm, Gebze. http://htakci.sucati.org/YSA/index_dosyalar/bolum-1.pdf - (EriŐim tarihi: 24.11.2012).

Yalın, N. 2009. Yapay sinir ađların giriŐ ders notları, Bilecik Őeyh Edebali niversitesi, Bilgisayar Mhendisliđi Blm, Bilecik. http://bm.bilecik.edu.tr/Dosya/Arsiv/odevnot/yapay_sinir_aglari.pdf - (EriŐim tarihi: 12.12.2012).

Zhang, G. Patuwo, B.E. Hu, M.Y. 1998. Forecasting with artificial neural Networks: The state of art. *International Journal of Forecasting*,14: 35-62.

Zheng, J. Wang, Q. Zhao, P. Wu, C. 2009. Optimization of high-pressure die-casting process parameters using artificial neural network. *Int J Adv. Manuf. Technol.*,44: 667-674.

ÖZGEÇMİŞ

Adı Soyadı : Gizem Göklü
Doğum Yeri ve Tarihi : BURSA-1988
Yabancı Dili : İngilizce

Eğitim Durumu (Kurum ve Yıl)
Lise : Bursa Anadolu Lisesi, 2006
Lisans : Uludağ Üniversitesi, 2010
Yüksek Lisans : Uludağ Üniversitesi, 2013

Çalıştığı Kurum/Kurumlar ve Yıl : Yön-Eylem Bilgi Sistemleri Ltd. Şti., 2011-2012
İletişim(e-posta) : gizemgoklu@gmail.com