

**T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**ALÜMİNYUM BOYASININ PARLAKLIK VE KAPLAMA
DEĞERLERİNİ YAPAY SINIR AĞLARI VE ÇOKLU
REGRESYON YÖNTEMLERİ İLE TAHMİNİ**

YÜKSEK LİSANS TEZİ

Zeynep DEMİR

Enstitü Anabilim Dalı : ENDÜSTRİ MÜHENDİSLİĞİ

Tez Danışmanı : Prof. Dr. Cemalettin KUBAT

Haziran 2019

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ALÜMİNYUM BOYASININ PARLAKLIK VE KAPLAMA
DEĞERLERİNİ YAPAY SİNİR AĞLARI VE ÇOKLU
REGRESYON YÖNTEMLERİ İLE TAHMİNİ

YÜKSEK LİSANS TEZİ

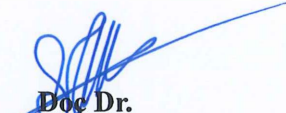
Zeynep DEMİR


Enstitü Anabilim Dalı

ENDÜSTRİ MÜHENDİSLİĞİ

Bu tez 13.06.2019 tarihinde aşağıdaki jüri tarafından oybirliği ile kabul edilmiştir.


Prof. Dr.
Cemalettin KUBAT
Jüri Başkanı


Doç Dr.
Safiye SENCER
Jüri Üyesi


Dr. Öğr. Üyesi
Buket KARATOP
Jüri Üyesi

BEYAN

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

Zeynep DEMİR

28.03.2019

TEŐEKKÜR

Üniversite yolculuđuna bařladıđım ilk günden beri tüm eđitim hayatımda her zaman yanımda olduđunu hissettiđim, tez alıřmamı hazırlarken en bařından bu yana yön gösterip yolumu aydınlatan hiçbir yardımını esirgemeyen deđerli hocam Sayın Prof. Dr. Cemalettin KUBAT'a tüm bu süreçte adım adım özveriyle yardım edip yol gösteren Sayın hocam Cem ÖZKURT'a teşekkürlerimi sunarım. Uygulamayı yaparken Özveriyle yardım eden Sümbüle SAĐDI ve Enis SEVİM'e son olarak hayatım boyu yanımda olan kıymetli annem, babam ve kardeřlerime teşekkürlerimi sunarım.

İÇİNDEKİLER

TEŞEKKÜR.....	i
İÇİNDEKİLER	ii
SİMGELER VE KISALTMALAR LİSTESİ	iv
ŞEKİLLER LİSTESİ	v
TABLolar LİSTESİ.....	vii
ÖZET.....	ix
SUMMARY	x
BÖLÜM 1.	
GİRİŞ	1
BÖLÜM 2.	
LİTERATÜR ÖZETİ.....	5
BÖLÜM 3.	
TAHMİN YÖNTEMLERİ.....	17
3.1. Nitel Tahmin Yöntemleri.....	17
3.1.1. Yönetici grubunun görüşlerini esas alan tahmin	17
3.1.2. Kilit personelinin fikirleri	17
3.1.3. Anketler	18
3.2. Nicel Tahmin Yöntemleri	18
3.2.1. Nedensel modeller	19
3.2.1.1. Regresyon analizi	19
3.2.1.2. Çoklu regresyon analizi	21
3.2.2. Zaman serileri yöntemleri.....	23
3.2.2.1. Aritmetik ortalama yöntemi	23
3.2.2.2. Hareketli ortalama yöntemi.....	24

3.2.2.3. Ağırlıklı hareketli ortalama yöntemi.....	25
3.2.2.4. Üstel düzgünleştirme yöntemi.....	26
3.2.2.5. Çift üstel düzeltme yöntemi	27
3.2.3. Yapay zekâ tabanlı yöntemler	28
3.2.3.1. Bulanık mantık.....	29
3.2.3.2. Genetik algoritma.....	30
3.2.3.3. Gri sistem ve gri tahmin yöntemi.....	33
3.2.3.4. Yapay sinir ağları	33
BÖLÜM 4.	
TÜRKİYE’DE VE DÜNYADA ALÜMİNYUM.....	57
4.1. Alüminyumun Tarihçesi ve Özellikleri	57
4.2. Alüminyum Kullanım Alanları.....	60
BÖLÜM 5.	
UYGULAMA	63
BÖLÜM 6.	
SONUÇLAR VE ÖNERİLER.....	82
KAYNAKÇA.....	89
ÖZGEÇMİŞ	93

SİMGELER VE KISALTMALAR LİSTESİ

ANN	:Yapay Sinir Ađı
ART	:Adaptif Rezonans Teorisi
ASL	:Amerikan İşaret Dili
CNEAR	:Karmaşık Doğrusal Üstel Otoregresif
FFN	:İleri Beslemeli Sinir Ađı
GSYİH	:Gayri Safi Yurt İçi Hâsıla
LRA	:Lojistik Regresyon Analizi
MAD	:Ortalama Mutlak Hata
MAPE	:Ortalama Mutlak Yüzde Hata
MLR	:Çoklu Doğrusal Regresyon
MSE	:Ortalama Hatalar Karesi
M.T.A	:Maden Tektik ve Arama Enstitüsü
TEİAŞ	:Türkiye Elektrik İletişim Anonim Şirketi
VIF	:Varyans Şişme Deđeri
YSA	:Yapay Sinir Ağları

ŞEKİLLER LİSTESİ

Şekil 1.1. Tahminin yapı akışı	3
Şekil 2.1. Yapay sinir ağları ile görüntü işleme örneği.....	5
Şekil 2.2. Yapay sinir ağları ile kimlik belirleme örneği	6
Şekil 2.3. Yapay sinir ağları ile çekirdek analizi	7
Şekil 2.4. Çekirdek analiz sonuçları.....	8
Şekil 2.5. Siber eldivenle kelime tanıma.....	9
Şekil 2.6. Saatlik yer altı suyu seviye tablosu.....	10
Şekil 2.7. Bulanık mantık netleştirme grafiği	30
Şekil 3.1. Genetik algoritma çalışma mantığı	32
Şekil 3.2. Biyolojik sinir hücresinin temel yapısı	43
Şekil 3.3. Tek katmanlı YSA yapısı.....	44
Şekil 3.4. YSA modeli	48
Şekil 3.5. Yapay sinir ağının yapısı	52
Şekil 4.1. Dünya üzerindeki element oranları.....	57
Şekil 4.2. Alüminyum metali özellikleri.....	59
Şekil 4.3. Kullanım alanlarına göre alüminyum	60
Şekil 5.1. Çıplak alüminyum rulo	63
Şekil 5.2. Boyalı alüminyum rulo	64
Şekil 5.3. Sürekli boyama hattı	65
Şekil 5.4. Potakalanma yaşanan yüzey görüntüsü	66
Şekil 5.5. Korozyon örneği	67
Şekil 5.6. Boyalı alüminyum yüzeydeki blister oluşumu	67
Şekil 5.7. Krater oluşumu.....	68
Şekil 5.8. Parlaklık ölçüm cihazı	69
Şekil 5.9. Girdi çıktı parametreleri.....	70
Şekil 5.10. 30 nöronlu ağ yapısı.....	78

Şekil 5.11. 30 nöronlu yapay sinir ağı.....	78
Şekil 5.12. 30 nöronlu YSA modelinin gerçekleştiği tahmin sonuçları.....	79

TABLolar LİSTESİ

Tablo 3.1. Regresyon örneđi çözüümü	20
Tablo 3.2. Aritmetik ortalama ile tahmin örneđi	24
Tablo 3.3. Hareketli ortalama ile tahmin örneđi	25
Tablo 3.4. Ađırlıklı hareketli ortalama örneđi	26
Tablo 3.5. Üstel düzgünleştirme yöntemi örneđi	27
Tablo 3.6. Çift üstel düzeltme yöntemi örneđi.....	28
Tablo 3.7. Bazı toplama fonksiyonları	50
Tablo 3.8. Aktivasyon fonksiyonları.....	51
Tablo 3.9. Tahmin dođruluđu ölçme örneđi	55
Tablo 3.10. Tahmin sonuçları	56
Tablo 5.1. Veri kümesi örnekleme.....	72
Tablo 5.2. Kaplama alanı regresyon analizi sonucu	73
Tablo 5.3. Parlaklık deđeri dođrusal regresyon analizi sonucu	74
Tablo 5.4. Çoklu regresyon parlaklık denklemleri.....	75
Tablo 5.5. Geliştirilmiş çoklu regresyon analizi sonuçları	75
Tablo 5.6. Farklı nöron sayılı YSA kaplama alanı tahminlerinin karşılaştırması...	77
Tablo 5.7. Farklı nöron sayılı YSA parlaklık tahminlerinin karşılaştırılması.....	77
Tablo 5.8. 30 nöronlu eğitimi tamamlanmış ađın R oranları	80
Tablo 5.9. 30 nöronlu YSA tahmin sonuçları ve gerçek deđerler.....	80
Tablo 6.1. Kaplama alanı deđerlerinin çoklu regresyon tahmini hata deđerleri	82
Tablo 6.2. Kaplama alanı deđerlerinin yapay sinir ađları modeli tahmini hata deđerleri	83
Tablo 6.3. Kaplama alanı yapay sinir ađları ve çoklu regresyon tahminleri karşılaştırma tablosu	83
Tablo 6.4. Parlaklık çıktısı için oluşturulmuş çoklu regresyon denklemleri.....	84
Tablo 6.5. Parlaklık deđerlerinin çoklu regresyon tahmini hata deđerleri.....	85

Tablo 6.6. 30 nöronlu YSA R oranları.....	85
Tablo 6.7. Parlaklık değerlerinin yapay sinir ağı modeli tahmini hata değerleri	85
Tablo 6.8. Parlaklık yapay sinir ağı ve çoklu regresyon tahminleri karşılaştırma tablosu.....	86
Tablo 6.9. Tahmin öncesi ve sonrası kalite kusurları oranları	87
Tablo 6.10. Kalite kusurlarında iyileşme oranları.....	88

ÖZET

Anahtar kelimeler: Yapay Sinir Ağları, Çoklu Regresyon, Kaplama Alanı ve Parlaklık Değeri

Doğada pek çok şey bilinmeyen doğa kurallarına göre meydana gelmektedir. Ve insanoğlu bunu tahmin edemediği sürece bunların olumlu veya olumsuz sonuçlarına katlanmak durumunda kalmaktadır. Örneğin fiyat istikrarsızlıkları önemli sorunlara ve olağandan fazla maliyete yol açmaktadır. Enflasyondaki belirsizlik finansal kesimde ve reel kesimde ekonomik kararları etkilemektedir. Veya yağacak olan yağmur miktarını tahmin edememe tarımı buradan yapılacak hasadı doğrudan etkilemektedir. Bu gibi pek çok nedenle insanoğlu tahmin etmenin önemini kavramasıyla çeşitli tahmin yöntemleri geliştirilmiştir.

Yeryüzünde oksijen ve silisyum'dan sonra en çok bulunan üçüncü elementtir. Yerkabuğunda oksijen ve silisyum'dan sonra en çok bulunan (ağ. %8,1) metal alüminyumdur. Bu nedenle diğer metallerden daha ucuz daha kolay işlenebilir ve daha hafif olması nedeniyle endüstriyel anlamdan yüzlerce farklı alanda kullanımı vardır. İnşaat sektörlerinde dış cephe olarak boyalı alüminyum levhalar kullanılmaktadır. Dış cephe levhalarında dikkat çekici farklılığa sahip iki faktör bulunmaktadır. Bunlar müşteri için oldukça kritikleşen Parlaklık değeri ve üretici verimliliğini artıran Kaplama Alanı değeridir.

Bu çalışmada ise bunlar arasında oldukça yaygın olarak kullanılan yapay sinir ağları ve çoklu regresyon yöntemleri ele alınarak boya Kaplama Alanı ve Parlaklığı konusunda bir çalışması ve tahminlemesi gerçekleştirilmiştir.

ESTIMATION OF THE BRIGHTNESS AND COVERAGE OF ALUMINUM PAINT BY ARTIFICIAL NEURAL NETWORKS AND MULTIPLE REGRESSION METHODS

SUMMARY

Keywords: Artificial Neural Networks, Multiple Regression, Coverage and Brightness Value

In nature, many things occur according to unknown nature rules. And so long as human beings cannot predict it, they have to bear the consequences. For example, price instabilities lead to significant problems and many costs. The uncertainty in inflation affects the decisions of economic units in financial sector and real sector. Or the inability to predict the amount of rain to be rained directly affects its cultivation and harvest. Various estimation methods have been developed by understanding the importance of human estimation for many reasons. In this study, artificial neural networks and multiple regression methods which are widely used among them are described. Then, a study and estimation of the paint coating area and brightness were carried out.

Aluminum is the third most common element in the world after oxygen and silicon. In the earth's crust, after oxygen and silicon, the most common metal (8,1%) is aluminum. Therefore, cheaper than other metals can be processed more easily and lighter because of the industrial meaning has hundreds of different uses. Painted aluminum sheets are used as exterior facades in construction sectors. There are two factors with remarkable differences in the exterior panels. These are highly critical luster values for the customer and the coating area value that increases the productivity of the manufacturer.

In this study, artificial neural networks and multiple regression methods, which are widely used among them, were studied, and a study and estimation of the paint coverage area and brightness were performed.

BÖLÜM 1. GİRİŞ

Talep tahminindeki gelişim sürecinde bilgisayarın gelişmesi ile beraber farklı yöntemler uygulanmaya başlanmıştır. Bilgisayarlar sayesinde daha çok veri ile kısa sürede etkin bir sonuç alınması sağlanmıştır. Bununla beraber tahmin yöntemleri dört çeşide göre aşağıdaki şekilde sınıflandırılabilir.

1. Nitel Yöntemler: Nitel tahmin yöntemleri öznel olup insan yargılarına dayanmaktadır. Verinin yeterli olmadığı durumlarda ya da uzmanların pazar zekâlarına sahip olabildiklerinde uygun olur. Bu tahmin yöntemi gelecekte açılacak yeni alanlardaki talebi tahmin etmede gerekli olabilir.
2. Zaman Serileri Tahmin Yöntemleri: Zaman serisi kümelerinin tahmin edilmesi için geçmiş veri kümelerinden yararlanır. Bu yöntemler talep örneklerinin ancak çok fazla boyutta değişmediği durumlarda uygundur. Bu yöntemlerin kullanımı basittir aynı zamanda talep tahmini için iyi bir başlangıç noktasıdır.
3. Nedensel Yöntemler: Nedensel tahmin yöntemleri talebi dış faktörler ile etkileşim içerisinde varsayar. Nedensel tahmin yöntemleri talep ve dış faktörler arasındaki ilişkiyi saptar. Bu yöntemler hangi faktörlerin tahmin edilen talepleri etkilediğini bulur. Mesela dolar kuru değişmesi altın piyasasını ne şekilde etkilemektedir gibi.
4. Simülasyon Tahmin Yöntemi: Simülasyon yöntemleri, talebi artıran tüketici davranışlarını tahmine ulaştırmasını simüle eder. Simülasyon metodu kullanılarak, bir kurum veya kuruluş zaman serisi ve nedensel yöntemleri birleştirip tahmin ile ilgili konulara cevap bulabilirler (Boltürk, 2013).

Tahmin çoğu operasyonel aktiviteler için gerekli bir ön ihtiyaçtır. Geleceği ön görmeden yapılacak işlerin miktarını planlamak; tasarımı yapılacak, planlanıp kontrol edilip buna bağlı olarak ihtiyacı tahmin etmek mümkün değildir (Lewis, 1997).

Talep tahmini eğlence, tarım, eğitim, enerji, sanayi, ekonomi, gibi pek çok alanda önem sahibidir. Planlama yapılmasında, maliyet analizlerinde, risk analizi durumlarında ve satış gibi önemli çalışmalarda insanlara ön görü vereceği için görülmek istenecektir.

Talep tahmini özellikle planlama için önemlidir. Birçok sektörde ve konuda önemli olduğu gibi boya ihtiyaç tahmininde inceleyecek olursak ihtiyacı gerçek tüketimden az tahmin edildiği zaman siparişlerin az üretilmesi yoluna gidilmektedir bu da müşteri memnuniyetsizliği yaratacaktır.

Boya ihtiyaç tahmini gerçekleşen tüketimden fazla olması durumunda ise fazladan boya ücreti ödenmiş olur. Böylece boştan yere ödenen boya tüketimleri ücretlerinin başka yerlerde kullanılabilmesinin önü kesilecektir.

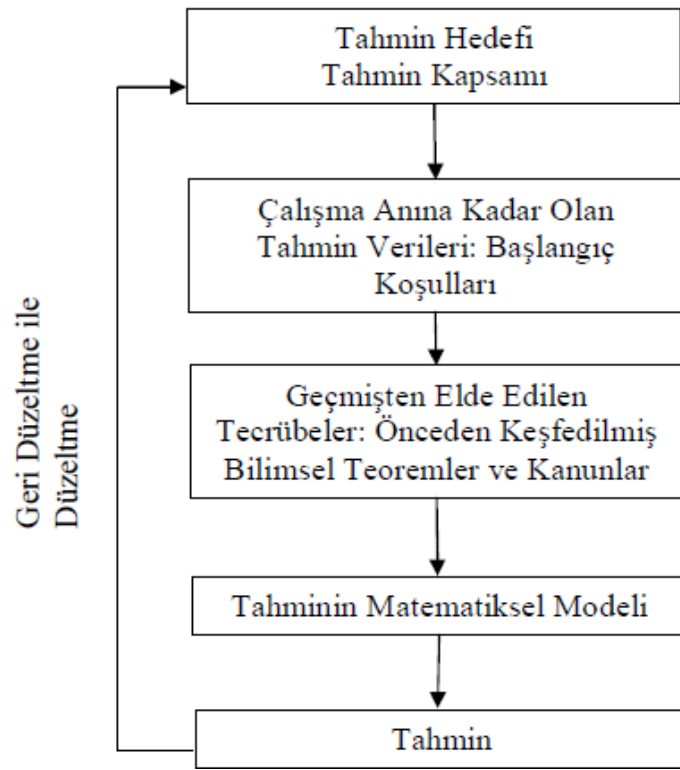
Yani tahmin edilecek tüketim miktarı ne kadar gerçekçi olursa o kadar iyi bütçe belirlenip planlaması yapılabilir. Şirketler kendi tüketimlerini ve tüketimlerini etkileyen değişkenleri içeren modeller bulmaya uğraşmaktadırlar. Modelleri gerçekleştirmek içinde kullandıkları tahmin serisinde yer alan veri kümesi eleman sayısı önemli olmaktadır (Boltürk, 2013).

Talep tahmininin etkili yapılabilmesi oldukça kritik bir konudur. Doğru tahmin edilemeyen bir model tamamen yanlış karar alınmasına yanlış yatırımlara ve bunun gibi günümüz dünyasında rekabetin oldukça yüksek olduğu piyasada içerisinde bulunan kurumu geriye taşıyacak kararlar alınmasına neden olabilmektedir. Bunun için Chopra ve Meindl altı adımlı bir yaklaşım önermişlerdir (Chopra & Meindl, 2004).

1. Tahminin amacını anlamak.
2. Tedarik zincirine talep planlamasını ve tahmini bütünleştirmek.

3. Müşteri çeşitliliği anlamak ve tanımlamak.
4. Talep tahminlerini etkileyen en büyük ve etkili faktörleri tanımlamak.
5. Uygun tahmin yöntemine karar vermek.
6. Tahmin için performans ve hata ölçütlerini kurmak.

Talep tahmininde önemli bir konu da tahmin akışını doğru anlamaktır. Tahmin yapılırken tahminin amacı, boyutu, gerekli koşulların olup olmaması gibi gerekli adımlar yer almaktadır. Şekil 1.1.'de tahminin akış algoritması verilmiştir (Ziębik & Hoinka, 2013).



Şekil 1.1. Tahminin yapı akışı

Yapılan tahminler kapsadığı zaman aralığına göre aşağıdaki gibi sınıflandırmıştır;

Uzun vade tahminleri: kurumların, tesislerin büyütülmesi, yeni makine alımı ve donanım için gerekli maddi ihtiyacı saptamak için yapılmaktadır. Beş veya daha fazla yıllık olabilir.

Orta vade tahminleri: Tedarik süresinin belirsiz olduđu durumlarda veya tedarik süresinin belirli olup uzun olduđu durumlarda, talebi mevsimsel dalgalanmalara bađlı olarak deđişiklik gösteren ürün stoklarının ön görülmesinde kullanılmaktadır. Altı aydan ila beş yıl periyodunda deđişiklik gösteren zaman periyodunu kapsayabilirler.


Kısa vade tahminleri: Kısa vadeli tahminler, temini kolay ve düşük oranlardaki ihtiyaç durumunda ekstra maliyeti yüksek olmayan durumlarda yapılır. Üç aydan, altı aya kadar deđişen bir periyodu kapsar.

Çok kısa vadeli tahminler: Haftalık, hatta günlük olarak her türlü malzeme stoklarının kontrol edilmesi için kullanılmaktadır. İş çizelge ve programlarının hazırlanması amacı ile kullanılmaktadır. Daha çok kurum dâhilindeki verilerden yararlanılarak tahminler oluşturulur.

BÖLÜM 2. LİTERATÜR ÖZETİ


Literatür araştırmasında, çeşitli sayıda parametreye sahip problem türleri için çeşitli tahminleme teknikleri kullanılan çalışmalar incelenmiştir.

Yapay Sinir Ağları konusunda görünü iyileştirme ile çalışan Haykin Şekil 2.1.'de görüldüğü üzere görüntü işleme yaparak piksel kalitesi iyileştirilmiş bir resim örneğidir (Haykin, 1994).



Şekil 2.1. Yapay sinir ağları ile görüntü işleme örneği (Haykin, 1994)

Bu makalede, parçalı bir yaklaşım ve hiyerarşik genetik algoritmalar ile optimizasyon kullanan yeni bir modüler sinir ağı modeli (MNN) kullanılmıştır. Bu model insan tanıma ve zaman serisi tahmini gibi farklı uygulama alanlarında kullanılabilir. Bu yazıda önerilen model kulak biyometrik ölçütlerine dayalı olarak insan tanınması için test edilmiştir. Önerilen modelin literatürdeki mevcut yaklaşımlara göre avantajlarını göstermek için kulak biyometrik ölçümünün bir karşılaştırma veri tabanı kullanılmıştır. Önerilen yöntem, parça sayısı, eğitim fazı için veri yüzdesi, hedef hatası, öğrenme algoritması, gizli katman sayısı ve ilgili nöron sayısı gibi modüler bir sinir ağının tasarım parametrelerinin optimizasyonundan oluşur (Sánchez & Melin, 2014).



Şekil 2.2. Yapay sinir ağları ile kimlik belirleme örneği


Şekil 2.2.'de Granüler yaklaşım ile kulak katmanlarının incelenme aşamalarını gösterilmiştir.

Çalışmada öneriyi test etmek amacıyla Pekin Bilim ve Teknoloji Üniversitesi Kulak Tanınma Laboratuvarı'ndan (USTB) elde edilen 77 kişiyi kapsayan veri kümesi kullanılmıştır. Tanımlama için her bir kulak granülü Şekil 2.2.'de gösterildiği üzere üç parçaya bölünür, bunlar helezon, kabuk ve lob 'tur. Girdilerin % 70'i eğitim için kullanılmış olup % 30u test için kullanılmıştır. %80 oranında hatasız tahmin elde edilmiştir (Sánchez & Melin, 2014).

Bu makalede İspanya'nın elektrik üretim piyasasındaki enerji fiyatı için YSA ile tahmin çalışması yapılmıştır. İspanyada kullanılan elektrik tüketim verileri ele alınarak

bir gün öncesinden saatlik tahminler hesaplanmıştır. Bu tahminleri gerçekleştirmek için kullanılan metot, birçok tahmin uygulamasında son yıllarda başarılı bir şekilde kullanılan YSA'dır. Enerji fiyatının tahmin edilecek güne bağlı olarak farklı davranışlar göstermesi nedeniyle, tahmin edilecek günler arasında iş günleri ile hafta sonları ve bayramlar bulunmaktadır. Örneğin 1 yıl öncesinde 1 Kasım Pazar gününe gelmiş ve tüketim yoğun olmuş iken bir sene sonrasında bu gün hafta içine gelmiştir ve bir yıl önceki veriye dayalı olarak yanlış tahminde bulunmamıştır. Bu çalışmada görüldüğü üzere YSA ile doğru sonuçlar elde edilmiştir. Ardından YSA tahminleri Box-Jenkins (BJ) ARIMA modelleriyle hesaplanan tahminlere karşı test edilmiştir (Priore ve ark., 2008).

Bu makalede şarap üretiminde kullanılmak üzere toplanan üzümün olgunluk evrelerine göre en doğru zamanda hasat edilmesi amacı ile tahmin gerçekleştirilmek istenmiştir. Üzüm çekirdeklerinin olgunluk aşamalarının doğru belirlenmesi hedeflenmiş ve bu olgunluk evresini anlamak amacıyla üzüm çekirdeklerinin görüntüleri işlenerek YSA tabanlı bir model geliştirilmiştir. Şarap imalatında ham madde olarak kullanılan üzüm için üç farklı olgunluk evresi belirlenmiştir. Bunlar olgunlaşmamış olgun ve aşırı olgun şeklindedir (Zuñiga ve ark., 2014).



Şekil 2.3. Yapay sinir ağları ile çekirdek analizi

Şekil 2.3.'te İncelemesi yapılan üzüm çekirdeklerinden 3 farklı aşamaya gelmiş örnekleri gösterilmiştir.

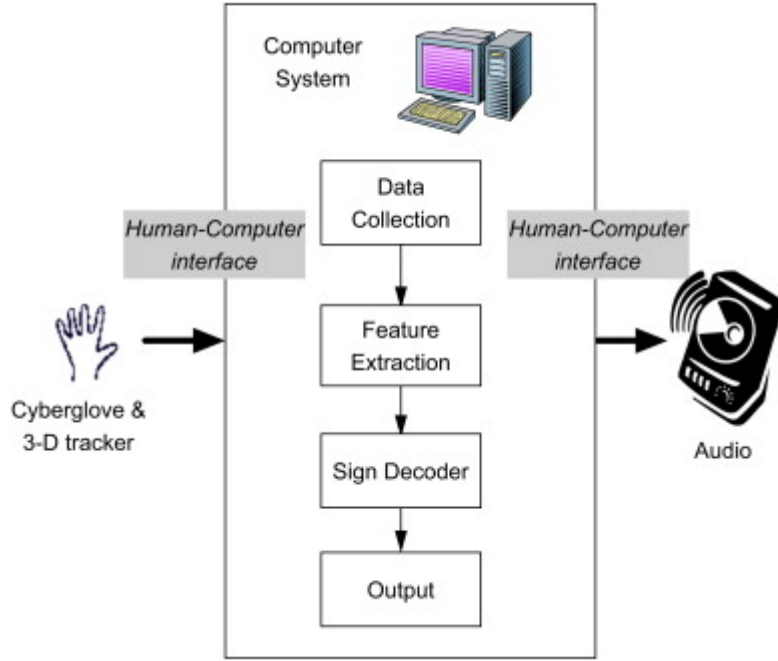
Bu problem için tasarlanmış sınıflandırma modeli, her sınıf için bir tane olmak üzere 3 sinir ağı içermektedir. Bu ağ tarayıcıdan alınan bir çekirdek görüntüsünü kullanarak işleme almaktadır. Eğitim seti, grup başına 20 tohumdan oluşur ve bunun yanında test seti de kullanılmıştır. YSA'nın gizli katmanı için sigmoid transfer fonksiyonu kullanılırken, çıkış katmanı için doğrusal bir aktarım fonksiyonu kullanılmıştır. Test sonuçlarına göre %90 başarı ile eğitime olumlu sonuç vermiş başarılı bir ayırt edici olarak kullanılmaya başlanmıştır (Zuñiga ve ark., 2014).

Deneme seti ve test seti sonuçlarının 3 farklı grup üzüm çekirdeğine verdiği sonuçlar Şekil 2.4.'te gösterilmiştir.

Seed class	Training set			Test set		
	Qty.	Hits	Hit rate (%)	Qty.	Hits	Hit rate (%)
Immature	20	15	75	13	9	69
Mature	20	19	95	170	141	83
Over mature	20	20	100	74	71	96
Total	60	54	90	257	221	86

Şekil 2.4. Çekirdek analiz sonuçları

Bu makalede hareket esaslı siber eldivenler ile YSA kullanılarak Amerikan İşaret dilinde kelime tanımlama amaçlanmıştır. Çalışmanın asıl amacı işitme engelli insanların kullandığı dili (ASL) bilmeyen insanlar ile bu dili bilen insanlar arasındaki iletişimini kolaylaştırmaktır (Leu & Oz, 2011).




Şekil 2.5. Siber eldivenle kelime tanıma

Şekil 2.5.'te Siber eldivenlerin kelimeleri harekete dayalı olarak tanımlayıp bir sesli çıktıya dönüştürme aşamalarını göstermektedir. Siber eldivenler hareketi algılar ve bu hareketleri depolar. Bu eldivenler sayesinde alınan veriler harfler veya kelimeler girdi olarak kullanılır ve ardından YSA ile eğitilir. YSA girdileri alfabedeki tüm harflerin çeşitli gösterimleri ve kelimelerdir. Bunlar 300 işaret ve 50 kelimedir. Bu girdiler 3 boyutlu hareketleri ve hareket hızları gibi ayırt edici özellikleri ile YSA'da eğitici olarak kullanılmıştır. Ardından YSA eğitim setinde var olmayan 120 işaret ile test edilmiştir. %90 oranında doğrulukla YSA'nın doğru olarak çalıştığı saptanmıştır (Leu & Oz, 2011).

Bu makalede, İtalya'nın Venedik Lagününde yer alan kıyı şeridi olmayan bir akiferde saatlik yeraltı suyu seviyelerinin uzun dönem simülasyonları için ileri beslemeli sinir ağı (FFN) uygulaması yapılmıştır. Belli bir zaman aralığında gözlenen yeraltı suyu yükselmeleriyle modele girdi akışı başlatıldıktan sonra, gelişmiş FNN modeli ile sadece yağış ve buhar soğuması olarak tanımlanan harici girdi değişkenlerini kullanarak su seviyesi değişimleri tahmini üretimi hedeflenmiştir. Bu amaca ulaşmak için, modeller ilk önce belli bir veri seti ile kalibre edilmiş ve geçmişte gözlemlenen yeraltı suyu seviyeleri ve harici girdiler kullanılarak gelecekteki yeraltı suyu

seviyelerinin 1 saat periyodundaki öngörüsü gerçekleştirilmiştir (Taormina ve ark., 2012).

Yer altı sularının tahminini gerçekleştiren böyle bir ağın, gelecekteki olası senaryolar altında akiferin tepkilerini tahmin etmek için fiziksel tabanlı modellere uygulanabilir bir alternatif olarak kullanılabilceğini göstermiştir. YSA ile öğrenmesi sağlanmış simülasyon uygulaması sonucu elde edilen veriler gözlenen veriler ile büyük oranda benzerlik sağlamıştır (Taormina ve ark., 2012).



Şekil 2.6. Saatlik yer altı suyu seviye tablosu

Şekil 2.6.'da İtalya'nın Venedik lagününde gerçekleşen yer altı suyu seviye değişimlerinin saatlere göre dağılımı çizelgelenmiştir.

Bu çalışmada Amerika Birleşik Devletleri'nin gelecekteki endüstriyel enerji talebini tahmin edebilen iki tür sayısal enerji modelinin geliştirilmesi anlatılmaktadır. Bir model olarak ANN (yapay sinir ağı) tekniğini kullanılırken diğer model olarak MLR (çoklu doğrusal regresyon) tekniğini kullanılmıştır. Modellerde var olan bağımsız değişkenler GSYİH, enerji taşıyıcılarının fiyatı olarak belirlenmiştir. Bundan sonra, gelecekteki endüstriyel enerji talebi, tanımlanmış bir senaryoya dayanarak iki model ile de tahmin edilmiştir (Kialashaki & Reisel, 2014).

ANN modeli, 2012 yılından itibaren 2030 yılına kadar enerji talebinde % 16'lık bir artış olacağını öngörmüştür. Bu tahminde, modelin bağımsız parametrelerinin tahmin edilen dönemde sabit kalacağını sadece GSYİH'nın ikinci dereceden bir polinom eğilimiyle büyüdüğünü varsaymaktadır. Yayımlanan öngörülerle tutarlı olan öngörme sonucu şu şekilde açıklanmıştır; yükselen enerji ihtiyacının bir sonucu olarak yeni ve düşük maliyetli enerji kaynaklarının geliştirilmesi ihtiyacı öngörülmüştür (Kialashaki & Reisel, 2014).

Bu çalışmada, hem girdi hem de hedef vektörlere normalizasyon uygulanmıştır. Bu normalizasyon, girdileri ve hedefleri $[-1,1]$ aralığına düşecek şekilde ölçeklendirilmiştir. Bu normalizasyonda, girdi ve hedef vektörlerin yalnızca sonlu gerçek değerlere sahip olduğu ve her vektörün elemanlarının hepsinin eşit olmadığı varsayılmaktadır. Bu çalışmada veriler rasgele üç takıma ayrılmıştır: eğitim için % 70, geçerlilik süreci için % 15 ve test işlemi için % 15. Eğitim süreci, ağırlıkları ve tahmini ayarlayarak performans işlevinin optimizasyonu Denklem (2.1)'de ki formülüzayon kullanılarak yapılmıştır (Kialashaki & Reisel, 2014).

$$y = \frac{(y_{\max} - y_{\min}) \times (x - x_{\min})}{(x_{\max} - x_{\min})} \quad (2.1)$$

2009 yılında yapılan bu çalışmada, beş farklı yüksek sıcaklık değeri uygulanmış katkılı betonun basınç dayanımı tahmini çoklu regresyon ve bulanık mantık yöntemleri kullanılarak gerçekleştirilmiştir. Modellerde; gerçek değerler ile tahmin edilen değerlerin ilişki durumlarına bakıldığında, tahmin için kullanılan bulanık mantık metodu ve çoklu doğrusal regresyon metotlarından bulanık mantık metodunun daha iyi sonuç verdiği gösterilmiştir (Durmuş & Can, 2009).

Bu çalışmada, hava kirliliği tahmini için bir öngörü modelinin kurulmasını amaçlanmıştır. Bu modeli kurmak için YSA, Çoklu Doğrusal Regresyon Analizi ve Bulanık Sinir Ağları yöntemleri kullanılmış olup ardından elde edilen bu yöntemlerin kıyaslaması yapılmıştır. YSA ile Bulanık Sinir Ağları için en yüksek performansa sahip modellerin belirlenmesi amacıyla çeşitli ağ yapıları çeşitli eğitim algoritmaları kullanılarak eğitilmiş ve deneyler gerçekleştirilmiştir. Elde edilen sonuçlardan, Yapay

Sinir Ağının denenen bu modeller içerisinde en iyi performansa sahip olduğu gösterilmiş ve Bulanık Sinir Ağının Regresyon Analizinden daha iyi ancak YSA'dan daha kötü performans gösterdiği gösterilmiştir (Yüksek, 2007).

Bu çalışmada Akkuş ve ark. (2016) savunma ve havacılık sanayinde enerji emilimi yüksek olan bal peteği ürünü için ihtiva ettiği kuvvet değerinin ölçümü yapılarak tahminlemesi hedeflenmiştir. İhtiva ettiği yüksek enerji sebebi ile kullanılan bir alüminyum bal peteği yapılarının malzemesinin ihtiva ettiği kuvvet değerlerinin ölçümü çok önemli bir durum olmaktadır. Bal peteği ürünlerine uygulanan düşük hızda darbe davranışları incelenmiş, uygulanan bu deneysel kuvvet değerlerinden alınan örneklem ile çoklu regresyon yöntemi kurulmuş ve kurulan yöntem ile tahminleme yapılmıştır (Akkuş ve ark., 2016).

Tolon ve Tosunoğlu yaptıkları bu çalışmada (2008) tüketici tatmini verilerini temel almışlardır. Tahminlerini YSA ve Regresyon yöntemleri ile gerçekleştirmişlerdir. Bu iki yöntemde de birbirine yaklaşık sonuçlar elde etmiş olup evlere servis imkânının olmaması ve satış geliştirme faaliyetlerinin doğru ilerlemesi sebepleriyle müşteri hizmetleri parametresinin tatmine negatif etkisi olmuştur. Kullanılmış diğer değişken kümeleri ise tahmini olumlu olarak etkilediği görülmüştür. Regresyon ve YSA ile oluşturulan bu modellerden YSA'nın regresyon modeline oranla daha düşük hata ile daha doğru neticelerle tahmin yaptığı görülmüştür (Tolon & Güneri Tosunoğlu, 2008).

Bu çalışmada sinterleme tambur mukavemetini güçlendirecek denemelerle mukavemet değeri ölçümünü tahminlemek için YSA ve Regresyon modeli kurulmuştur. Karışım suyu, sinterleme hızı ve sinterleme tamburu mukavemeti girdi değerleri olarak alınmış ve bunlarla ilgili çıktı değişkenleri ise; maksimum molekülize edilmiş su, demir içeriği, sıvı faz hacmi, hava geçirgenliği, sıvı faz hızı, yakıt oranı parametreleridir. 2 girdi değişkeni ve 6 çıktı değişkenli olan bu tahmin yapısı modeli Regresyon ve YSA yöntemlerini Visual C++ ve Matlab programları ile uygulayarak nem içeriği ile yakıt oranı optimize edilebileceği sonucunu göstermiştir (Fan ve ark., 2012).

Güngör bu çalışmada (2013), Isparta ilindeki hava kirliliği artışını konu almış ve yapılan çalışmada, 2007-2012 yılları Ekim-Mart kış ayları döneminde gözlemlenen meteoroloji ve hava kalitesi verilerini günlük bazda ele alıp YSA ile çoklu doğrusal regresyon yöntemleri ile tahmin modeli kurmuştur. 2011-2012 kış dönemini tahminleme amacı ile üç model kurulmuştur. Bunlardan birinci ve üçüncü model hava kalitesini tanımlayan SO₂ ve parçacık madde miktarını en doğru tahminleyen modeller olarak ortaya çıkmıştır (Güngör, 2013).

Bu çalışmada Şener (2005), Ankara ili anakent alanı elektrik sarfı tahmini için regresyon modeli oluşturmuştur. Çalışma verileri TEİAŞ(Türkiye Elektrik İletişim A.Ş.)'a ait 6 yıllık puant (anlık en yüksek değer) güç verileri, puant gerçekleşen günlerde ki tüketilen enerji verileri kullanılmıştır. TEİAŞ verilerinden yararlanarak gelecek yıllara dair regresyon modeli ile tahminlemeler yapılmıştır (Şener, 2005).

Shenshu ve Zhaoying (2000), doğrusal olmayan zaman serileri tahmin modellerinde şekilleri sınıflandırmayı amaçlamışlardır. Bu tahmini gerçekleştirmek için YSA ve CNEAR modellerini kullanmışlardır. Modeli çözmek için Karmaşık doğrusal üstel otoregresif model kullanılmıştır (CNEAR). Deney sonuçları CNEAR modelinin güvenilir olduğunu ve Yapay Sinir Ağı yönteminin de benzer doğruluğa sahip olduğunu göstermiştir (Shenshu & Zhaoying, 2000).

Saravanakumar ve ark. (2012) bu çalışmada, alüminyum malzemesi akma, çekme ve uzama gibi 3 önemli mukavemet özelliklerini incelemiş, 3 parametrenin YSA ile tahminlemesine dayalı bir model kurmuşlardır. Hadde sıcaklığı, son tezgâhtan çıkan derece, bobin sıcaklığı ve karbon eş değeri girdileri kullanılarak tahminleme modeli oluşturulmuştur. 4 girdi ve 3 çıktılı yapıda oluşturulan YSA modeli tahminlerinin üretim sürelerini ve maliyetini düşürmede etkili bir yöntem olduğunu göstermiştir. Yapılan tahminler ölçülen değerler ile benzer olarak çıktığından dolayı modelin başarılı olduğu gösterilmiştir (Saravanakumar ve ark., 2012).

Hatipoğlu ve ark. (2013) bu çalışmada, galvanizleme işlemi sonucunda çinko kaplama kalınlığının tahminlemesi için YSA ile çalışmışlardır. Tahmin değerlerinin gerçek

verilerle olan uygunluğu için hipotez testi kurulmuş kontrol edilen sonuçlarda herhangi bir negatif farklılık gözlemlenmemiştir. Galvanizleme sektöründe çinko tüketimi ekonomik açıdan oldukça büyük önem arz etmesi nedeniyle tam kararında kullanımı çok önemlidir. Çoklu regresyon modeli ile düşük performans ile çalışıldığı YSA'nın daha uygun olduğu görülmüştür (Hatipoğlu ve ark., 2013).

Bahadır yaptığı bu çalışmada (2013) , öğrencilerin lisans eğitimleri süresince belirli derslerden aldıkları geçme notları, genel not ortalamaları, üniversiteye giriş puanlarının yanı sıra akademik kariyer yapma hususundaki tutumlarını incelemiş ve bütün bu verileri tahmin modeli girdi verileri olarak kullanarak, öğrenci başarıları öngörülme çalışılmıştır. Akademik başarı tahmininde göreceli olarak yeni bir öngörü tekniği olan YSA yöntemi ile LRA (Lojistik Regresyon Analizi) yöntemleri karşılaştırılmıştır. Eğitim fakültesi öğrencilerinin üniversite mezuniyet dereceleri ve eğitim hayatındaki başarıları, derslerindeki sınavlardan aldıkları ders geçme notu, genel ortalamaları, ÖSYM (Öğrenci Seçme Yerleştirme Merkezi)'nin yaptığı sınav sonuçları gibi parametreleri kullanarak tahmin modeli oluşturulmuş bu modeller ile değerlendirme yaparak yorumlarda bulunmuştur (Bahadır, 2013).

Braun ve ark. (2014) iklim değişikliğinin binaların enerji tüketimini nasıl etkilediğini araştırmışlardır. Yapılan çoğu çalışmada ofis ve evlerde ki enerji tüketimini araştırılmasına rağmen bu çalışma İngiltere'nin kuzeyinde bulunan süpermarketlerin enerji tüketimini incelenerek iklimin süper marketlere olan etkilerini araştırmıştır. Elde edilen geçmişe dayalı verilerle geleceğe dönük çoklu regresyon modeli enerji tüketimleri tahmin edilmiştir (Braun ve ark., 2014).

Apronit ve ark. bu çalışmada (2016), trafik yoğunluğunu tahmin edebilecek maliyeti yüksek olmayan efektif iki model oluşturulmuştur. Bunlardan ilki lineer regresyon modeli; kaldırım tipi, karayollarına erişim, baskın arazi kullanım türleri ve nüfus ile trafik hacmini tahminlemek amacıyla geliştirilmiştir. Diğer modelle ise, lojistik regresyon modeli yollardaki trafik seviyesini beş aşama kullanarak belirlemektedir. Lojistik Regresyon modeli, trafik hacmi eşiklerini tahmin edip verilen seviye sonuçlarını doğru olarak sınıflandırılmış bunun sonucu olarak yolların trafik yoğunluk

yüzdelerini belirlemiştir. İki modelde iyi derecede ve az maliyetli olarak trafik yoğunluklarını tahmin etmektedir (Apronti ve ark., 2016).

Alan, bu çalışmasında (2013) geçmişte yapılmış farklı deneysel çalışmalara ait fosfor kapasitesi değerleri kullanılarak Yapay Sinir Ağı modelleri oluşturmuştur. YSA'dan elde edilen fosfor kapasitesi ile sistemin üç bileşenli faz diyagramının sıvı bölgesi için eş değer fosfor kapasitesi eğrilerinin çizilmesi hedeflenmiştir. Diğer modellerin sonuçlarına kıyasla deneysel verilere bakılarak YSA ile tahmin edilen fosfor kapasitesinin daha uyduğunu olduğu gözlemlenmiştir (Alan, 2013).

Syarif ve ark. bu çalışmada (2010), Ti-6Al-4V alaşımının mekanik özelliklerini tahmin etmek için ileri beslemeli geri yayımlı bir YSA sistemi oluşturmuşlardır. Ti-6Al-4V alaşımının temel mekanik özellikleri olan sertlik, çekme, akma ve uzama değerlerini mukavemet değerleri ısıl işlem adımının birer fonksiyonu olarak düşünmüştür. Gerilme oranı da bu girdi değerleri arasında kullanılmıştır. Normalleştirilmiş kök ortalama karelerinin hatası ve katsayı korelasyonu değerlerine bakılarak en uygun model seçilmiştir. Kullanılan iki yöntem olan Gradient Descent with Momentum ve Lavenberg Marquardt yöntemleri karşılaştırılmış, Lavenberg Marquardt tahminleri ağ için en uygun yöntem olduğu görülmüştür. Oluşturulan ağ için ara katman nöron sayısı da 25 olarak belirlenmiştir (Syarif ve ark., 2010).

Bapari ve ark. bu çalışmada (2007), CrMoV çeliğinin sıcak akış gerilmesini test etmek amacıyla sıkıştırma testi kullanmışlardır. Akış stresinin tahmininde basit doğrusal regresyon kullanılmıştır. Bu yöntem ile tahmin edilen sonuçların tahmin oranı düşük olarak görülmüştür. Bu nedenle daha iyi bir yöntem olarak düşünülen iki gizli katmanlı geri yayımlı momentum öğrenme süreci ile eğitilmiş YSA tahmin modeli oluşturulmuştur. Gerilme, gerilme oranı ve sıcaklık parametreleri 3 farklı girdi değeri olarak alınmış akış gerilmesi parametreleri de çıktı olarak kullanılmıştır. 3-9-10-1 yapısında ki YSA mimarisi en iyi tahminlemeyi yaptığı bu çalışma ile gösterilmiştir (Bapari ve ark., 2007).

Soundararajan ve ark. bu çalışmada (2016), Alüminyum katkılı kompozitleri üzerinde maliyet azaltıcı çalışmalarda bulunmuşlardır. Otomotiv sektöründe yoğun olarak kullanılan geniş bir uygulama alanına sahip olması nedeniyle de göz önünde olan alüminyum kompozit ürünleri üzerinde bir tahmin modeli kurulmuştur. Deney sonuçlarını tahmin etmek ve sıkıştırılmış A413 ve B4C kompozitlerinin belirlenmiş değişkenlerinin etkilerini ortaya çıkarmayı amaçlayan bu çalışmada mekanik özellikler için, farklı tasarımlardaki ağlar oluşturulmuştur. Oluşturulan ağ ileri beslemeli geri yayımlı YSA olmuştur. Model tahmin edilecek en optimum sonuçları göstermiştir, bu sayede test süresi ve maliyet azaltılmıştır, ortalama hata yüzdelerine bakılarak ağ yapısı oluşturulan 40 farklı Yapay Sinir Ağından en optimum sonuçları veren ağ seçilmiştir (Soundararajan ve ark., 2016).

Mashhadban ve ark. (2016), inşaat sektöründe yoğun olarak kullanılan elyafların kendini sıkıştıran betonun performansı arasındaki etkiyi araştırmışlardır. Yapılan bu çalışmada ise iki elyaf türü içeren dokuz beton karışım ve güçlendirilmemiş numuneler test edilip karşılaştırılmıştır. Kullanılan veriler yapılmış deneylerden elde edilen veriler olmuş olup ileri beslemeli YSA ile eğitilmiş, çelik liflerin, mekanik özelliklerle ilişkili olarak, polifenilen sülfür liflerine oranla daha yüksek bir performans gösterdiği gözlemlenmiştir (Mashhadban ve ark., 2016).

Araştırmalarda gözlemlenmiştir ki, değişkenler arasında bulunan ilişkiyi belirlemek için kullanılan tekniklerden biri de regresyon analizi tekniğidir. Çoğu bilim adamı YSA'nı daha iyi inceleyebilmek için, yapay sinir ağları ile regresyon modelleri arasındaki ilişkiyi konu alarak kıyaslama çalışmaları gerçekleştirmişlerdir. Doğrusal, doğrusal olmayan, basit, çoklu, parametrik, parametrik olmayan, lojistik, vb. gibi çok sayıda regresyon modeli bulunmaktadır (Tolon & Güneri Tosunoğlu, 2008).

Bu çalışmada incelenmiş modeller gibi yapay sinir ağları ve çoklu regresyon modelleri kullanılarak Alüminyum boyası parlaklık ve kaplama alanı değerleri tahmini gerçekleştirilerek karşılaştırması yapılmıştır.

BÖLÜM 3. TAHMİN YÖNTEMLERİ

3.1. Nitel Tahmin Yöntemleri

Verilere dayanarak bilimsel yöntemler yerine öznel, yargısal olarak yapılan tahminlerdir. Tahmin etme yöntemi bilimsel verilere dayanmadığı için tahmin performansı diğer tahmin yöntemlerine göre daha düşüktür (Olgun, 2009).

Bu yöntemin kullanılabilmesi için elde yeterli veri olmaması durumu ya da veriye sahip olup bu verileri analiz için gerekli süre olmaması durumları bulunmaktadır. Bu yöntemin en önemli özelliği, sezgisel yargıları da talep tahminine dâhil edebilmesidir. Talep tahminlerinde, matematik ve istatistiğe dayanan teknikler dışında öznel, bilimsellik derecesi daha az bazı metotlar da kullanılabilir.

3.1.1. Yönetici grubunun görüşlerini esas alan tahmin

Üretim, satış, satın alma ve idari yöneticiler de dâhil olmak üzere işletmenin üst basamaklarında bulunan görevliler, geçmiş deneylerini ve bilgilerini kullanırlar ve satışların plan dönemin tahminini birlikte yaparlar. Bu yöntem, yöneticilerin istatistiki bilgiler arasında bocalamalarını önler ise de satış tahmin sorumluluğunun çeşitli yöneticiler arasında paylaşılması durumunu ortaya çıkarır, fakat bu önemli görevin çok ciddi ve bilimsel yöntemlere dayandığını göstermemektedir (Tosun ve ark., 2019).

3.1.2. Kilit personelinin fikirleri

Talep tahmini mevcut bir kuruluşun yeni bir yatırım yapması durumlarında, bu kuruluşun satış başta olmak üzere mali birimler bölümlerinde bulunan deneyimli personelin fikirlerini dikkate alarak karar verdiği tekniktir.

Gerek yöneticilerin gerek deneyimli kilit personelin görüşlerinde yoruma bağlı olma durumu bulunduğu için talep tahmini yaparken bu tekniklere fazla güvenilmemektedir. Ancak bu tecrübeye dayanan tahmin yolları, matematiksel ve istatistiksel yöntemlerle bulunan sonuçları yorumlamada kullanılabilir (Tosun ve ark., 2019).

3.1.3. Anketler

Yeni kurulması planlanan veya mevcut olan yeni bir yatırım alanı veya hizmet üretecek işletmelerin kullandığı bir yöntem olarak; talebi direkt olarak tüketicilere veya hizmetten faydalanacak kişilere soru göndererek tahmin etmeye çalışan yöntemdir. Soru formlarının gönderildiği kişilerin veya işletmelerin tümünün cevap vermesi sağlanamasa dahi gelen cevaplar belli bir istatistiki yöntem ya da yöntemler ile analiz edilerek, genel bir talep tahmini yapılmaya çalışılır.

Anket yönteminin gelişmiş ülkelerde pazarlama araştırması yöntemleri içerisinde en çok kullanılanı olarak öne çıkmaktadır. Sık kullanılmış olmasına rağmen en az bilimsel olanıdır. Bu yöntemlerle elde edilen bilgilerin, yoruma bağlı ve güvenilir olamaması nedeniyle yapılan tahmine güven düzeyi düşük tutulması gerekmektedir. Soruları yöneltilen kişi veya kurumların istenen bilgileri vermeyişi veya vermek istemeyişi, yanlış aktarımı, bahsedilen yöntemin doğruluğunu azaltmaktadır. Ancak pazar araştırması için gerekli olan bilgileri sadece soru sorarak ve bunun toplu değerlendirmesini yaparak elde etme seçeneği, anket yöntemini çok yönlü ve sık kullanılan yöntemlerden biri haline getirmektedir.

3.2. Nicel Tahmin Yöntemleri

Bu yöntemler üç ana başlık altında incelenmiştir. Bu başlıklar aşağıdaki gibidir:

1. Nedensel Modeller
 - a. Regresyon
 - b. Çoklu Regresyon
2. Zaman Serileri Analizleri
 - a. Aritmetik Ortalama

- b. Hareketli Ortalama
 - c. Ağırlıklı Hareketli Ortalama
 - d. Üssel Düzeltme
 - e. Çift Üssel Düzeltme
3. Yapay Zekâ Tabanlı Yöntemler
- a. Genetik Algoritmalar
 - b. Bulanık Mantık
 - c. Parçacık Sürü Algoritması
 - d. Gri Sistem ve Gri Tahmin Yöntemi
 - e. Yapay Sinir Ağları

3.2.1. Nedensel modeller

Nedensel yöntemler, tahmin edilmek istenen etkeni, kendisini etkileyen faktörler ile ilişkilendirerek, tahminlerin bu faktörlerdeki değişmelere bağlı olarak yapılmasını amaçlayan yöntemlerdir. Talep ile talebi etkileyen faktörler arasında sebep-sonuç ilişkisi vardır. Nedensel yöntemlerde genellikle, bir değişkenin bir değeri tahmin etmesinin dışında, bu değişkeni etkileyen durumlar arasındaki ilişkinin açıklanmasına çalışılmaktadır. Bağımlı değişken ile ilişkisi olan değişkenlerin belirlenmesi ve bu ilişkinin bir matematiksel modelinin bulunması amaçlanmaktadır.

Bu yöntemler arasında en çok tercih edilenleri, regresyon analizi ve korelasyon analizidir.

3.2.1.1. Regresyon analizi

Regresyon analizi bağımlı değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkiyi inceleyen bir yöntemdir. Eğer bağımsız değişken sayısı tek ise tek değişkenli regresyon analizi, birden fazla ise çok değişkenli (çoklu) regresyon analizi olarak adlandırılır.

Regresyon yönteminde çıktı Y, sistem girdileri ile X1, X2, ..., Xn parametreleri arasındaki ilişki incelenir. Burada Y bağımlı değişken iken X1, X2, ..., Xn ise bağımsız değişkenlerdir. Bu bağımsız ve bağımlı değişkenler arasındaki ilişki doğrusal veya eğrisel olabilmektedir. Bağımsız değişkenler seçilip, veriye dayanarak bağımlı değişken ile bağlantılarını açıklayan matematiksel model geliştirilir ve bu model ele alınan bağımlı değişkenin tahmini değerini bulmak için kullanılır.

Regresyon analizin en önemli özelliği, bu yöntemle geliştirilen modelin kurumun karar mekanizmasına (yöneticilerine) çeşitli birden çok durum etkenlerinin sonuç üzerinde değerlendirme yapma olanağı sağlamasıdır. Bu nedenle regresyon analizi çoğu firmada kullanılmaktadır.

Tek değişkenli regresyon analizi: Tek değişkenli regresyon analizi bir bağımlı değişken ve bir bağımsız değişken arasındaki ilişkiyi inceler. Bu regresyon analizinde bağımlı ile bağımsız değişken arasında doğrusal bir ilişki vardır.

Örneğin bir hastanenin ilk yardım bölümüne gelen hasta sayılarının aylara göre dağılımı görülmektedir. Regresyon tekniğini kullanarak talep tahminlerini belirlemek için Tablo 3.1.'de gösterilen hesaplamalar yapılmaktadır.

Tablo 3.1. Regresyon örneği çözümü

Aylar	(X _i)	Hasta Sayısı (y _i)	X _i ²	X _i y _i
Ocak	1	328	1	328
Şubat	2	310	4	620
Mart	3	355	9	1065
Nisan	4	362	16	1448
Mayıs	5	375	25	1875
Haziran	6	380	36	2280
Temmuz	7	408	49	2856
Ağustos	8	415	64	3320
Eylül	9	417	81	3753
Ekim	10	412	100	4120
Kasım	11	429	121	4719
Aralık	12	434	144	5208
TOPLAM	78	4625	650	31592

$$b = \frac{12(31592) - (78)(4625)}{12(650) - 78^2} \quad (3.1)$$

$$b = 10,7 \quad (3.2)$$

$$a = 10,7 \frac{78}{12} \quad (3.3)$$

$$a = 315,9 \quad (3.4)$$

Denklem (3.1) ,(3.2), (3.3), (3.4) de hesaplanan katsayılar doğru denkleminde yerine ($Y=a+bX$) yerine konursa;

$F_t = 315.9 + 10.7X$ biçimindeki sayısal tahmin modeli kurulmuş olur.

Örnek olarak Haziran ayındaki hasta sayısını tahmin için bu denklemi kullandığımızda;

$F_t = 315.9 + 10.7 (6) = 380.1$ değerini elde ederiz.

3.2.1.2. Çoklu regresyon analizi

Basit regresyon analizinde bağımlı ve bağımsız değişken arasındaki ilişkiler analiz edilmektedir. Bazı analizlerde; incelenen bir bağımlı değişkeni birçok bağımsız değişken etkileyebilir. Bir bağımlı değişkeni birçok bağımsız değişkenin etkileme durumlarında ise çoklu regresyon modeli ile analiz yapılması gerekmektedir (Okutan, 2014) .

Tek değişkenli regresyon modelinin formülasyonu (Denklem 3.5) gibidir:

$$Y_i = \beta_0 + \beta_1 X_i + \epsilon_i \quad i= 0,1,\dots n \quad (3.5)$$

Birden çok bağımsız değişken içeren bir model kullanıldığında formülasyonu (Denklem 3.6) gibidir:

$$y = \alpha + \beta_1 X_1 + \beta_2 X_2 + \epsilon \quad (3.6)$$

Bağımsız değişkeni belirlerken değişkenlerin arasında en yüksek korelasyona sahip bağımsız değişkenlerden sadece birisinin seçilmesi yoluna gidilmelidir. Çoklu regresyon analizinde değişkenlerden sadece biri seçilmelidir. Bunun için de analize başlamadan bütün değişkenlerin korelasyon matrisine bakıp aralarında yüksek korelasyon alanlardan biri tercih edilmesi gerekmektedir. Çoklu regresyonda bazen hangi bağımsız değişkenin daha etkili olduğunu ve bağımlı değişkeni daha çok etkilediğini bilmek gerekir. Bunun için önce korelasyonlara bakılır. Yüksek korelasyon, parametreler arasındaki daha güçlü ilişkiyi gösterir (Okutan, 2014).

Regresyon testinin kullanılabilmesi için gerekli adımlar şu şekilde sıralanabilir (Ersöz & Ersöz, 2015);

1. Bağımlı ve bağımsız değişkenler arasında doğrusal bir ilişki olmalıdır.
2. Bağımsız değişkenlerin birbiriyle ilişkili olmaması gerekmektedir (çoklu bağıntı- Multicollinearity).
3. Hata terimlerinin normal dağılması (Normallik- Normality).
4. Hata terimlerinin varyansının sabit olması (Otokorelasyon- Autocorrelation).

Çoklu bağıntı; bağımsız değişkenler arasında güçlü bir ilişki olmasına denir. "Collinearity Statistics" değerine bakıldığında yüksek tolerans ve düşük VIF değeri bağımsız değişkenler arasında çoklu bağıntı olmadığını gösterir. Tolerans değerinin 0,05 'den küçük olması, VIF değerinin 10'dan büyük olması, 0'a yakın olması çoklu bağıntı olduğunun göstergesidir (Ersöz & Ersöz, 2015).

Durbin Watson katsayısı oto korelasyonu test eder. Değer 0 ile 4 arasında değişir. 0'a yakın değerler pozitif korelasyonu, 4'e yakın değerler negatif korelasyonu, 2'ye yakın değerler otokorelasyon olmadığını gösterir (Ersöz & Ersöz, 2015).

Çoklu regresyon metotları dört adettir (Okutan, 2014).

1. Enter Metodu: Bağımsız değişkenlerin bir küme olarak tek seferde girilip değerlendirildiği methodudur.

2. İleri Doğru Seçim Metodu (Forward Selection): Bağımlı değişken ile en yüksek korelasyona sahip bağımsız değişken seçilir. Daha sonra girilen değişkenin katsayısının 0 olduğu hipotezi F testi ile belirlenir.
3. Geriye Doğru Eleme (Backward Elimination) Metodu: İleri doğru seçimin aksine, burada önce bütün bağımsız değişkenler seçilir; sonra sırasıyla mevcut ölçütlere göre eleme yapılır.
4. Adım Adım Seçme (Stepwise Selection) Metodu: Öncelikli olarak bağımsız değişken seçimi yapılır; eğer bu ileri doğru seçmedeki FIN veya PIN gereklerini yerine getirirse ikinci değişken seçilir; yoksa işlem orada biter. İkinci değişken olarak en yüksek kısmi korelasyona sahip değişken alınır. Seçimler yüksek korelasyon değerinden düşüğe doğru yapılır.

3.2.2. Zaman serileri yöntemleri

Eşit zaman aralıkları bulunan serilere zaman serileri denilmektedir. Zaman Serileri Yöntemleri ilerleyen 5 alt bölümde belirtilen yöntemleri içermektedir.

3.2.2.1. Aritmetik ortalama yöntemi

Geleceğe en direkt bakış geleceğin, geçmişteki verilerin ortalamasına doğru eğilim göstereceğini varsaymaktadır. Bu varsayımına göre geleceğin en geçerli tahmini, geçmişte olup bitenlerin toplanıp ortalamasını alarak gerçekleştirmektir. Formülü (Denklem 3.7)'de verilmiştir.

$$AO = \frac{\sum_{t=1}^n y_t}{n} \quad (3.7)$$

Örneğin bir üretim tesisinde son 8 ay içinde kayıt altına alınmış her aylık motor arızaları aşağıdaki gibidir. Aritmetik ortalama tekniğini kullanarak her ayın talep tahminini ve 9. Ay talep tahminini belirlemek için Tablo 3.2.'deki işlemler sıralaması ile gerçekleştirilmesi gerekmektedir.

Tablo 3.2. Aritmetik ortalama ile tahmin örneği

Ay (t)	Gerçekleşen Arıza (y _t)	Tahmin (F _t)
1	200	----
2	250	200 = (200) / 1
3	175	225 = (200+250) / 2
4	186	208.33 = (200+250+175) / 3
5	225	202.75 = (200+250+175+186) / 4
6	285	207.20 = (200+250+175+186+225) / 5
7	305	190.17 = (200+250+175+186+225+285) / 6
8	190	232.29 = (200+250+175+186+225+285+305) / 7
9		227 = (200+250+175+186+225+285+305+190) / 8

F9 değeri bu yolla 227 olarak elde edilmektedir.

3.2.2.2. Hareketli ortalama yöntemi

Yaygın olarak kullanılan bir tahmin yöntemidir. Hareketli ortalama yöntemi, uzak geçmişten çok, yakın geçmişe ağırlık vererek, yalnızca bir sonraki tek dönemin tahminini yapar. Örneğin geçmiş tarihi dönem verilerinin belirlenen sayıdaki örneği alınarak, en son gerçekleşen dönem bunlara ilave edilir. Daha sonra, bu verilerin ortalaması, bir sonraki dönem tahmin miktarı olarak kabul edilir. Formülü (Denklemler 3.8)'de verilmiştir.

$$HO(n) = \frac{y_t + y_{t-1} + \dots + y_{t-n+1}}{n} \quad (3.8)$$

Örneğin bir üretim tesisinde son 8 ay içinde kayıt altına alınmış her aylık motor arızaları aşağıdaki gibidir. Üçerli hareketli ortalama yöntemini kullanarak arıza tahmini Tablo 3.3.'teki gibi gerçekleştirilebilmektedir (n=3).

Tablo 3.3. Hareketli ortalama ile tahmin örneği

Ay (t)	Gerçekleşen Arıza (y_t)	Tahmin (F_t)
1	200	----
2	250	----
3	175	----
4	186	208.33 = (200+250+175) / 3
5	225	203.66 = (250+175+186) / 3
6	285	195.33 = (175+186+225) / 3
7	305	232 = (186+225+285) / 3
8	190	271.66 = (225+285+305) / 3
9		260 = (285+305+190) / 3

$HO(3) = 260$ Olarak elde edilmektedir.

3.2.2.3. Ağırlıklı hareketli ortalama yöntemi

Hareketli ortalama yönteminin sakıncalarından birisi bazı durumlarda son dönemin bir sonraki dönemi daha fazla etkilediği durumu göz ardı etmesidir. Bu negatif durum ağırlıklı hareketli ortalama yöntemi kullanılarak giderilebilir. Bu yöntemde en yakın veriye en büyük ağırlık verilir. Formülü (Denklem 3.9)'de verilmiştir.

$$AHO(N) = w_1 y_t + w_2 y_{t-1} + \dots + w_n y_{t-n+1} \quad (3.10)$$

w: Ağırlık katsayıdır.

Örneğin bir x firmasının yetkilisi her hafta sonu talep tahmini istemektedir. Aşağıdaki Tablo 3.4.'de şirketin satış adetlerini görülmektedir. Ağırlıklı Hareketli Ortalama tekniğini kullanarak her haftanın talep tahminini ve 10.hafta talep tahmini Tablo 3.4.'te hesaplanarak verilmektedir.

$$(n=4, w_1=0,4 w_2=0,3 w_3=0,2 w_4=0,1)$$

Tablo 3.4. Ağırlıklı hareketli ortalama örneği

Hafta (t)	Gerçekleşen Satış (y _t)	Tahmin (F _t)
1	110	----
2	102	----
3	108	----
4	121	----
5	112	112.2 = 0.4(121) + 0.3(108) + 0.2(102) + 0.1(110)
6	105	113.9 = 0.4(112) + 0.3(121) + 0.2(108) + 0.1(102)
7	114	110.6 = 0.4(105) + 0.3(112) + 0.2(121) + 0.1(108)
8	106	111.6 = 0.4(114) + 0.3(105) + 0.2(112) + 0.1(121)
9	115	108.8 = 0.4(106) + 0.3(114) + 0.2(105) + 0.1(112)
10	----	111.1 = 0.4(115) + 0.3(106) + 0.2(114) + 0.1(105)

AHO(4) = 111.1 Olarak elde edilmektedir

3.2.2.4. Üstel düzgünleştirme yöntemi

Üstel düzleştirme yöntemi, verilerdeki son farklılıkların ve sıçramaları dikkate alarak tahminlerin ya da öngörülerin sürekli güncellendiği bir yöntemdir.

Üstel düzleştirme yönteminde gelecek dönemin (T+1 döneminin) tahminin hesabında son döneme ait tahmin ile bu tahmininden gelen hatanın bir kısmını içererek çalışmaktadır.

Bu ifade (Denklem 3.11) ile gösterilebilir.

$$Z_{T+1} = Z_T + \alpha(e_t) \quad (3.11)$$

α : Düzleştirme katsayısıdır.

Tablo 3.5. Üstel düzgünleştirme yöntemi örneği

Hafta (t)	Gerçekleşen Satış (y _t)	Tahmin (F _t)
1	110	110
2	102	110.0 = 110.0 + 0.2 (110-110.0)
3	108	108.4 = 110.0 + 0.2 (102-110.0)
4	121	108.3 = 108.4 + 0.2 (108-108.4)
5	112	110.8 = 108.3 + 0.2 (121-108.3)
6	105	111.0 = 110.8 + 0.2 (112-110.8)
7	114	109.8 = 111.0 + 0.2 (105-111.0)
8	106	110.6 = 109.8 + 0.2 (114-109.8)
9	115	109.7 = 110.6 + 0.2 (106-110.6)
10	----	110.8 = 109.7 + 0.2 (115-109.7)

Tablo 3.5.'te gerçekleşen satış verilerinden yola çıkarak üstel düzeltme yöntemi ile bir sonraki dönem tahmini gösterilmiştir.

3.2.2.5. Çift üstel düzeltme yöntemi

Diğer bir adıyla Holt metodu, zaman serilerinin, doğrusal eğilim ile izlenmesi için tasarlanmış bir yöntemdir.

Yöntem α (seri için) ve β (trend için) olmak üzere iki düzeltme katsayısının belirlenmesini gerektirir. Bu metot için (3.12) ve (3.13)deki eşitlikler kullanılır.

$$S_t = \alpha D_t + (1 - \alpha)(S_{t-1} + G_{t-1}) \quad (3.12)$$

$$G_t = \beta(S_t + S_{t-1}) + (1 - \beta)G_{t-1} \quad (3.13)$$

T adım sonrasındaki eşitlik için (Denklem 3.14) elde edilir.

$$F_{t,t+1} = S_t + G_t \quad (3.14)$$

Örnek olarak yine motor arızası verileri temel alınmış ve Tablo 3.6.'da Holt metodu ile çözümü açıklanmıştır. $S_0=200$ ve $G_0=10$ alınmıştır.

2. Dönemden 5.ci dönemi tahmin için formülasyonu (Denklem 3.15) gibi elde edilmektedir.

$$F_{2,5} = S_2 + 3 * G_3 = 222,01 + (3) * (10,211) = 252,643 \quad (3.15)$$

Tablo 3.6. Çift üstel düzeltme yöntemi örneği

$S1 = 0,1 * 200 + 0,9 * (200 + 10) = 209$
$G1 = 0,1 * (209 - 200) + 0,9 * 10 = 9,9$
$S2 = 0,1 * 250 + 0,9 * (209 + 9,9) = 222,01$
$G2 = 0,1 * (222,01 - 209) + 0,9 * 9,9 = 10,211$
$S3 = 0,1 * 175 + 0,9 * (222,01 + 10,211) = 226,499$
$G3 = 0,1 * (226,499 - 222,01) + 0,9 * 10,211 = 9,639$
$S4 = 0,1 * 186 + 0,9 * (226,499 + 9,639) = 231,124$
$G4 = 0,1 * (231,124 - 226,499) + 0,9 * 9,639 = 9,137$
$S5 = 0,1 * 225 + 0,9 * (231,124 + 9,137) = 238,735$
$G5 = 0,1 * (238,735 - 231,124) + 0,9 * 9,137 = 8,985$
$S6 = 0,1 * 285 + 0,9 * (238,735 + 8,985) = 251,448$
$G6 = 0,1 * (251,448 - 238,735) + 0,9 * 8,985 = 9,358$
$S7 = 0,1 * 305 + 0,9 * (251,448 + 9,358) = 265,225$
$G7 = 0,1 * (265,225 - 251,448) + 0,9 * 9,358 = 9,800$
$S8 = 0,1 * 190 + 0,9 * (265,225 + 9,800) = 266,522$
$G8 = 0,1 * (266,522 - 265,225) + 0,9 * 9,800 = 8,949$

3.2.3. Yapay zekâ tabanlı yöntemler

Yapay Zekâ tabanlı modeller ana konumuzu da barındıran yöntemlerden YSA içermektedir. İlerleyen alt başlıklarda bu modellerden bahsedilecektir.

3.2.3.1. Bulanık mantık

Bulanık mantık kavramı ilk kez 1965 yılında ortaya atılmıştır. Zadeh tarafından yapılan arařtırmalar sonucunda Bulanık mantık yöntemi bulunmuřtur. Bu arařtırmalarda, girdi deęerlerinin farklı kümelerdeki farklı üyelik derecelerinden ve girdinin çıktıya dönüşümünün bu kümeler aracılığıyla yapılabileceğinden bahsetmiştir. Bu yöntem özellikle deneyimlere dayalı verilerin ya da sayısal olarak ifade edilemeyen verilerin yorumlanmasında yaygın olarak kullanılmaktadır (Yazıcıođlu, 2010).

Bulanık küme, farklı üyelik derecesine sahip öğelerin olduđu bir kümedir. Bulanık küme, klasik küme teorisindeki evet-hayır kümelerinin ikisinde ait olana iki veya ikiden fazla kısmi üyelik içeren kavrama çevirmek anlamına gelmektedir.

Bir kavramı anlatan, bir amacı aktaran veya bir sistemi tanıtan ifadelerdeki belirsizliđi veya kesin olmama haline bulanıklık denmektedir. İnsanların zihinsel algılama farklılıkları, onların öznel davranışları, ifade ve amaçlarındaki belirsizlikler bulanıklık kavramı ile açıklanabilmektedir (Aikeshan, 2014).

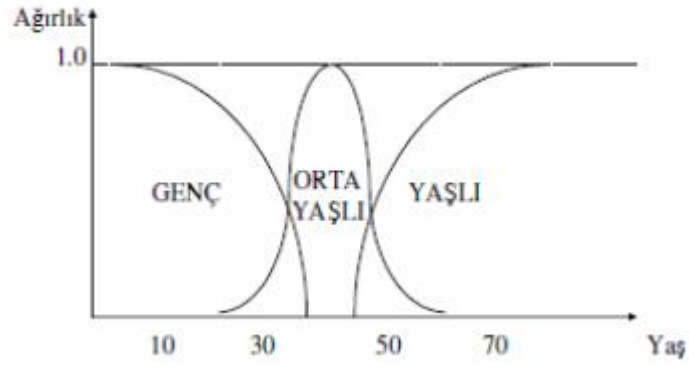
Bulanık mantığın özellikleri ařağıdaki gibidir:

1. Bulanık mantık, kesin deęerlere dayanan düşünmenin aksine, yaklaşık düşünme tekniđi kullanır.
2. Bulanık mantıkta bilgi dilsel ifadeler (fazla, az, büyük, küçük vb.) şeklindedir.
3. Bulanık mantıkta her şey $[0,1]$ Aralığında belirli bir derece ile gösterilir.
4. Bulanık çıkarım işlemi, dilsel ifadelerin birbirleri arasında tanımlanan kurallar ile gerçekleşir.
5. Mantıksal olan tüm sistemler, bulanık olarak ifade edilir.
6. Bulanık mantık, matematiksel modellerle elde edilmesi zor olan sistemler için oldukça uygundur.

Bulanıklaştırma işlemi, sistemden alınan giriş verileri dilsel niteleyiciler olan sembolik deęerlere dönüřtürme işlemine denmektedir. Üyelik işlevinden yararlanılarak giriş

bilgilerinin ait olduğu bulanık küme/kümeler ve üyelik derecesi tespit edilerek girilen değerler küçük, en küçük gibi dilsel değişkenler olarak atanmaktadır. Bulanıklaştırma, çözülecek problemle ilgili bulanık önerme değişkenlerinin ve karar verme kurallarının belirlenmesi ve üyelik fonksiyonunun oluşturulması işleminin adıdır. Netleştirme işlemi; bulunan çözüm alanından tek bir değer elde edilmesi işlemine denmektedir. Netleştirme yöntemlerinden bir tanesi kullanılarak kesin değer belirlenir. (Aikeshan, 2014)

Şekilde 2.7.'de Yaşlara göre niteliklendirme konusu bulanık mantık çerçevesinde belirlenen bir grafik ile belirtilmiştir.



Şekil 2.7. Bulanık mantık netleştirme grafiği

Örneğin 35 yaşındaki birine orta yaşlı denemeyeceği gibi, o kişi genç de sayılmaz, duruma göre belki genç tanımı, belki de orta yaşlı tanımı daha uygun düşer. Kümelerin birbirlerinden keskin çizgilerle ayrılmamış olması, aralarında belirli bir örtüşüm olması, 35 yaşın bir oranda hem orta yaşlı hem genç olarak düşünülmesine olanak tanır.

3.2.3.2. Genetik algoritma

Genetik algoritmalar (GA) günlük hayatta karşılaştığımız çözümü olanaksız ya da çok zor olan karmaşık problemlerin hesaplanmasında kullanılmaktadır. Genetik algoritmalar, doğal seçim ilkelerine dayanan bir arama ve en uygun şekle sokma

yöntemi olarak ifade edilmektedir. Geleneksel optimizasyon yöntemlerine göre genetik algoritmalar daha farklı bir yöntem olup, parametre kümesini değil, kodlanmış biçimlerini kullanır. Genetik algoritmalar; fonksiyon optimizasyonu, tasarım, çizelgeleme, makine öğrenmesi, hücresel üretim gibi alanlarda başarılı bir şekilde kullanılmaktadır.

Genetik algoritmalar alt dizi ile arama yapmaktadırlar. Alt diziler, genetik algoritmaların davranışlarını açıklayan teorik yapı taşlarıdır. Bir alt dizi, belirli dizi kümeleri arasındaki benzerliği tanımlar. Alt dizilerin iki özelliği vardır Bunlar; alt dizi derecesi ve uzunluğudur. Alt dizi derecesi, mevcut alt dizi kalıbında bulunan sabit konumların sayısına denmektedir. Alt dizi uzunluğu ise; mevcut alt dizi kalıbında bulunan belirli ilk ve son konumlar arasındaki uzaklığa denmektedir. Alt dizi derecesi ve alt dizi uzunluğu kavramları genetik algoritma teoreminde önemli bir yere sahiptir (Kubat, 2012).

Genetik algoritmalar, bir çözüm uzayındaki her noktayı kromozom adı verilen ikili bit dizisi ile kodlamaktadır. Her noktanın bir uygunluk değeri bulunmaktadır. Tek bir nokta yerine genetik algoritmalar bir nüfus olarak noktalar kümesini muhafaza etmektedir. Her kuşakta genetik algoritma, çaprazlama ve mutasyon gibi genetik faktörleri kullanarak yeni bir varlık oluşturur (Emel, 2002).

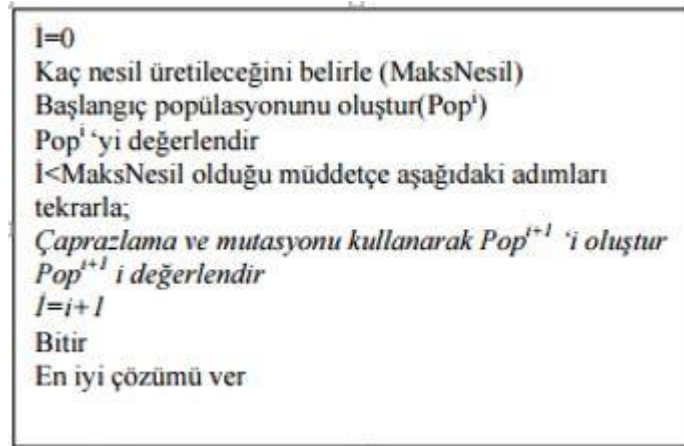
Genetik algoritmanın işlem adımları aşağıdaki gibidir:

1. Arama uzayındaki tüm mümkün çözümler dizi olarak kodlanır.
2. Genellikle rastsal bir çözüm kümesi seçilir ve başlangıç popülasyonu olarak kabul edilir.
3. Her bir dizi için bir uygunluk değeri hesaplanır, bulunan uygunluk değerleri dizilerin çözüm kalitesini gösterir.
4. Bir grup dizi belirli bir olasılık değerine göre rastsal olarak seçilip çoğalma işlemi gerçekleştirilir.
5. Yeni bireylerin uygunluk değerleri hesaplanarak, çaprazlama ve mutasyon işlemlerine tabi tutulur.

6. Önceden belirlenen kuşak sayısı boyunca yukarıdaki işlemler devam ettirilir.
7. İterasyon, belirlenen kuşak sayısına ulaşıncaya kadar devam ettirilir. Amaç fonksiyonuna göre en uygun olan dizi seçilir. Genetik algoritma tabanlı yaklaşım kullanılarak veri yığınlarından modeller elde edilmektedir. Talep tahmininin bulunmasında yararlanılan bir yöntemdir.

Örnek olarak ele alınan bu çalışmada Türkiye'nin Elektrik Enerjisi Tüketimi tahmini yapılmıştır. 2020 yılına kadar ihtiyaç duyulacağı tahmin edilen net Elektrik Enerjisi Tüketimi Genetik Algoritma yaklaşımı kullanılarak bulunmaya çalışılmıştır. Ekonomik göstergelere dayalı GAETM_Lineer ve GAETM_Karesel isimli iki farklı model geliştirilmiştir. Geliştirilen modellerde kullanılan ekonomik birimler: Gayri Safi Yurt İçi Hâsıla, Nüfus, İthalat ve İhracattır. Geliştirilen modellerin uygunluğu ise tahmin edilen veriler ile 1979 ile 2009 yılları arasındaki gerçek değerlerle gösterildikten sonra farklı çalışmalarla karşılaştırılmıştır. Sonuçlara bakarak geliştirilen modellerin Türkiye'nin gelecekteki Elektrik Enerjisi ihtiyacını tahmin etmek için uygun ve geçerli olduğunu sonucu elde edilmiştir (Vecihi, June 2011).

Şekil 3.1.'de çalışmada kurulan genetik algoritmanın genel akış mantığı kodlama yoluyla ifade edilmiştir.



Şekil 3.1. Genetik algoritma çalışma mantığı

3.2.3.3. Gri sistem ve gri tahmin yöntemi

Olasılık ve istatistik, bulanık mantık ve gri sistemler belirsiz sistemlerin araştırılmasında en çok tercih edilen araştırma yöntemleridir. Bulanık mantık belirsizliğin olduğu problemlerin üzerinde durur. Yani araştırma konuları açık olmayan bir kapsama sahiptir. Örneğin “Genç Adam” tabiri bulanık bir kavramdır. Çünkü genç tabirinin açık bir ifadesi yoktur ve genç tabiri kişiden kişiye değişen bir kavramdır. Bu tür bilişsel kesinliğin olmadığı problemlerde kişilerin tecrübesi ve üyelik fonksiyonları sayesinde problemler ele alınır.

Olasılık ve istatistik stokastik belirsizliğin olduğu görüngülerin üzerinde çalışır. Gerçekleşecek olayda stokastik belirsizlik olan her bir olası çıktının olasılığı araştırılır. Başlama noktası geniş örneklerin olduğu ve bu örneklerin tipik bir dağılım gösterdiği hazır olduğu zamandır.

Bulanık matematiğin ve olasılığın çözüm yapmasının zor olduğu, küçük örneklerin ve bilginin az olduğu belirsizliklerin olduğu durumlarda Gri Sistem devreye girer (Boltürk, 2013).

3.2.3.4. Yapay sinir ağları

Yapay Sinir Ağları (YSA), insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetip oluşturabilme ve keşfedebilme gibi yetenekleri, herhangi ekstra bir dış etkenden beslenmeden otomatik olarak gerçekleştirebilmek amacı ile geliştirilen bilgisayar sistemleridir (Öztemel, 2003) .

Doğayı araştırıp taklit ederek yöntemler geliştiren insanoğlunun en son ürünlerinden biri olarak Yapay Sinir Ağları teknolojisi bulunarak basit biyolojik sinir hücrelerinin simüle edilme hedefi amaç edinilerek geliştirilmiştir (Kubat, 2012).

Tanım 1: Yapay Sinir Ağları, en basit şekilde, bir örnekler kümesi yardımıyla parametrelerin uyarlanabilmesini sağlayacak bir matematiksel formül için yazılan

program olarak tanımlanabilir. Bu tanım, YSA'yı en basit şekilde ve teknik detaya girilmeksizin ifade etmektedir.

Tanım 2: Yine basit ama daha teknik ikinci bir tanım ise şu şekildedir: YSA, ilgili bağlantı ağırlıklarıyla (synaptic wheights) bir ağa bağlanmış basit işlem elemanlarından (nöron) oluşan bir sistemdir.

Tanım 3: Bir YSA, birbirlerine muvazi olarak çalışan birçok basit işlem elemanı ve fonksiyonunu içeren, ağı yapısı, bağlantı ağırlıkları ve elemanlarda gerçekleştirilen işlemler tarafından belirlenen bir sistemdir.

Tanım 4: Daha kapsamlı ve genel kabul gören bir tanım ise: "Bir sinir ağı, basit işlem birimlerinden oluşan, deneysel bilgileri biriktirmeye yönelik doğal bir eğilimi olan ve bunların kullanılmasın sağlayan yoğun şekilde paralel dağıtılmış bir işlemcidir. Bu işlemci iki şekilde beyin ile benzerlik göstermektedir (Haykin, 1999).

1. Bilgi, ağ tarafından bir öğrenme süreciyle çevreden elde edilir.
2. Elde edilen bilgileri biriktirmek için sinaptik ağırlıklar olarak da bilinen nöronlar arası bağlantı güçleri kullanılır (Haykin, 1994).

Yapay Sinir Ağları; insan beyninin öğrenmesi temel alınarak, öğrenme sürecinin matematiksel olarak modellenmesi çalışmaları sonucu ortaya çıkmıştır. Bu nedenle bu konudaki araştırmalara başlanırken beyni oluşturan biyolojik yapılar olan nöronların modellenmesi ve bunların basit yapılarda bilgisayar sistemlerinde uygulanması ile başlamış, daha sonraları bilgisayar sistemlerinin gelişimine muvazi olarak birçok alanda kullanılır hale gelmiştir.

İnsan beyninin çalışma prensibini taklit ederek çalışan bu sistemler, her ne kadar bilgisayar teknolojisi hızlı bir gelişim göstermiş, işlem hızları nano saniyeler civarına inmiş olsa dahi, insan beyninin taklit edilmesi şöyle dursun, ilkel bir canlı beyninin fonksiyonları dahi temel alındığında, böyle bir organizmanın yanında çok ilkel kalmaktadır. Nano saniyeler bazındaki işlem hızları ile YSA'lar, mili saniyeler

mertebesindeki işlem hızları ile işlem yapan insan beyninin işlevselliğinin henüz çok uzağındadır.

YSA'nın insan beynine kıyasla nerede olduğunu görmek amacıyla belirtilmektedir ki insan beyninde yaklaşık 10^{11} sinir hücresi bulunmakta iken bu sayıda bağıntının bilgisayar ortamında modellenmesi henüz mümkün görünmemektedir. Karar hızı açısından da insan beyni ile henüz yarışmasalar bile, YSA'lar yapısallıkları ve hassas eşleştirmelerin başarı ile gerçekleştirebilmeleri ile gün geçtikçe daha fazla alanda uygulama bulmaktadır.

Bilim adamları, araştırmacılar insanlık tarihi boyunca insan beyninin nasıl çalıştığını merak etmiştir. Bu merakın bir neticesi olarak doğan bilgisayarlar ilk hesap makinelerinden bu yana gelişerek karşımızı çıkmaktadır. Gelişmelere bakarak gelecekte daha karmaşık sistemlerin çıkacağı da rahatlıkla kestirilebilmektedir. Bilgisayarlar başlangıçta sadece aritmetik işlemler yapmak amacı ile geliştirilmiş iken, bugün olayları öğrenme ve çevre şartlarına göre karar vermeleri istenmektedir bu durum bilgisayar gelişimini gelecekte de önemli bilim dallarından birisi olarak bize sunacaktır.

Yapay Sinir Ağları ilgili çalışmaları 1970 öncesi ve sonrası olarak ikiye ayırmak gerekecektir. Çünkü 1970 yılında bu bilimin tarihinde dönüm noktası olmuştur. O zamana kadar olmaz diye düşünülen birçok sorun çözülmüş ve yeni gelişmeler başlamış her şey YSA için yeniden doğmuştur (Öztemel, 2003).

İnsan beyninin nasıl çalıştığı ve fonksiyonları uzun yıllar araştırılmıştır. 1890 yılında beynin fonksiyonları hakkında bilgi veren ilk eser yayınlanmıştır. (James, 1890). 1940'dan önceki yıllarda bazı bilim adamlarının (Helmholtz, Pavlov, Poincare vb.) yapay sinir ağı kavramı üzerinde çalışmışlardır. Fakat bu çalışmaların mühendislik değeri olduğu oldukça düşüktür.

1940'li yıllardan sonra Hebb, McCulloch ve Pitts gibi bilim adamları yapılan araştırmaları mühendislik alanlarına kaydırmaya başladılar böylece günümüzdeki

YSA'nın temelleri atılmaya başlamıştır. İlk yapay sinir hücresinin yapısını oluşturduklarında bununla yapay sinir hücreleri ile her türlü mantıksal matematiksel ifadeyi ifade etmenin mümkün olduğunu gösterilmiş oldu. Hücrelerin birbirleri ile müvazi çalışması gerektiği fikrini ortaya atarak öğrenme kurallarını belirlemeye başladılar 1949 yılında Donald Hebb, yapay hücrelerden oluşan bir yapay sinir ağının değerini değiştiren bir öğrenme kuralı geliştirdi (Hebb, 1949). "Hebbian öğrenme" kuralı denilen bu kural günümüzde de birçok öğrenme kuralının temelini oluşturmaktadır.

Çalışmaların 1969 yılında sekteye uğraması ve gerekli finansal desteklerin kesilmesine rağmen bazı bilim adamları çalışmalarına devam etmiştir Bunlar Amar Anderson, Cooper, Fukushima, Grossberg, Kohonen ve Hopfield gibi araştırmacılarıdır. Bu araştırmacıların çalışmaları 1980'li yıllara gelindiğinde sonuçlarını göstermeye başlamıştır ve YSA çalışmalarındaki bu şekilde tekrar hararet kazanarak devam etmiştir.

1972'de farklı disiplinlerde çalışan elektrik mühendisi Kohonen ve nöropsikolojist Anderson çağrışimli bellek (associative memory) konusunda hemen hemen birbirinin aynı çalışmalar yayınladılar. Bu çalışmalar daha sonraları geliştirilecek olan öğretmensiz öğrenme kuralının temeli oldu. Kohonen daha sonra 1982 yılında "kendi kendine öğrenme nitelik haritaları (self organizing feature maps- SOM) konusundaki çalışmasını yayınladı. 1960'li yılların sonlarına doğru sahneye çıkan Grossberg YSA'nın psikolojik mantıksallığı ve mühendislik uygulamalarındaki kolaylığını gösterdi; Carpenter ile Adaptif Rezonans Teorisini (ART) geliştirdi. Bu öğretmensiz öğrenme konusunda zamanının geliştirilmiş en karmaşık yapay sinir ağı oldu.

1970'lerin sonlarına doğru Fukushima görsel şekil ve örüntü tanıma amaçlı geliştirdiği NEOCOGNITRON modelini tanıttı. Bu model önceleri sadece öğretmensiz öğrenme yapıyorken daha sonra geliştirilerek öğretmenli öğrenme yapacak hale de getirilmiştir (Öztemel, 2003).

YSA'lar, uygulanan ağ modeline göre değişik karakteristik özellikler göstermelerine karşın temel birkaç ortak özelliğe sahiptirler (Çayıroğlu, 2017).

1. YSA'lar pek çok hücreden meydana gelir ve bu hücreler muvazi çalışarak karmaşık işlevleri yerine getirir. Süreç içerisinde bu hücrelerden herhangi biri işlevini yitirse dahi çalışmasına devam edebilen güvenli bir sistemdir.
2. Eğitim sürecinde kullanılan sayısal bilgilerden, problemin genel özellikleri elde etmesi ve böylelikle eğitim sırasında kullanılmayan girdiler için de, anlamlı yanıtlar üretebilmesidir.
3. Lineer olmayan problemlerin de çözümünü mümkün kılmaktadır.
4. YSA'lar makina öğrenmesi gerçekleştirebilirler bu sayede benzer olaylar karşısında mantıklı kararlar verebilirler.
5. Bilgi işleme yöntemlerinin geleneksel programlamadan farklı olmasından dolayı geleneksel programlamanın getirdiği birçok olumsuzluk ortadan kaldırılabılır.
6. Bilgiler ağın tamamında saklandığı için hücrelerden bazılarının işlevini yitirmesi, anlamlı bilginin kaybolmasına neden olmaz. Bu durum geleneksel programlamanın tersine bir durumdur. Geleneksel programlamada bir bilginin kaybolması bütünü etkileyebilmektedir.
7. Dağıtık belleğe sahiptirler. YSA'larda bilgi ağa dağılmış bir şekilde tutulur. Hücrelerin bağlantı ve ağırlık dereceleri, ağın bilgisini gösterir. Bu nedenle tek bir bağlantının kendi başına anlamı yoktur.
8. YSA örnekle öğrenen bir ağ yapısına sahiptir. YSA'nın öğrenebilmesi için örneklerin belirlenmesi, bu örneklerin ağa gösterilerek ağın eğitilmesi gerekmektedir. Ağın başarısı, seçilen örneklere bağlıdır eğer ağa olay bütün yönleri ile gösterilemezse ağ yanlış çıktılar üretebilir.
9. Örneklerle öğrenen YSA'lar daha önce yaşanmamış, öğretilmemiş durumlar hakkında bilgi üretebilir çünkü YSA'lar öğrendikleri bilgilerin genellemelerini çıkartarak öğrenme yapar.
10. Algılamaya yönelik durumlarda YSA'ların kullanımı geniştir. Bu alanda başarılı algılamaya yönelik uygulamalar yapmaktadırlar.
11. YSA'lar Örüntü ilişkilendirme ve sınıflandırma yaparak girdi olarak örnekler halinde verilen örüntüleri kendisi veya diğerleri arasında ilişkilendirebilir. Ayrıca örneklerin kümelerinin dâhil olması gereken veri grubunu da belirlemede başarılıdırlar.

12. Eksik bilgileri tamamlama konusunda da başarılı olarak çalışan YSA'lar eksik örüntülerinde tamamlanmasında kullanılabilirler
13. YSA'lar çevrimiçi öğrenme yaparak kendilerini eğitebilirler ve kendi kendini organize edebilme yeteneğine sahiptirler.
14. Geleneksel programlamanın ve sistemlerin aksine eksik bilginin olması YSA'nın çalışmasına engel değildir. Bu gibi eksik bilgi içeren durumlarda geleneksel programlama eksik kalmakta ve doğru sonuçlar verememekte iken YSA'lar bu konuda toleranslı ve başarılı bir şekilde çalışmaktadır.
15. YSA'nın çalıştığı hücrelerden bir veya birkaçında bozulma meydana gelmesi yapay sinir ağlarının yanlış çalışmasına neden olmamakla birlikte hataya tolerans sahibi olduğunu gösteren özelliklerinden biridir.
16. Dereceli bozulma gösteren YSA'lar zaman içerisinde yavaş ve göreceli bir bozulmaya uğrar. Bu da ağın her bozulma yaşandığında hemen bozulmayacağını bir göstergesidir

YSA'ların, pek çok avantajın yanında belirli birkaç dezavantajları da mevcuttur. Başlıca görülen dezavantajları aşağıdaki şekilde listelenmektedir;

1. YSA'ların en önemli sorunu manuel çözümünün kolay ve konforlu olmaması ve donanım bağımlı olmalarıdır. YSA'larının çıkış nedenlerinden birisi olan muvazi işlem yapabilme yeteneğidir. Muvazi çalışan işlemciler ile başarılı performans gösterir.
2. Doğru ve uygun ağ yapısını belirleyecek bir yöntem veya matematiksel formül yoktur. Buda ağ yapısının deneyime bağlı olmasına ve yanılma payının olmasına neden olur.
3. Ağın içerisindeki parametreleri belirlemede de herhangi belirli bir kural yoktur. Bu durum ağın içerisinde mevcut olan öğrenme katsayısı, hücre sayısı, katman sayısı gibi parametrelerin deneme yanılma yoluyla bulunarak çalıştırıldığını ve buna bağlı olarak yanılma payına sahip olabileceğini göstermektedir. Bahsedilen bu parametreler her bir olay için tasarlanan ağ yapısında farklılık göstereceğinden net bir yaklaşım bulunmamaktadır.

4. Kullanıcıya bağlı bir özelliği de girdi parametrelerinin girilmesindeki manuelliktir. Sayısal olmayan girdiler için belirlenen sayısal karşılıklarının doğru saptanması ve ağa doğru tanıtılması gerekmektedir. Burada yapılacak bir hata ağın yanlış çalışmasına neden olacaktır.
5. Ağın eğitilmesindeki zaman ve deneme kıstası tamamen kullanıcıya bağlıdır. Eğitiminin ne zaman bitirileceği hangi hata seviyesine ulaştığında durdurulacağı da kullanıcıya bağlı olduğundan hataya açık bir alandır.
6. En büyük sorunlarından bir tanesi de probleme çözüm yaklaşımının açıklanamaz olmasıdır. Ağın problemi çözerken ki davranışlarının neden ve nasıl olduğuna dair mevcut bir açıklama yoktur. Buda ağın güvenilirliğini azaltıcı bir durumdur.

Yapay Sinir Ağları başlıca; Sınıflandırma, Çizelgeleme, Modelleme ve Tahmin uygulamaları olmak üzere, pek çok alanda kullanılmaktadır. Bu alanda başarılı uygulamaları ele alındığında, YSA'ların çok boyutlu, gürültülü, karmaşık, kesin olmayan, eksik, kusurlu, hata olasılığı yüksek durumlarda da çalıştığı ve problemi çözmek için matematiksel modelin ve algoritmaların bulunmadan sadece örneklerin verilerek eğitildiği ve sonuçların alındığı durumlarda yaygın olarak kullanıldıkları görülmektedir. Bu amaçla geliştirilmiş ağlarda kullanılan fonksiyonlar aşağıdaki gibidir.

Muhtemel fonksiyon kestirimleri, Sınıflandırma, İlişkilendirme veya örüntü eşleştirme, Zaman serileri analizleri, Sinyal filtreleme, Veri sıkıştırma, Örüntü tanıma, Doğrusal olmayan sinyal işleme, Doğrusal olmayan sistem modelleme, Optimizasyon ve Kontrol.

YSA'lar pek çok sektörde değişik uygulama alanları bulmuştur. Bunlardan bazıları;

- Uzay: Uçuş benzetimleri, otomatik pilot uygulamaları vs.
- Otomotiv: Otomatik yol izleme, rehber, garanti aktivite analizi, sürüş analizi vs.
- Bankacılık: Kredi uygulamaları geliştirilmesi, müşteri analizi ve kredi müracaat değerlendirilmesi, bütçe yatırım tahminleri vs.

- Savunma: Silah yönlendirme, hedef seçme, radar, sensör sonar sistemleri, sinyal işleme, görüntü işleme vs.
- Elektronik: Kod sırası öngörüsü, çip bozulma analizi, non-lineer modelleme vs.
- Eğlence: Animasyonlar, özel efektler, pazarlama öngörüsü vs.
- Finans: Kıymet biçme, pazar performans analizi, bütçe kestirimi, hedef belirleme vs.
- Sigortacılık: Ürün optimizasyonu, uygulama politikası geliştirme vs.
- Üretim: Üretim işlem kontrolü, ürün dizaynı, makina yıpranmalarının tespiti, girdi ve çıktı tespiti, dayanıklılık analizi, kalite kontrolü, iş çizelgeleri hazırlanması vs.
- Sağlık: Göğüs kanseri erken teşhis ve tedavisi, EEG, ECG, MR, kalite artırımı, ilaç etkileri analizi, kan analizi sınıflandırma, kalp krizi erken teşhis ve tedavisi vs.
- Petro kimya: Arama, verim analizi vs.
- Robotik: Yörünge kontrol, görsel sistemler programlama, uzaktan kumandalı sistemler, optimum rota belirleme vs.
- Dil: Sözcük tanıma, yazı ve konuşma çevrimi, dil tercüme vs.
- Telekomünikasyon: Görüntü ve veri karşılaştırma, filtreleme, eko ve gürültü sönmülendirilmesi, ses ve görüntü işleme, trafik yoğunluğunun kontrolü ve anahtarlama vs.
- Güvenlik: parmak izi tanıma, kredi kartı hileleri saptama, retina tarama, yüz eşleştirme vs.

Görüldüğü gibi YSA'lar günlük hayatımızda pek çok alanda kullanılmaktadır. Gün geçtikçe uygulama alanları genişlemekte ve gelişmektedir.

Yapay Sinir Ağları işleyiş olarak benzer olmalarına rağmen herhangi bir ağ yapısı ve işleyiş standardı bulunmamaktadır. Nöron dizilimlerine, nöronların ağırlıklarının düzenleme için yapılan hesaplamaların türüne ve zamanına göre Yapay Sinir Ağlarını üç ayrı dalda inceleyebiliriz.

Yapay Sinir Ağları içerdiği nöronların birbirine bağlantı şekline göre ileri ve geri beslemeli olarak ikiye ayrılır.

İleri Beslemeli Ağlar: İleri beslemeli ağlarda nöronlar girişten çıkışa doğru katmanlar halinde ilerlediği düzenli şekillerdeki ağlardır. Bir katmandan sadece kendinden sonraki katmanlara bağ bulunmaktadır. YSA'ya gelen bilgiler giriş katmanına daha sonra sırasıyla ara katmanlardan ve çıkış katmanından işlenerek geçer ve nihai çıktıyı oluşturur (Şeker, 2008).

Geri Beslemeli Yapay Sinir Ağları: Geri beslemeli YSA'da ileri beslemeli olanların aksine bir hücrenin çıktısı sadece kendinden sonra gelen hücrenin katmanına girdi olarak verilmez. Kendinden önceki katmanda veya kendi katmanında bulunan herhangi bir hücreye de girdi olarak bağlanabilir (Şengöz, 2017).

Bu yapısı ile geri beslemeli YSA doğrusal olmayan dinamik bir davranış göstermektedir. Geri besleme özelliğini kazandıran bağlantıların bağlantı şekline göre geri aynı yapay sinir ağıyla farklı davranışta ve yapıda geri beslemeli YSA elde edilir.

Yapay Sinir Ağlarının verilen girdilere göre çıktı üretebilmesinin yolu ağın öğrenebilmesidir. Bu öğrenme işleminin de birden fazla yöntemi vardır. YSA öğrenme algoritmalarına göre danışmanlı, danışmansız ve takviyeli öğrenme olarak üçe ayrılır.

Danışmanlı Öğrenme: Danışmanlı öğrenme ağı verilen giriş değerleri için çıktı değerleri de verilir. Ağ verilen girdiler için istenen çıkışları oluşturabilmek için kendi ağırlıklarını günceller. Ağın çıktıları ile beklenen çıktılar arasındaki hata hesaplanarak ağı yeni ağırlıkları bu hata payına göre düzenlenir (Atmaca, 2016).

Hata payı hesaplanırken ağı bütün çıktıları ile beklenen çıktıları arasındaki fark hesaplanır ve bu farka göre her hücreye düşen hata payı bulunur. Daha sonra her hücrenin kendine gelen ağırlıkları günceller (Atmaca, 2016).

Danışmansız Öğrenme: Danışmansız öğrenmede ağı öğrenme sırasında sadece örnek girdiler verilmektedir. Herhangi bir beklenen çıktı bilgisi verilmez. Girişte verilen bilgilere göre ağ her bir örneği kendi arasında sınıflandıracak şekilde kendi kurallarını

oluşturur. Ağ bağlantı ağırlıklarını aynı özellikte olan dokuları ayırabilecek şekilde düzenleyerek öğrenme işlemini tamamlar (Atmaca, 2016).

Destekleyici Öğrenme: Bu öğrenme yaklaşımında ağın her iterasyonu sonucunda elde ettiği sonucun iyi veya kötü olup olmadığına dair bir bilgi verilir. Ağ bu bilgilere göre kendini yeniden düzenler. Bu sayede ağ herhangi bir girdi dizisiyle hem öğrenerek hem de sonuç çıkararak işlemeye devam eder (Atmaca, 2016).

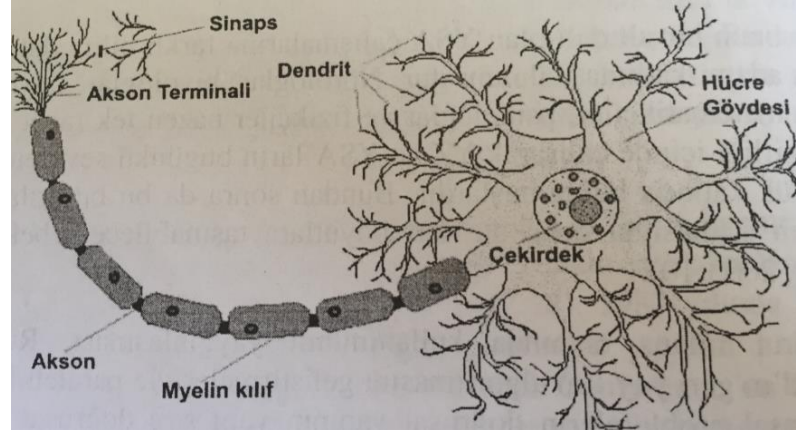
Örneğin satranç oynayan bir yapay sinir ağı yaptığı hamlenin iyi veya kötü olduğunu anlık olarak ayırt edememesine rağmen yine de hamleyi yapar. Eğer oyun sonuna geldiğinde program oyunu kazandıysa yaptığı hamlelerin iyi olduğunu varsayacaktır ve bundan sonraki oyunlarında benzer hamleleri iyi olarak değerlendirerek oynayacaktır (Atmaca, 2016).

Yapay Sinir Ağları öğrenme zamanına göre de statik ve dinamik öğrenme olarak ikiye ayrılır.

Statik Öğrenme: Statik öğrenme kuralıyla çalışan YSA kullanmadan önce eğitilmektedir. Eğitim tamamlandıktan sonra ağı istenilen şekilde kullanılabilir. Ancak bu kullanım sırasında ağın üzerindeki ağırlıklarda herhangi bir değişiklik olmaz (Atalay ve ark., 2010).

Dinamik Öğrenme: Dinamik öğrenme kuralı ise YSA'nın çalıştığı süre boyunca öğrenmesini öngörerek tasarlanmıştır. Yapay sinir eğitim aşaması bittikten sonra da daha sonraki kullanımlarında çıkışların onaylanmasına göre ağırlıklarını değiştirerek çalışmaya devam eder (Atalay ve ark., 2010).

Yapay bir ağ, biyolojik sinir ağları ile ortak performans özelliklerine sahip bir bilgi işleme sistemidir. Şekil 3.2.'de biyolojik bir sinir ağı gösterilmiştir (Diamantaras & Kung, 1996).



Şekil 3.2. Biyolojik sinir hücresinin temel yapısı

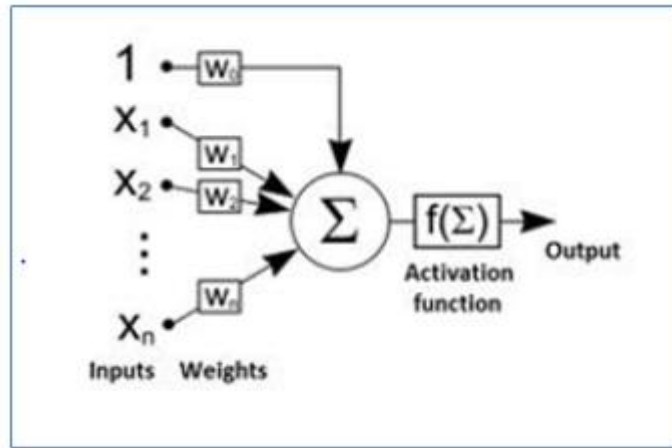
Her ne kadar değişik tipteki sinir hücrelerinin şekil ve işlev açısından farklılıkları bulunsa da hepsinin ortak özelliği hücre gövdesi, dendrit, akson ve akson terminallerinden olmak üzere 4 farklı bölgeden oluşmaktadır (Guyton & Hall, 2006).

Dendritler gelen uyarıyı alarak, çekirdek gövdesine iletir ve burada uyarılar işlenir. İşlenen uyarılar aksonlara, aksonlardan sinaplara iletilir ve sinapsların yardımı ile diğer sinir hücresine iletim gerçekleşir.

Gerçek sinir ağları ve YSA karşılaştırması yapılacak olursa aşağıdaki şekilde eşleşme yapılacaktır (Kubat, 2012).

1. Sinir= Yapay Sinir Hücresi
2. Sinaps= Ağırlıklar
3. Dendrit= Toplama Fonksiyonu
4. Hücre Gövdesi= Transfer Fonksiyonu
5. Aksonlar= Eleman Çıkışı

Yapay Sinir Ağları, iki özelliği ile biyolojik sinir hücresine benzerler. Birincisi; bilginin bir öğrenme işlemi ile ağın çevriminden elde edilmedi, ikincisi; sinaptik elemanlar olarak bilinen işlem elemanları arasındaki bağlantı ağırlıkları, elde edilen bilgileri depolamak için kullanılır (Haykin, 1999).



Şekil 3.3. Tek katmanlı YSA yapısı

Şekil 3.3.'de tek katmanlı YSA yapısına örnek verilmiştir.

Yapay Sinir Ağları, insan beyninin matematiksel modelinin geliştirilmesi olarak şu varsayımlara dayanılarak geliştirilmiştir (Frausett, 1993) :

1. Bilgi işlemi, nöron adı verilen birçok basit birimde gerçekleşir.
2. Sinyaller bağlantı linkleri üzerinden nöronlar arasında iletilir.
3. Her bir bağlantı hattı iletilen sinyali çarparak ilişkili bir ağırlığa sahiptir.
4. Her nöron, çıktısını belirlemek için net girişi için bir aktivasyon işlevi ima eder.

Yapay Sinir Ağları ile ilgili ilk çalışmalar tek katmanlı algılayıcılar ile başlamıştır. Bilinen en önemli tek katmanlı algılayıcılar aşağıdaki gibidir.

1. Basit tek katmanlı algılayıcılar (perseptron)
2. ADALINE/MADALINE üniteleri

Basit Algılayıcı (Perceptron)

Bir sinir hücresinin birden fazla girdiyi alarak bir çıktı üretmesi prensibine dayanır. Eğitilebilme yeteneğine sahip programlanmış ilk YSA'dır. Bu özelliği ağırlıklarının değiştirilebilir olması ile sağlanır.

Problemin çözümünün varlığı durumunda ağa girilen girdi değişkenlerinden doğru ağırlıkları yakınsama özelliğine sahiptir. Bu özellik en önemli niteliklerinden biridir (Frausett, 1993).

Basit algılayıcı model, daha sonraları geliştirilecek ve YSA modelleri için devrim niteliğinde olacak çok katmanlı algılayıcıların temelini oluşturmaktadır (Öztemel , 2003).

Basit Algılayıcı Öğrenme Kuralı

Girdiler proses elamanına gösterilir, her girdiye karşılık gelen çıktı değeri de ağa gösterilir(X,B). Çıktı değerleri 1 ve 0 mantıksal değerlerinden birini alır.

Perseptron ünitesine gelen net girdi değeri (Denklem 3.16) ifade edilmiştir:

$$Net = \sum_{i=1}^m (w_i * x_i) \quad (3.16)$$

Perseptron ünitesine gelen çıktı değeri (Denklem 3.17) ifade edilmiştir:

$$\zeta = \begin{cases} 1, & \text{Eğer } NET > \varphi \\ 0, & \text{Eğer } NET \leq \varphi \end{cases} \quad (3.17)$$

φ :Eşik değeri (aktivasyon fonksiyonunun konumunu belirlemek için kullanılır) Eğer hata (E);

$$E = B - \zeta \quad (3.18)$$

Eğer hata(E) (Denklem 3.18) 0 olursa ağırlıklarda bir değişiklik olmaz.

Eğer ağ beklenmeyen bir çıktı üretmişse iki durum söz konusudur:

Beklenen çıktının 0 ve gerçekleşen çıktının 1 olması durumunda; net girdi değeri, eşik değerinin üstündedir. Bu durumda ağırlık değerleri azaltılmalıdır.

$$W_n = W_o - \lambda X \quad (3.19)$$

Beklenen çıktının 1 ve gerçekleşen çıktının 0 olması durumunda; net girdi değeri, eşik değerinin altındadır. Bu durumda ağırlık değerleri arttırılmalıdır.

$$W_n = W_o + \lambda X \quad (3.20)$$

W_n : Yeni ağırlık

W_o : Eski ağırlık

λ : Öğrenme Katsayısı (ağırlıkların değişim miktarını belirlemekte ve sabit değer olarak alınmakta)

Girdi setinde ki örnekler için doğru sınıflandırmalar yapılmaya kadar (Denklem 3.19) ve (Denklem 3.20)'deki bu iterasyonlar devam etmektedir.

Basit Algılayıcının Problemleri

Basit algılayıcının en önemli problemi doğrusal olmayan problemin çözümünde başarılı olmamasıdır. Çok katmanlı algılayıcılar ile bu problem çözülmektedir.

Ağın her iterasyonunda ağırlıklarını değiştirdikçe öğrendiklerini unutma olasılığıdır. Bir girdi seti ağırlıkları arttırdıkça diğeri azalmaktadır. Bu sorun çoğu zaman içerisinde ağırlıkların bulunması ile çözülebilmektedir. Fakat eğitim zamanının uzamasına neden olmaktadır (Öztemel , 2003).

Adaline/Madaline Modeli

Adaptif Doğrusal Element (Adaptif Linear Element)'in kısaltması olan ADALINE, yapı olarak Basit Algılayıcı'ya benzemektedir. Tek farkı en küçük kareler yöntemine dayanan Delta Kuralı olarak geçen öğrenme kuralı görülmektedir.

Adaline Ünitesinin Öğrenme Kuralı

Öğrenme kuralı YSA da genel öğrenme prensibine göre çalışmaktadır. Girdi setlerinden çıktılar hesaplanır ve ağırlıklar çıktıya göre değiştirilir.

ADALINE ünitesinde girdileri (Denklem 3.21)gibi formülize edilerek hesaplanır;

$$Net = \sum_{i=1}^m (w_i + x_i) + \varphi \quad (3.21)$$

Çıktıların hesaplanması (Denklem 3.22) verilmiştir;

$$\zeta = \begin{cases} 1, & \text{Eğer } NET \geq 0 \\ 0, & \text{Eğer } NET < 0 \end{cases} \quad (3.22)$$

Çıktısını ürettikten sonraki hatası (Denklem 3.23) hesaplanır;

$$E = B - \zeta \quad (3.23)$$

Bu yöntemde ağırlıklar hata minimumuma yaklaştıracak şekilde çalışır. t anındaki yeni ağırlığı (Denklem 3.24) hesaplanır;

$$W_i(t) = W_i(t - 1) + \alpha * E * X_i \quad (3.24)$$

α : öğrenme katsayısı Benze şekilde eşik değerinin de değişmesiyle;

$$\omega_y = \omega_e + \alpha * E$$

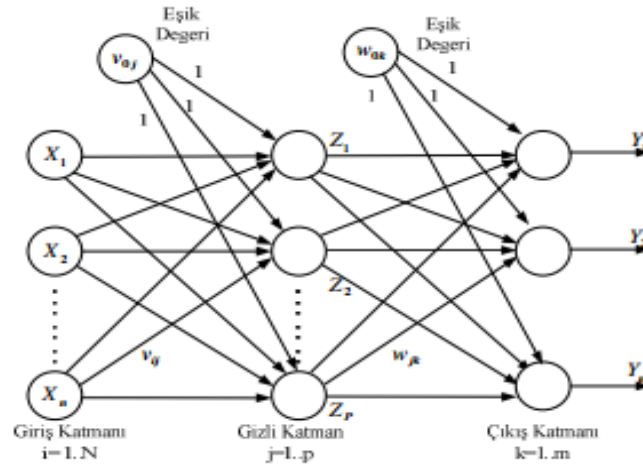
ω_y : Yeni eşik değeri

ω_e : Eski eşik değeri

MADALINE Ünitesinin Öğrenme Kuralı

Birden fazla ADALINE ünitesinin bir araya gelerek oluşturduğu ağıdır. Öğrenme kuralı ADALINE ile aynıdır. MADALINE ağında ADALINE üniteleri birbirlerine AND ve OR operatörlerinin klasik mantığını kullanarak bağlanırlar. Tek katmanlı algılayıcıların en büyük problemi doğrusal olmayan olayları öğrenememeleridir. Bu nedenle yeni modellerin geliştirilmesine ihtiyaç vardır.

Yapay sinir hücreleri de biyolojik sinir hücrelerinden esinlenerek oluşturulduğu için bunlarla benzer yapıdadırlar. Yapay nöronlarda aralarında bağ kurarak Yapay Sinir Ağlarını oluştururlar. Biyolojik nöronlarda gerçekleştiği gibi yapay nöronların da giriş sinyallerini alıp toplayarak işledikleri ve çıktılar buldukları alanları Şekil 3.4.'te bulunmaktadır.



Şekil 3.4. YSA modeli

Bir yapay sinir hücresi beş bölümden oluşmaktadır;

1. Girdiler
2. Ağırlıklar
3. Toplama Fonksiyonu (Birleştirme Fonksiyonu)
4. Aktivasyon fonksiyonu
5. Çıktılar

Girdiler: Girdiler nöronlara gelen verilerdir. Girdiler yapay sinir hücresine bir diğer hücreden gelebileceği gibi direk olarak dış dünyadan da gelebilir. Bu girdilerden gelen

veriler biyolojik sinir hücrelerinde olduğu gibi toplanmak üzere nöron çekirdeğine gönderilir (Kubat, 2012).

Ağırlıklar: Yapay sinir hücresine gelen bilgiler girdiler üzerinden çekirdeğe ulaşmadan önce geldikleri bağlantıların ağırlığıyla çarpılarak çekirdeğe iletilir. Bu sayede girdilerin üretilen çıktı üzerindeki etkisi ayarlanabilmektedir. Bu ağırlıkların değerleri pozitif, negatif veya sıfır olabilir. Ağırlığı sıfır olan girdilerin çıktı üzerinde herhangi bir etkisi olmamaktadır (Kubat, 2012).

Toplama Fonksiyonu (Birleştirme Fonksiyonu): Toplama fonksiyonu bir yapay sinir hücresine ağırlıklarla çarpılarak gelen girdileri toplayarak o hücrenin net girdisini hesaplayan bir fonksiyondur (Kubat, 2012).

Bazı durumlarda gelen girdilerin değeri dikkate alınırken bazı durumlarda ise gelen girdilerin sayısı önemli olabilmektedir. Bir problem için en uygun toplama fonksiyonu belirlenirken geliştirilmiş bir yöntem yoktur. Genellikle deneme yanılma yoluyla toplama fonksiyonu belirlenmektedir. Bazen her hücrenin toplama fonksiyonunun aynı olması gerekmez. Bu konulara karar vermek tasarımcıya aittir (Kubat, 2012).

Aktivasyon Fonksiyonu: Bu fonksiyon hücreye gelen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı belirler. Aktivasyon fonksiyonu genellikle doğrusal olmayan bir fonksiyon seçilir. YSA'nın bir özelliği olan "doğrusal olmama" aktivasyon fonksiyonlarının doğrusal olmama özelliğinden gelmektedir. Aktivasyon fonksiyonu seçilirken dikkat edilmesi gereken bir diğer nokta ise fonksiyonun türevinin kolay hesaplanabilir olmasıdır. Geri beslemeli ağlarda aktivasyon fonksiyonunun türevi de kullanıldığı için hesaplamaların yavaşlamaması için türevi kolay hesaplanabilir bir fonksiyon seçilir. Günümüzde en yaygın olarak kullanılan "Çok katmanlı algılayıcı" modelinde genel olarak aktivasyon fonksiyonu olarak "Sigmoid fonksiyonu" kullanılır. Kullanılan Aktivasyon fonksiyonları Tablo 3.8.'de açıklamaları ile belirtilmiştir (Kubat, 2012).

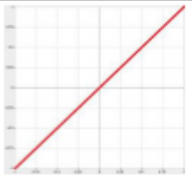

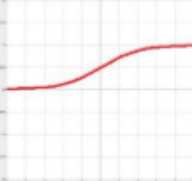
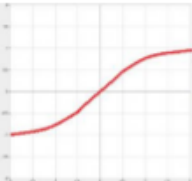
Tablo 3.7. Bazı toplama fonksiyonları

Toplam $Net = \sum_{i=1}^N X_i * W_i$	Ağırlık değerleri girdiler ile çarpılır ve bulunan değerler birbirleriyle toplanarak Net girdi hesaplanır.
Çarpım $Net = \prod_{i=1}^N X_i * W_i$	Ağırlık değerleri girdiler ile çarpılır ve daha sonra bulunan değerler birbirleriyle çarpılarak Net Girdi Hesaplanır.
Maksimum $Net = \text{Max}(X_i * W_i)$	n adet girdi içinden ağırlıklar girdilerle çarpıldıktan sonra içlerinden en büyüğü Net girdi olarak kabul edilir.
Minimum $Net = \text{Min}(X_i * W_i)$	n adet girdi içinden ağırlıklar girdilerle çarpıldıktan sonra içlerinden en küçüğü Net girdi olarak kabul edilir.
Çoğunluk $Net = \sum_{i=1}^N \text{Sgn}(X_i * W_i)$	n adet girdi içinden girdilerle ağırlıklar çarpıldıktan sonra pozitif ile negatif olanların sayısı bulunur. Büyük olan sayı hücrenin net girdisi olarak kabul edilir.
Kümülatif Toplam $Net = \text{Net}(\text{eski}) + \sum_{i=1}^N X_i * W_i$	Hücreye gelen bilgiler ağırlıklı olarak toplanır. Daha önce hücreye gelen bilgilere yeni hesaplanan girdi değerleri eklenerek hücrenin net girdisi hesaplanır.


Tablo 3.7.'de bahsedilen toplama kuralları Yapay Sinir Ağlarında ağ içinde kullanılan toplama kurallarıdır.

Hücrenin Çıktısı: Aktivasyon fonksiyonundan çıkan değer hücrenin çıktı değeri olmaktadır. Bu değer ister yapay sinir ağının çıktısı olarak dış dünyaya verilir isterse tekrardan ağın içinde kullanılabilir. Her hücrenin birden fazla girdisi olmasına rağmen bir tek çıktısı olmaktadır. Bu çıktı istenilen sayıda hücreye bağlanabilir (Kubat, 2012).

Tablo 3.8. Aktivasyon fonksiyonları

Doğrusal (Lineer) Aktivasyon Fonksiyonu		$F(\text{NET})=A \cdot \text{NET}$ (A sabit bir sayı)	Doğrusal problemler çözmek amacıyla aktivasyon fonksiyonu doğrusal bir fonksiyon olarak seçilebilir. Toplama fonksiyonundan çıkan sonuç, belli bir katsayı ile çarpılarak hücrenin çıktısı olarak hesaplanır.
Adım (Step) Aktivasyon Fonksiyonu		$F(\text{Net})= \begin{cases} 1 & \text{if Net} > \text{Eşik Değer} \\ 0 & \text{if Net} \leq \text{Eşik Değer} \end{cases}$	Gelen Net girdinin belirlenen bir eşik değerinin altında veya üstünde olmasına göre hücrenin çıktısı 1 veya 0 değerini alır.
Sigmoid Aktivasyon Fonksiyonu		$F(\text{Net})= \frac{1}{1+e^{-\text{Net}}}$	Sigmoid aktivasyon fonksiyonu sürekli ve türevi alınabilir bir fonksiyondur. Doğrusal olmayışı dolayısıyla yapay sinir ağı uygulamalarında en sık kullanılan fonksiyondur. Bu fonksiyon girdi değerlerinin her biri için 0 ile 1 arasında bir değer üretir.
Tanjant Hiperbolik Aktivasyon Fonksiyonu		$F(\text{Net})= \frac{e^{\text{Net}} + e^{-\text{Net}}}{e^{\text{Net}} - e^{-\text{Net}}}$	Tanjant hiperbolik fonksiyonu, sigmoid fonksiyonuna benzer bir fonksiyondur. Sigmoid fonksiyonunda çıkış değerleri 0 ile 1 arasında değişirken hiperbolik tanjant fonksiyonunun çıkış değerleri -1 ile 1 arasında değişmektedir.
Eşik Değer Fonksiyonu		$F(\text{Net})= \begin{cases} 0 & \text{if Net} \leq 0 \\ \text{Net} & \text{if } 0 < \text{Net} < 1 \\ 1 & \text{if Net} \geq 1 \end{cases}$	Gelen bilgilerin 0 dan küçük-eşit olduğunda 0 çıktısı, 1 den büyük-eşit olduğunda 1 çıktısı, 0 ile 1 arasında olduğunda ise yine kendisini veren çıktılar üretilebilir.
Sinüs Aktivasyon Fonksiyonu		$F(\text{Net}) = \text{Sin}(\text{Net})$	Öğrenilmesi düşünülen olayların sinüs fonksiyonuna uygun dağılım gösterdiği durumlarda kullanılır.

YSA'ları yapay sinir hücrelerinin birbirine bağlanmasıyla oluşan yapılardır. YSA Şekil 3.5.'de verildiği gibi üç ana katmanda incelenir; Giriş Katmanı, Ara (Gizli) Katmanlar ve Çıkış Katmanı.



Şekil 3.5. Yapay sinir ağının yapısı

Giriş Katmanı: Yapay sinir ağına girdilerin geldiği katmandır. Bu katmanda dışarıdan gelecek giriş sayısı kadar hücrenin bulunmaktadır. Bu bölümde girdiler herhangi bir işleme uğramadan alt katmanlara iletilmektedir.

Ara Katman: Giriş katmanından çıkan bilgilerin geldiği diğer adıyla gizli katmandır. Ara katman kullanıcıya bağlı olarak değişiklik gösterebilir. YSA’larda ara katman bulunana katman sayısı ve bu katmanlardaki nöron sayısı kullanıcıya bağlı olarak farklılık gösterebilmektedir.

Çıkış Katmanı: Ara katmanlardan gelen bilgileri eğitip çıktıya dönüştüren katmandır. Geri beslemeli ağlarda bu katmanda üretilen çıktı kullanılarak ağın yeni ağırlık değerleri hesaplanır.

İnsan beyninin çalışma prensiplerinden etkilenecek doğan YSA’lar tıpkı insanoğlunun çevreden edindiği tecrübeler gibi tecrübe edinip kendi genellemelerini çıkararak karar mekanizması oluşturur bu karar mekanizması açıklanabilir formülize edilebilir değildir. İnsan gibi daha önce hiç eğitilmediği görmediği olay ve durumlar karşısında ise tecrübesiz olduğu için tepkisiz kalabilir.

Çeşitli öğrenme algoritmalarıyla çalışılan bu ağın amacı hatayı azaltmak en doğru öğrenmeyi sağlamaktır. Çalışma süresince yenilenerek eğitilen ağ ağırlıklarını sürekli olarak günceller. Böylece yenilenen ağırlıklar sayesinde amacına ulaşmaya çalışır.

Amaca ulaşmanın veya yaklaşmanın ölçüsü de yine dışarıdan verilen bir değerdir. Eğer YSA istenen çıkış değerine yaklaşırsa ağ bu haliyle kaydedilir.

Ağın deneme ile tekrar tekrar ağırlık güncellediği süreye öğrenme denir. Öğrenme tamamlandıktan sonra ağa test verileri olarak ayrılan veriler verilerek test edilir. Bu test verilerinde gösterdiği başarı da ağın başarısı olarak kabul edilir. Genelde girdi verilerinin %80'lik kısmı ağa verilip ağ eğitilir. Kalan %20 lik kısım ile de ağın testi gerçekleştirilir. YSA hesaplama aşamaları aşağıdaki gibi detaylandırılmıştır (Derviş, 2015).

1. Örneklerin toplanması: Çözülmesi istenen olay için girdi verilerinin toplandığı aşamaya denir. Bu aşamada ağın test edilmesi ve eğitilmesi için veri toplanması ve bunların sayısal karşılıklarına çevrilmesi gerekmektedir. Ağ eğitim verisi ile eğitilip test yenisiyle test edilerek performansı ölçülebilmektedir
2. Ağın topolojik yapısının belirlenmesi: Ağın topolojik yapısı yani girdi ünitesi adedi, ara katman sayısı, ara katmandaki eleman sayısı belirlenmesi gerekmektedir. Öğrenilmesi istenen ağın çıktı eleman sayısı da bu adımda belirlenmektedir.
3. Öğrenme parametrelerinin belirlenmesi: Ağın öğrenme katsayısı, süreç elemanlarının toplama ve aktivasyon fonksiyonları, momentum katsayısı gibi parametreler bu adımda belirlenmektedir.
4. Ağırlıkların başlangıç değerlerinin atanması: ağırlık değerleri başlangıçta rastsal olarak seçilip, eşik değer ünitesinin ağırlıklarının başlangıç değerlerinin atanması yapılır. Eğitim ile uygun değerler belirlenir.
5. Öğrenme setinden örneklerin seçilmesi ve ağa gösterilmesi: Ağın öğrenmesini sağlamak için kullanılacak eğitim seti seçimi yapılır.
6. Öğrenme sırasında ileri hesaplamaların yapılması: girdi için ağın çıktı değerleri hesaplanır.
7. Gerçekleşen çıktının beklenen çıktı ile karşılaştırılması: Ağın ürettiği hata değerleri bu adımda hesaplanır.
8. Ağırlıkların değiştirilmesi: Geri hesaplama yöntemi uygulanarak üretilen hatanın azalması için ağırlıkların değiştirilmesi yapılır.

9. Öğrenmenin tamamlanması: İleri beslemeli sinir ağı eğitimi bitip çıktı ile beklenen arasındaki hatalar belirlenir ve bu hatalar kabul edilebilir düzeye ininceye kadar devam eder.

Ağın kendisine gösterilen girdi örneği için beklenen çıktıyı üretmesini sağlayacak ağırlık değerleri başlangıçta rastgele atanır ve örnekler ağda gösterildiği gibi ağırlıklar istenen değerlere değiştirilir. İstenen ağırlık değerleri bilinmemektedir. Bu nedenle YSA'nın davranışını yorumlamak ve açıklamak mümkün değildir.

Sinir ağının geri bildirimlerinin yerel sonuçlara takılmasını önlemek için momentum katsayısı geliştirilmiştir. Ağların eğitiminde bir diğer önemli sorun, öğrenme sürecinin çok uzun olmasıdır. Ağırlık değerleri, ağın yerel sonuçlara takılmasına ve başlangıçta büyük değerler varsa bir yerel sonuçtan diğerine atlamasına neden olur. Ağırlıklar küçük aralıklarla seçilirse, doğru değerleri bulmak uzun zaman alır. Bazı sorunlara çözüm sadece 200 yineleme ve 5-10 milyon yinelemedir (Çayıroğlu, 2017).

Benzer şekilde momentum katsayısı da öğrenmenin performansını etkiler. Momentum katsayısı bir önceki iterasyondaki değişimin belirli bir oranının yeni değişim miktarına eklenmesidir. Bu özellikle yerel çözümlere takılan ağların sıçrama ile daha iyi sonuçlar bulmasını sağlamak amacıyla önerilmiştir. Bu değerlerin küçük olması yerel çözümlerden kurtulmayı zorlaştırabilir. Çok büyük değerler ise çözüme ulaşmada sorunlar yaşatabilir. Tecrübeler momentum katsayısının 0.6-0.8 arasında seçilmesinin uygun olacağını göstermiştir. Problemin niteliğine göre kullanıcının almasında fayda vardır (Çayıroğlu, 2017).

Tahmin yöntemlerinin doğruluklarını belirlemek ve yöntemleri birbiriyle karşılaştırabilmek için 3 tane yöntem (Denklem 3.25), (Denklem 3.26) ve (Denklem 3.27) kullanılır. Bunlar:

1. Mean squared error- Ortalama Hatalar Karesi (MSE)
2. Mean absolute deviation- Ortalama Mutlak Hata (MAD)
3. Mean absolute percent- Ortalama Mutlak Yüzde Hata (MAPE)

$$MSE = \frac{\sum_{i=1}^K (Y_i - F_i)^2}{K} \quad (3.25)$$

$$MAD = \frac{\sum_{i=1}^K |Y_i - F_i|}{K} \quad (3.26)$$

$$MAPE = \frac{\sum_{i=1}^K |Y_i - F_i| / Y_i}{K} \quad (3.27)$$

Her üç doğruluk ölçüsünde de çıkan sonuçlar ne kadar düşüğe gerçek talebe o kadar yaklaşmış demektir.

Örneğin bir x şirketinin verilerini kullanarak Hareketli Ortalamaya göre talep bulunmuş tahminlerini, ağırlıklı hareketli ortalamaya göre talep tahminlerini, üssel düzeltme yöntemine göre talep tahminlerini MSE, MAD ve MAPE ölçüm yöntemlerine göre Tablo 3.9.'da karşılaştırılacaktır.

Tablo 3.9. Tahmin doğruluğu ölçme örneği

Hafta	Satış	HO (3) Tahmin (F _i)	Hata	Hata ²	AHO (4) Tahmin (F _i)	Hata	Hata ²	ÜDY (α=0,2) Tahmin (F _i)	Hata	Hata ²
1	110							110.0		
2	102							110.0	-8.0	64.0
3	108							108.4	-0.4	0.2
4	121	106.7	+14.3	204.5				108.3	+12.7	161.3
5	112	110.3	+ 1.7	2.9	112.2	-0.2	0.0	110.8	+1.2	1.4
6	105	113.7	- 8.7	75.7	112.9	-7.9	62.4	111.0	-6.0	36.0
7	114	112.7	+ 1.3	1.7	110.6	+3.4	11.6	109.8	+4.2	17.6
8	106	110.3	- 4.3	18.5	111.6	-5.6	31.4	110.6	-4.6	21.2
9	115	108.3	+ 6.7	44.9	108.8	+6.2	38.4	109.7	+5.3	28.1
TOPLAM			21	140.8		23.1	143.8		20.1	102.8

Tam anlamıyla bir karşılaştırma yapabilmek için denklemlerde, 6.hafta ile 9.hafta arasındaki verileri kullanılacaktır. Yani K=4 olarak alınacaktır. Bu verileri denklemlerde yerlerine koyulduğunda Tablo 3.10.'daki sonuçlar çıkmaktadır.

Tablo 3.10. Tahmin sonuçları

	HO(3)	AHO(4)	ÜDY ($\alpha=0.2$)
MSE	35.20	35.95	25.73
MAD	5.25	5.78	5.03
MAPE	%4.83	%5.30	%4.59

Buna göre gerek MSE’de gerek MAD’da gerek de MAPE’de en küçük değerleri veren Üssel Düzeltme yöntemi gerçekleşen satışa en yakın tahminleri belirlemiştir. Yani bu işletme, talep tahmin yöntemi olarak üssel düzeltme yöntemini kullanarak satış rakamlarına en yakın tahmini yapabilir.

BÖLÜM 4. TÜRKİYE'DE VE DÜNYADA ALÜMİNYUM

4.1. Alüminyumun Tarihçesi ve Özellikleri

Saf alüminyum, doğada hafif mavimsi beyaz bir metaldir halinde bulunur ve Al ile sembolize edilir. Atomik ağırlığı 26,9 g/mol'dür. Alüminyum, 1807 yılında Sir Humprey Davy tarafından ilk kez oksit halinde bulunan bileşiğinden ayrıştırılarak elde edilmiştir. Yeryüzünde oksijen ve silisyumdan sonra bulunan üçüncü element(metal) olmasına ve dünya kabuğunun %8'ini oluşturmasına karşılık, alüminyumun endüstriyel çapta üretimine 1886 yılında Charles Martin Hall ve Paul T. Heroult'un birbirinden habersiz olarak yaptıkları elektroliz yönteminin kullanımını keşfetmesiyle başlanmıştır. Böylece, elektroliz yöntemi ile üretimin keşfedilmesinden günümüze kadar alüminyum üretimi ivme kazanarak yükselmiştir ve demir ve çelikten sonra en çok kullanılan ikinci metal olmuştur. Alüminyumun fiyatı ilk çıktığı yıllarda gramaj olarak altın ve gümüş gibi kıymetli metaller sınıfında bulunmaktaydı ancak Üretim miktarlarının artışıyla şu an bakır ile karşılaştırılabilir düzeyde inmiştir (Ankara Alüminyum Sanayicileri Derneği, 2003).



.0001%	Copper
.006%	Sulphur
.009%	Manganese
.009%	Carbon
0.12%	Phosphorus
0.14%	Hydrogen
0.62%	Titanium
2.07%	Magnesium
2.58%	Potassium
2.83%	Sodium
3.64%	Calcium
5.06%	Iron
8.07%	Aluminium
27.61%	Silicon
46.46%	Oxygen

Source: Metals in the Service of Man, 9th Ed. 1989

Şekil 4.1. Dünya üzerindeki element oranları

Şekil 4.1.'de Dünya üzerindeki Alüminyum ve diğer elementlerin bulunma yüzdeleri gösterilmiştir.

Tarihsel akışta Alüminyum adına yapılan önemli gelişmeler aşağıdaki gibi özetlenebilir.

1886: Fransa'da Paul T. Héroult ve Amerika'da Charles Martin Hall birbirlerinden bağımsız olarak kriyolitte çözülmüş alüminanın elektrolitik parçalanması ile ilgili patent almışlardır.

1886: Ernst Werner von Siemens'in dinamoyu keşfi ile hidroelektrik santrallerinin temeli atılmış ve alüminyum imalatı için ihtiyaç duyulacak olan elektrik enerjisinin kitlesel üretimi mümkün hale gelmiştir.

1887: İsviçre' de Paul T. Héroult, Metallurgischen Gesellschaft firması ile elektroliz tesisinin kurulumuna başlamıştır. Daha sonra bu firma Alman Edison Gesellschaft (daha sonra AEG) firması ile birleşmiştir.

1888: Charles Martin Hall; Pittsburgh yakınında Kensington' da ilk alüminyum elektroliz ile üretim tesisini kurmuştur. Kurulan bu firmanın ismi "Pittsburgh Reduction Co." dir. Bu firma ilk üretiminde günde 22,5 kg ile başlamışken 1890 yılında 240 kg değerine ulaşmıştır. Bu firmanın ismi daha sonrasında Aluminium Cooperation of America olmuştur.

1889: Carl Josef Bayer; Avusturyalı kimyacı, St. Petersburg civarında Tentelevsk firmasında çalışırken boksitten çözelti işleme yöntemi ile toz alümina imalatına ait yöntemi geliştirmiştir. Günümüzde halen bu yöntem üretilen toplam alümina miktarının % 80'inin üstündeki miktarın üretildiği yöntem olarak kullanılmaya devam etmektedir.

1907: Robert Viktor Neher sürekli haddeleme ile folyo üretimine ait bir yöntem geliştirmiştir. 1910 yılında bu yöntemle üretim yapan firmanın kuruluşunu İsviçre’ de gerçekleştirmiştir.

1911: Tobler isimli İsviçreli çikolata imalatçısı Alüminyum folyoları kullanmaya başlanmıştır.

Alüminyum üretimi dünyada demirden sonra en fazla gerçekleştirilen metal olarak ikincidir (Ana Metal Sanayileri Özel İhtisas Komisyonu, 1995). Alüminyum, hafifliği, rahat işlenebilirliği, iletkenliği, sağlam olması ve korozyondan etkilenmemesi gibi özellikleriyle diğer tüm metallere göre daha fazla avantaja sahiptir. Bu avantajlar sebebiyle pek çok üretim dalında tercih edilir. Saf olarak kullanıldığı gibi, alaşım olarak da kullanılabilir. Sıcak çekilmeyi azaltmak, korozyona olan direnci, akışkanlığı, işlenebilirlik ve kaynak edilebilirlik özelliklerini arttırmak hedefi ile alüminyuma yüzden fazla çeşitte alaşım elementleri eklenebilmektedir (Yağcıgil, 1997).

ÖZELLİK	ALÜMİNYUM	MAGNEZYUM	TİTANYUM	PASLANMAZ ÇELİK
Ergime noktası (°C)	474-638	455-610	1604-1660	1400-1427
Yoğunluk (gr/cm ³)	2.80	1.84	4.43	7.76
Çekme gerilimi (MPa)	300-525	280	1205	510-860
Elastisite modülü (GPa)	72	45.5	119	203
Isıl genleşme katsayısı (10 ⁻⁶ .K ⁻¹)	23.6	26.0	8.0	16.5
Isıl iletkenliği (W.m ⁻¹ .K ⁻¹)	130	84	5.6	18.0

Periodic Table of the Elements

13
Al
Aluminum
26.982

Yoğunluk: 2.70 g/cm³
Ergime sıcaklığı: 660.32 °C
Kaynama sıcaklığı: 2470 °C




Şekil 4.2. Alüminyum metali özellikleri

Şekil 4.2.'de Alüminyum metalinin yoğunluk ergime sıcaklığı kaynama sıcaklığı ve katı haldeki görünümü yer almaktadır.

Türkiye’de alüminyum sanayisinin kurulmasına yönelik çalışmalar, 1960’lardan itibaren, özellikle dayanıklı tüketim mallarının üretimine başlanmasına ve otomotiv sektöründeki gelişmelere paralel olarak artmıştır. 1962 yılında M.T.A. Konya ili Seydişehir ilçesi Mortaş ve Doğanlıkuzu yörelerinde başlatmış olduğu araştırmalar sonucunda, 1964 yılında bu bölgede 25 milyon tonajında boksit rezervi bulunduğunu saptanmış ve 1965 yılı itibariyle ise bulunan bu maden sahaları işletilmek üzere Etibank’a devredilmiştir (Ankara Alüminyum Sanayicileri Derneği, 2003). Tüketim 1970 yılında 20.000 tondan 1992 yılında 150.000 tona, 2005’de ise 700.000 tona yükselmiştir. Türkiye’de 2.5 kg./yıl olan kişi başına düşen tüketim, gelişmiş ülkelerdeki 30 kg./yıl seviyesindeki tüketimin oldukça altındadır (Anon., 2011).

4.2. Alüminyum Kullanım Alanları

Alüminyum inşaattan tarıma kadar pek çok alanda kullanılmaktadır. Şekil 4.3.’te görüldüğü gibi alüminyum en yüksek oranda inşaat ve ulaşım sektörlerinde kullanılmaktadır. Bunları ambalajlama ve elektrik sektörleri izlemektedir. Bu çalışmada ise inşaat sektöründe kullanılan boyalı alüminyum konu alınmıştır.



Şekil 4.3. Kullanım alanlarına göre alüminyum

İnşaat: Konut ve diğer yapılar, karayolları, radyatör, bina çatı iskeleti, seralar, kapı/pencere doğramaları, cephe/çatı kaplamaları ve aksesuarlar gibi pek çok alanda kullanılır. Alüminyum sağlamlığı yanında dekoratif görünümü ile de tercih edilir. Gerek natürel veya renkli kaplama gerekse lake boyama ile alüminyum; kullanıcılara inşaat sektöründe fazlaca seçenekler sunar (Kocacıçak, 1996).

Otomobil ve Ulaşım: Gün geçtikçe, alüminyumun yüksek mukavemet / ağırlık avantajından yararlanmak için otomobillerde alüminyum kullanımı artmaktadır (Öztürk, 2003). Otomobillerde daha çok döküm parçaları kullanılır. Karayolu, demiryolu, denizyolu ve havayolu taşıtlarında kullanılmaktadır. Alüminyum, araçlarda mukavemetinden herhangi bir taviz verilmeden ağırlığın azaltılabildiği anahtar bir malzemedir. Bunun neticesinde aynı hacimdeki bir motorla daha kısa zamanda istenen hıza ulaşılabilir ve araçta yakıt tasarrufu sağlanabilir. Böylece, alüminyum alaşımlarının ilk alış fiyatı çeliğe göre daha pahalı olmasına rağmen hem araç performansı artırılmış hem de uzun vadede tasarruf sağlanmış olur.

Ambalaj ve İçecek: Alüminyum hava geçirmezliği ve kolay şekillenebilmesi dolayısıyla, konteynir imalatından ilaç kutularına, diş macunu tüpünden folyolarına ve meşrubat kutularına kadar kullanılmaktadır. Alüminyum folyo gıdaların sağlık bilgisi şartlarında taze kullanılabilmesi için kullanılmaktadır. Alüminyum folyolar % 98 saflıkta üretilmektedir. Meyve sulu kutular ve kahve torbaları gibi paketlerde ince bir tabaka (5µ) alüminyum folyo içerir (Öztürk, 2003).

Alüminyumun en yaygın kullanıldığı alanlardan birisi de içecek kutularıdır. Dünyada kullanılan metal kutuların % 80'i alüminyumdur. Bunun nedenleri hafif, açılması kolay, darbeye dayanıklı, sağlam, geri kazanılabilir oluşu ve çabuk soğutma özellikleridir. Toplumun çevre bilincinin artması ve alüminyum üreticilerinin desteğiyle alüminyum içecek kutularını toplama ve geri kazanım programları hızla gelişmiştir. Bu durum özellikle alüminyumun yüksek Pazar payının böyle projeleri gerekli kılan yatırımları teşvik ettiği ülkeler için daha geçerlidir.

Elektrik ve Elektronik Sektörü: İletkenliği nedeni ile iletişim sektöründe kullanılmaktadır. Tel ve kablo üretimi, enerji dağıtım cihazları, güç üretim ve düzeltme araçlarında, haberleşme ve elektronik cihazlarda, iç dağıtım ve aydınlatma gereçlerinde kullanılmaktadır (Ana Metal Sanayileri Özel İhtisas Komisyonu, 1995).

Diğer Kullanım Alanları:

1. Toz haline getirilmiş alüminyum boyalara gümüşümsü renk vermede,
2. Alüminyumun çok hızlı oksitlenme özelliği, kati roket yakıtı olarak kullanılmasını sağlamaktadır. Masif olarak yanmaz özellikte olan alüminyum mikro parçalar haline getirildiğinde büyük ısı açığa çıkararak yanar. Bu özelliği nedeniyle roketlerde yakıt olarak kullanılabilir.

Tüm bu kullanım alanları içerisinde en çok inşaat sektöründe kullanımı olan boyalı alüminyum lezha üretimi konu alınacaktır.

BÖLÜM 5. UYGULAMA

Bu uygulama Türkiye’de faaliyet gösteren bir alüminyum firmasının boyalı yassı mamuller tesisinde gerçekleştirilmiştir. Alüminyum Sanayi Yassı Mamuller tesisinde ürünler dökümden başlayarak haddeleme tavlama soğutma dilme gerdirme boyama ve paketlenme gibi pek çok prosesden geçmektedir. Tüm bu prosesler sonraki nihai malzeme oluşturulup müşteriye sevki gerçekleştirilir.

Fabrikadaki prosesler dökümle başlayıp haddeleme tav gerdirme operasyonları sonucu Şekil 5.1.’de görülen çıplak rulolar halini almaktadır.



Şekil 5.1. Çıplak alüminyum rulo

Şekil 5.1.'deki çıplak rulolar üretildikten sonra müşteriden alınan talebe bağlı olarak farklı renk ve desenlerde boyalı alüminyum rulolar üretilir.



Şekil 5.2. Boyalı alüminyum rulo

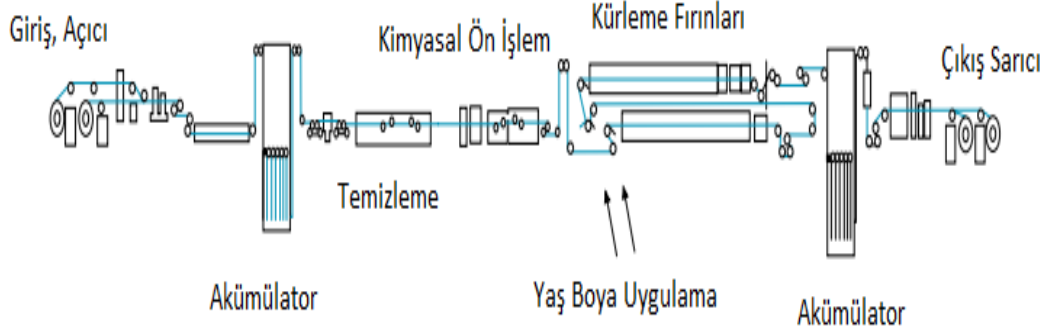
Bobin boyama rulo halindeki Alüminyum' a poliüretan merdaneler ile uygulanan yüksek otomasyona dayalı kesintisiz bir boyama işlemidir.

Şekil 5.2.'de görünen boyalı alüminyum rulolar sırasıyla aşağıdaki gibi işlemlerden geçerek üretilir.

1. Yıkama
2. Gerdirme
3. Astarlama
4. Boyama
5. Kurutma

Şekil 5.3.'te boyama işlemlerinin yapıldığı örnek bir boyama tezgâhı gösterilmiştir. Öncelikle Rulo halinde malzeme hattın girişine takılıp açıcıya bağlanarak hatta ilerlemeye başlar. Ve açılan bu ruloya ilk başta boyanın yapışmasını kolaylaştıracak akım verilir ardından yıkama temizleme yapılır. Bu adımdan sonra kimyasal yıkama astarlama ve yedek merdanelerle boya Alüminyum ruloya aktarımı gerçekleştirilir. Tezgâhtan çıkan rulonun boyalı Şeridi 1 km olan bu hatta kürleme fırınlarında hızlı sıcak hava ile kurutulup ardından Ruloda bulunan akımın ters şekilde alınmasını

sağlayan son akümülatöre de uğrayıp buradan çıkış satıcıda rulo şeklinde sarılarak paketlenmeye hazır hale getirilir.



Şekil 5.3. Sürekli boyama hattı

Boya, katı bir yüzey üzerine yayılabilen, kuruyarak veya sertleşerek o yüzey üzerine yapışıp dekoratif ve koruyucu bir yüzey oluşturan sıvı veya toz malzemelerdir. Bahsedilen bu dekoratif ve koruyucu özelliklerin bazıları aşağıdaki gibidir.

Dekoratif Özellikler: Renk

Parlaklık

Desen

Koruyucu Özellikler: Korozyon direnci sağlama

Su, yağ, aside karşı koruma

Güneş ışığının tahrip edici özelliklerini azaltma

Isı ve ısı değişimlerinden etkilenmesini azaltma

Anti bakteriyellik sağlama

Elektrik yalıtkanlığı sağlama

Boyalı rulo üretiminde en çok bu hatta hurda olmaktadır. Bunun nedenleri aşağıdaki gibi sıralanabilir.

1. Portakallanma oluşumu
2. Oksit lekesi/Korozyon oluşumu
3. Kabarcık(blister) oluşumu
4. Krater oluşumu
5. Renk farklılığı oluşumu
6. Sararma oluşumu
7. Kūrlenme (aşırı kūrlenme/eksik kūrlenme)

Bahsettiğimiz bu kalite kusurları en çok karşılaştığımız kusurlar olup boyalı malzemeler detayında incelediğimiz Parlaklık ve kaplama değeri parametreleri ile bağımlı kusurlardır. Kısaca etkileri şu şekilde açıklanabilir.

Portakallanma oluşumu; Boyanın yayılma sorunundan kaynaklanan bir kusurdur. Yani yoğunluk yüzey alanı ve dolayısıyla Kaplama Alanı değeriyle bağımlı olup doğru hesaplanan bir Kaplama Alanı parametresiyle portakallanma sorunu önlenir. Örneği Şekil 5.4.'teki gibi görülmektedir.



Şekil 5.4. Potakalanma yaşanan yüzey görüntüsü

Oksit lekesi/Korozyon oluşumu; Malzemelerin çevreleriyle girdikleri kimyasal ve elektrokimyasal tepkimeler sonucunda tahrip olmaları olarak tanımlanan doğal bir olgudur. Yıkama kaynaklı su lekeleri ve oksitlenme nedeniyle oluşan bu kusur boyama sonrasında boyanın parlaklığını düşürdüğü için istenmeyen bir durumdur. Örneği Şekil 5.5.'deki gibi görülmektedir.




Şekil 5.5. Korozyon örneği

Kabarcık(blister) oluşumu; Boyalı metalin yüzeyinde suda çözünme özelliğinde herhangi bir kalıntı varsa ve yüzey su ya da neme maruz kalırsa, filmin altında ve üstünde çözünür malzeme derişimi eşitlenene kadar boya filminin bir tarafından diğerine su geçişi oluşur. Böylece, boya filmi üzerinde içi su dolu kabarcıklar (blisterler) oluşur. Örneği Şekil 5.6.'daki gibi görülmektedir.



Şekil 5.6. Boyalı alüminyum yüzeydeki blister oluşumu

Krater oluşumu; Boya yüzeyinde oluşan yoğunluk temelli bir alçaklı ve yüksekli yüzey gerilimden kaynaklanan yarıklara krater denmektedir. Örneği Şekil 5.7.'deki gibi görülmektedir.



Şekil 5.7. Krater oluşumu

Renk Farklılığı ve Sararma; Doğru homojenleştirilememiş boya kullanımı astar kalitesi gibi nedenlerle oluşabilmektedir. Bu iki durumda da müşteriye malzeme gönderimi gerçekleştirilemez.

Kürlenme (aşırı kürlenme/eksik kürlenme); Kürleme Aşırı kürlendiğinde malzemenin parlaklığını düşürür ve kırılganlığını artırır bu nedenle istenmeyen bir durumdur. Eksik kürlenmesi ise dış etkilere kimsayallara karşı direnci düşük olacağından zayıf bir malzeme kabul edilir.

Uygulanan tüm bu prosesler istenen sipariş özelliklerine göre çeşitlilik göstermektedir örneğin ahşap renk boyalı bir dış cephe için birbirinden farklı alıştırma ve kondisyona sahip malzemeler üretilmektedir bu farklılıklar Proseslerin de gördükleri tav sıcaklıkları tav süreleri haddelme işlemleri gibi süreç farklılıklarıyla elde edilir.

Müşterinin istediği mekanik özelliklere getirilen malzemeyi talep edilen renk ve desene boyama operasyonuna geçilir. Bu operasyon geri dönüşümündeki zorluk, süreç maliyeti ve boya maliyetinin yüksek olması nedeniyle oldukça önem taşımaktadır. Kullanılan boya için iki çıktı değeri müşteri memnuniyeti açısından ve verimlilik açısından son derece önemlidir; bunlar Parlaklık ve Kaplama Alanı değerleridir.

Parlaklık bir yüzeyin üzerine düşen ışınları yansıtması demek olup, Parlaklık derecesi bir kaynaktan gelen ışınlarla yüzeyde oluşan görüntünün netlik derecesi ile ifade edilir. Şekil 5.8.'de gösterilen cihaz yardımıyla ölçümü sağlanır. G.U (Gloss Unit) birimi ile ifade edilir.



Şekil 5.8. Parlaklık ölçüm cihazı

Parlaklık değeri müşteri standartlarının altında olduğunda memnuniyetsizlik ve buna bağlı iade durumları oluşmaktadır. Bu nedenle istenen eşik değerleri arasında bulunması elzemdir.

Kaplama Alanı boyanın malzemenin ne kadarını kapladığını ölçen yoğunluk viskozite ve ısı ile ilgili bir değer olup boyalı malzeme üretmenin birinci ölçütüdür. Birimi $m^2/kg/\mu$ ile ifade edilmektedir.

Kaplama Alanı değerinin bilinmesi kaç km malzemenin boyanması için ne kadar boya sarfı gerektirdiği hesaplama anlamında önemlidir. Boyanın tedarik edilmesi süreci uzun olması ve az gelen boyanın siparişi geciktirme manasına gelmesi ve fazla alınan boyanın ise kullanılmadığı için ekstra maliyet olarak zarar verdiği gerekçeleriyle dikkat edilmesi gereken önemli faktörlerden biri olarak karşımıza çıkmaktadır.

Kaplama Alanının olağandan düşük hesaplanıp toplam malzemenin boyanamaması malzemeyi eksik üretmeye müşteri talebini karşılayamaya neden olmaktadır. Veya müşteri miktarda ısrarcı ise, farklı boya ile üretim yapıldığından renkte farklılık oluşma riski ortaya çıkacaktır. Bu ise müşteriye gönderme riski alınamayan bir durumdur çünkü çoğu boyalı rulolar dış cephe giydirmelerinde kullanılmaktadır ve müşteri aynı proje içerisinde iki farklı tonu kabul etmeyecektir.

Boyalı yassı mamul üretiminde tahmini kritik olan Parlaklık ve Kaplama Alanı değerlerini etkileyen 5 ana faktör bulunmaktadır bunlar sırasıyla aşağıdaki gibi gösterilmektedir.

1. Uygulama Koşulları
2. Kuruma Zamanı
3. Yoğunluk
4. Hacimsel Km Miktarı
5. Katı İçerik Miktarı



Şekil 5.9. Girdi çıktı parametreleri

Uygulama Koşulları: Uygulanacak boyalar 15 dakika süresince belirli sıcaklıklarda karıştırılarak boyanın homojenliği sağlanır. Uygulama koşulu ise 15 dakika boyunca hangi sıcaklıkta karıştırıldığını gösteren parametredir. Derece olarak ifade edilmektedir.

Kuruma zamanı: Kuruma zamanı aslında isminde geçtiği gibi süreyi ifade etmez Malzemeye uygulanmış boyanın kaç derece sıcaklık aralığında kurduğunu gösteren parametredir. Ortalama sıcaklık derecesi ile ifade edilir.

Yoğunluk: gr/cm^3 formülü ile ifade edilen boyanın yoğunluğunun gösterildiği parametredir.

Hacimsel km miktarı: Rulo malzemenin yüzey alanını km cinsinden vererek gösteren parametredir.

Katı içerik miktarı: Yaş boyanın uçucu olmayan kısmına katı içerik miktarı denmektedir. Ortalama kg olarak ifade edilmektedir.

Girdi parametreleri ve çıktı parametreleri Şekil 5.9.'da gösterilmiştir. Bu çalışmada da bağımsız 5 ana girdiye karşılık bağımlı 2 çıktının vereceği tepki incelenip tahmin edilmeye çalışılmıştır.

Bağımsız değişkenler ve bağımlı değişkenler aşağıdaki gibi ifade edilmiştir. Elde edilecek regresyon tahmin denklemlerinde bu değişkenlerle gösterilecektir.

1. Y_1 = Kaplama Alanı, Bağımlı Değişkeni
2. Y_2 =Parlaklık, Bağımlı Değişkeni
3. X_1 =Uygulama Koşulları, Bağımsız Değişkeni
4. X_2 = Kuruma Zamanı, Bağımsız Değişkeni
5. X_3 = Hacimsel km Miktarı, Bağımsız Değişkeni
6. X_4 = Yoğunluk, Bağımsız Değişkeni
7. X_5 = Katı İçerik Miktarı, Bağımsız Değişkeni

Tez çalışmasının yapılabilmesi için 1250 adet yaklaşık 2 yıllık veri kümesi kullanılmıştır. Test verileri ise ana veri kümesinden bağımsız olarak ana veri kümesinin %20 si büyüklüğünde bir veri kümesi olarak alınmıştır.

Yöntem olarak YSA ve Çoklu Regresyon yöntemleri kullanılmıştır. YSA modeli Matlab yazılımı kullanılarak çözülmüştür. Çoklu regresyon yöntemi ise Excel Solver yazılımı aracılığıyla çözümlenmiştir. Daha sonra iki model arasındaki başarı oranı R

Regresyon oranı, MAD, MSE ve MAPE yöntemleri ile karşılaştırılarak daha iyi olanı seçilmiştir.

Veri kümesinden alınan bir örneklem Tablo 5.1.'de gösterilmiştir.

Tablo 5.1. Veri kümesi örnekleme

X_1 UYGULAMA KOŞULLARI	X_2 KURUMA ZAMANI	X_3 YOĞUNLUK	X_4 HACİMSEL KM MİKTARI	X_5 KATI İÇERİK	Y_1 KAPLAMA ALANI GERÇEK DEĞERİ	Y_2 PARLAKLIK GERÇEK DEĞERİ
249	249,00	1,27	34,30	47,84	270,10	35,00
224	228,00	1,32	51,80	93,71	393,90	26,00
249	251,50	1,17	36,30	96,32	311,00	27,00
232	232,00	1,13	53,80	62,46	476,10	35,00
249	251,50	1,26	35,70	50,08	282,80	29,00
249	251,50	1,19	35,20	46,65	295,60	29,00
243	232,00	1,20	44,12	56,97	367,70	58,00
243	241,00	1,36	49,80	66,27	367,50	27,00
243	243,00	1,25	46,80	57,56	375,30	21,00
232	236,50	1,36	50,60	66,57	372,30	34,00
232	236,50	1,34	54,40	65,92	406,60	30,00
249	249,00	1,31	34,30	49,40	262,40	31,00
249	251,50	1,28	35,10	50,11	275,30	28,00
249	251,50	1,26	34,70	49,40	274,80	26,00
241	241,00	1,42	50,20	67,24	353,50	31,00
249	251,50	1,27	34,90	49,80	274,60	30,00
232	236,50	1,34	50,20	65,90	374,00	38,00
249	251,50	1,19	36,40	47,63	305,60	30,00
232	232,00	1,35	52,40	68,41	388,20	59,00
□	□	□	□	□	□	□

Excel Solver yazılımında çoklu regresyon yöntemi çalıştırılarak regresyon sonuçları Kaplama Alanı çıktısı için Tablo 5.2.'deki sonuçlar elde edilmiştir.

Tablo 5.2. Kaplama alanı regresyon analizi sonucu

ÖZET ÇIKIŞI								
Regresyon İstatistikleri								
Çoklu R	0,990033628							
R Kare	0,980166584							
Ayarlı R Kare	0,980086804							
Standart Hata	9,663064867							
Gözlem	1249							
ANOVA								
	df	SS	MS	F	Anlamlılık F			
Regresyon	5	5735922,782	1147184,556	12285,80172	0			
Fark	1243	116064,9045	93,37482263					
Toplam	1248	5851987,686						
	Katsayılar	Standart Hata	t Stat	P-değeri	Düşük %95	Yüksek %95	Düşük 95,0%	Yüksek 95,0%
Kesişim	317,8215505	15,08620568	21,0670302	1,71474E-84	288,2243111	347,41879	288,2243111	347,41879
X Değişkeni 1	0,278605454	0,120865324	2,305090037	0,021325619	0,041482879	0,515728029	0,041482879	0,515728029
X Değişkeni 2	-0,066020198	0,128716993	-0,512909732	0,608105603	-0,318546762	0,186506365	-0,318546762	0,186506365
X Değişkeni 3	-311,0238056	2,73968708	-113,5253029	0	-316,3987273	-305,6488839	-316,3987273	-305,6488839
X Değişkeni 4	8,532008715	0,06077744	140,3811797	0	8,412771016	8,651246413	8,412771016	8,651246413
X Değişkeni 5	-0,017886537	0,025466671	-0,702350835	0,482591898	-0,067848944	0,03207587	-0,067848944	0,03207587

Tablo 5.2.'deki özet çıktıdan hareketle verinin tutarlılığını gösteren R kare ve Çoklu R değerlerini 0,99 ve 0,98 oranda çıktığını görmekteyiz. 0,99 ve 0,98 oranı R kare ve Çoklu Regresyon değerleri için çok yüksek oranlardır. Bu değer ise şunu ifade eder; Y_1 Kaplama Alanı çıktısının çok yüksek oranda ilişkili olarak girdilere bağımlı olduğu göstermektedir. Standart hata 9,66 ile oldukça düşük çıkmıştır. Ve son tabloda görüldüğü üzere 5 girdi değişkenimizin Kaplama Alanı değerini açıklayan katsayıları listelenmiştir. Buna göre Kaplama Alanı çıktısının girdilerle olan ilişkiyi ifade eden regresyon denklemi (Denklem 5.1) de görüldüğü gibi ortaya çıkar.

$$Y_1 = 317,82 + 0,28X_1 + (-0,07)X_2 + (-311,02)X_3 + 8,53X_4 + (-0,02)X_5 \quad (5.1)$$

Excel Solver yazılımında Çoklu Regresyon yöntemi çalıştırıldığında regresyon sonuçları Parlaklık çıktısı için Tablo 5.3.'te görüldüğü gibi elde edilmiştir.

Tablo 5.3. Parlaklık değeri doğrusal regresyon analizi sonucu

ÖZET ÇIKIŞI								
<i>Regresyon İstatistikleri</i>								
Çoklu R	0,174721586							
R Kare	0,030527633							
Ayarlı R Kare	0,026627905							
Standart Hata	17,85571665							
Gözlem	1249							
ANOVA								
	<i>df</i>	<i>SS</i>	<i>MS</i>	<i>F</i>	<i>Anlamlılık F</i>			
Regresyon	5	12479,10366	2495,820731	7,82814419	2,8803E-07			
Fark	1243	396301,4852	318,8266172					
Toplam	1248	408780,5889						
	<i>Katsayılar</i>	<i>Standart Hata</i>	<i>t Stat</i>	<i>P-değeri</i>	<i>Düşük %95</i>	<i>Yüksek %95</i>	<i>Düşük 95,0%</i>	<i>Yüksek 95,0%</i>
Kesişim	61,86801133	27,87676763	2,219339493	0,026643606	7,177296863	116,5587258	7,177296863	116,5587258
X Değişkeni 1	-0,301170392	0,223338765	-1,348491347	0,177746047	-0,73933298	0,136992195	-0,73933298	0,136992195
X Değişkeni 2	0,179637464	0,237847328	0,755263744	0,450233831	-0,286989101	0,646264028	-0,286989101	0,646264028
X Değişkeni 3	-8,064297804	5,062480372	-1,592953891	0,111424778	-17,99624803	1,867652419	-17,99624803	1,867652419
X Değişkeni 4	0,240129868	0,112306474	2,138165845	0,03269782	0,01979868	0,460461055	0,01979868	0,460461055
X Değişkeni 5	0,057646844	0,047058119	1,225013774	0,220802115	-0,034675271	0,149968959	-0,034675271	0,149968959

Tablo 5.3.'de çıkan değerlerin R kare ve Çoklu R regresyon değerleri 0,03 ve 0,17 oranında olduğu gözlemlenmektedir. Çoklu R ve R kare değerlerinin çok düşük kaldığı durumlarda veri kümesinin çıktı ile yeteri kadar ilişkili olmadığı anlaşılmaktadır. Böylece girdi faktör değerlerinin Parlaklık çıktı değerini yeteri kadar açıklayamadığı kabul edilmektedir. Buna bağlı olarak yapılan tahminlerde hata oranlarının yüksek olacağı öngörülerek 5 girdi değeri ile Parlaklık çıktı değerini açıklayan aşağıdaki regresyon denkleminin (Denklem 5.2) yeterli olmaması sebebi ile farklı regresyon modelleri de çalıştırılmıştır.

$$Y_2 = 61,8 + (-0,3)X_1 + 0,17X_2 + (-8,06)X_3 + 0,24X_4 + 0,05X_5 \quad (5.2)$$

Bu durumda regresyon denkleminde kareler toplamı, küpler toplamı eklenerek elde edilen regresyon denklemleri denenecektir. Denenen Çoklu Regresyon denklemleri ve bunların Çoklu R ve R kare sonuçları Tablo 5.4.'de gösterilmiştir.

Tablo 5.4. Çoklu regresyon parlaklık denklemleri

Parlaklık Çoklu Regresyon Denklemleri	Çoklu R	R Kare
$Y_2 = X_1 + \dots + X_5$	0,17	0,03
$\ln Y_2 = X_1 + \dots + X_5$	0,17	0,03
$1/Y_2 = X_1 + \dots + X_5$	0,11	0,013
$Y_2 = X_1 + \dots + X_5 + X_1^2 + \dots + X_5^2$	0,23	0,05
$1/Y_2 = X_1 + \dots + X_5 + X_1^2 + \dots + X_5^2$	0,40	0,16
$\ln Y_2 = X_1 + \dots + X_5 + X_1^2 + \dots + X_5^2$	0,24	0,06
$Y_2 = X_1 + \dots + X_5 + X_1^2 + \dots + X_5^2 + X_1^3 + \dots + X_5^3$	0,30	0,09
$1/Y_2 = X_1 + \dots + X_5 + X_1^2 + \dots + X_5^2 + X_1^3 + \dots + X_5^3$	0,48	0,23
$\ln Y_2 = X_1 + \dots + X_5 + X_1^2 + \dots + X_5^2 + X_1^3 + \dots + X_5^3$	0,30	0,09
$\sqrt[2]{Y_2} = X_1 + \dots + X_5 + X_1^2 + \dots + X_5^2 + X_1^3 + \dots + X_5^3$	0,30	0,09
$-Y_2 = X_1 + \dots + X_5 + X_1^2 + \dots + X_5^2 + X_1^3 + \dots + X_5^3$	0,30	0,09

Parlaklık çıktısı ile girdi faktörleri arasındaki çeşitli regresyon modelleri denerek daha yüksek Çoklu R ve R kare sonuçlarının elde edilmesi amaçlanarak 11 farklı Çoklu Regresyon denklemi üzerine Excel Solver yazılımı Çoklu Regresyon metodu çalıştırılmıştır. Tablo 5.4’de görülen Çoklu Regresyon modeli denklemlerinde en iyi sonuç Çoklu R için 0,48 R Kare için ise 0,23 olarak elde edilmiştir. Çoklu Regresyon yöntemi ile çalıştırılan işlemlerden en yüksek Çoklu R ve R kare değerine sahip olan Regresyon denklemi modeli çıktıları Tablo 5.5.’teki gibi elde edilmiştir.

Tablo 5.5. Geliştirilmiş çoklu regresyon analizi sonuçları

ÖZET ÇIKIŞI									
Regresyon İstatistikleri									
Çoklu R	0,48006445								
R Kare	0,230461877								
Ayarlı R Kare	0,221100099								
Standart Hata	0,68531931								
Gözlem	1249								
ANOVA									
	df	SS	MS	F	Anlamlılık F				
Regresyon	15	173,4275016	11,56183344	24,61732002	4,09982E-60				
Fark	1233	579,0939316	0,469662556						
Toplam	1248	752,5214332							
	Katsayılar	Standart Hata	t Stat	P-değeri	Düşük %95	Yüksek %95	Düşük 95,0%	Yüksek 95,0%	
Kesişim	-57510,44635	7319,797072	-7,856836163	8,52571E-15	-71871,08175	-43149,81094	-71871,08175	-43149,81094	
X Değişkeni 1	-315,1591784	46,72739739	-6,744633683	2,35242E-11	-406,8331839	-223,4851728	-406,8331839	-223,4851728	
X Değişkeni 2	-44,84467713	9,590248533	-4,676070383	3,2462E-06	-63,65968815	-26,02966611	-63,65968815	-26,02966611	
X Değişkeni 3	-92,82739951	111,3044818	-0,833995164	0,404445248	-311,1945299	125,5397309	-311,1945299	125,5397309	
X Değişkeni 4	1,14981662	0,588852732	1,952638676	0,051088435	-0,005447565	2,305080804	-0,005447565	2,305080804	
X Değişkeni 5	0,243290986	0,117629423	2,068283428	0,038821491	0,012515018	0,474066955	0,012515018	0,474066955	
X Değişkeni 6	7807,137687	1162,088738	6,718194085	2,80315E-11	5527,247615	10087,02776	5527,247615	10087,02776	
X Değişkeni 7	1106,741493	242,0845604	4,57171449	5,32408E-06	631,7982566	1581,684729	631,7982566	1581,684729	
X Değişkeni 8	170,1325349	197,4395727	0,861694201	0,389023363	-217,222154	557,4872238	-217,222154	557,4872238	
X Değişkeni 9	-11,39238001	6,124758265	-1,860053821	0,06311589	-23,40848094	0,62372091	-23,40848094	0,62372091	
X Değişkeni 10	-3,627272087	1,646549383	-2,20295372	0,027782453	-6,857620568	-0,396923606	-6,857620568	-0,396923606	
X Değişkeni 11	0,000365363	5,33059E-05	6,85407667	1,13124E-11	0,000260782	0,000469943	0,000260782	0,000469943	
X Değişkeni 12	5,27338E-05	1,02408E-05	5,149378245	3,0396E-07	3,26424E-05	7,28251E-05	3,26424E-05	7,28251E-05	
X Değişkeni 13	3,534653116	4,870973231	0,725656445	0,468187115	-6,021659706	13,09096594	-6,021659706	13,09096594	
X Değişkeni 14	-4,47929E-05	2,12759E-05	-2,10533987	0,035463573	-8,65339E-05	-3,05202E-06	-8,65339E-05	-3,05202E-06	
X Değişkeni 15	-1,99138E-06	1,2766E-06	-1,559906629	0,119038564	-4,49593E-06	5,13172E-07	-4,49593E-06	5,13172E-07	

Tablo 5.5.'teki özet çıktıdan hareketle verinin tutarlılığını gösteren R kare ve Çoklu R değerlerinin değerlerini 0,23 ve 0,48 oranda çıktığını görmekteyiz. 0,23 ve 0,48 oranı R kare ve Çoklu Regresyon değerleri veri kümesinin bağımsız girdi değişkenleri ve bağımlı çıktı değişkenleri arasında 0,48 oranında çok yüksek olmayan bir bağlantı olduğunu göstermektedir. Bu oran hesaplanmak istenen Parlaklık parametresinin girdi faktörleri ile yeterli derecede açıklanabilir olmadığı anlamını taşımaktadır. Standart hata 0,68 olarak çıkmıştır. Ve son tabloda görüldüğü üzere 5 girdi değişkenimizin Parlaklık değerini açıklayan katsayıları ekstra küpler ve ekstra kareler parametreleri için listelenmiştir. Buna göre Parlaklık çıktısının girdilerle olan ilişki (Denklem 5.3) gibi olmaktadır.

$$\begin{aligned}
 1/Y_2 = & - 57510,45 + (-315,16)X_1 + (-44,84)X_2 + (-92,83)X_3 + 1,15X_4 \\
 & + 0,24X_5 + 7807,14X_1^2 + 1106,74X_2^2 + 170,13X_3^2 \\
 & + (-11,39)X_4^2 + (3,63)X_5^2 + (3 \times 10^{-3})X_1^3 + (5,27 \times 10^{-5})X_2^3 \\
 & + 3,53X_3^3 + (-4,47 \times 10^{-5})X_4^3 + (-1,99 \times 10^{-6})X_5^3
 \end{aligned} \tag{5.3}$$

Parlaklık çıktısı ile girdi faktörleri arasında oluşturulan regresyon denklemlerinin düşük seviyelerde sonuç verdiği görülmüş, buna karşılık alternatif olarak YSA – Yapay Sinir Ağları yönteminin kullanmasına karar verilmiştir.

Aşağıda Kaplama Alanı ve Parlaklık çıktıları ile girdiler arasındaki tahminler için sırasıyla YSA tahmin modelleri uygulanacaktır.

Ana veri kümesinin, 1250 adedi eğitim veri kümesi olarak Matlab Yapay Sinir Ağları modülünde eğitilerek en doğru ağ ve nöron sayısı saptanmaya çalışılmıştır. Denenen modeller ve bunlara ait istatistikî değerler aşağıdaki gibi elde edilmiştir.

Denemeler; 5 nöronlu, 10, 15, 20, 30, 50, 100 ve 200 nöronlu yapılar oluşturularak gerçekleştirilmiştir. Bu yapılar arasında tümüne oranla en iyi tahmini yapan 3 ağ; 10, 20 ve 30 nöronlu YSA olmuştur.

En iyi sonucu veren 3 ađın tahmin deđerleri ve karřılařtırması ařađıdaki gibi 3 farklı yöntemle karřılařtırılarak Tablo 5.6.'deki ve Tablo 5.7.'deki deđerler elde edilmiřtir.

Tablo 5.6. Farklı nörön sayılı YSA kaplama alanı tahminlerinin karřılařtırması

Kaplama Alanı	MAD- Ortalama Mutlak Hata	MSE- Ortalama Hatalar Karesi	MAPE- Ortalama Mutlak Yüzde Hata	R Oranı
10 nörönlu ađ	0,99	483,65	0,83%	0,97
20 nörönlu ađ	17,84	6923,45	16,70%	0,91
30 nörönlu ađ	0,03	3,01	0,34%	0,99


Tablo 5.7. Farklı nörön sayılı YSA parlaklık tahminlerinin karřılařtırılması

Parlaklık	MAD- Ortalama Mutlak Hata	MSE- Ortalama Hatalar Karesi	MAPE- Ortalama Mutlak Yüzde Hata	R Oranı
10 nörönlu ađ	1,86	172,70	0,33%	0,97
20 nörönlu ađ	30,72	2931,99	1,65%	0,91
30 nörönlu ađ	0,59	123,38	0,21%	0,99

Tablo 5.6.'deki ve Tablo 5.7.'deki deđerler 3 farklı yöntemle bulunmuř hataların Kaplama Alanı ve Parlaklık için verdiđi hata karřılařtırmasını göstermektedir. Bu yöntemlerin tümü için en başarılı yöntem en küçük hataya sahip olan seçenek olmaktadır.

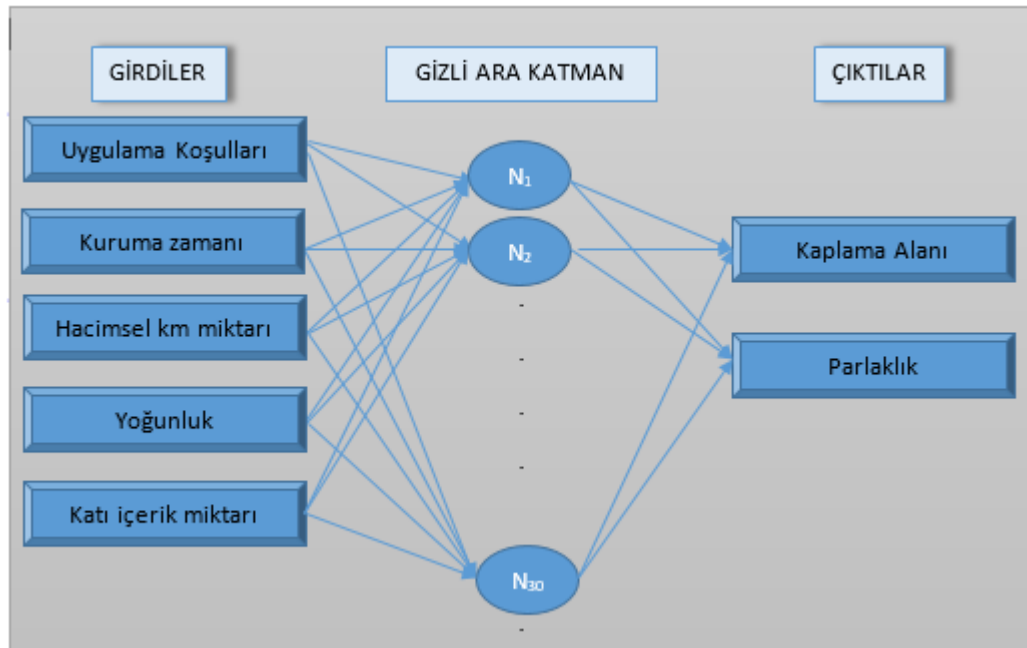
Elde edilen bu hata oranlarından hareketle 20 nörönlu ađ diđer ađlara kıyasla çok kötü bir performans sergilemiřtir. 10 ve 30 nörönlu ađlar birbirine çok yakın deđerlerde tahminler yapmıř olup 30 nörönlu ađ 10 nörönlu ađdan daha iyi bir tahmin sađlamıřtır. Ancak tüm denenen ađlar iđerisinden en dođru tahminlemeyi 30 nörönlu ađ yapmıř bulunmaktadır. Bu nedenle 30 nörönlu YSA tahmin modeli ile her iki çıktı (Y_1 , Y_2) için de en iyi sonuçlar $R = 0.99$ olarak Tablo 5.6.'de ve Tablo 5.7.'de elde edilmiřtir.

Kurulan ađın řeması ařađıdaki gibi olup 5 girdili (X_1 , X_2 , X_3 , X_4 , X_5) saklı katmanda 30 nörönla alıřan çıktı olarak 2 çıktıyı (Y_1 , Y_2) tahminleyen bir model olduđunu göstermektedir.



Şekil 5.10. 30 nöronlu ağ yapısı

Şekil 5.10.'daki Yapay Sinir ağı modeli Matlab programında oluşturulmuş ağ görünümüdür girdi çıktı değişkenlerinin isimleriyle belirtildiği Şekil 5.11.'de ağ daha detaylı olarak görülmektedir.

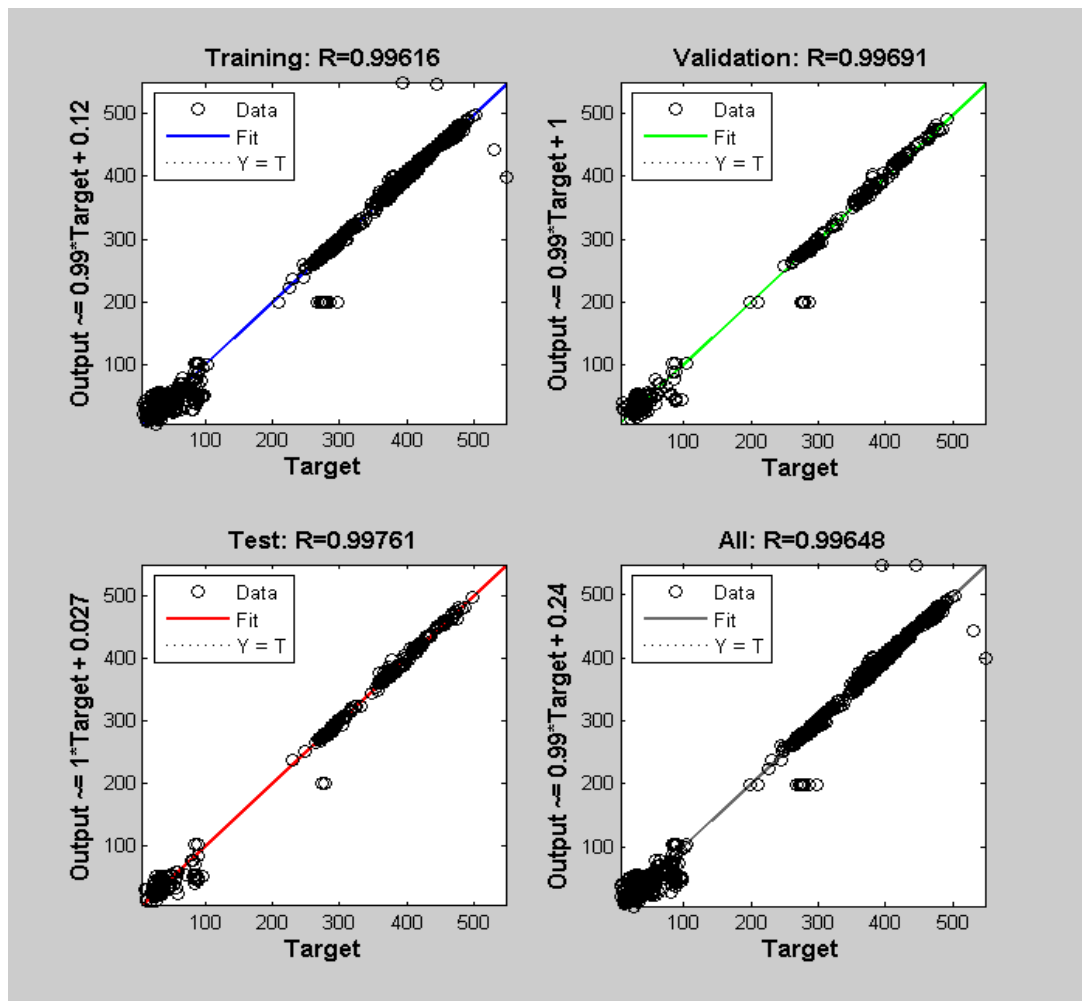


Şekil 5.11. 30 nöronlu yapay sinir ağı

Ağ ile öncelikli olarak 30 nöronlu öğrenme denemeleri yapılmıştır. 10 deneme sonrasında ağ her denemede nerdeyse aynı sonuçları vermeye başlamıştır. Ağın bu şekilde sürekli aynı sonucu veriyor olması ağın öğrenmeyi tamamladığı anlamına gelmektedir. Bu aşamada ağa bir isim verilerek kaydedilir ve tahmin yapmaya hazır hale getirilir. Öğrenmeyi sağladığımız bu ağın çıkan R istatistik değerleri kararlılığa

ulaştığında ağ tahminleme modelini gerçekleştirmek için olgunlaşmış olduğuna karar verilerek kaydedilmiştir.

Şekil 5.12.'de öğrenmesi tamamlanmış ağın verdiği deneme test değerleri R istatistik değerleri gösterilmiştir. R istatistik değerlerinin 1'e yakın olması bu ağın kendi içinde tutarlı ve açıklanabilir olduğunu göstermektedir.



Şekil 5.12. 30 nöronlu YSA modelinin gerçekleştirdiği tahmin sonuçları

30 nöronlu ağ yapısıyla öğrenme tamamlanmış ve Data 0,99 oranında kendini açıklayan 0,99 oranında tahmini gerçekleştiren ve aynı doğrulukla test edebilir bir ağ olduğu ortaya çıkmıştır. Elde edilen R oranları Tablo 5.8.'deki gibi gösterilmiştir. Tablo 5.8.'e göre eğitilmiş YSA 0,99 oranında öğrenme sağlanmış, bu öğrenmeyi 0,99 oranında doğrulamış, öğrenmesi tamamlanmış bu ağın test verileriyle testinde 0,99

regresyon değeri elde edilmiş ve tüm YSA Regresyon değeri 0,99 olarak elde edilmiştir.

Tablo 5.8. 30 nöronlu eğitimi tamamlanmış ağıın R oranları

	R Oranı
Öğretme	0,9961
Doğrulama	0,9969
Test	0,9976
Tümü	0,9964

30 nöronlu eğitimi tamamlanmış ağ kullanılarak test verisi ile gerçekleştirilmiş birkaç X_1, X_2, X_3, X_4, X_5 girdi değerleri için elde edilmiş Y_1 , Kaplama Alanı ve Y_2 , Parlaklık çıktısı sonuçları Tablo 5.9.'daki gibi elde edilmiştir.

Tablo 5.9. 30 nöronlu YSA tahmin sonuçları ve gerçek değerler

X_1 UYGULAMA KOŞULLARI	X_2 KURUMA ZAMANI	X_3 YOĞUNLUK	X_4 HACİMSEL KM MİKTARI	X_5 KATI İÇERİK	Y_1 KAPLAMA ALANI GERÇEK DEĞERİ	Y_1 KAPLAMA ALANI YSA TAHMİNİ	Y_2 PARLAKLIK GERÇEK DEĞERİ	Y_2 PARLAKLIK YSA TAHMİNİ
249	249,00	1,27	34,30	47,84	270,10	269,71	35,00	34,95
224	228,00	1,32	51,80	93,71	393,90	394,19	26,00	25,74
249	251,50	1,17	36,30	96,32	311,00	310,17	27,00	26,98
232	232,00	1,13	53,80	62,46	476,10	475,38	35,00	35,20
249	251,50	1,26	35,70	50,08	282,80	283,16	29,00	28,40
249	251,50	1,19	35,20	46,65	295,60	295,94	29,00	29,77
243	232,00	1,20	44,12	56,97	367,70	367,49	58,00	58,94
243	241,00	1,36	49,80	66,27	367,50	367,84	27,00	26,14
243	243,00	1,25	46,80	57,56	375,30	374,32	21,00	21,33
232	236,50	1,36	50,60	66,57	372,30	371,87	34,00	32,93
232	236,50	1,34	54,40	65,92	406,60	406,40	30,00	31,47
249	249,00	1,31	34,30	49,40	262,40	263,29	31,00	31,87
249	251,50	1,28	35,10	50,11	275,30	274,01	28,00	28,53
249	251,50	1,26	34,70	49,40	274,80	275,14	26,00	27,48
241	241,00	1,42	50,20	67,24	353,50	354,91	31,00	31,44
249	251,50	1,27	34,90	49,80	274,60	274,55	30,00	28,04
232	236,50	1,34	50,20	65,90	374,00	374,83	38,00	39,24
249	251,50	1,19	36,40	47,63	305,60	305,99	30,00	28,30
232	232,00	1,35	52,40	68,41	388,20	388,43	59,00	60,89
□	□	□	□	□	□	□	□	□

Tahmin edilen Y_1 ve Y_2 değerleri için Çoklu Regresyon ve Yapay Sinir Ağları Yöntemi kullanılmıştır. Y_1 , Kaplama Alanı değeri tahmini için kullanılan her iki yöntem de $R=0,99$ ile yüksek oranda R değeri ile başarılı ve kendini açıklayabilen modellerle tahmini gerçekleştirmiştir.

Toplamda denenen 2 yöntemden alınan çıktıları Parlaklık için şu şekilde olmaktadır; Y_2 , Parlaklık değeri için birbirinden farklı 11 lineer, lineer olmayan Çoklu regresyon denklemleri denenmiş olmasına rağmen R Kare değeri 0,48 en yüksek değerine sahip olmuştur. Y_2 , Parlaklık değeri Yapay Sinir Ağları Modeli ile ise $R=0,99$ ile tahmini gerçekleştirmiştir. Bu durum parlaklık değeri tahmini için Çoklu Regresyon yönteminin yetersiz kaldığını ancak Yapay Sinir Ağları yönteminin ise başarılı olarak tahminlerde kullanıldığını göstermektedir.

Toplamda denenen 2 yöntemden alınan çıktıları Kaplama Alanı için şu şekilde olmaktadır; Y_1 , Kaplama Alanı değeri için Çoklu regresyon 0,99 R Kare değeri 0,98 en yüksek değerine sahip olmuştur. Y_1 , Kaplama Alanı değeri Yapay Sinir Ağları Modeli ile ise $R=0,99$ ile tahmini gerçekleştirmiştir. Bu durum Kaplama Alanı değeri tahmini için Çoklu Regresyon yönteminin de Yapay Sinir Ağları yönteminin ise başarılı olarak tahminlerde kullanıldığını göstermektedir. R değerlerinde gerçekleşen ufak bir farklılıkla YSA'nın daha iyi tahmin edildiği görülmektedir.

BÖLÜM 6. SONUÇLAR VE ÖNERİLER

Bu bölümde uygulama bölümünde anlatılmış olan modellerin sonuçlarına ve değerlendirmelerine yer verilecektir. Çoklu Regresyon ve Yapay Sinir Ağları Tahmin verileri kendi aralarında değerlendirilip en iyi tahmin yapan yöntem ortaya konulacaktır. Ardından seçilen yöntemlerin sonuçlar belirtilecektir.

Öncelikli olarak Çoklu Regresyon Yöntemi ile Kaplama Alanı çıktısı tahmini için R 0,99 oranıyla bulduğumuz (Denklem 6.1) ile tahminleme yapılmıştır.

$$Y_1 = 317,82 + 0,28X_1 + (-0,07)X_2 + (-311,02)X_3 + 8,53X_4 + (-0,02)X_5 \quad (6.1)$$

Çoklu Regresyon yönteminde girdi değeri olan uygulama koşulları, kuruma zamanı, yoğunluk, hacimsel km miktarı, katı içerik miktarına olan bağıntısını bulduğumuz Kaplama Alanı değerleri için test yapılmıştır. Yapılan hata testi, test veri kümesi ile tahminleme arasındaki hata oranlarından elde edilmiştir. Elde edilen hata testleri verileri aşağıdaki gibi, R Oranı, Ortalama Hatalar Karesi (MSE), Ortalama Mutlak Hata (MAD), Ortalama Mutlak Yüzde Hata (MAPE) hata testleri başlığında Tablo 6.1.'de gösterilmiştir.

Tablo 6.1. Kaplama alanı değerlerinin çoklu regresyon tahmini hata değerleri

Çoklu Regresyon Kaplama Alanı Tahmini Hata Verileri	
Ortalama Mutlak Hata (MAD)	66,16
Ortalama Hatalar Karesi (MSE)	2028
Ortalama Mutlak Yüzde Hata (MAPE)	11,28%
R Oranı	0,9900

Kaplama Alanı çıktısı için karşılaştırma yapmak amacıyla Yapay Sinir Ağları ile eğitilmiş 30 nöronlu tahmin modeli ile ana veriden ayrılan test veri kümesinin tahminlemesi yapılmıştır. Bu veri kümesi ana veri kümesinin %20'si büyüklüğündedir. Test veri kümesi ile tahmin veri kümesi arasındaki hata oranı Kaplama Alanı çıktı değeri için Tablo 6.2.'deki gibi elde edilmiştir.

Tablo 6.2. Kaplama alanı değerlerinin yapay sinir ağları modeli tahmini hata değerleri

YSA kaplama alanı tahmini hata verileri	
Ortalama Mutlak Hata (MAD)	0,03
Ortalama Hatalar Karesi (MSE)	3,01
Ortalama Mutlak Yüzde Hata (MAPE)	0,34%
R Oranı	0,9964

Kaplama Alanı için yapılmış iki model karşılaştırılmasından görüldüğü üzere R oranı her iki modelde de 0,99 ile benzer yakınlıkta çıkmıştır. Elde edilen Çoklu Regresyon ve YSA tahminlerinin ise Kaplama Alanı çıktı değeri için Tablo 6.3.'de gösterildiği gibi YSA metodu ile daha yüksek doğrulukla tahminlenmiştir.

Tablo 6.3. Kaplama alanı yapay sinir ağları ve çoklu regresyon tahminleri karşılaştırma tablosu

Kaplama alanı model tahminleri		
	Çoklu regresyon modeli hata oranı	Yapay sinir ağı modeli hata oranı
Ortalama Mutlak Hata (MAD)	66,16	0,03
Ortalama Hatalar Karesi (MSE)	2.028	3,01
Ortalama Mutlak Yüzde Hata (MAPE)	11,28%	0,34%
R Oranı	0,9900	0,9964

İkinci çıktı olan Parlaklık değeri için sırasıyla Çoklu Regresyon yöntemi ve YSA yöntemi ile yapılan tahminlemeler sonuçları ve karşılaştırmaları aşağıda gösterilecektir.

Parlaklık çıktısı ilk önce Çoklu Regresyon yöntemi ile tahmin edilmiştir. Bu yöntemde girdi değeri olan uygulama koşulları, kuruma zamanı, yoğunluk, hacimsel km miktarı, katı içerik miktarına olan bağıntısını bulduğumuz Parlaklık değerleri için test veri kümesi ile tahminleme yapılmıştır. Çoklu Regresyon yöntemiyle Parlaklık çıktısı için

kurulan $Y_2 = X_1 + \dots + X_5$ denkleminde elde edilen Çoklu ve R kare değerlerinin çok düşük oranda çıkması sebebiyle R değeri geliştirilmesi adına Parlaklık çıktısı tahmini modelinde 11 farklı Çoklu Regresyon modeli oluşturulmuştur. Tablo 6.4.'teki gibi oluşturulmuş modeller test edilmiş ve Çoklu R ve R Kare sonuçları elde edilmiştir.

Tablo 6.4. Parlaklık çıktısı için oluşturulmuş çoklu regresyon denklemleri

Parlaklık çoklu regresyon denklemleri	Çoklu R	R Kare
$Y_2 = X_1 + \dots + X_5$	0,17	0,03
$\ln Y_2 = X_1 + \dots + X_5$	0,17	0,03
$1/Y_2 = X_1 + \dots + X_5$	0,11	0,013
$Y_2 = X_1 + \dots + X_5 + X_1^2 + \dots + X_5^2$	0,23	0,05
$1/Y_2 = X_1 + \dots + X_5 + X_1^2 + \dots + X_5^2$	0,40	0,16
$\ln Y_2 = X_1 + \dots + X_5 + X_1^2 + \dots + X_5^2$	0,24	0,06
$Y_2 = X_1 + \dots + X_5 + X_1^2 + \dots + X_5^2 + X_1^3 + \dots + X_5^3$	0,30	0,09
$1/Y_2 = X_1 + \dots + X_5 + X_1^2 + \dots + X_5^2 + X_1^3 + \dots + X_5^3$	0,48	0,23
$\ln Y_2 = X_1 + \dots + X_5 + X_1^2 + \dots + X_5^2 + X_1^3 + \dots + X_5^3$	0,30	0,09
$\sqrt[2]{Y_2} = X_1 + \dots + X_5 + X_1^2 + \dots + X_5^2 + X_1^3 + \dots + X_5^3$	0,30	0,09
$-Y_2 = X_1 + \dots + X_5 + X_1^2 + \dots + X_5^2 + X_1^3 + \dots + X_5^3$	0,30	0,09

Elde edilen Çoklu R ve R Kare sonuçlarının en yüksek orana sahip olduğu model olarak, Çoklu R değerinin 0,48 R kare değerininse 0,23 olduğu model seçilmiştir. Bu modelin denklemi (Denklem 6.2) ile ifade edilmiştir.

$$\begin{aligned}
 1/Y_2 = & -57510,45 + (-315,16)X_1 + (-44,84)X_2 + (-92,83)X_3 + 1,15X_4 + \\
 & 0,24X_5 + 7807,14X_1^2 + 1106,74X_2^2 + 170,13X_3^2 + (-11,39)X_4^2 + (3,63)X_5^2 + \\
 & (3 \times 10^{-3})X_1^3 + (5,27 \times 10^{-5})X_2^3 + 3,53X_3^3 + (-4,47 \times 10^{-5})X_4^3 + (-1,99 \times \\
 & 10^{-6})X_5^3
 \end{aligned} \tag{6.2}$$

Elde edilen bu denklem ile tahminleme yapılmış ve test verileri ile arasındaki hata oranları ise aşağıdaki gibi R Oranı, Ortalama Hatalar Karesi (MSE), Ortalama Mutlak Hata (MAD), Ortalama Mutlak Yüzde Hata (MAPE) hata testleri başlığında Tablo 6.5.'te gösterilmiştir.

Tablo 6.5. Parlaklık değerlerinin çoklu regresyon tahmini hata değerleri

Çoklu regresyon parlaklık tahmini hata verileri	
Ortalama Mutlak Hata (MAD)	2825
Ortalama Hatalar Karesi (MSE)	639264
Ortalama Mutlak Yüzde Hata (MAPE)	96,04%
R Oranı	0,48

Parlaklık çıktısı için regresyon sonucunun iyi çıkmadığı görülmüş buna karşılık daha iyi bir tahmin sonucu elde etmek için 10, 20, 30 nöronlu YSA denemeleri yapılmıştır. Bunlar içinde 30 nöronla hesaplamaların R 0,99 ile yüksek regresyon oranına sahip sonuçlar olduğu elde edilmiştir. Bu hesaplamalarla ilgili sonuçlar Tablo 6.6.'da görülmektedir.

Tablo 6.6. 30 nöronlu YSA R oranları

	R Oranı
Öğretme	0,9961
Doğrulama	0,9969
Test	0,9976
Tümü	0,9964

Böylece Regresyon yöntemi ile yapılan tahminlerin ilişkileri yeteri kadar yansıtmadığı en yüksek Regresyon R oranının 0,48 şeklinde düşük kaldığı buna karşılık 30 nöronlu YSA yöntemi ile yapılan tahminlemelerin ise Regresyon R oranı 0,99 şeklinde yüksek bir tahmin sonucu verdiği görülmüştür.

R 0,99 sonucu elde edilen 30 nöronlu bu YSA sistemde uygulanarak test edilmiştir. Test kümesi ile tahmin kümesi arasındaki hata oranı Parlaklık çıktı değeri için Tablo 6.7.'deki gibi elde edilmiştir.

Tablo 6.7. Parlaklık değerlerinin yapay sinir ağı modeli tahmini hata değerleri

YSA parlaklık tahmini hata verileri	
Ortalama Mutlak Hata (MAD)	0,59
Ortalama Hatalar Karesi (MSE)	123,38
Ortalama Mutlak Yüzde Hata (MAPE)	0,21%
R Oranı	0,99

Tablo 6.8.'de Parlaklık değeri tahmini için kurulan 2 model karşılaştırılmıştır. Ölçülen hata değerlerinin en küçüklerine sahip olan Yapay Sinir Ağları modeli en doğru tahmini gerçekleştirmiş demektir. Hata Değerleri 0'a yakın çıktığı için çok iyi bir tahminin yapıldığı sonucu elde edilmiştir.

Tablo 6.8. Parlaklık yapay sinir ağları ve çoklu regresyon tahminleri karşılaştırma tablosu

Parlaklık model tahminleri		
	Çoklu regresyon modeli hata oranı	Yapay sinir ağı modeli hata oranı
Ortalama Mutlak Hata (MAD)	2825	0,59
Ortalama Hatalar Karesi (MSE)	639264	123,38
Ortalama Mutlak Yüzde Hata (MAPE)	96,04%	0,21%
R Oranı	0,48	0,99

Her iki modelde incelendiğinde Tahmin sonuçları hata oranlarının Yapay Sinir Ağları modelinin Çoklu Regresyon modelinden daha doğru sonuçlar verdiği görülmüştür. Hem Kaplama Alanı hem Parlaklık Çıktısı için YSA modeli 0,99 R değeri ile en yüksek doğrulukla tahmini yapmıştır buna karşılık Çoklu Regresyon modeli Kaplama Alanı çıktısında R 0,99'luk bir tahmin yaparken Parlaklık çıktısı tahmininde R 0,48'lik doğrulukla tahminde yetersiz kaldığı görülmüştür.

Bu durumda göstermektedir ki Çoklu Regresyon gibi geleneksel modellerin yetersiz kaldığı durumlarda bile Yapay zekâ temelli YSA modeli yüksek R değerleri ile doğru tahminler yapabilmektedir.

Bu tez için en iyi sonucu verdiği gösterilen 30 nöronlu YSA modeli Alüminyum yassı mamuller boyama bölümünde Ocak 2019 itibari ile kullanılmaya başlanmış ve kullanım sonrasındaki kazanımları aşağıdaki gibi açıklanmıştır.

Daha doğru tahmini yaptığı gösterilen Yapay Sinir Ağları modeli Alüminyum yassı mamuller boyama bölümünde kullanımı tavsiye edilmiş ve Ocak 2019 itibari ile kullanıma geçirilmiştir. Tavsiye edilen modelin kullanımı sonrası oluşan kalite kusurlu malzeme oranlarında Tablo 6.9.'daki gibi düşüş gerçekleşmiştir.

Tablo 6.9. Tahmin öncesi ve sonrası kalite kusurları oranları

Kalite kusurları	YSA modeli ile tahmin	YSA modeli ile tahmin
	öncesi oranı	sonrası oranı
Portakallanma oluşumu	%3,77	%2,93
Oksit lekesi/Korozyon oluşumu	%5,20	%5,01
Kabarcık(blistir) oluşumu	%2,39	%2,06
Krater oluşumu	%4,54	%2,78
Renk farklılığı oluşumu	%5,79	%1,95
Sararma oluşumu	%5,64	%2,08
Kürlenme (aşırı kürlenme/eksik kürlenme)	%1,25	%0,69
Toplam	%28,58	%17,5

Tablo 6.9.'da kullanımı tavsiye edilen 30 nöronlu Yapay Sinir Ağı tahmin modeli öncesinde meydana gelen kalite kusurlarından maddeler halinde ne kadar iyileşme sağladığı gösterilmiştir. YSA modeli uygulaması öncesindeki veriler 2017-2018 yılı verileri olup 24 aylık bir periyotta elde edilen kalite kusur oranlarıdır. 30 nöronlu YSA modeli sonrasında elde edilen veriler ise 2 aylık dönemde gerçekleşen verilerdir.

Toplam boyalı mamul üretimin %40,8'i kalite kusuruna sahip olup siparişinden sapmaktadır. Bunlar içerisinde incelediğimiz maddeler ise bu kalite kusurlarının %28,58'ini kaplamaktadır. Kalan %12,22'lik kalite kusurları ise farklı nedenlerden kaynaklanmakta olup Parlaklık ve Kaplama Alanı değerleri ile ilişkili değildir.

İncelediğimiz kalite kusurları Kaplama Alanı ve Parlaklık çıktıları ile ilişkili olup bu kusurlarının %28,58'lik kısımda iyileşme sağlayarak kalitesizlik oranını %28,58'den %17,5'e düşürerek toplam aylık üretimde %11,08'lik bir iyileşme sağlamıştır.

Tablo 6.10. Kalite kusurlarında iyileşme oranları

Kalite Kusurları	YSA modeli ile tahmin öncesi tüm üretimdeki kalitesizlik oranı	YSA modeli ile tahmin sonrası tüm üretimdeki kalitesizlik oranı	YSA modeli ile tahmin sonrası tüm üretimde iyileşme oranı	YSA modeli ile tahmin sonrası birim kalite kusurlu üretimde iyileşme oranı
Portakallanma oluşumu	3,77%	2,93%	0,84%	22,28%
Oksit lekesi/ Korozyon oluşumu	5,20%	5,01%	0,19%	3,65%
Kabarcık(blistir) oluşumu	2,39%	2,06%	0,33%	13,81%
Krater oluşumu	4,54%	2,78%	1,76%	38,77%
Renk farklılığı oluşumu	5,79%	1,95%	3,84%	66,32%
Sararma oluşumu	5,64%	2,08%	3,56%	63,12%
Kürlenme (aşırı kürlenme/eksik kürlenme)	1,25%	0,69%	0,56%	44,80%
Toplam	28,58%	17,50%	11,08%	38,77%

Tablo 6.10.'daki iyileşme oranları incelendiğinde toplam aylık üretimde %11,08 iyileşmenin olduğu görülmektedir. Toplam Aylık Üretimin %40,2'de gerçekleşen kalite kusurlarının içerisinde ise %28,58'den %17,50'ye inerek kalite kusurları arasında %27,56'lık bir iyileşme sağlamıştır. Toplam üretimde sağlanan %11,08'lik iyileşme ise yüksek oranda fark edilen bir iyileşmedir.

Kalite kusurlarını ayrı ayrı ele aldığımızda ise toplam üretimdeki en büyük iyileşme oranları renk farklılığı oluşumu ve sararma oluşumundaki iyileştirme ile elde edilmiştir. Oranlar %66,32 ile renk farklılığı %63,12 ile sararma oluşumunda sağlanmıştır. Kalite kusurlarından sararma ve renk değişimi problemleri malzemeyi direkt olarak hurdaya yönlendiren sebepler olup yarıdan fazla iyileşme sağlanması büyük bir avantaj sağlamıştır. Daha sonra kürlenme ve krater oluşumunda gerçekleşen iyileştirmeler gelmekte son olarak da kabarcık oluşumu ve oksit oluşumu kusurları gelmektedir. Oksit oluşumu en az iyileşen kalite kusuru olarak Tablo 6.10.'da hesaplanmıştır.

Sonuç olarak yapılan çalışma ile en iyi tahmini yapan YSA ile 30 nöronlu bir model kurularak bu model ile tahminleme sağlanmış ve bu tahminlemenin çıktısı olarak toplam boyalı üretiminde %11,08 oranında iyileşmenin olduğu gözlemlenmiştir.

KAYNAKÇA

- Aikeshan, A., 2014. Bulanık Doğrusal Regresyon Yöntemi ile Talep Tahmini: Medikal Asistans Firmasında Bir Uygulama,. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İşletme Mühendisliği Ana Bilim Dalı, Yüksek Lisans Tezi.
- Akkuş, H., Düzcükoğlu, H. & Şahin, Ö. S., 2016. Alüminyum bal peteği yapılarında darbe mukavemeti tahmini için regresyon modeli oluşturulması. Erzincan: Erzincan University Graduate School of Natural and Applied Sciences.
- Alan, E., 2013. Yapay sinir ağları yaklaşımı ile curuflarda fosfor kapasitelerinin incelenmesi. İstanbul: İstanbul Teknik Üniversitesi.
- Ana Metal Sanayileri Özel İhtisas Komisyonu, 1995. Alüminyum Çalışma Grubu Raporu, Ankara: TC Başbakanlık Devlet Planlama Teşkilatı Müsteşarlığı.
- Ankara Alüminyum Sanayicileri Derneği, 2003. Alüminyum Tarihçesi, Gelişimi, <https://www.google.com/search?q=ankara+asad+org+tr+2011+turkiye+aluminum+sempozyumu+mayis+2003&spell=1&sa=X&ved=0ahUKEwiDs7vKzIbhAhXWxMQBHa8oBV0QBQgqKAA&biw=1366&bih=657> Erişim Tarihi: 16 03 2019.
- Anon., 1988. neural network study. darpa.
- Anon., 2011. MMP Ön Raporu. http://www.tubitak.gov.tr/tubitak_content_files/vizyon2023/mm/Ek2f.pdf. Erişim Tarihi: 04 09 2011.
- Apronti, D., Ksaibati, K., Gerow, K. & Hepner, K. K., 2016. Estimating traffic volume on Wyoming low volume roads using linear and logistic regression methods. Journal of Traffic and Transportation Engineering, pp. 493-506.
- Atalay, G., Kaya, E., Vergili, L. & Çelebi, S., 2010. Yapay Sinir Ağları, İzmir: Dokuz Eylül Üniversitesi.
- Atmaca, K., 2016. Yapay Sinir Ağları Nedir?. <https://kenanatmaca.com/yapay-sinir-aglari-nedir/>. Erişim Tarihi: 07 04 2019.
- Bahadır, E., 2013. Yapay sinir ağları ve lojistik regresyon analizi yaklaşımları ile öğretmen adaylarının akademik başarılarının tahmini. İstanbul: Marmara Üniversitesi.
- Baparı, A., Najafzadeh, A. & Moazeny, M., 2007. Prediction of hot flow stress of CrMoV steel using artificial neural network (ANN). ISIJ International, pp. 1126-1130.

- Boltürk, E., 2013. Elektrik Talebi Tahmininde Kullanılan Yöntemlerinin Karşılaştırılması. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi,, p. s.18.
- Braun, M., Altan, H. & Beck, S., 2014. Using regression analysis to predict the future energy consumption of a supermarket in the UK. Applied Energy, pp. 305-313.
- Chopra, S. & Meindl, . P., 2004. Supply Chain Management, Strategy, Planning And Operation. New Jersey: Prentice Hall.
- Çayıroğlu, İ., 2017. İleri algoritma analizi. Karabük: Karabük Üniveristesi Mühendislik Fakültesi Ders Notları.
- Derviş, S., 2015. Slideplayer.: <https://slideplayer.biz.tr/slide/2390529/>. Erişim Tarihi: 7 4 2019.
- Diamantaras, K. & Kung, S., 1996. Principal Component Neural Network Theory and Applications. Newyork, USA: John Wiley and Sons Inc Pres.
- Durmuş, G. & Can, Ö., 2009. Yüksek sıcaklık uygulanmış katkılı betonun bulanık mantık ve regresyon yöntemiyle basınç dayanımının tahmini. Politeknik Dergisi, pp. 195-200.
- Emel, G. v. T. Ç., 2002. Genetik Algoritmalar ve Uygulama Alanları. Uludağ Üniversitesi, İdari ve İktisadi Bilimler Fakültesi Dergisi,, pp. 11(1):129- 152.
- Ersöz, F. & Ersöz, T., 2015. IBM SPSS ile İstatistiksel Veri Analizi. Ankara: Sage Yayınları.
- Fan, X., Ying, L. & Chen, X., 2012. Prediction of iron ore sintering characters on the basis of regression analysis and artificial neural network. Energy Procedia, pp. 769-776.
- Fauset, L., 1994. Fundamentals of neural networks;architectures, algorithm, and application. basım yeri bilinmiyor:Englewood Cliffs: Prentice Hall.
- Frausett, L., 1993. "Fundamental of Neural Network". Prentice Hall.
- Göksu, Y. D. D. A., 2015. tahmin yöntemleri dersi ders notları. p. s.57.
- Guyton & Hall, J., 2006. Textbook Medical of Physiology, Pennsylvania, USA: Elseiver Sounders.
- Güngör, A., 2013. Isparta ilindeki atmosferde bulunan kükürtdioksit (So2) ve partikül madde (pm) konsantrasyonunun çoklu doğrusal regresyon yöntemi ile modellenmesi. Isparta: Graduate School of Natural and Applied Sciences.
- Hatipoğlu, T., Boran, S., Özcan, B. & Fırlı, A., 2013. Yapay sinir ağı yaklaşımıyla çinko kalınlığının tahminlenmesi. SAÜ. Fen Bil. Dergisi, pp. 61-69.
- Haykin, S., 1994. neurol networks a comprehensive foundation. Prentice Hall.
- Haykin, S., 1999. Neural Networks A Comprehensive Foundation, India: Pearson Prentice Hall.
- Haykin, S., 1999. neurol networks a comprehensive foundation. prentice hall international.

- Hebb, D., 1949. the organization of behavior. new york.
- James, W., 1890. psychology (briefer course). new york.
- Kialashaki, A. & Reisel, J. R., 2014. Development and validation of artificial neural network models of the energy demand in the industrial sector of the United States. Energy, p. Pages 749–760.
- Kocabıçak, G., 1996. Malzeme seçiminde bilgi tabanlı sistemler ve alüminyum döküm. Sakarya: Sakarya Üniversitesi Fen Bilimleri Enstitüsü.
- Kubat, C., 2012. Matlab Yapay Zeka ve Mühendislik Uygulamaları. 1. dü. Sakarya: Beşiz Yayınları.
- Leu, M. C. & Oz, C., 2011. American Sign Language word recognition with a sensory glove using artificial neural networks. Engineering Applications of Artificial Intelligence, pp. 1204-1213.
- Lewis, C. D., 1997. Demand Forecasting & Inventory Control. New York: Butterworth-Heinemann.
- Liu, S. v. L., 2011. Y.Introduction to grey theory. Springer.
- Mashhadban, H., Kutanaei, S. S. & Sayarinejad, M. A., 2016. Prediction and modeling of mechanical properties in fiber reinforced self-compacting concrete using particle swarm optimization algorithm and artificial neural network. Construction and Building Materials, pp. 277-287.
- Okutan, C., 2014. Borsa İstanbul şirketlerinin hisse senedi getirilerinin yapay sinir ağları ve çoklu regresyon yöntemleri kullanarak analizi. Kocaeli: Kocaeli üniversitesi.
- Olgun, S. ., 2009. Tedarik Zinciri Yönetiminde Talep Tahmini Yöntemler ve Yapay Zeka Tabanlı Bir Talep Tahmini Modelinin Uygulanması, Öztemel , E., 2003. Yapay Snir Ağları. Ankara: Papatya Yayıncılık.
- Öztemel, E., 2003. yapay sinir ağları. istanbul: papatya yayıncılık.
- Öztürk, M., 2003. Alüminyumun Geri Kazanılması.
- Priore, P., Gomez, A., Parreno, J. & Pino, R., 2008. Forecasting next-day price of electricity in the Spanish energy market using artificial neural networks. Engineering Applications of Artificial Intelligence , pp. 53-62.
- Sánchez, D. & Melin, P., 2014. Optimization of modular granular neural networks using hierarchical genetic algorithms for human recognition using the ear biometric measure.. Engineering Applications of Artificial Intelligence, pp. 41-56.
- Saravanakumar, P. ve diğerleri, 2012. Prediction of mechanical properties of low carbon steel in hot rolling process using artificial neural network model. Kuala Lumpur, Procedia Engineering.
- Shenshu, X. & Zhaoying, Z., 2000. Nonlinear time series model for shape classification using neural networks. Çin, Beijing 100084, pp. 374-377.

- Soundararajan, R., Ramesh, A., Sivasankaran, S. & Vignesh, M., 2016. Modeling and analysis of mechanical properties of aluminium alloy (A413) reinforced with boron carbide (B4C) processed through squeeze casting process using artificial neural network model and statistical technique. ICMPC.
- Syarif, J., Detak, Y. P. & Ramlı, R., 2010. Modeling of correlation between heat treatment and mechanical properties of Ti-6Al-4V alloy using feed forward back propagation neural network. ISIJ International, pp. 1689-1694.
- Şeker, S. E., 2008. İleri Beslemeli Ağlar (Feedforward Neural Networks): <http://bilgisayarkavramlari.sadievrenseker.com/2008/11/02/ileri-beslemeli-aglar-feedforward-neural-networks/>. Erişim Tarihi: 7 4 2019.
- Şener, F., 2005. Yük tahmin yöntemleri ve Ankara merkez metropol alan için regresyon analizi yöntemi kullanılarak uygulanması. Ankara: Graduate School of Natural and Applied Sciences.
- Şengöz, N., 2017. Derin Öğrenme. <http://www.derinogrenme.com/2017/03/04/yapay-sinir-aglari/>. Erişim Tarihi: 7 4 2019.
- Taormina, R., Chau , K.-w. & Sethi, R., 2012. Artificial neural network simulation of hourly groundwater levels in a coastal aquifer system of the Venice lagoon. Engineering Applications of Artificial Intelligence, pp. 1670-1676.
- Tolon, M. & Güneri Tosunoğlu, N., 2008. Tüketici tatmini verilerinin analizi: yapay sinir ağları ve regresyon analizi karşılaştırması. Faculty of Economic and Administrative Sciences Magazine, pp. 247-259.
- Tosun, D., Dingilli, Z. & Yücel, S., 2019. slideplayer.: <https://slideplayer.biz.tr/slide/2404038/>. Erişim Tarihi: 06 04 2019.
- Vecihi, Y., June 2011. Genetik Algoritma ile Türkiye Net Elektrik Enerjisi Tüketiminin 2020 Yılına Kadar Tahmini. International Journal of Engineering Research and Development,, 2(3), pp. 2-3.
- Yağcıgil, H., 1997. Alüminyum Mamulleri Sanayi, Ankara: Türkiye İş Bankası A.Ş. Genel.
- Yazıcıoğlu, N., 2010. Yapay Zeka İle Talep Tahmini. Uludağ Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Bölümü, Yüksek Lisans Tezi.
- Yüksek, A. G., 2007. Hava kirliliği tahmininde çoklu regresyon analizi ve yapay sinir ağları yönteminin karşılaştırılması. Sivas: Cumhuriyet Üniversitesi.
- Ziębik, A. & Hoinka, K., 2013. Energy Systems Of Complex Buildings. Green Energy And Technology. London: Springer.
- Zuñiga, A., Mora, M., Oyarce, M. & Fredes, C., 2014. Grape maturity estimation based on seed images and neural networks. Engineering Applications of Artificial Intelligence, pp. 95-104.

ÖZGEÇMİŞ

Zeynep Demir, 20.09.1994'de Bilecik'te doğdu. İlk, orta ve lise eğitimini İstanbul'da tamamladı. 2012 yılında Kırımlı Fazilet Olcay Anadolu Lisesi'nden mezun oldu. 2012 yılında başladığı Sakarya Üniversitesi Endüstri Mühendisliği Bölümü'nü 2016 yılında bitirdi. 2016 yılında Sakarya Üniversitesi Endüstri Mühendisliği Bölümü'nde yüksek lisans eğitimine başladı. 2017 yılında ASAŞ Alüminyum firmasında üretim planlama uzmanı olarak çalışmaya başladı halen bu pozisyonda görev yapmaktadır.