

**KIRIKKALE ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**YÜKSEK LİSANS TEZİ**

**YAPAY SİNİR AĞLARI İLE KONUT KİRA DEĞERLERİ**  
**ANALİZİ**

**Mahmut İBİŞ**

**OCAK 2019**

## ÖZET

### YAPAY SİNİR AĞLARI İLE KONUT KİRA DEĞERLERİ ANALİZİ

İBİŞ, Mahmut

Kırıkkale Üniversitesi

Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı, Yüksek Lisans Tezi

Danışman: Prof. Dr. Hasan ERBAY

Günümüzde en iyi yatırımlardan birisi olan gayrimenkulün geri dönüş süresini hesap etmek en sık karşılaşılan problemler arasındadır. Gayrimenkul konut piyasası araştırmalarında kira getirisi konutun metro duraklarına, hastanelere, okullara, alışveriş merkezlerine, parklara uzaklıkları gibi bir çok faktöre bağlıdır. Bir gayrimenkulü değerli kılan faktörler arasında en önemli etken, o gayrimenkulün konumudur. Bir diğer etken ise yakın gelecekte gayrimenkulün etrafında, gayrimenkulün değerini arttıracak olan herhangi bir projenin yapılmasıdır. Bu çalışma kapsamında bu faktörlerin konut kira üzerindeki etkisini araştırmak için yapay sinir ağları yöntemi alternatif bir yaklaşım olarak kullanılmıştır. Çalışma sonucu elde edilen sonuçlar konut kira tahmininde yapay sinir ağlarının etkin bir yöntem olduğunu göstermektedir.

**Anahtar Kelimeler:** Konut Kira Değeri, Yapay Sinir Ağları, Gayrimenkul Konut

## **ABSTRACT**

### **ANALYSIS OF HOUSING RENTAL VALUES WITH ARTIFICIAL NEURAL NETWORKS**

İBİŞ, Mahmut

Kırıkkale University

Graduate School of Natural and Applied Sciences

Department of Computer Engineering, M. Sc. Thesis

Supervisor: Prof. Dr. Hasan ERBAY

Today, one of the best investments is to buy real estate. It is necessary to calculate the return period of this investment. In real estate housing market research, rental income depends on many factors such as distance to subway stops, hospitals, schools, shopping centers and parks. The most important factor that makes a property valuable is the location of that real estate. Another factor is the realization of any project that will increase the value of the real estate in the near future. In this study, artificial neural network method was used as an alternative approach to investigate the effect of these factors on housing rent. The results of the study show that artificial neural networks are an effective method in the estimation of housing estates.

**Key Words:** Housing Value, Artificial Neural Networks, Real Estate

## **TEŐEKKÖR**

Tezimin hazırlanması esnasında yardımlarını esirgemeyen ve büyük destek olan tez yöneticisi hocam, Sayın Prof. Dr. Hasan ERBAY'a, teşekkürlerimi sunarım.



## İÇİNDEKİLER DİZİNİ

	<u>Sayfa</u>
<b>ÖZET</b> .....	ii
<b>ABSTRACT</b> .....	iii
<b>TEŞEKKÜR</b> .....	iv
<b>İÇİNDEKİLER DİZİNİ</b> .....	v
<b>ŞEKİLLER DİZİNİ</b> .....	viii
<b>ÇİZELGELER DİZİNİ</b> .....	x
<b>1. GİRİŞ</b> .....	<b>1</b>
<b>2. YAPAY ZEKÂ</b> .....	<b>2</b>
2.1. Tarihçe.....	2
2.2. Yapay Zekânın Amaçları.....	4
2.3. Yapay Zekâ Kullanım Alanları.....	4
2.4. Yapay Zekâ Uygulama Alanları.....	5
2.5. Yapay Zekâ Teknikleri.....	7
2.5.1. Uzman Sistemler.....	7
2.5.2. Bulanık Mantık.....	8
2.5.3. Genetik Algoritmalar.....	9
2.5.4. Yapay Sinir Ağları.....	10
<b>3. YAPAY SİNİR AĞLARI</b> .....	<b>11</b>
3.1. Yapay Sinir Ağları Bileşenleri.....	12
3.1.1. Girdiler.....	12
3.1.2. Ağırlıklar.....	12
3.1.3. Toplama Fonksiyonu.....	13
3.1.4. Aktivasyon Fonksiyonu.....	14

3.1.4.1.	Doğrusal Aktivasyon Fonksiyonu.....	14
3.1.4.2.	Adım Aktivasyon Fonksiyonu.....	15
3.1.4.3.	Sigmoid Fonksiyonu.....	16
3.1.4.4.	Tanjant Hiperbolik Aktivasyon Fonksiyonu.....	16
3.1.5.	Çıktılar.....	17
3.2.	Yapay Sinir Ağları Yapısı.....	17
3.2.1.	Giriş Katmanı.....	18
3.2.2.	Gizli Katmanı.....	18
3.2.3.	Çıkış Katmanı.....	19
3.3.	Yapay Sinir Ağlarının Sınıflandırılması.....	19
3.3.1.	Yapılarına Göre Sınıflandırılması.....	19
3.3.1.1.	İleri Beslemeli.....	20
3.3.1.2.	Geri Beslemeli.....	20
3.3.2.	Algoritmalarına Göre Sınıflandırılması.....	21
3.3.2.1.	Danışmanlı Öğrenme.....	21
3.3.2.2.	Danışmansız Öğrenme.....	22
3.3.2.3.	Pekiştirmeli Öğrenme.....	23
3.4.	Yapay Sinir Ağlarının Özellikleri.....	23
3.4.1.	Avantajları.....	23
3.4.2.	Dezavantajları.....	23
3.4.3.	Aşırı Öğrenme (Overfitting).....	24
3.4.4.	Eksik Öğrenme (UnderFitting).....	25
3.4.5.	Çapraz Geçerlilik.....	25
3.4.5.1.	Rasgele Geçerlilik.....	26
3.4.5.2.	K Parçalı.....	27
<b>4.</b>	<b>KONUT KİRAYI ETKİLEYEN FAKTÖRLER.....</b>	<b>27</b>
<b>5.</b>	<b>ARAŞTIRMA BULGULARI VE SONUÇ.....</b>	<b>27</b>



## ŞEKİLLER DİZİNİ

<u>ŞEKİL</u>	<u>Sayfa</u>
2.4. Görüntü İşleme.....	5
2.5.1. Uzman Sistemlerin Genel Yapısı.....	8
2.5.2. Bulanık Mantık Çalışma Prensipleri.....	9
2.5.3. Genetik Algoritma Akış Şeması.....	10
3. İnsan Nöron Sistemi.....	11
3.1.2. Girdi ve Ağırlıklar.....	13
3.1.4.1. Doğrusal Aktivasyon Fonksiyonu.....	15
3.1.4.2. Adım Aktivasyon Fonksiyonu.....	15
3.1.4.3. Sigmoid Aktivasyon Fonksiyonu.....	16
3.2. Mimari Yapı.....	18
3.2.1. Giriş Katmanı.....	18
3.2.2. Gizli Katmanı.....	19
3.3.1.1. İleri Beslemeli.....	20
3.3.1.2. Geri Beslemeli.....	21
3.3.2.1. Danışmanlı Öğrenme.....	22
3.3.2.2. Danışmansız Öğrenme.....	22
3.4.3. Aşırı Öğrenme (Overfitting).....	24
3.4.4. Eksik Öğrenme (Underfitting).....	25
3.4.5. Çapraz Geçerlilik.....	26
3.4.5.1. Rasgele Geçerlilik.....	26
3.4.5.2. K Parçalı.....	27



5. Aydınlikevler konut yerleşimi.....	28
5. Gizli katmanlar.....	31
5. Scatter ve lineer regresyon.....	34
5. Confusion matrix.....	35
5. Renk ile ağırlaştırılmış Confusion matrix .....	35



## ÇİZELGELER DİZİNİ

<u>ÇİZELGE</u>	<u>Sayfa</u>
3.1.1. Giriş Parametreleri Tablosu .....	12
3.1.5. Çıkış Parametresi Tablosu .....	17
5. Normalize Edilen Mesafeler Tablosu.....	29
5. Girdi Verisi Sonuç Parametresi Tabloları .....	29
5. Epoch Tablosu.....	31
5. Test Parametreleri Girdi parametreleri.....	32
5. Modelin Gerçeklik Değeri.....	32
5. Confusion Matrix .....	33

## 1. GİRİŞ

Yapay zekâ, insanın yapabildiği tüm aktiviteleri robotlara ve makinelere öğretmek bu aktiviteleri yerine getirmelerini hedefler. Bu yönüyle yapay zekâ bir algoritmadır. Algoritma, belli bir problemi çözmek için ya da belirli bir amaca ulaşmak için geliştirilen düzenli işlem basamaklarıdır. Algoritmik açıdan bakıldığında istenilen yeteneklerin makinelerle kazandırılması düşüncesini ilk kez Alan Mathison Turing ortaya atmıştır [1]. Yapay zekâ terimi ise McCulloch-Pitts tarafından 1956 yılında kullanılmıştır [2]. Problem karşısında insanın sinir sisteminin verdiği tepkileri inceleyerek yaptığı bu çalışma yapay sinir ağlarının temelini oluşturmuştur. 1960'lı yıllarda MIT (Massachusetts Institute of Technology) yapay zekâ alanında çalışmalar yaparak yapay sinir ağlarına katkıda bulunmuştur [3]. Bu alanda asıl patlama ise 1986 yılından sonra yaşanmıştır. Geoffrey Hinton yapay sinir ağlarının bir problem karşısında daha önceki tecrübelerini göz önünde bulundurarak hataları en aza indirgeyen bir algoritma (backpropagation) önermiştir [4]. 2000'li yıllara doğru artık yapılan çalışmalarda zamanla bilgisayar donanımlarının yetersiz kaldığı görülmüştür. Ancak, sonraki yıllarda grafik işlemci ünitesi ve donanımsal yeteneklerin gelişmesi ve yapay sinir ağlarında çok sayıda ara katmanlar kullanılması yeniden yapay zekânın gelişmesine yardımcı olmuştur [5].

Günümüzde yapay zekâ alanındaki gelişmeler insan hayatına olumlu bir şekilde yansımaya başlamıştır. Dünyanın en kalabalık ülkesi olan Çin'de teknoloji devi Alibaba trafik yoğunluğunu azaltmak için yapay zekâdan faydalanarak akıllı şehir uygulamasını geliştirmiştir. Söz konusu sistem (City Brain) [6] Çin'in Hangzhou kentinde uygulanmaya başlanmış ve trafiği en sıkışık şehirler sıralamasında 52 basamak geriletirerek 57. sıraya getirmiştir.

Ayrıca, yapay zekâdan siber ortamda da yararlanılmaya başlanmıştır. Bilgileri sayısallaştırmak için yapılan maliyetler arttıkça internet korsanların da iştahını arttırmaktadır, çünkü bilgiler artık dijital ortamdadır. Draper ve Art Jahnke'in Boston Üniversitesi'nde yaptıkları bir çalışma, bilgisayar korsanları herhangi bir sisteme sızmaya çalıştıklarında yapay zekâ yardımıyla ağa sızmalarını zorlaştıracak bir araç geliştirmişlerdir [7]. Ürettikleri güvenlik aracı, internet korsanlarının sisteme ekledikleri kod bloğunu anında sistem yöneticisine rapor etmektedir.

Bu mevcut çalışmamız kapsamında Ankara ilinin Aydınlikevler mahallesinde bulunan bağımsız bölümlerin okula, parklara, bulvarlara ve alışveriş merkezlerine olan uzaklıklarını göz önüne alarak yapay sinir ağları yaklaşımıyla konut kira değerleri incelenmiş ve sonuçları karşılaştırılmıştır.

Tezin geriye kalan kısmı şu şekilde organize edilmiştir. İkinci bölümünde yapay zekâ ele alınmıştır. Ayrıca bu alanda yapılmış çalışmalar hakkında literatür bilgisi verilmiştir.

Tezin üçüncü bölümünde çalışma boyunca kullanılan metot olan yapay sinir ağları hakkında bilgi verilmiştir.

Tezin dördüncü bölümünde günümüz gayrimenkul konut kira değerlerini etkileyen faktörler anlatılmıştır.

Tezin beşinci bölümünde Ankara ilinin Aydınlikevler mahallesindeki konutların analizi ele alınmıştır. Son olarak tezin altıncı bölümünde tez çalışması sonucunda elde ettiğimiz sonuçlara yer verilmiştir. Bu sonuçlar arasında veri setimizde yer alan test verileri kullanılarak elde ettiğimiz performans sonuçları bulunmaktadır. Ayrıca çalışma sonucu elde ettiğimiz sonuçlar bu bölümde tartışılmıştır.

## **2. YAPAY ZEKÂ**

Yapay zekâ, insanın düşünebilme yetisini bilgisayar ortamına kazandırabilmektir. Geniş tanımı ile insana özgü özellik olan düşünebilme, karar verme, algılama ve görme gibi nitelikleri dijital ortama aktararak insan gibi bu özellikleri kullanmasını sağlamaktır. Bu özellikleri kullanarak bilgisayarlara mantıksallaştırma ve kendini düzeltme gibi özellikler kazandırma hedeflenmektedir.

### **2.1. Tarihçe**

Yapay zekâ, genel olarak bilgisayar kavramları ile paralel bir gelişme göstermiştir. Alan Mathison Turing, insan gibi hesap yapabilen makineler konusunda çalışmalar yapmıştır [3].

1950 yılında Alan Turing, bir makinanın karar verme yetisini test etmek için “taklit oyun” ismini verdiği Turing Testini açıklayan bir makale yayınladı [8]. Bu çalışma bilgisayarın bir insan gibi düşünebilmesini temel almıştır.

1956 yılında Dartmouth Üniversitesi’ndeki bir konferansta, bilgisayar bilimcisi John McCarthy ilk kez “yapay zekâ” terimini ortaya atmıştır. Özellikle soğuk savaş yıllarında Amerika hükümeti bu alanda çalışma yapmak için finansal destek sağlaması, yapay zekânın gelişmesini hızlandırmıştır [8].

1961 ve 1965 yılları arasında A. L. Samuel, yüksek seviyede dama oyunu oynayabilen bir program geliştirmiştir [9]. 1968 yılında Carl Engelman, William Martin, Joel Moses matematiksel hesaplamalar yapabilen MACSYMA isimli sistem geliştirilmeye başlamıştır [10]. Öte yandan 1965 ve 1970 yılları bilgi tabanlı uzman sistemlerin geliştiği dönemdir. Stanford Üniversitesi’nde başlatılan Dendral programı kapsamında, kimyasal bileşen verilerinden yola çıkarak moleküler yapıları bulan sistem geliştirilmiştir [11].

1970’li yıllarda büyük bilgisayar şirketlerinin etkisiyle yapay zekâ gelişimi yavaşlamıştır. Buna ilaveten gelişmenin yavaş olması sebebiyle hükümet bu alandaki fonlarını kesmiştir [8].

1973 yılında Profesör Sir James Lighthill, düşünebilen makinelerin “deneyimli bir amatör” seviyesinden ileri gidemeyeceği fikrini savunmuştur [8].

1980’li yıllarda yapay zekânın gelişiminin hızlandırdığı yıllar olmuştur. Özellikle IBM’in bu yıllardaki ekonomik başarısı sonucunda 1997 yılında dünya satranç şampiyonu Garry Kasparov’u mağlup etmesi, yapay zekâ gelişimini hızlandırmıştır [8].

2000 yılında Honda firması Asimo adlı robot geliştirmiştir [12]. 2008 yılında NASA, Phoenix isimli robotu Mars’ı incelemek üzere göndermiş ve Phoenix çalışmalarına devam etmektedir [12].

## 2.2. Yapay Zekânın Amaçları

Yapay zekâ, insan hayatını kolaylaştırmak için bir takım algoritmaları gerçekleştirmek ve gerçekleştirirken de sahip olduğu verilerden yararlanarak düşünme, karar verme ve yanlışlarından tecrübe ederek insanoğluna zeki sistemler sunmayı amaçlar.

## 2.3. Yapay Zekâ Kullanım Alanları

Günümüzde yapay zekâdan hayatımızın her alanında yararlanılmaya başlanmıştır. Bu yönüyle yapay zekâ artık hayatımızın bir parçası olmuştur. California'da sürücüsüz otonom araçlar için artık yasal bir zorunluluk getirilmiştir [13].

Yapay zekânın kullanım alanlarının bazıları aşağıdaki başlıklarda sıralanabilir.


- a. Muhakeme
- b. Dil İşleme
- c. Ses Tanıma
- d. Görüntü İşleme

Ses Tanıma; hayatımızın her alanında görmek mümkündür. Akıllı telefonlardan alışık olduğumuz Siri ve Cortana en basit örnekleridir. Yapay zekâ sesi tanımakla kalmıyor, aynı zamanda algılayıp, anlayıp ve cevap vermektedir [14].

Dil işleme; Google ve Yandex gibi arama motorlarında kullanılan algoritmalar hayatımızı kolaylaştırmak için geliştirilen dil işleme tekniklerinden sadece birisidir. Bu yönüyle yapay zekânın ne kadar önemli olduğunu gözler önüne sermektedir.

Muhakeme; Yapay zekâ sahip olduğu verileri süzerek ve bunun yanında hatalarını inceleyerek en iyi ve en mantıklı kararı vermeyi amaçlar. Böylece doğruyu ve yanlış ayırt etmeyi öğrenir.

Görüntü işleme; Görüntüyü bilgisayarlara yani dijital ortama aktararak bir takım işlemleri gerçekleştirir. Örneğin arama motorlarında herhangi bir resim aratıldığında arka planda görüntü işleme algoritmaları çalışır.



**Şekil 1.** Görüntü İşleme [15]

#### **2.4. Yapay Zekâ Uygulama Alanları**

Günümüzde gelişen teknolojiye bağlı olarak özellikle sanayi ve endüstri alanlarında yapay zekâya duyulan ihtiyaç sürekli artmaktadır. Artık günlük işlerimizde yapay zekâdan faydalanmadığımız alan neredeyse yok denecek kadar azdır. Bu denli hayatımızla iç içe olan yapay zekânın uygulama alanları şu şekilde sıralayabiliriz.

1. Otomotiv
2. Bilişim Teknolojileri
3. Sağlık Teknolojileri
4. Eğitim
5. Satış
6. Tekstil
7. Ses ve Görüntü
8. Hukuk
9. Pazarlama

Otomotiv; gelişen teknolojiyle birlikte otomotiv sektörü artık sürücüsüz araçlar alanına ilerlemektedir. Bu araçların görüntü işleme sayesinde diğer araçlarla birlikte uyumlu şekilde kullanılabilir. Bu araçların görüntü işleme sayesinde diğer araçlarla birlikte uyumlu şekilde kullanılabilir.

Bilişim Teknolojileri; değerli verileri saklamak artık dijital dünyada önemli bir yere sahiptir. Zeki sistemler dış tehditlere karşı anında önlemini alarak sistem yöneticisine gerekli bilgilendirme yaparak değerli verilerin yabancı kişilerce ele geçirilmesinin önüne de geçmeye başlamıştır.

Sağlık Teknolojileri; önceki verilerden faydalanarak en doğru yöntemi bularak ve Ar-Ge maliyetlerini indirerek en uygun yöntemi uygulamaktadır. Bu doğrultuda hastaya en doğru teşhis konabilmektedir.

Eğitim; her öğrenci özel öğrenme tekniklerinden yararlanır. Her seviyede öğrenciye ait verileri toplanmayı ve sunmayı amaçlar. Engelli öğrenciler için bilgileri dijital ortamda sunar.

Satış; firmaların daha önceki satış bilgilerini analiz ederek satış politikasını düzenler. Satış ekiplerin yıl boyu tahmini istatistik oluşturmasına zemin hazırlar. Müşterilerin hangi ürünlere talep gösterdiğini analiz ederek firmanın hangi sektör firmasıyla temasa geçmesi gerektiğini bildirir.

Tekstil; geçmişte çok büyük insan gücüne ihtiyaç duyulan bu alanda ham maddenin toplanıp işlenmesi, gözlemlenmesi ve anlaşılması gibi bir takım aşamalardan geçerek satışa uygun hale gelmektedir. Bu basamakların her birinde çok hassas analizlerin zeki sistemler tarafından yapılması verimliliği artırarak firmanın satış politikasına yön vermektedir.

Ses ve Görüntü; verilerin daha iyi anlaşılabilmesi için görselleştirme önemli bir yere sahiptir. Görsel veriler daha iyi analiz edilmektedir. Uydu görüntüleri buna en iyi örnektir. Aynı zamanda verilerin anlaşılmasında ses analizleri ve arayüzler kullanıcılara birçok konuda yardımcı olmaktadır.

Hukuk; özellikle dava olaylarında karar verme aşamasında zeki sistemler kullanılmaya başlanmıştır. Önceki davalardan çıkan sonuçları ve verileri analiz ederek daha sağlıklı sonuçlar ortaya koyabilmektedir.



Pazarlama; müşteriye en etkili teklifi sunmak için uygun bir strateji ile doğru yoldan efektif bir hizmet sunar. Hizmetin oluşturulmasından müşteriye kadar tüm basamaklarda zeki sistemler kullanılmaya başlanmıştır.

## **2.5. Yapay Zekâ Teknikleri**

Günümüzde yapay zekânın giderek önem kazanmasıyla iş verimliliği artmaktadır. Zeki olmayan sistemler yerlerini otonom sistemlere bırakmasıyla hayatın her alanında tekrarlı ve insan gücüne dayalı sistemler azalmaya başlamıştır. Bu faktörler yapay zekânın daha da gelişmesine ortam sağlamaktadır. Aşağıda yapay zekâ teknikleri sıralanmıştır.

1. Uzman Sistemler
2. Bulanık Mantık
3. Genetik Algoritmalar
4. Yapay Sinir Ağları

### **2.5.1. Uzman Sistemler**

Uzman Sistemler, günümüzde insan uzmanlara gerek kalmadan belli bir algoritma çerçevesinde çözüm yolu bulan zeki sistemler olarak tanımlayabiliriz. Bu algoritmaları daha önceden oluşturulan bir takım çözüm yollarını takip ederek en mantıklı yolu seçer. Burada uzmanların bilgilerinden ve tecrübelerinden faydalanır.

Uzman sistemler problemleri çok hızlı şekilde çözmenin yanında doğruluğunu tartışmaya açık bırakmayacak şekilde kesin olmalıdır. Aksi takdirde sonuçların kullanıcılar açısından doğruluğu tartışılmaya başlanılacaktır.

Uzman sistemler, günümüzde en çok işletmelerin kullandıkları bir sistem olarak karşımıza çıkmaktadır. Bir uzman sistemin yanılma payı yok denecek kadar azdır. Bu nedenle müşterilerine çok hassas olmaları gereken bu alanda uzman sistemler olmazsa olmaz bir sistem haline gelmiştir.

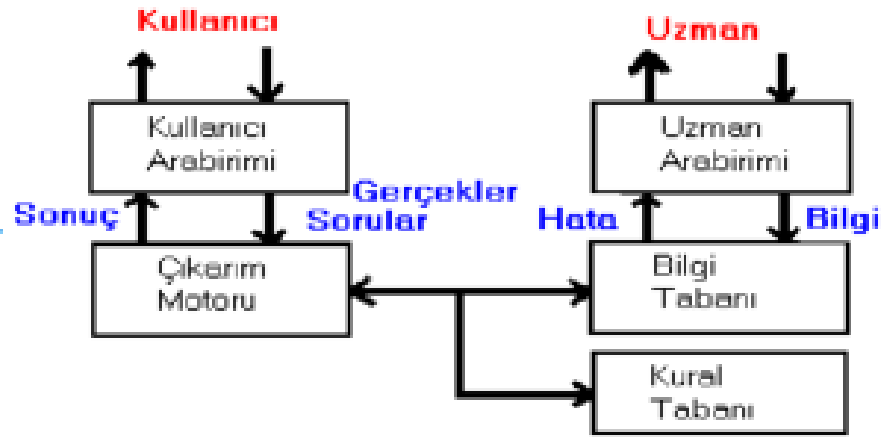
Uzman sistemler, tıp, eczacılık ve mühendislik alanlarında da kullanılmaktadır. Hastalara tanı koyma ya da reçete yazma işlemlerini doğru ve hassas şekilde yapabilmektedir. Ayrıca bilgisayar tasarımı, emlak konut alım ve satımında ya da tekstil alanlarında ürün satışlarında sıkça faydalanılan zeki bir sistem olarak karşımıza çıkmaktadır.

Uzman sistemlerin en büyük avantajları, uzman insanlar gibi karar verme kabiliyetine sahip olmaları, bilgi birikimlerinden faydalanmaları ve bir uzmandan çok daha kısa sürede en mantıklı ve doğru çözümü sunmalarıdır.

Uzman sistemlerin tarihi 1950'li yıllara dayanmaktadır [15]. Bu yıllarda “insanlar problemlerini acaba makineler yapabilir mi?” sorusunu sorgulamaya başlamasıyla ilk uzman sistemlerin temelini atmıştır.

1960'lı yıllarda bilim insanları daha çok minimize edilmiş problemler üzerinde çalışmalarını yoğunlaştırmıştır. Bu dönemde özel amaçlı programlar geliştirilmiştir[16].

1980'li yıllardan itibaren uzman sistemler artık ticari alanda düşünülmesiyle günümüz sistemlerin merkezi haline gelmiştir [17].



Şekil 2. Uzman Sistemlerin Genel Yapısı [18]

### 2.5.2. Bulanık Mantık

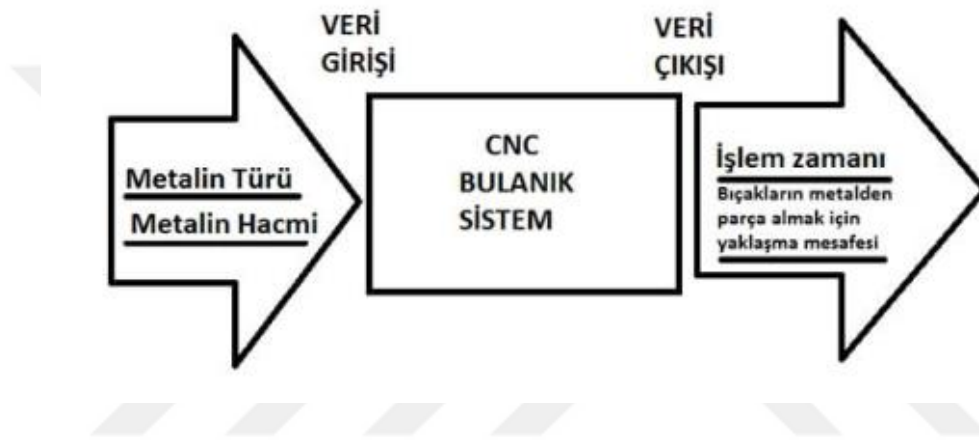
Dijital dünyada veriler ya 0 ya da 1'dir. Ancak gerçek hayatta hiçbir şey bu kadar net olmayabilir. Bu durum bazen insan hayatına olumlu yansırken bazı durumlarda doğru ya da yanlış, iyi veya kötü durumlar haricinde başka durumlara ihtiyaç duymaktayız. Bu aşamada karşımıza bulanık mantık çıkmaktadır. Bazen ara katmanlara ihtiyaç duymaktayız.

Bulanık mantık, zeki sistemlere seçim şansı vererek sadece siyah ve beyazın yanında gri tonlara da fırsat vererek, bir problem karşısında belli bir aşamadan sonra farklı

düşünerek kesin yanıtlar vermez. Bu durum insanlara belli bir sınıflandırma yapmak zorunda bırakmaz.

Bulanık mantık kavramını Azeri Lütü Askerzade Zadeh [19] adlı bilim insanı ortaya atmıştır. 1965 yılından itibaren bulanık mantık alanına yoğunlaşmıştır. Bu yıllarda birçok değerli bilim adamı küme teorisi geliştirmiş ve “bulanık” kelimesini ilk kez kullanmıştır.

Günümüzde endüstri alanında CNC makinaları üzerinde bulanık mantığı inceleyecek olursak metalin türüne göre metal parçaları bilgisayar ile programlayarak işler.

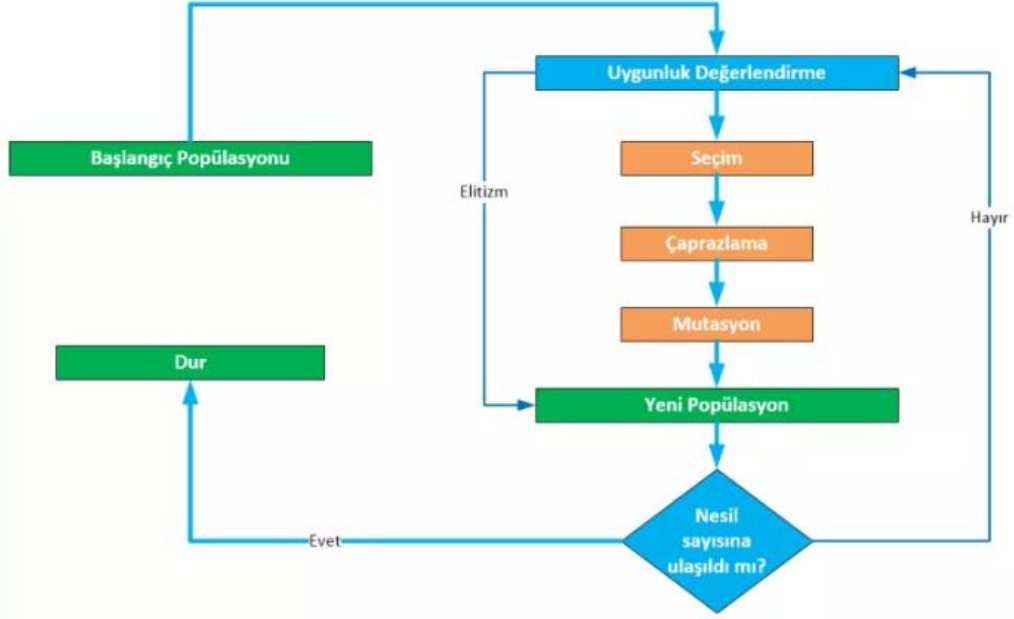


Şekil 3. Bulanık Mantık Çalışma Prensipleri [20]

### 2.5.3. Genetik Algoritmalar

Genetik algoritmalar yapay zekânın alt dalı ve araştırma alanlarından birisidir. Günümüzde ise birçok alanda kullanılmaktadır. Temel olarak evrim sürecini esas alır. Evrim sürecindeki örnekleri inceleyerek başarılı sonuçlar üretir. Bu yönüyle bir arama yöntemi de denilebilir.

Evrim, canlıların ortama adaptasyonunu sağlar. Bu süreçte yalnızca güçlüler kalır ve zayıflar elenir. Bu nedenle evrim canlıları geliştirir ve güçlendirir. Bu süreçleri dijital ortama aktarmak ise genetik algoritmanın gelişmesini sağlamıştır.



**Şekil 4.** Genetik Algoritma Akış Şeması [21]

#### 2.5.4. Yapay Sinir Ağları

Yapay sinir ağları herhangi bir problem karşısında bilgiler toplayıp ve sınıflandırma yaparak elde ettiği sonuçlarla karar verir. Daha önce karşılaşmadığı bir problemle karşılaşırsa önceden öğrendiği bilgilerden yararlanarak karmaşık problemleri çözmektedir.

Yapay sinir ağları insan beynini örnek alarak karmaşık problemleri kendine özgü katman aralıklarından süzerek her biri kendi belleğine sahip işlem elemanlarından oluşan bilgi işleme yapılarıdır.


Yapay sinir ağları, problemleri çözmek için kendisine önceden verilen eğitim setlerinden yararlanır. Bu eğitim setlerini kendi ara katmanlarından süzerek çıkış parametreleri üretir.

Günümüzde birçok alanda yapay sinir ağlarından yararlanılmaktadır. Tıp alanında; kanserli hücrelerin tespit edilmesi ve sınıflandırılması, askeri alanda; hedef tespiti, görüntü tanıma işleme ve değerlendirme ekonomi alanında; döviz kuru tahminlerinde yaygın olarak kullanılmaktadır.

### 3. YAPAY SİNİR AĞLARI

İnsanoğlunun yapay zekâ alanındaki amacı, bir davranış karşısında insanların tepkileri göz önünde bulundurularak bu yeteneklerin makinelere kazandırılmasıdır. Kısaca makinelerin daha zeki hale gelmesi istenmektedir. Bu amaca uygun olarak yapay zekâ gelişimini birçok teknik ile hızlandırılmak amaçlanmıştır.

Yapay sinir ağları, insanın bir davranış karşısında verdiği tepkiyi insan beyin hücrelerinin karmaşık yapısından faydalanarak makinelere aktarılmasını amaçlamaktadır.



Şekil 5. İnsan Nöron Sistemi [22]

Bir sinir hücresinin matematiksel modeli ise;

$$y = w * x + b$$

y:bağımlı değişken olup girdi parametresine ait skor değeridir,

w:ağırlık parametresi,

x:girdi parametresi,

b:bias değeri

### 3.1. Yapay Sinir Ağları Bileşenleri

Yapay sinir ağları insan sinir hücrelerinden esinlenilmiş benzer yapıya sahip olan sistemlerdir. İnsanlardaki biyolojik sinir hücrelerin barındırdığı nöronları, yapay sinir ağlarında yapay nöronlar olarak görülmektedir. Burada da yapay nöron hücreleri aldıkları dış dünyadan gelen girdileri, bir takım katmanlardan geçerek çıktı olarak iletirler.

#### 3.1.1. Girdiler

Yapay sinir ağlarında dış faktörlerden gelen veriler girdi olarak adlandırılırlar. Ayrıca başka bir yapay nörondan diğer nörona geçen verilerde girdi olarak gelebilir. Girdi verileri işlemek üzere merkezi bir çekirdeğe iletilir.

Aşağıdaki şekilde bu çalışmanın girdi parametreleri gösterilmiştir.

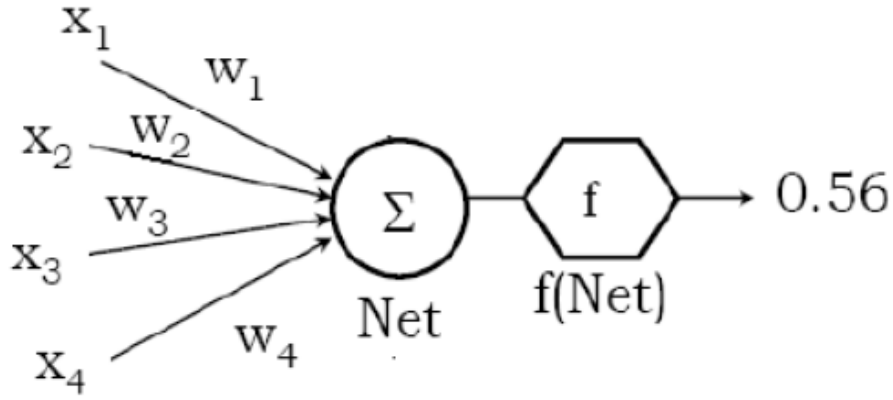
Id	Avm	Bulvar	Park	Okul
1	75	10	6	3
2	73	8	5	2
3	73	15	11	10
4	63	15	10	5
5	75	8	4	1
6	75	10	6	3
7	69	11	8	12
8	73	8	5	2
9	74	8	5	5
10	73	15	11	10

Şekil 6. Giriş Parametreleri

#### 3.1.2. Ağırlıklar

Yapay sinir ağlarındaki yapay nöron hücreler arasındaki ilişkinin bir sayısal değeridir. Bu sayısal değerler hücreler arasındaki ilişkinin ağırlık değeriyle çarpılarak hesaplanır.

Bu değerler pozitif, negatif veya sıfır olabilir. Değeri sıfır olan girdi verilerin çıktıları üzerinde herhangi bir etkisi yoktur.



Şekil 7. Girdi ve Ağırlıklar [23]

Girişler	Ağırlıklar
$x_1=0,5$	$w_1=-0,2$
$x_2=0,6$	$w_2=0,6$
$x_3=0,2$	$w_3=0,2$
$x_4=0,7$	$w_4=-0,1$

Hücrenin net girdisi;

$$\text{Net}=\sum x_i w_i \quad i=1,2,3,4$$

$$\text{Net}=0,5*(-0,2)+0,6*0,6+0,2*0,2+0,7*(-0,1)$$

$$\text{Net}=0,23$$

### 3.1.3. Toplama Fonksiyonu

Yapay nöronlara gelen girdi verileri ağırlıklarıyla çarpılarak her bir nöron hücrelerin girdi verisi hesaplanır.

$$\text{Net} = \sum_{i=1}^N X_i * W_i$$

$X_i$  :  $i$  yapay nöronunun girdisi,

$W_i$  :  $i$  yapay nöronunun ağırlığı

Net girdileri hesaplamak için ağırlık deęerleri girdi deęerleri ile arpılarak toplanır.

#### **3.1.4. Aktivasyon Fonksiyonu**

Yapay sinir aęlarında toplama fonksiyonlarından elde edilen yapay nron hcre ıktısını oluřturmak iin aktivasyon fonksiyonlarına iletilir. Yapay sinir aęlarının doęrusal olmama zellięinden dolayı aktivasyon fonksiyonları da lineer olmayan bir baęlantıya sahip olur. Aktivasyon fonksiyonlarının lineer bir yapıya sahip olması daha dar bir pencerede fonksiyonları modellenmesini temsil eder. Bu yapıya sahip bir yapay sinir aęları gnmze kadar geirdięi evrim basamaklarına gelemeyeceęi anlamını tařır. Aktivasyon fonksiyonu seilirken trevi kolay hesaplanabilecek bir metot seilmelidir.

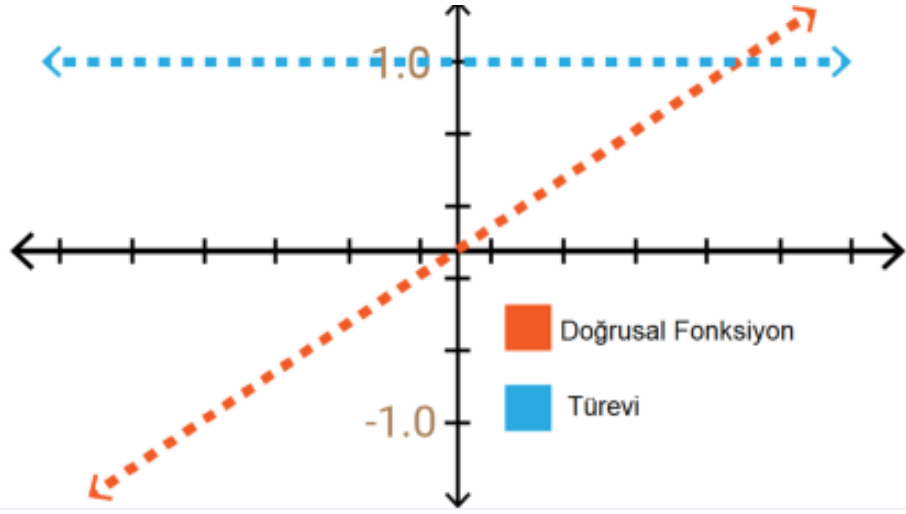
##### **3.1.4.1. Doęrusal Aktivasyon Fonksiyonu**

Doęrusal problemleri ozmek iin kullanılan aktivasyon fonksiyon eřididir. Doęrusal aktivasyon fonksiyonları birkaç yapay nronu birbirine baęlayabilir. Ancak bu fonksiyonun iki dezavantajı vardır. İlki bu fonksiyonun trevi sabit bir sayıdır.

$$A = c * x$$

Trevi alındıęında x ile bir iliřkinin kurulamaması bu fonksiyonun olumsuz bir yanıdır. İkinci dezavantajı ise doęrusal bir fonksiyon seildięinde girdi ile ıktı arasındaki katmanlardan yine lineer bir sonu elde edilebilecek olmasıdır. Bu durumda eřitlilik azalacak ve ara katmanlar zelliklerini kaybedeceklerdir.






Şekil 8. Doğrusal Aktivasyon Fonksiyonu [24]

### 3.1.4.2. Adım Aktivasyon Fonksiyonu

Adım aktivasyon fonksiyonları sadece iki değer çıktı verir. Girdi verileri sıfırdan küçük veya büyük olup olmasına göre 0 ve 1 değerlerini alır. Böylece ikili sınıflandırıcı olarak kullanılır. Genellikle çıkış katmanlarında kullanılır.




Şekil 9. Adım Aktivasyon Fonksiyonu [24]

Girdi parametresinin değeri eşik değerinin üzerinde ya da altında olup olmasına göre çıkış parametresi 0 veya 1 değerini alır.

### 3.1.4.3. Sigmoid Fonksiyonu

Sigmoid aktivasyon fonksiyonu doğrusal olmadığı için en sık kullanılan fonksiyondur. Yapay sinir ağlarının da doğrusal olmayan bir yapıya sahip olması nedeniyle karşımıza çıkan problemlerde sık sık kullanılır. Girdi değerlerine karşılık çıktı değerleri sıfır ile bir arasında değerler üretir.



Şekil 10. Sigmoid Aktivasyon Fonksiyonu [24]

$$F(x) = \frac{1}{1 + e^{-x}}$$

F(x) = y: Aktivasyon fonksiyon sonucu

### 3.1.4.4. Tanjant Hiperbolik Aktivasyon Fonksiyonu

Sigmoid aktivasyon fonksiyonuna benzer bir yapıya sahip olmakla birlikte çıktı değerleri -1 ile +1 arasında değerler üretir. Sigmoid aktivasyon fonksiyonundan farkı ise daha dik bir türev değerine sahip olmasıdır.

$$F(x) = \frac{e^x + e^{-x}}{e^x - e^{-x}}$$

### 3.1.5. Çıktılar

Aktivasyon fonksiyonlarından elde edilen deęerler yapay nöronların çıktı deęeri olarak adlandırılmaktadır. Elde edilen bu deęerler dış etkenlere ya çıktı olarak verilir ya da tekrardan başka bir yapay nörona girdi olarak verilebilir.


Aşağıdaki şekilde bu çalışmanın çıkış parametresi gösterilmektedir.

<b>Id</b>	<b>Mahalle</b>	<b>Sokak</b>	<b>Tür</b>	<b>Kira (TL)</b>
1	Aydınlıkevler	Gökyüzü	Konut	320
2	Aydınlıkevler	Gökyüzü	Konut	320
3	Aydınlıkevler	Eğilmez	Konut	518
4	Aydınlıkevler	Eğilmez	Konut	518
5	Aydınlıkevler	Eğilmez	Konut	515
6	Aydınlıkevler	Eğilmez	Konut	487
7	Aydınlıkevler	Şehit Cemalettin	Konut	450
8	Aydınlıkevler	Şehit Cemalettin	Konut	300
9	Aydınlıkevler	Uzayan	Konut	725
10	Aydınlıkevler	Uzayan	Konut	805

Şekil 5. Çıkış parametresi

### 3.2. Yapay Sinir Ağları Yapısı


Yapay sinir nöronlarının birbirleriyle ilişki kurması sonucu yapay bir ağ yapısı oluşur. Böylece yapay sinir ağları en az üç katmandan oluşur.



Şekil 11. Mimari Yapı [25]

### 3.2.1. Giriş Katmanı


Dış etkenlerden gelen girdi verilerin ilk geldiği katmandır. Her bir girdi verisine karşılık birer yapay nöron karşılık gelir. Girdi verileri bu katmandan gizli katmana doğru iletilir. Aşağıdaki şekilde uygulamanın giriş katmanı gösterilmiştir.



Şekil 12. Giriş Katmanı

### 3.2.2. Gizli Katmanı

Girdi katmanından iletilen girdi verileri gizli katmana iletilir. Bu katmanda veriler işlenerek bir sonraki katmana iletilir. Aşağıdaki şekilde uygulamanın gizli katmanları gösterilmiştir.



**Şekil 13.** Gizli Katman

### 3.2.3. Çıkış Katmanı

Gizli katmandan iletilen verileri çıkış parametresi olarak iletir. Bu katmanda yapay çıkış hücreleri birden fazla olabilir. Bu durumda her bir yapay hücrenin sadece bir çıktı parametresi olur.

## 3.3. Yapay Sinir Ağlarının Sınıflandırılması


Tezin bu kısmında, yapay sinir ağlarının yapılarına ve algoritmalarına göre sınıflandırılmasına yer verilmiştir.

### 3.3.1. Yapılarına Göre Sınıflandırılması

Bu kısımda, yapay sinir ağları yapılarına göre incelenerek ileri beslemeli ve geri beslemeli yapay sinir ağları açıklanmıştır.

### 3.3.1.1. İleri Beslemeli


Yapay sinir nörönları, girdi parametresi olarak gelen verileri girdi katmanına ve gizli katmana daha sonra ise çıkış katmanına iletir. İleri beslemeli yapay sinir ağıları düzenli bir katmana sahiptir.



Şekil 14. İleri Besleme [26]

### 3.3.1.2. Geri Beslemeli

Bir yapay nörönun çıktısı bir sonraki katmana giriş parametresi olarak verilmeyebilir. Bir önceki katmana tekrardan girdi verisi olarak gönderilebilir.




Şekil 15. Geri Besleme [27]

### 3.3.2. Algoritmalarına Göre Sınıflandırılması

Bu kısımda, yapay sinir ağları algoritmalarına göre danışmanlı, danışmansız ve pekiştirmeli öğrenme kavramları açıklanmıştır.

#### 3.3.2.1. Danışmanlı Öğrenme

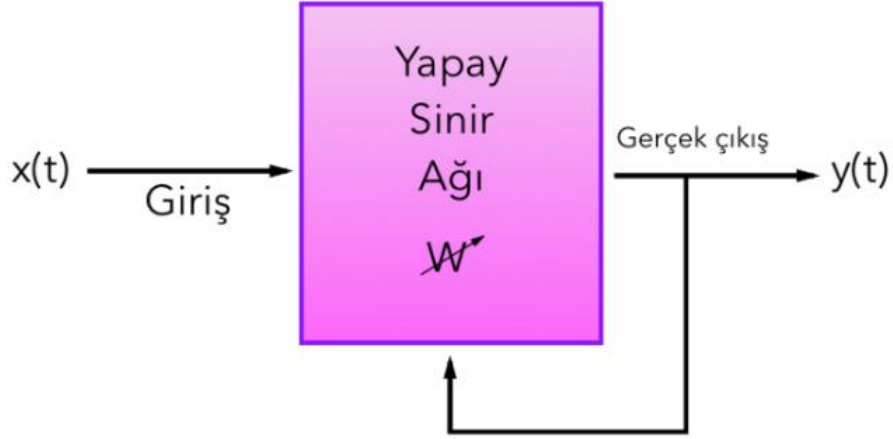
Yapay sinir ağlarında yapı daha önceden bir takım verilerle eğitilir. Giriş parametresine karşılık çıkış parametreleri sisteme verilerek öğrenilmesi sağlanır. Daha sonra başka bir eğitim seti verilerek bunlara karşılık üretilen çıkış verileri karşılaştırılarak sistemin doğruluğu tespit edilir.



Şekil 16. Danışmanlı Öğrenme [28]

### 3.3.2.2. Danışmansız Öğrenme

Danışmanlı öğrenme algoritmasından farkı girdi parametrelerine karşılık çıkış parametreleri verilmez. Sistem sahip olduğu giriş verilerine karşılık çıkış verileri üretir.



Şekil 17. Danışmansız Öğrenme [28]



### 3.3.2.3. Pekiştirmeli Öğrenme

Sisteme giriş verileri verilerek uzman tarafından sonuçların değerlendirilmesi sağlanır. Daha sonra yapay sinir nöronların ağırlıkları güncellenir. Örneğin, satranç oyununda herhangi bir hamle yapılacağında karşı tarafın buna verecek muhtemel cevap dikkate alınır.

## 3.4. Yapay Sinir Ağlarının Özellikleri

Yapay sinir ağları tıpkı insanlar gibi karar verme ve öğrenebilme yeteneklerine sahiptir. Girdi verileri ne kadar çeşitli ve fazla olursa sistemin doğruluğu o kadar kesine yakın olur. Böylece belirsiz ve eksik verileri işleyebilir, hata oranı en az olur. İnsanların çözmesi zor problemleri çözmek için tasarlanmış bir sistemdir.

### 3.4.1. Avantajları

- a) Tam anlaşılmayan verilerle çalışabilir
- b) Hata oranı her zaman vardır
- c) Sisteme verilen girdiler ağın tamamında saklanır
- d) Benzer problemleri öğrenerek yorum yapabilir. Eğitim verilerinden elde edilen bilgilerle daha önce karşılaşmadığı test verisinden anlamlı sonuçlar çıkarabilir.
- e) Elde ettiği bilgilerle sınıflandırma yapabilir.
- f) Aynı anda birden fazla işlemi yapabilme kabiliyetine sahiptir
- g) Birden fazla yapay nöronlardan meydana gelen karmaşık yapısı sayesinde işlem sırasında işlevsiz kalan bir nöron sistemin çalışmasını engellemez.


### 3.4.2. Dezavantajları

- a) Üretilen sonuçların açıklaması yoktur. Ağın davranışları açıklanamamaktadır.
- b) Ağda belirli bir kural yoktur. Farklı metotlar kullanılır
- c) Problemin teşhisi sisteme öğretilmelidir
- d) Sisteme verilecek eğitim seti için genel bir kural yoktur
- e) Güçlü donanıma ihtiyaç duyması

### 3.4.3. Aşırı Öğrenme (Overfitting)

Makine Öğrenmesi uygulamalarında temel mantık, belli bir amacı gerçekleştirmek için makinelere öğretilen eğitim setinden yola çıkarak örüntüler öğretmek ve bu örüntüleri kullanarak sonuç değerleri üretmektir. Bu esnada model belirlendikten sonra yapılmaması gereken iki tip hata vardır. Bunlar aşırı öğrenme (overfitting) ve eksik öğrenme (underfitting)'dir.

Aşırı öğrenme, kısaca veri setinin öğrenilmesidir. Böyle bir durumdan ise kaçınılması gerekir. Çünkü sistem çıkarımlar üzerinden değil elindeki eğitim setinden ezberlediği sonuçlar üzerinden parametre üretir. Böylece elindeki veri setinden hariç başka bir gözlemlerle karşılaşırsa hatalı ve başarısız bir sonuç çıkarmış olacaktır.




Şekil 18. Aşırı Öğrenme [29]

Yukarıdaki şekilde, sistem elindeki veri setini ezberleyerek, tahminden ziyade sonuçları tam bulmuştur.

### 3.4.4. Eksik Öğrenme (UnderFitting)

Eksik öğrenme, istediğimiz tahminleri sistemin yapamamasıdır. Böyle bir durumda eğitim verileri üzerinde düşük performans elde edilecektir.

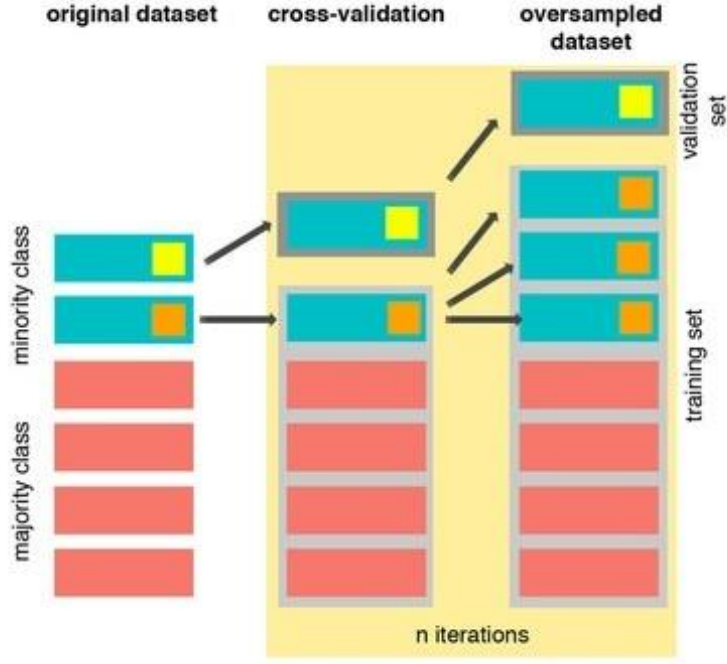


Şekil 19. Eksik Öğrenme [29]

Yukarıdaki şekilde eksik öğrenme gösterilmiştir. İstenilen sonuçların elde edilemediği gözlenmiştir.

### 3.4.5. Çapraz Geçerlilik

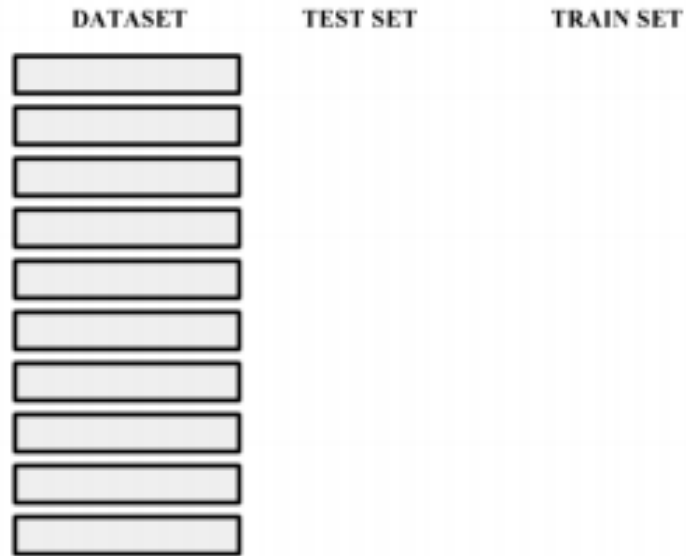
Sistemin bir problem karşısında tahmin edilebilir hale gelmesi için veri seti ikiye ayrılır. İlk parçaya eğitim seti denilerek sistemin öğretilmesi sağlanır. Böylece test seti için çıkarımlar elde etmek için sistem eğitilmiş olur.



Şekil 20. Çapraz Geçerlilik [30]

### 3.4.5.1. Rasgele Geçerlilik

Veri seti rasgele kümelerle ayrılarak sistemin birkaç kez bu kümeleri tekrarlar. En başarılı sonuçlar burada alınır.



Şekil 21. Rasgele Geçerlilik [31]

### **3.4.5.2. K Parçalı**

Veri seti K çeşit kümeye ayrılır. Bu kümelerden biri eğitim seti olurken geri kalan K-1 adet küme birleştirilerek test seti olur. Sistem birleştirilmiş kümeyi K kez tekrarlayarak elde edilen sonuçların ortalaması alınır.

## **4. KONUT KİRAYI ETKİLEYEN FAKTÖRLER**

Yatırım dendiği zaman akla ilk gelen hususlardan biri gayrimenkul satın almaktır. Dünyanın her yerinde olduğu gibi ülkemizde de gayrimenkul fiyatı belirlenmesinde birçok bilgi ve istatistik ihtiyacı olduğu gerçeği ortadadır [32].

Bir gayrimenkul değerini etkileyen en önemli faktör bulunduğu muhittir. Tabi ki bu muhitin önemini merkeze olan uzaklığı, önemli ulaşım yollarına yakınlığı, park, alışveriş merkezleri vb. faktörler doğrudan etkiler. Ama bir gayrimenkul değerini sadece bu faktörlere bağlamakta çok sağlıklı olmaz. O dönemin piyasa koşulları, ekonomik seviyesi ve tüm riskler göz önüne alınarak daha verimli ve kullanılabilir değer belirlemek son derece önemlidir.

Bu alanda yapılan bir anket çalışmasında gayrimenkul değerini; konutun bulunduğu kat, asansör, oda sayısı, banyo sayısı, kaloriferli ısınma sistemi, eğitim kurumlarına uzaklık, sağlık kuruluşlarına ve şehir merkezine yakınlık arasında doğrudan bir ilişki olduğu anlaşılmıştır. [33].

Ayrıca, Gayrimenkul değeri ile bu değeri etkileyen faktörleri arasında anlamlı bir bağ kurup tahmin edilmesinde yapay sinir ağları 1990'lı yıllardan bu yana kullanılmaktadır. Bu alanda ilk çalışmayı Borst 1991 [34] yapmış daha sonra ise 1993'te Evan [34] , 1995'te Worzala [34] ve 1996'da ise McCluskey [34] yapmıştır.

## **5. ARAŞTIRMA BULGULARI VE SONUÇ**

Veritabanında bulunan text tipinde ve açık adresleri bilinen Aydınlikevler mahallesindeki konutların Google harita üzerinde göstermek üzere Google api kullanılmıştır.

**ApiKey:** Google sitesinden ücretsiz olarak alınır.

**acikAdres:** Veritabanında bulunan text tipindeki konutların açık adresleridir.

Gayrimenkul konutların alışveriş merkezlerine, parka, okullara ve önemli bulvar-caddelere uzaklıklarını hesaplamak için aşağıdaki parametreler kullanılmıştır.

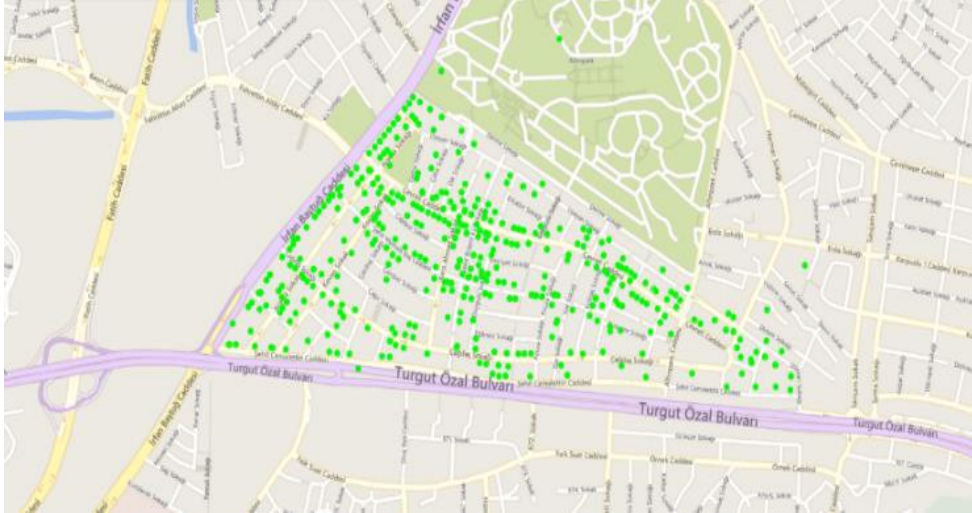
**&origin :** Başlangıç noktası olarak kullanılan parametredir. Her bir konutların açık adresi bu parametreye atanmıştır.

**&destination :** Hedef noktasıdır. Harita belirlenen alışveriş merkezleri, okul, park ve bulvarların açık adresidir.

Adres verilerinden yola çıkılarak bulunan her bir konutun geometrik verilerini harita üzerinde marker olarak işaretlemek için aşağıdaki teknolojiler kullanılmıştır.

- **Openlayers :** Harita kütüphanesidir. Bu uygulama konutlar haritada işaretlemek için ve layer oluşturmak için kullanılmıştır.
- **Geoserver:** Harita sunucusudur. Konutların layer'ı create edilmiştir ve localhost'ta yayınlanmıştır.

Aydınlıkevler mahallesi konut yerleşimi aşağıdaki şekilde gösterilmiştir.



**Şekil 23.** Aydınlikevler konut yerleşimi

Konutların parklara, okullara, alışveriş merkezlerine ve önemli cadde-bulvarlara olan uzaklığını belirten 800 test verilerinin girdi parametrelerinin 10 tanesi Şekil 24’de gösterilmiştir. Test verileri, SQL Server veritabanında 1NF normalize edilmiştir. Test verilerin sonuç parametreleri ise Şekil 25’de “kira” kolonunda gösterilmiştir.

<b>Id</b>	<b>Avm</b>	<b>Bulvar</b>	<b>Park</b>	<b>Okul</b>
1	75	10	6	3
2	73	8	5	2
3	73	15	11	10
4	63	15	10	5
5	75	8	4	1
6	75	10	6	3
7	69	11	8	12
8	73	8	5	2
9	74	8	5	5
10	73	15	11	10

**Şekil 24.** Normalize edilen mesafeler

<b>Id</b>	<b>Mahalle</b>	<b>Sokak</b>	<b>Tür</b>	<b>Kira (TL)</b>
1	Aydınlıkevler	Gökyüzü	Konut	320
2	Aydınlıkevler	Gökyüzü	Konut	320
3	Aydınlıkevler	Eğilmez	Konut	518
4	Aydınlıkevler	Eğilmez	Konut	518
5	Aydınlıkevler	Eğilmez	Konut	515
6	Aydınlıkevler	Eğilmez	Konut	487

7	Aydınlıkevler	Şehit Cemalettin	Konut	450
8	Aydınlıkevler	Şehit Cemalettin	Konut	300
9	Aydınlıkevler	Uzayan	Konut	725
10	Aydınlıkevler	Uzayan	Konut	805


**Şekil 25.** Girdi verisi sonuç parametresi

800 adet eğitim verileri “Numpy” kütüphanesi ile dataset parametresine import edilmiştir. Aşağıdaki işlem basamakları takip edilerek sistem eğitilmiştir.

- `model.add(Dense())` ile 4 gizli katman oluşturulmuştur.
- `model.add(Activation('sigmoid'))` ile Sigmoid aktivasyon fonksiyonu belirlenmiştir.
- `Model.fit()` ile sistem eğitim verileri ile eğitilmiştir.



Sistemde oluşturulan 4 gizli katman Şekil 26’da gösterilmiştir.



Şekil 26. Gizli katmanlar

Sistemin eğitilme süreç basamaklarına ilişkin epoch Şekil 27’de gösterilmiştir.

Epoch	Loss	Acc	Val_loss	Val_acc
50/55	0.1126	0.9375	0.3137	0.7885
51/55	0.2281	0.8438	0.3073	0.7885
52/55	0.3880	0.7812	0.2981	0.7788
53/55	0.5199	0.8438	0.3160	0.7885
54/55	0.1413	0.9375	0.3624	0.7885
55/55	0.4018	0.7812	0.2874	0.8173
Accuracy Score	0.8562			

Şekil 27. Epoch

Sistemdeki 800 adet eğitim verisinin ağırlıkları 55 kere(epoch) güncellenmiştir. Sistem her bir epoch seviyesinde tüm dataseti tekrardan gözden geçirerek öğrenme sürecini %85.62 doğruluk payı ile tamamlamıştır.

Eğitim sürecinden test aşamasına geçen sisteme test verileri import edilir. Ancak burada sisteme sadece test verilerinin girdi parametreleri verilerek sonuç parametresini tahmin etmesi beklenir.

500 adet test verilerinin girdi parametreleri Şekil 28’de gösterilmiştir.

<b>Id</b>	<b>Avm</b>	<b>Bulvar</b>	<b>Park</b>	<b>Okul</b>
1	71	1	7	6
2	75	13	10	6
3	65	8	8	6
4	65	15	11	1
5	75	10	6	3
6	71	1	7	6
7	74	8	5	5
8	73	15	11	10
9	74	7	9	4
10	73	8	5	2

**Şekil 28.** Test verileri girdi parametreleri

Eğitim sürecini %85.62 doğruluk oranı ile tamamlayan sistem, test verilerini ise Şekil 29’da gösterilen %84 doğruluk ile tahmin etmiştir.

<b>Toplam</b>	<b>Doğru</b>	<b>Yanlış</b>	<b>Başarı Yüzdesi</b>
500	421	79	84

**Şekil29.** Modelin gerçeklik değeri

Sistemin 500 gayrimenkul konut incelenmesinde %84 başarı yüzdesine ulaşıldığı görülmektedir.

Numara	Precision	Recall	F1-score	Support
1.0	0.98	0.89	0.93	56
2.0	0.91	0.93	0.92	212
3.0	0.88	0.84	0.86	161
4.0	0.49	0.91	0.63	43
5.0	0.0	0.0	0.0	18
6.0	0.0	0.0	0.0	4
7.0	0.0	0.0	0.0	6

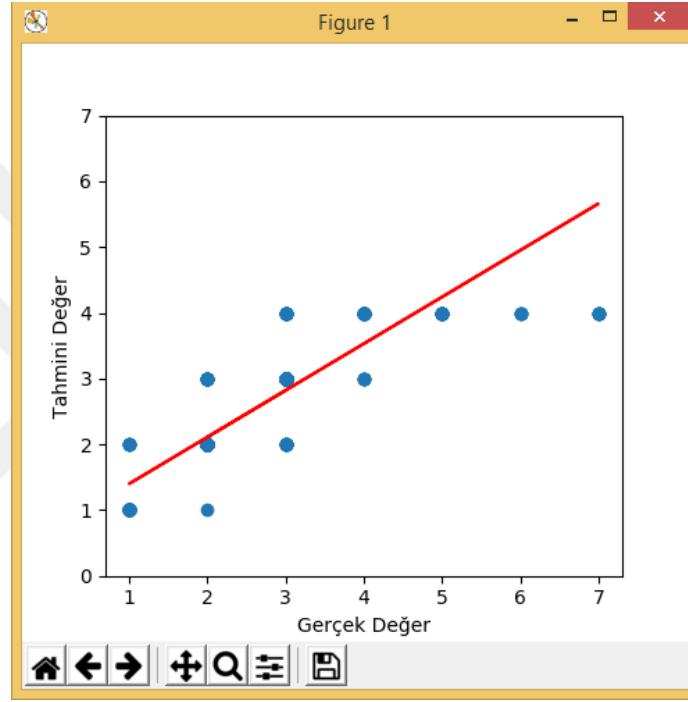
Şekil 30. Confusion matrix

Aydınlıkevler mahallesindeki gayrimenkul kira değerleri 0-300TL, 300-600TL, 600-900TL, 900-1200TL, 1200-1500 TL, 1500-1800 TL, 1800-2100 TL olmak üzere 7 parçaya ayrılmıştır. Bu parçalara sırasıyla 1'den 7'ye kadar sayı verilmiştir. Şekil 30 analizi şu şekilde yorumlanmıştır.

- 1.0; 1 aralığına denk gelmekle birlikte kira değeri 0-300 TL aralığında 56 tane konutu %98 doğruluk payı ile tahmin etmiştir.
- 2.0; 2 aralığına denk gelmekle birlikte 300-600 TL aralığında 212 konutu %91 doğruluk payı ile tahmin etmiştir.
- 3.0; 3 aralığına denk gelmekle birlikte 600-900 TL aralığında 161 konutu %88 doğruluk payı ile tahmin etmiştir.
- 4.0; 4 aralığına denk gelmekle birlikte 900-1200 TL aralığında 43 konutu %49 doğruluk payı ile tahmin etmiştir.
- 5.0; 5 aralığına denk gelmekle birlikte 1200-1500 TL aralığında 18 konutu %0 doğruluk payı ile tahmin etmiştir.

- 6.0; 6 aralığına denk gelmekle birlikte 1500-1800 TL aralığında 4 konutu %0 doğruluk payı ile tahmin etmiştir.
- 7.0; 7 aralığına denk gelmekle birlikte 1800-2100 TL aralığında 6 konutu %0 doğruluk payı ile tahmin etmiştir.

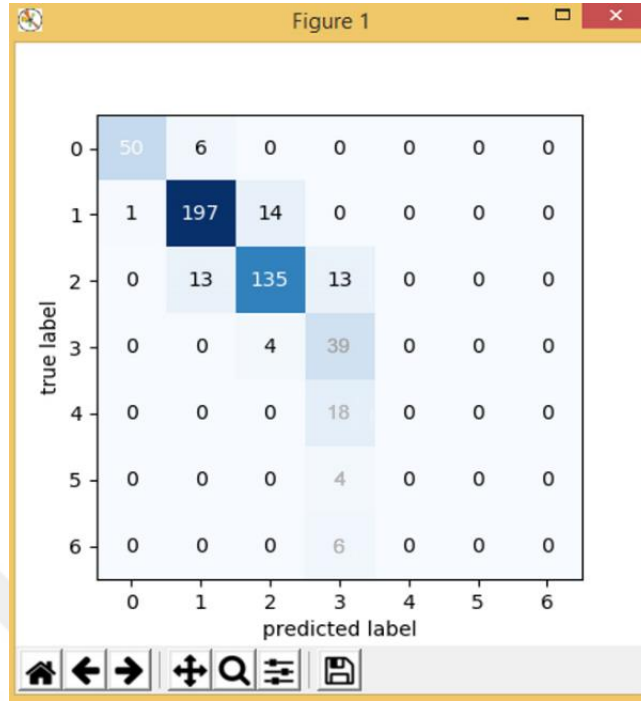
Şekil 31’de yatay eksen gayrimenkulün gerçek kira değerleridir. Dikey eksen ise gerçek kira değerine karşılık gelen tahmini değerdir. Her bir gayrimenkul nokta ile tanımlanmıştır.



Şekil 31. Scatter ve lineer regresyon

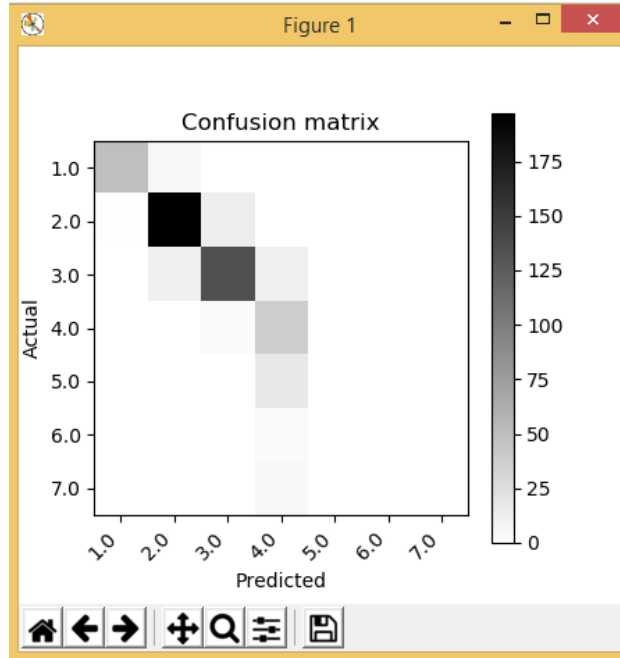
Yukarıda gerçek değeri 1(bir) ve tahmini değeri 1(bir) olan scatter grafiği, şekil 30 Confusion matrix şeması göz önüne alındığında bu aralıkta 56 tane gayrimenkul bulunduğu anlaşılabilir olup bu gayrimenkul kira değerleri doğruluk oranı (precision) ise %98 olarak ölçülmektedir. Fakat gerçek değeri 7(yedi) tahmini değeri 4 olarak tahmin edilen 6 tane gayrimenkulün kira değerini yanlış hesaplanmış ve Confusion Matrix şemasında %0 doğruluk (precision) oranı görülmüştür.

Aşağıdaki şekilde ağırlıklı confusion matrix gösterilmektedir.



Şekil 32. Confusion matrix

Her bir ağırlıklı confusion matrix'e karşılık gelen renklerle ağırlaştırılmış confusion matrix şekil 33'de gösterilmiştir.



Şekil 33. Renk ile ağırlaştırılmış Confusion matrix

## KAYNAKLAR

- [1] «İTÜ NOVA,» [Çevrimiçi]. Available: <http://blog.itunovatto.com.tr/bilim-insanlari-hucreleri-yapay-zekâ-kullanarak-gozlemlemeye-basladi/>.
- [2] 2015. [Çevrimiçi]. Available: <https://t24.com.tr/haber/bilim-insanlarindan-yapay-zekâ-uyarisi>.
- [3] A. Evrim, «Evrım Ağacı,» 2011. [Çevrimiçi]. Available: <https://evrimagaci.org/katledilmis-deha-bilgisayar-ve-yapay-zekânin-fikir-babasi-alan-turing-27>.
- [4] F. Daşkırın, «Denizli Kentinde Konut Talebine Etki Eden Faktörlerin Hedonik Fiyatlandırma,» Uluslararası Sosyal Araştırmalar Dergisi, 2015.
- [5] R. Gotesman, 2018. [Çevrimiçi]. Available: <https://towardsdatascience.com/learning-backpropagation-from-geoffrey-hinton-619027613f0>.
- [6] A. Jahnke, «Boston University,» 2019. [Çevrimiçi].
- [7] A. Kızrak, 2018. [Çevrimiçi]. Available: <https://medium.com/deep-learning-turkiye/yapay-zekâya-ba%C5%9Flama-rehberi-91e79d3de8e1>.
- [8] M. M. Mijwel, *Yapay Zeka Nedir?*, 2016.
- [9] J. Schaeffer ve R. Lake, 1996. [Çevrimiçi]. Available: <http://library.msri.org/books/Book29/files/schaeffer.pdf>.
- [10] C. Maccone, *Mathematical SETI, Praxis*.
- [11] E. A. Feigenbaum ve B. G. Buchanan, 1993. [Çevrimiçi]. Available: <https://stacks.stanford.edu/file/druid:rv258md4469/rv258md4469.pdf>.
- [12] «Moment Expo,» 2010. [Çevrimiçi]. Available: <http://www.moment-expo.com/m-oden-gunumuze-robot-tarihi>.
- [13] A. J. Hawkins, 2018. [Çevrimiçi]. Available: <https://www.theverge.com/2018/2/26/17054000/self-driving-car-california-dmv-regulations>.

- [14] M. Arıkan, «Mediaclick,» [Çevrimiçi]. Available: <https://www.mediaclick.com.tr/blog/yapay-zeka-nedir>. [Erişildi: 2019].
- [15] A. Sönmez, Uzman Sistemler.
- [16] A. Sönmez, «İstanbul Teknik Üniversitesi,» [Çevrimiçi]. Available: [https://web.itu.edu.tr/~sonmez/lisans/es/uzman\\_sistemler\\_giris.pdf](https://web.itu.edu.tr/~sonmez/lisans/es/uzman_sistemler_giris.pdf).
- [17] A. Sönmez. [Çevrimiçi]. Available: [https://web.itu.edu.tr/~sonmez/lisans/es/uzman\\_sistemler\\_giris.pdf](https://web.itu.edu.tr/~sonmez/lisans/es/uzman_sistemler_giris.pdf).
- [18] 2015. [Çevrimiçi]. Available: <https://protechnowall.wordpress.com/2015/05/17/bir-uzmana-gorunmekte-fayda-var-uzman-sistemler-nedir/>
- [19] M. F. Keskenler ve E. F. Keskenler, «Bulanık Mantığın Tarihi Gelişimi,» pp. 1-10, 2017.
- [20] 2016. [Çevrimiçi]. Available: <https://www.muhendisbeyinler.net/bulanik-mantik-nedir/>
- [21] Ç. Telef, 2016. [Çevrimiçi]. Available: <https://caglarartef.com/genetik-algoritmalar-nedir/>.
- [22] 2013. [Çevrimiçi]. Available: <http://www.ibrahimbayraktar.net/2013/11/sinir-sisteminin-yaps-ve-islevleri.html>
- [23] N. YALÇIN. [Çevrimiçi]. Available: <https://docplayer.biz.tr/3314312-Yapay-sinir-aglari-aras-gor-nesibe-yalcin-bilecik-universitesi.html>
- [24] A. KIZRAK. [Çevrimiçi]. Available: <https://medium.com/deep-learning-turkiye/derin-%C3%B6%C4%9Frenme-i%C3%A7in-aktivasyon-fonksiyonlar%C4%B1n%C4%B1n-kar%C5%9F%C4%B1la%C5%9Ft%C4%B1r%C4%B1lmas%C4%B1-cee17fd1d9cd>
- [25] M. USLU 2016. [Çevrimiçi]. Available: <http://kod5.org/yapay-sinir-aglari-ysa-nedir/>
- [26] Öztemel, E., 2006, Yapay Sinir Ağları, Papatya Yayıncılık, İstanbul.
- [27] (Kabalcı, 2015)

- [28] Y. GÜZEL, 2018. [Çevrimiçi]. Available:  
<https://medium.com/@yasinguzel/yapay-zeka-ders-notlar%C4%B1-04-yapay-sinir-a%C4%9Far%C4%B1n%C4%B1n-yap%C4%B1s%C4%B1-6b9bfc3004bf>
- [29] [Çevrimiçi]. Available: [https://scikit-learn.org/stable/auto\\_examples/model\\_selection/plot\\_underfitting\\_overfitting.html](https://scikit-learn.org/stable/auto_examples/model_selection/plot_underfitting_overfitting.html)
- [30] [Çevrimiçi]. Available: <https://veribilimcisi.com/2017/07/13/capraz-dogrulama-cross-validation-nedir/>
- [31] U. ORHAN. [Çevrimiçi]. Available:  
<http://bmb.cu.edu.tr/uorhan/DersNotu/Ders01.pdf>
- [32] McCulloch ve Pitts, «A Logical calculus of the ideas immanent,» 1948, pp. 115-133.
- [33] Rossini, «A Comparison Of Models Measuring The Implicit Price Effect Of Aircraft Noise,» New Zeland, 2002.
- [34] Schmidhuber, «Deep learning in neural networks,» 2015, pp. 87-117.