

T.C.

BEYKENT ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

BİLGİSAYAR MÜHENDİSLİĞİ BİLİM DALI

**MELEZ ÖĞRENME İLE KALP VE DAMAR  
HASTALIĞININ TAHMİNİ**

(Yüksek Lisans Tezi)

Tezi Hazırlayan:

**Cansu TOKYÜZ**

İstanbul, 2018

T.C.

BEYKENT ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

BİLGİSAYAR MÜHENDİSLİĞİ BİLİM DALI

**MELEZ ÖĞRENME İLE KALP VE DAMAR  
HASTALIĞININ TAHMİNİ**

(Yüksek Lisans Tezi)

Tezi Hazırlayan:

**Cansu TOKYÜZ**

Öğrenci No:

150820003

Danışman:

Dr. Öğr. Üyesi Atınc YILMAZ

İstanbul, 2018

## YEMİN METNİ

Yüksek lisans tezi olarak sunduğum "Melez Öğrenme ile Kalp ve Damar Hastalığının Tahmini" başlıklı bu çalışmamın, bilimsel ahlâk ve geleneklere uygun yazıldığını, yararlandığım eserlerin tamamının kaynaklarda gösterildiğini ve çalışmamın içinde kullanıldıkları her yerde bunlara atıf yapıldığını belirtir ve bunu onurumla doğrularım. 25.05.2018

Cansu TOKYÜZ



T.C.  
BEYKENT ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ




YÜKSEK LİSANS TEZ SAVUNMA SINAVI SONUÇ TUTANAĞI

Beykent Üniversitesi  
Fen Bilimleri Enstitüsü Müdürlüğü'ne,

Aşağıda tez adı belirtilen yüksek lisans öğrencisi ...150820003... no'lu  
.....CANSU TOKYÜZ.....'in 12/6/18 tarihinde yapılan tez savunma sınavı<sup>1</sup>  
sonucunda ...45... dakika süreyle sunduğu ve savunduğu tezi hakkında<sup>2</sup> oybirliğiyle,  
.....KABUL... kararı verilmiştir.

Bilgilerinize saygılarımızla arz ederiz.

Anabilim Dalı : BİLGİSAYAR MÜHENDİSLİĞİ  
Programı : BİLGİSAYAR MÜHENDİSLİĞİ  
Tez Başlığı<sup>3</sup> : Melez Öğeme İle Kalp ve Damar Hastalığının  
Tahmini

<u>Tez Sınav Jürisi</u>	<u>Öğretim Üyesi</u>	<u>İmza</u>
Danışman	: Dr. Öznü LİYUİ ATINÇ YILMAZ	
Üye	: Prof. Dr. Gökhan DAHTAR OĞLU	
Üye	: Dr. Ediz ŞAYKOL	

<sup>1</sup>Jüri üyeleri, söz konusu tezin kendilerine teslim edildiği tarihten itibaren en geç bir ay içinde toplanarak öğrenciyi tezsınavına alır. Tez savunma sınav süresi en az 45, en çok 90 dakikadır. Jüri üyeleri, sınav öncesi yapılacak toplantıda, kendi aralarından danışman dışında bir üyeyi başkan seçer. Tezsınavı, tez çalışmasının sunulması ve bunu izleyen soru-cevap bölümünden oluşur. Tezsınavı, öğretim elemanları, lisansüstü öğrenciler ve alanın uzmanlarından oluşan dinleyicilerin katılımına açık ortamlarda gerçekleştirilir. Belirli gündey yapılacak jüri toplantısı, katılanların hazırladığı birtutanakla enstitü yönetimine bildirilir. Bu durumda, jüri geç on beş gün içinde toplanarak adayın tezsavunmasını alır. (05 Ağustos 2017 tarihli 30145 sayılı Resmi Gazetede Yayınlanan Değişiklik-Madde 29-3)

<sup>2</sup>Tezsınavının tamamlanmasından sonra jüri, tez hakkında salt çoğunlukla "kabul", "düzeltme" veya "ret" kararı verir. Jüri başkanı, jüri üyelerince imzalanmış karar tutanağını, tezsınavı ile ilgili enstitü yönetimete teslim eder. Tezi hakkında düzeltme kararı verilen öğrenciye geç üç ay içinde gerekli düzeltmeleri yapar ve birinci fıkradaki usule göre tezi aynı jüri önünde yeniden savunur. Süresi içerisinde "düzeltme" savınması girmeyen öğrencinin enstitü ile ilişkisi kesilir. (Beykent Üniversitesi Lisansüstü Eğitim ve Öğretim Yönetmeliği-Madde 29-4)

<sup>3</sup>İleri de doğabilecek aksaklıkların engellenmesi için tezin başlığını yazılması gerekmektedir.

## TEŐEKKÖR

Bu tez alıőmamda bana desteklerini esirgemeyen, bana bilgi ve önerileri ile yol gösteren danışman hocam sayın Dr. Öđr. Üyesi Atın Yılmaz'a, Öğretim Görevlisi Umut Kaya'ya, Msc. Tolga Bodrumlu'ya ve hayatım boyunca her zaman desteklerini benden esirgemeyen aileme ve dostlarıma sevgi, saygı ve teşekkürlerimi sunarım.

Cansu TOKYÜZ

Adı ve Soyadı : Cansu TOKYÜZ

Danışmanı : Dr. Öğr. Üyesi Atınç YILMAZ

Türü ve Tarihi : Yüksek Lisans, 2018

Alanı : Bilgisayar Mühendisliği

Anahtar Kelimeler : Yapay Sinir Ağı; Yapay Zeka; Melez Öğrenme; Makine Öğrenmesi; K-Ortalamaları Algoritması; Hastalık Tahmini; Kardiyoloji

## ÖZ

### MELEZ ÖĞRENME İLE KALP VE DAMAR HASTALIĞININ TAHMİNİ

Ülkemizde ve dünyada yaşam kalitesini düşüren, çok sayıda ölüme sebep olan ve tedavi giderleri fazla olan kalp ve damar hastalıklarına yakalanma riski yaşı gün geçtikçe düşmektedir. Hastalığın tedavisinde erken tanının rolü büyüktür. Bununla ilgili birçok alanda çalışmalar yapılmaktadır. Teknolojinin gelişmesiyle günümüzde makinelerin insan öğrenmesini taklit edebilmesi ve çıkarım yapabilmesi sağlanmıştır. Yapay Zeka adı verilen bu yöntem ile makinelerin günlük hayatımızda ve bir çok alanda insan yaşamını kolaylaştıracağı düşünülmektedir. Yapay zekanın alt dalları olan yapay sinir ağları hastalıkların erken tanısında kullanılmaktadır. Literatürde birçok çalışmada kullanılan bu yöntemler ile hastalıklara neden olan faktörler girdi olarak alınıp hastalık sonucu tahminlemesi yapılabilmektedir. Böylece hastalığa yakalanma riski olanların erken tanı ile tedavisi mümkün olabilmektedir.

Bu çalışmada, yapay sinir ağları yöntemi ile birlikte önerilen melez (hibrit) sistem kıyaslanarak kalp ve damar hastalıklarının tedavisinde hastanın durumunun önceden tahmini sağlanmaktadır. Önerilen melez sistemin yapısında k - ortalamalar algoritması ve yapay sinir ağı yöntemi kullanılmaktadır. Kardiyoloji verilerinin hastalık tahmininde en iyi sonucu veren modelin tespit edilmesi için yapılan çalışmada yapay sinir ağı ve melez sistem iki farklı model oluşturulmuştur. Kardiyoloji verileri kullanılarak yapılan hastalık tahmininde model başarımları ölçütlerinde kullanılan ortalama karesel hata, kök ortalama karesel hata ve ortalama

mutlak yüzde hatası performans kriterleri ile en doğru sonucu veren model belirlenmektedir.



Name and Surname : Cansu TOKYÜZ

Supervisor : Asst. Prof. Dr. Atınç YILMAZ

Degree and Date : Master's Thesis/2018

Major : Computer Engineering

Key Words : Artificial Neural Network; Artificial Intelligence; Hybrid Learning; Machine Learning; K-Means Algorithm; Disease Prediction; Cardiology

## **ABSTRACT**

### **PREDICTING CARDIOVASCULAR DISEASE WITH HYBRID LEARNING**

The age of getting heart and vascular diseases risk, which decrease the quality of life in our country and world, cause lots of deaths and has a high cost of treatment, decrease day by day. The role of early diagnosis in the treatment of disease is really important. There are many works related this field nowadays. In recent days, with the development of technology, machines imitate the human learning and make predictions. With this method, which called Artificial Intelligence, machines are thought to facilitate the daily life. Artificial neural networks, which are the lower branches of artificial intelligence, are used for early diagnosis of diseases. With these methods used in many studies in the literature, the factors causing diseases can be taken as input and the disease result can be estimated. Therefore, early diagnosis of those who are at risk and treatment could be possible.

In this thesis study, the aim is to determine the disease in early diagnosis by estimating the treatment of cardiovascular diseases. This study used artificial neural network and k-means algorithm. Therefore, there exist a hybrid system. Two different models of artificial neural network and hybrid system have been developed in order to determine the model that gives the best result in the prediction of disease of cardiology data. To determine the best result model, the mean squared error, root mean squared error and average absolute percent error used in the model success criterion were used.



# İÇİNDEKİLER

Sayfa No:

ÖZ.....	i
ABSTRACT.....	iii
ŞEKİLLER TABLOSU.....	v
TABLolar LİSTESİ.....	vi
KISALTMALAR.....	vii
1. GİRİŞ.....	1
2. BENZER ÇALIŞMALAR.....	3
3. PROBLEM.....	7
4. YÖNTEMLER.....	8
4.1. Yapay Zeka.....	8
4.2. Yapay Sinir Ağları.....	8
4.2.1. Yapay Sinir Ağlarını Genel Özellikleri.....	8
4.2.2. Yapay Sinir Ağında Öğrenme ve Test Edilmesi.....	9
4.2.3. Yapay Sinir Ağlarının Çalışma Şekli.....	10
4.2.4. Biyolojik Sinir Hücresinin Yapısı.....	10
4.2.5. Yapay Sinir Ağları Yapısı ve Modelleri.....	12
4.2.5.1. Katmanlar.....	15
4.2.5.2. Tek Katmanlı Algılayıcılar.....	16

4.2.5.3.	Çok Katmanlı Algılayıcılar.....	16
4.2.5.3.1.	İleri Beslemeli Ağlar.....	17
4.2.5.3.2.	Geri Beslemeli Yapay Sinir Ağları.....	20
4.2.6.	Öğrenme Algoritmalarına Göre Yapay Sinir Ağları.....	20
4.2.7.	Levenberg - Marquardt Algoritması.....	22
4.3.	K-Means Algoritması (K-Ortalamlar Kümeleme Algoritması) .....	23
<b>5.</b>	<b>UYGULAMA.....</b>	<b>26</b>
5.1.	Veri.....	26
5.2.	Önerilen Yapı.....	27
5.3.	YSA VE Melez Sistem Uygulamaları.....	29
<b>6.</b>	<b>SONUÇ.....</b>	<b>37</b>
<b>KAYNAKÇA.....</b>		<b>41</b>
<b>ÖZGEÇMİŞ.....</b>		<b>44</b>

## ŞEKİLLER TABLOSU

**Sayfa No:**

<b>Şekil 1.</b> Biyolojik Sinir Hücresinin Yapısı.....	11
<b>Şekil 2.</b> Yapay Sinir Ağı Katmanları.....	15
<b>Şekil 3.</b> Tek Katmanlı Algılayıcı.....	16
<b>Şekil 4.</b> İleri Beslemeli Yapay Sinir Ağı.....	17
<b>Şekil 5.</b> Geri Beslemeli Yapay Sinir Ağı.....	20
<b>Şekil 6.</b> Danışmanlı Öğrenme.....	21
<b>Şekil 7.</b> Danışmansız Öğrenme.....	22
<b>Şekil 8.</b> K-Ortalamlar Kümeleme Algoritmasının Adımları.....	24
<b>Şekil 9.</b> Yapay Sinir Ağı Modeli.....	29
<b>Şekil 10.</b> Yapay Sinir Ağı Giriş ve Çıkış Verisi Yükleme.....	29
<b>Şekil 11.</b> Yapay Sinir Ağı Ayarları.....	30
<b>Şekil 12.</b> Yapay Sinir Ağı Yapısı.....	31
<b>Şekil 13.</b> Yapay Sinir Ağı Regresyon Grafiği.....	31
<b>Şekil 14.</b> Melez Sistem Modeli.....	32
<b>Şekil 15.</b> Giriş Verilerinin K- Ortalamalar ile Kümelere Ayrılması.....	33
<b>Şekil 16.</b> K- Ortalamalar ile Ayrılan Kümelerin Merkezleri.....	34
<b>Şekil 17.</b> Melez Sistem Yapısı.....	35
<b>Şekil 18.</b> Melez Sistem Regresyon Grafiği.....	35

## TABLolar LİSTESİ

**Sayfa No:**

<b>Tablo 1.</b> Toplama Fonksiyonları.....	13
<b>Tablo 2.</b> Aktivasyon Fonksiyonu.....	14
<b>Tablo 3.</b> Örnek Kardiyoloji Veri Seti.....	27
<b>Tablo 4.</b> YSA Modeli ile Elde Edilen Sonuçlar.....	37
<b>Tablo 5.</b> Melez Modeli ile Elde Edilen Sonuçlar.....	38
<b>Tablo 6.</b> YSA Performans Kriterleri Tablosu.....	39
<b>Tablo 7.</b> Melez Sistem Performans Kriterleri Tablosu.....	39
<b>Tablo 8.</b> YSA ve Melez Sistem Performans Kriterleri Karşılaştırması.....	40

## KISALTMALAR

- YSA** : Yapay Sinir Ađı
- K-Means** : K – Ortalamalar
- MSE** : Ortalama Karesel Hata (Mean Squared Error)
- RMSE** : Ortalama Karesel Hatanın Karekoku (Root Mean Squared Error)
- MAPE** : Ortalama Mutlak Yüzde Hatası



## 1. GİRİŞ

Dünyada ve ülkemizde bulaşıcı olmayan hastalıklar içerisinde, kalp ve damar hastalıkları ölüm nedenleri arasında ilk sıralarda yer almaktadır [1]. Sağlık bakanlığı 2015 yılı verilerine göre bulaşıcı olmayan hastalıkların görülme sıklığında artış yaşandığı belirlenmiştir [2]. Günlük yaşamda kalp ve damar hastalıklarının olumsuz etkileri artmakta ve sosyo-ekonomik gelişmeyi engellemektedir.

Teknolojinin gelişmesiyle birlikte hastalık riskinin önceden tahmin edilebilmesi için bir çok yöntem geliştirilmiştir. Bu gelişmiş yöntemlerden biri, bir çok sektörde daha yaygın kullanılmaya başlayan Yapay Zekadır. Araştırmalar yapay zekanın geliştiği, yeni icat ve yenilikleri ortaya koyduğu yönündedir. Yapay zeka teknikleri ile geliştirilmiş bir sistem, konusunda profesyonelleşmiş olan insanların yapabildiği tasarım, plan yapma, teşhis, yorum yapabilme, kontrol edebilme, tavsiye gibi işlemleri gerçekleştirebilmektedir [3]. Yapay zeka yöntemleri tıp alanında da kullanılmaya başlanmıştır. Tıp alanında uzman sistemler, yapısal sorunlara çözüm getirmek amacıyla geliştirilmiştir. Bu sistemler bir veya daha fazla tıp alanındaki uzman kişilerin tavsiyeleri doğrultusunda eğitilmektedir. Böylece sorunların dikkate alınarak uygun ve doğru çözümlerin üretilmesi sağlanır. Tıp alanındaki uzman sistemlerin amacı hekimin yerini almak değil daha çok hastaya ait verileri kullanarak, hekime tavsiye ve öneriler sunmaktır [4].

Bu çalışmada kalp ve damar hastalığı riski taşıyan kişilerin kardiyoloji veriseti Datalab TR sitesinde yeralan UCI Kardiyoloji verilerinden yararlanılarak oluşturulmuştur. Hastalık riskinin tahmini için yapay zeka yöntemlerinden k-ortalamar kümeleme algoritması ile yapay sinir ağları (YSA) yönteminin birlikte çalıştırılması ile oluşturulan melez tahmin modeli kullanılmaktadır. Ayrıca önerilmekte olan melez sistem ile hasta olup olmama durumunun tahmin edilmesi amaçlanmıştır. Yapay sinir ağları yönteminin kullanılmasındaki sebep hesaplama ve bilgi işleme gücü bakımından güçlü olmasıdır. Yapay Sinir Ağı, öğrenebilme ve genelleme kabiliyetini, paralel dağılmış yapısından alır. Genelleme, yapay sinir ağının eğitimi aşamasında veya öğrenme sürecinde karşılaşmadığı girdiler için de uygun çıktıları üretebilmesidir. Bu yetenekler yapay sinir ağlarının karmaşık problemleri de

özebilme kabiliyetine sahip olduğunu işaret eder. Bu özelliđiyle doğrusal olmayan karmaşık problemlerin çözümleri için yapay sinir ađları önemli bir araç olmuştur [5].

Çalıřmada yapay zeka yöntemlerinden olan ileri beslemeli geri yayılımlı, Levenberg-Marquardt eğitim algoritmasına sahip yapay sinir ađı modeli kullanılarak oluşturulan melez sistem ile kalp ve damar hastalığında yüksek risk taşıyan kişilerin belirlenmesi ve önceden önlem alınması amaçlanmıştır. Melez modelin ve YSA yönteminin toplam karesel hata, ortalama karesel hata ve kök karesel hata performans kriterleri karşılaştırılarak en iyi tahmin sonucunu veren model belirlenmiştir.



## 2. BENZER ÇALIŞMALAR

Yapılan literatür taramasında YSA ve melez bir sistem olan K-Ortalamlar algoritmaları ile YSA ile ilgili benzer çalışmalar incelenmiş. Araştırma sonucunda benzerlikler ve farklılar belirtilmiştir.

Cemil Çolak, M. Çengiz Çolak ve M. Ali Atıcı'nın Ankara Üniversitesi Tıp Fakültesi'nde yayımladıkları çalışmada Ateroskleroz tahmini için yapay sinir ağı kullanmışlardır [6]. 2 yıl süreyle yirmi adet klinik değişken, on beş hastadan on kişide ateroskleroz tespit edilmiştir. YSA, ateroskleroz değerlerine uygulanmıştır. YSA'nın ayırimsama oranı, eğitim için %86.6, test için %80 oranında olduğu görülmüştür. Çalışmanın sonucunda ateroskleroz'un tahmin edilmesinde YSA'nın oldukça başarılı sonuçlar üretebileceğini görmüşlerdir, ek olarak daha doğru sonuçlar elde etmek için örnek olarak gösterilen sayısının artırılması gerektiğini önermişlerdir.

Özhan Özkan, Murat Yıldız ve Etem Köklükaya'nın Sakarya Üniversitesi'nin Fen Bilimleri Dergisi'nde yayımlanan çalışmada Fibromiyalji Sendromunun teşhisinde kullanılan sempatik deri cevabı değişkeniyle teşhis doğruluğunu artırılmasını amaçlamışlardır [7]. Fibromiyalji sendromlu (FMS) hastalığına yakalanmış kişilerden ve sağlıklı kişilerin kan değerleri alınarak yapılan analiz doğrultusunda çıkan değerler ve yapılan sempatik deri cevabı (SSR) ölçümlerinden faydalanılmıştır. Matlab uygulaması ile hesaplanan SSR değişkenleri ve laboratuvar testleri her biri yapay sinir ağlarıyla (YSA) çözümlenerek hastalığın teşhisinde kullanılmak üzere doğruluk oranları çıkarılmıştır. İki veri grubuna da YSA uygulanmıştır ve FMS'nin teşhisinde SSR değişkenlerinin ne kadar etkisi olduğu incelenmiştir. Çalışmanın sonucunda YSA ile yapılan analiz de %68.2'lik doğruluk başarısı elde edilmiş ve YSA'nın FMS'nin teşhisinde direkt uygulanabilecek bir yöntem olmadığı yalnızca teşhisi için yardımcı olabileceği sonucuna varılmıştır. SSR ile çıkan sonucun %54.5'lik oranında doğruluk yüzdesinin FMS'nin yalnız başına ayırt edici bir parametre olmadığı görülmüştür. SSR verilerinin YSA ile analiz edilmesi sonucunda %86.4'lük bir doğruluk payı görülmüş ve daha anlamlı sonuçlar ortaya çıkmıştır.



Esma Sezer'in tez çalışmasında elektroensefalogram (EEG) dalgacık analizi kullanılarak Epilepsi hastalığının teşhis edilmesi amaçlanmıştır. Çalışmada YSA kullanılmış ve sınıflandırılmıştır [8]. Sağlık ve epilepsi hastası bireylerden alınan EEG veri kümesi yapay sinir ağı mimarileri ile değerlendirilmiş, işlem karakteristik eğrisi (ROC) analizi yapılarak testlerin doğruluğu kontrol edilmiştir. Çalışmanın sonucunda iki gizli katmanlı Çok Katmanlı Algılayıcı (MLP) ağların daha başarılı olduğu ve daha az nöron ile yüksek performans sağlandığı görülmüştür. Ayrıca Elman ağı yapısının %95.6'lık bir başarı sağladığı ortaya çıkmıştır.

Fırat Hardalaç ve Mustafa Poyraz'ın Fırat Üniversitesi Politeknik Dergisi'nde yayımlanan çalışmada YSA ile EMG sinyallerinin sınıflandırılması ve Neuropathy kas hastalığının teşhis edilmesi amaçlanmıştır [9]. Çalışmada 59 hastaya ait Abductor Pollicis Brevis kası, First Dorsal Interosseous ve Abductor Digiti Minimi kaslarına ait EMG işaretlerini gösteren Hızlı Fourier Dönüşümü analizi uygulanmıştır. Uygulama tamamlandığında üretilen HFD verileri yapay sinir ağları öğrenmesi geri yayılım algoritmasıyla eğitilmiş ve teşhis edilmesi için sınıflama yapılmıştır. 500 öğrenme çevriminden sonra, YSA ve sınıflama ile elde edilen performans oranları hesaplanmıştır. Çalışmanın sonucunda, HFD verileri YSA ile eğitilmiş, neuropathy ve normal EMG sinyalleri %97 oranında başarılı şekilde sınıflandırma yapmıştır .

Dr. Birgül Elbozan Cumurcu ve arkadaşlarının Gaziosmanpaşa Üniversitesi Tıp Fakültesi'nde yaptıkları çalışmada YSA kullanarak Psikiyatrik Tanıların Sınıflanmasını amaçlamışlardır [10]. Çalışmada, yapay sinir ağları tekniğiyle, Gaziosmanpaşa Üniversitesi Araştırma ve Uygulama Hastanesi Psikiyatri Polikliniğine 2008 yılı Ocak-Nisan ayları arasında çeşitli şikâyetlerle başvuran sahip 196 hastanın parametreleri kullanılmıştır. Tanı sınıflaması için demografik özellikler, Beck depresyon ve Beck anksiyete ölçeği verilerinden faydalanılmıştır. Tanıların, ilk yapılan görüşmede DSM-IV-TR tanı kriterlerine bakılarak yapılan tanı ile benzer olduğu gözlemlenmiştir. Çalışmaya katılan 196 kişiden; 145 kişi kadın, 51'i erkektir. 66 kişinin medeni durumuna bakıldığında bekar olduğu görülmüştür. 79 kişinin ilkokul, 67 kişinin lise mezunu ve 97 kişinin ev hanımı olduğu belirlenmiştir. İlk tanılarına bakıldığında, 52 kişide anksiyete bozukluğu, 93 kişide ise depresif bozukluk

tespit edilmiştir. Çalışmanın sonucunda, kişide depresif bozukluğu olduğundan şüphe ediliyorsa Beck depresyon ölçeği ile kesinlikle takviye edilmesi gerektiği savunulmuştur. En başarılı sonucu çok katmanlı algılayıcı ağları vermiştir.

Nesibe Yalçın'ın yüksek lisans tezinde, epilepsi teşhisi için YSA ile Elektroansefalogram verilerinin kullanılması amaçlanmıştır [11]. Öğrenme algoritması olarak sezgisel algoritmalarından biri olan parçacık sürüsü optimizasyonu kullanılmıştır. Bu yöntem YSA'yı eğitmek için kullanılmış ve geri yayılım algoritması ile kıyaslanmıştır. PSO algoritması kullanılarak yapılan sınıflandırma başarısı %98 olarak hesaplanmıştır. Yapılan çalışmanın sonucunda PSO tabanlı sinir ağı modeli, geri yayılım sinir ağı modeli ile kıyaslandığında daha başarılı sınıflandırma tahmini yaptığı görülmüştür.

Ali Öter ve arkadaşlarının 2016 yılında KSU Mühendislik Bilimleri Dergisi'nde yayımlanan çalışmasında tıkayıcı uyku apnesinin YSA ve Morfolojik Filtreler kullanılarak sınıflandırılması amaçlanmıştır [12]. Çalışmada, Tıkayıcı Uyku Apnesini tespit etmek için İleri beslemeli Yapay Sinir Ağları ve morfolojik filtre birlikt kullanılmıştır. Doktor tarafından yapılan görsel skorlama ile önerilen yöntemin gerçekleştirdiği skorlama karşılaştırılmıştır. YSA'nın tek başına uygulanarak kullanıldığı çalışmada başarının düşük olduğu görülmüştür. YSA'nın Morfolojik filtreler ile desteklendiği yöntemde başarı dikkat çekici şekilde artmıştır. Bu yöntemde %90,7 oranında başarı yakalanmıştır. YSA'nın morfolojik filtrelerle birlikte kullanıldığı yöntem ile Tıkayıcı uyku apnesinin tedavisi için uygulanacak incelemelerin daha kısa zamanda gerçekleştirileceği düşünülmektedir.

Ramazan TEKİN ve arkadaşlarının 2011 yılında Elazığ, Türk Mühendis ve Mimar Odaları Birliği, Elektrik – Elektronik ve Bilgisayar Sempozyumu'nda yayımlanan Epileptik EEG İşaretlerinin Sınıflandırılmasınının K-Ortalar ve yapay sinir ağları temelli Melez bir model ile analizini yapmışlardır [13]. Epilepsinin tespiti ve epileptik atakların sebeplerinde beyin elektriksel aktivitesini veri kaynağı olarak ele alınmıştır. EEG işaretlerinin ayrık dalgacık dönüşümü kullanılarak ayrışması sağlanmış ve k-ortalamlar ile kümelere bölünmüştür. Veri setinde eğitim ve test verilerini bir kurala bağlı olmadan seçerek yapay sinir ağı oluşturulmuştur. Sınıflandırma işlemi yaptıklarında verilerin ortak özellikli olanların aynı kümede yer

almasından dolayı YSA eğitimini daha uygun verilerle yapılmıştır. Bu yöntem ile işlem zamanı ve kümeleme performansını iyileştirdiği görülmüştür. K-ortalamar – YSA ile oluşturdukları melez yöntemin daha başarılı bir sonuç oluşturduğunu gözlemlemişlerdir.

Hasan Demir ve arkadaşlarının 2018 yılında Düzce Üniversitesi Bilim ve Teknoloji Dergisi'nde yayımlanan çalışmalarında Destek Vektör Makineleri, yapay sinir ağları, K-Ortalamar ve KNN uygulanarak arı türlerini sınıflamışlardır [14]. Çalışmada arı kanatları üzerinde bulunan kavşak noktalar incelenerek arı türleri sınıflandırılmıştır. Kavşak noktalarına göre 27 morfolojik özellik çıkarılmış ve bu özellikler normalize edilerek kullanılmıştır. Destek vektör makineleri, YSA, K-Ortalama ve en yakın k komşuluk yöntemleri olarak karşılaştırılmıştır. Çalışmanın sonucunda yapay sinir ağları ile sınıflandırmanın en iyi sonuç verdiği belirlenmiştir.

İncelenen çalışmalar ile tez çalışması kıyaslandığında yöntemler, uygulamalar ve modeller arasında benzerlikler ve farklılıklar bulunmaktadır. Bu tez çalışmasında YSA ileri beslemeli geri yayımlı yöntem kullanılmıştır. Kardiyolojiye ait 13 parametreye sahip veri seti ile çalışılmıştır. Verileri yorumlamak ve sonuçları elde etmek için uygulama yapılmıştır. Literatüre katkı ve diğer çalışmalardan ayrılması için bu çalışmada YSA ve melez bir sistem olarak YSA ile birlikte K-Ortalamar algoritması kullanılmaktadır.

### 3. PROBLEM

Dünya genelinde bulaşıcı olmayan hastalıklar incelendiğinde kalp ve damar hastalıklarının ölüm nedenleri arasında ilk sıralarda olduğu gözükmektedir. Görülen problem, kalp ve damar hastalıklarına yakalanma oranlarının gün geçtikçe yükselmesidir.

Bu çalışmada sağlık alanındaki çalışmalar incelenmiştir. Hastalık riskini tahmin edilebilmesi teknolojinin gelişmesiyle daha başarılı hale gelmektedir. Tahmin yapma için kullanılan yöntemlerden biri yapay sinir ağlarıdır. Kullanılabilecek yapay sinir ağları ile kişilerde hastalık olup olmadığı analiz edilip, yorum yapılabilecek ve tavsiye verilebilir olacaktır.

Yapay zekanın tıp alanında kullanılması ile birlikte hastalık riski taşıyan kişilere hızlı bir şekilde analiz edilebilmesi amaçlanmıştır. Kullanılan sistemler tıp alanında uzman kişilerin aktardıkları doğrultusunda geliştirilmektedir.

Tez çalışmasında kullanılan kalp ve damar hastalıklarına ait veri seti ile kişilerin sonuçlarına bakılarak doğru ve başarılı bir sonuç üretmesi amaçlanmaktadır. Tıp alanında yapılan çalışmanın amacı hekime, hastanın sonuçları doğrultusunda öneri vermektir.

Bu çalışma kalp ve damar hastalıklarının hastaya ait olan belirli parametlerle önceden tahmin edilmesini sağlayacak ve olası hastalık durumunu en kısa sürede ortaya çıkaracaktır. Çalışma sonucunda, diğer hastalıklara göre teşhisi daha zor olan kalp ve damar hastalığının önceden tespit edilmesi için yardımcı bir araç olacaktır. Böylece en kısa sürede tedaviye başlanabilecektir.

## **4. YÖNTEM**

### **4.1. Yapay Zeka**

John McCarth, “zeki makineler özellikle de, zeki bilgisayar programları yapma bilimi ve mühendisliği” şeklinde ilk kez tanımlamıştır [15]. Makinelerin yeteneği, algılama, planlama, geçmişe ait verilerden faydalanma, öğrenme, iletişime geçme, cisimleri hareket ettirebilme yeteneğini kazanmasını amaçlayan bir bilim dalıdır [16]. Yapay sinir ağları, yapay zekanın en sık kullanılan yöntemlerinden biridir. Bu çalışmada yapay sinir ağı ve K-ortalama algoritmasının uygulandığı yapay sinir ağı modeli oluşturularak, literatüre katkı açısından her iki modelin karşılaştırılması yapılmıştır.

### **4.2. Yapay Sinir Ağları**

Yapay sinir ağlarının başlıca özelliği insan beyninin öğrenme yeteneğini sağlayabilen bilgisayar sistemleridir [17]. YSA Biyolojik sinir ağlarını taklit eden sentetik ağlar olarak da tanımlanmaktadır. Bir yapay sinir ağı, bilgiyi saklamak ve sakladığı bilgiyi işe yarar duruma getirmek için yalın birimlerden oluşan bir sistemdir. YSA ile insan beyninin iki temel özelliği benzerdir. Bu iki temel özelliklerden ilki yapay sinir ağının öğrenme süreciyle bilgiyi elde etmesidir. İkinci özelliği ise bilgiyi depolamak için nöronlar arasındaki bağlantıların kuvvetini (sinaptik ağırlıklar) kullanmasıdır.

#### **4.2.1. Yapay Sinir Ağlarının Genel Özellikleri**

Yapay sinir ağların genel özellikler uygulanan ağa göre farklılıklar göstermektedir. Yapay sinir ağı bütün modeller için genel özelliklere sahiptir. Bunlardan bazıları;

- Yapay sinir ağları makine öğrenmesi gerçekleştirirler. Bu sayede benzer örnekler durumunda karar verme özelliğine sahiptirler.
- Yapay sinir ağları bilgiyi saklamak için herhangi bir veritabanına ihtiyaç duymazlar. Ağın bağlantıları üzerinde tutulmaktadır.

- Yapay sinir ağı öğrenme yapabilmek için örnek bilgilere ihtiyaç duyar. Verilen örnek bilgiler sayasinde genelleme yapabilme özelliğine sahip olurlar. Örnekleri elde etmek için daha önceki gerçekleşmiş bilgiler kullanılması gerekmektedir. Ağa örnek veriler tam olarak gösterilmez ise ağ başarısız sonuçlar elde edebilmektedir. Bundan dolayı ağa örnekler sunup öğrenmesini sağlamak önemli bir yer tutmaktadır.
- Ağlar verilen örnekler doğrultusunda daha önce karşılaşmadığı veriler hakkında bilgi türetebilirler.
- Yapay sinir ağları verilen örnekleri kümeleme yapabilirler. Sonranda gelen örnekleri ise hangi kümeye vereceklerine kendileri karar vermektedirler.
- Yapay sinir ağlarının eğitimi tamamlandıktan sonra yeni gelen eksik örneklerle çalışıp bilgi türetebilmektedirler. Eksik bilginin ağı ne kadar etkileceği doğrultusunda performans düşmesi görülebilir.
- Yapay sinir ağları eksik bilgilerle çalışabilmesinden dolayı hata toleransına sahip olmaktadır.
- Bilgi, yapay sinir ağında dağılmış şekilde yer almaktadır. Hücrelerini birbiri ile bağlantıları ağın bilgisini gösterdiği için dağıtık belleğe sahiptirler.
- Yapay sinir ağları sadece nümerik bilgiler ile çalışmaktadır.

#### **4.2.2. Yapay Sinir Ağında Öğrenme ve Test Edilmesi**

Ağın eğitilmesi, proses elemanlarının bağlantılarının ağırlık değerlerinin belirlenmesi işlemi ile gerçekleşmektedir. İlk olarak ağırlık değerleri herhangi bir kural olmadan verilmektedir. Yapay sinir ağları verilen örnekler doğrultusunda ağırlıklarını yenilerler. Örnekler ağa tekrar tekrar verilerek doğru ağırlık değeri bulunması sağlanmaktadır. Doğru ağırlık değerleri bulunduğunda ağ genelleme yapabilme özelliğine sahip olur. Genelleme yapabilme özelliğine sahip olması ile ağın öğrenmesi gerçekleşmektedir.

Yapay sinir ağlarında öğrenme iki aşama gerçekleşmektedir. İlk aşamada yapay sinir ağlarına verilen giriş verisi ile doğru çıkış verisi üretebilmesi gerekmektedir. Ağa verilen örnekler vektör halinde olmalıdır. Çıkış verisinin doğruluğuna göre ağ bağlantılarının ağırlıkları değiştirilir. Bu ağırlıkların değiştirilmesi ikinci aşamayı oluşturmaktadır. Yapay sinir ağının test edilmesi ise eğitim tamamlandıktan sonra ağın performansı ölçülerek yapılmaktadır. Test aşamasında yapay sinir ağının ağırlıklarında herhangi bir değişiklik yapılmamaktadır. Yeni verilen örnekler karşısında ürettiği çıktılarının doğruluğu, ağın öğrenmesinin ne kadar başarılı olduğunu göstermektedir. Öğrenmesi başarılı olan ağların performansı da o derece iyi olmaktadır. Yapay sinir ağlarının yeni örnekler karşısında sonuç üretebilmesi ve genelleme yapabilmesine adaptif öğrenme denilmektedir.

#### **4.2.3. Yapay Sinir Ağlarının Çalışma Şekli**

Yapay sinir ağları verilen giriş örnekleri ile bir çıkış verisi oluşturmaktadır. Ağın eğitilmesi ile verilen örnekler ile başarılı bir çıkış üretebilmektedir. Ağa verilen giriş verileri vektör halinde olmalıdır. Bu doğrultuda ağın ürettiği çıkış verisi de vektör halindedir. Veriler nümerik bilgiler olması gerekmektedir. Yapay sinir ağları ürettiği çıkış verisini nasıl yaptığı hakkında bilgi vermemektedir. Bu konuda açıklama yapılamadığı için yapay sinir ağları kara kutu olarak görülmektedir. Kara kutu olarak görülmesine karşı ağlar başarılı sonuçlar ürettiği için yapay sinir ağları kullanılmaktadır.

#### **4.2.4. Biyolojik Sinir Hücresinin Yapısı**


Biyolojik sinir sisteminde nöronlar en temel yapı taşlarıdır. Dört ayrı bölümden oluşmaktadır. Şekil 1’de gösterilen bu bölümler dendrit, akson, çekirdek ve bağlantılardan oluşmaktadır. Dendrit, ağaç kökü gibi dallanmış bir yapıya sahiptir. Sinir hücresini ucunda olup duyu nöronlarında ve bağlantılı olduğu nöronlardan gelen sinyalleri çekirdeğe iletir. Dendritten gelen sinyaller toplayarak aksone aktarılmasını çekirdek tarafından gerçekleştirilir. Akson gelen sinyalleri işleyerek nöronun diğer ucunda bulunan bağlantılara iletir. Yeni işlenen sinyalleri ise diğer nöronlara aktarımını bağlantılar sayesinde gerçekleştirilir.

Dendrit; sinir hücrelerinden iletilen sinyalleri çekirdeğe aktarmakla görevlendirilmiştir. Dendritlerin görevi karmaşık bir yapıda olduğu ileri sürülmektedir. Dendritler arası iletişim, herbiri arasında farklı bir şekilde gerçekleşmektedir. Gelen sinyalin seçimi sinir hücresi tarafından gerçekleştirilir.

Soma; hücre çekirdeği olarak tanımlanmaktadır. Dendritten gelen sinyalleri toplar ve veriyi aksona aktarır.

Akson; hücre çekirdeğinden gelen bilgiyi sinir hücresine ayrı ayrı bölüştürür. İlk önce ön işlemlerden geçirerek sinir hücresine iletilir. Bu sayede akson ucunda yer alan sinapsise veri aktarmı gerçekleştirilir.

Sinapsis; aksondan gelen veriyi ilk işlemde geçirdikten sonra diğer sinir hücrelerinin dendritlerine iletir. Veri aktarılmadan önce yapılan ilk işlem ile gelen sinyalin eşik değerine göre değiştirilir. Bu sayede gelen toplam sinyal işlem yapılarak, belirli bir aralığa getirilerek iletilir. Toplam sinyal ile dendrite aktarılan sinyal ile arasında ilişki oluşturulur. Bu ilişki doğrultusunda sinapsislerde öğrenme yapıldığı görülmüştür. Dendritler ve sinapsisler arasındaki ağırlık katsayılarının yenilenmesiyle öğrenme işlemi yapılmaktadır.



**Şekil 1.** Biyolojik Sinir Hücresinin Yapısı



Yapay sinir ağlarında, nöronlar katmanlara ayrılarak birbiriyle bağlantı kurar. Tüm yapay sinir ağları birbirleriyle benzerlik göstermektedir. Yapay sinir ağında yer alan bir kısım nöron giriş verilerini alır, bir kısmı ise çıkış olarak aktarır. Diğer kalan nöronlar gizli katmanda yer alır. Gizli katmanda yer alan nöronlar sadece içerisinde bağlantı kurarken, giriş verilerini alan nöronlar ve çıkışa aktaran nöronlar dış ortam ile bağlantılı durumdadır. Oluşturulan ağın başarılı olabilmesi için üç ayrı katmana ihtiyaç duyulmaktadır. Bu üç katman girdi, gizli ve çıktı katmanından oluşmaktadır. Girdi katmanı, giriş verilerini alan nöronlardan oluşmaktadır. Bu katmanda giriş verilerine herhangi bir işlem yapılmadan diğer katmanına aktarılır. Çıktı katmanı, çıkış verilerini dış ortama aktaran nöronları içermektedir. Girdi ve çıktı katmanları tek katmandan oluşurken arada kalan gizli katman birden fazla katmandan oluşabilir. Gizli katmanda birden çok nöron barındırmaktadır. Nöronlar kendi arasında bağlantı kurmuş haldedir. Bu sayede bir önceki katmandan gelen sinyali, gizli katmandaki bir nöron alır ve işlem tamamlandıktan sonra çıkışı bir sonraki katmanın tüm nöronlarına iletir. Nöronlar arasındaki iletişim, yapay sinir ağları için önemli bir unsurdur. Bu yapıya sahip yapay sinir ağı ileri beslemeli bir yapıya sahiptir.

#### **4.2.5. Yapay Sinir Ağları Yapısı ve Modelleri**

Yapay Sinir Ağlarının yapay sinir hücreleri, proses elemanları olarak adlandırılır. Bu proses elemanlarını 5 elemanı şu şekildedir:

**Girdiler:** Dış dünyadan yapay sinir hücresine gelen bilgilere denir. Ağı eğitmek için kullanılır.

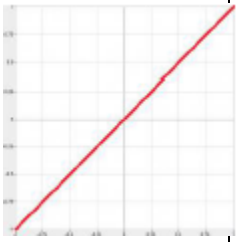
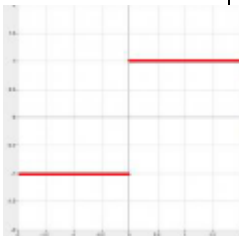
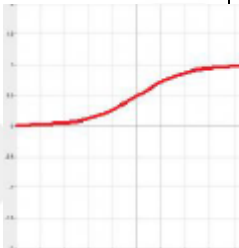
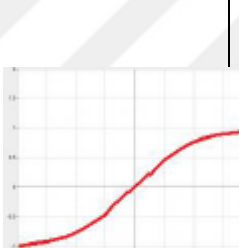
**Ağırlıklar:** Bilginin hücre üzerindeki etkisi ve önemini belirtir. Ağırlık değerinin büyük ya da küçük olması önemini ifade etmez.

**Toplama Fonksiyonu:** Fonksiyonda hücreye gelen net girdi hesaplanır. Bu durum için çeşitli fonksiyonlar kullanılmaktadır. Toplama Fonksiyonu Tablo 1 'de gösterilmiştir.

Toplam	$Net = \sum_{i=1}^N Xi * Wi$	Ağırlık değerleri girişler ile çarpıldıktan sonra çıkan sonuçlar toplanarak net girdi bulunur.
Çarpım	$Net = \prod_{i=1}^N Xi * Wi$	Ağırlık değerleri girişler ile çarpıldıktan sonra çıkan sonuçlar toplanarak net girdi bulunur.
Maksimum	$Net = Max(Xi*Wi)$	N adet girdi içinden ağırlıklar girişlerle çarpılır ve çıkan sonuçlardan en büyüğü net girdi olarak alınır.
Minimum	$Net = Min(Xi*Wi)$	N adet giriş içinden ağırlıklar girdilerle çarpıldıktan sonra çıkan sonuçlardan en küçük değeri net girdi olarak alınır.
Çoğunluk	$Net = \sum_{i=1}^N Sgn(Xi * Wi)$	N adet girdi içinden ağırlıklar girişlerle çarpıldıktan sonra çıkan sonuçlardan pozitif ve negatif olanların sayısı hesaplanır. Büyük olan sayı hücrenin net girdisidir.
Kumilatif Toplam	$Net = Net(eski) + \sum_{i=1}^N Xi * Wi$	Hücreye gelen bilgiler ağırlıklı olarak toplandıktan sonra daha önce hücreye gelen bilgilerle yeni değerler toplanır. Hücrenin net girdisi bulunur.

**Tablo 1.** Toplama Fonksiyonları

Aktivasyon Fonksiyonları: Fonksiyonda hücreye gelen girdi işlenerek hücrenin girdiye karşılık üreteceği çıktı belirlenir. Bu fonksiyon için genellikle doğrusal olmayan fonksiyon tercih edilir. Aktivasyon fonksiyonları doğrusal değildir ve türevi kolay hesaplanabilir. Günümüzde en sık kullanılan Aktivasyon fonksiyonlarından biri Sigmoid fonksiyonudur. Tablo 2’ de Aktivasyon Fonksiyonları gösterilmiştir.

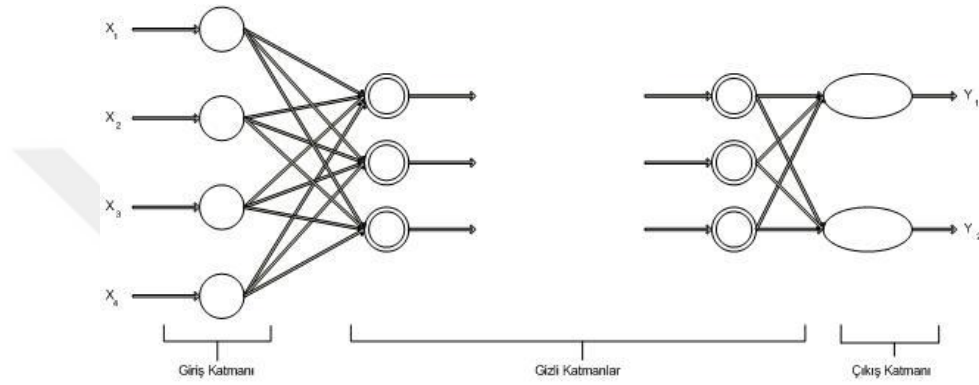
Doğrusal (Lineer) Aktivasyon Fonksiyonu		$F_{net} = A * Net$ (A bir sayı)	Doğrusal problemleri çözmek için kullanılır. Toplama fonksiyonundan çıkan değer, bir kat sayı ile çarpılarak hücrenin çıktısı alınır.
Adım Aktivasyon Fonksiyonu		$F(Net) = \begin{cases} 1 & \text{if } Net > \text{Eşik Değer} \\ 0 & \text{if } Net \leq \text{Eşik Değer} \end{cases}$	Gelen net girdinin belirlenen bir eşik değerinden daha az veya daha fazla olmasına göre hücrenin çıktısı 1 veya 0 olarak alınır.
Sigmoid Aktivasyon Fonksiyonu		$F_{net} = \frac{1}{1 + e^{-net}}$	Türevlenebilir fonksiyondur. Sürekli. Doğrusal değildir. Girdi değerleri için 0 ile 1 arasındadır.
Tanjant Hiperbolik Aktivasyon Fonksiyonu		$F_{net} = \frac{e^{net} + e^{-net}}{e^{net} - e^{-net}}$	Sigmoid fonksiyonuna benzerdir. Çıkış değerleri -1 ile +1 arasında değişir.
Eşik Değer Aktivasyon Fonksiyonu		$F_{net} = \begin{cases} 0 & Net \leq 0 \\ Net & 0 < Net < 1 \\ 1 & Net \geq 1 \end{cases}$	Girdilerin 0'dan küçük olması durumunda 0, 1'den büyük veya eşit olduğu durumda 1, 0 ile 1 arasında olduğu durumlarda kendisini veren çıktı üretir.
Sinüs Aktivasyon Fonksiyonu		$F_{net} = \sin_{net}$	Sinüs fonksiyonuna uygun dağılım gösterdiği durumda tercih edilir.

**Tablo 2.** Aktivasyon Fonksiyonu

Hücre Çıktısı: Aktivasyon fonksiyonu sonucunda çıkan değerdir. Çıktı dış dünya veya başka bir hücre tarafından kullanılır. Proses elemanının sadece bir çıktısı olabilir.

#### 4.2.5.1.Katmanlar

YSA, nöronların birbirine bağlanmasıyla oluşur. YSA, Şekil 2’de gösterilen giriş, ara ve çıkış şeklinde üç ana katmandan oluşur.



Şekil 2. Yapay Sinir Ağı Katmanları


**Giriş Katmanı:** Verilerin dış dünyadan giriş yaptığı katmandır. Veri bu katmana geldiğinde ağırlıkları diğer katmanlara giriş olacak şekilde çıkış üretir. Girdilere genelde bir işlem uygulanmadan doğrudan alt katmanlara iletilir.

**Ara Katmanı:** Giriş katmanından geçen bilgiler buraya iletilir. İkinci katman olarak adlandırılan gizli katman veriyi aktivasyon fonksiyonundan geçirerek sıradaki katman olan çıktı katmanına gönderir. YSA’larda birden fazla ara katman bulunduğu gibi bazılarında ara katman bulunmaz. Bu katmandaki sinir hücreleri giriş ve çıkış sayısından tamamen bağımsızdır. Düğüm sayısı ağı en iyi çalışabileceği sayıda seçilmelidir. Sinir hücre sayısının artması hesaplama karmaşıklığının artmasına ve sürenin uzamasına sebep olmasına rağmen daha karmaşık olabilecek problemlerin çözümünde kullanılır.

Çıkış Katmanı: Ara katmandan gelen işlenmiş bilgilere karşılık olarak çıktıların üretildiği katmandır. Bu katmana gelen bilgiyi kendi aktivasyon fonksiyonundan geçirerek çıktı üretir. Bu katmanda üretilen veriler dış dünyaya verilir.

#### 4.2.5.2. Tek Katmanlı Algılayıcılar

Tek katmanlı yapay sinir ağları yalnızca giriş ve çıktı katmanlarından oluşur. Karmaşık problemlere cevap verebilme yeteneği yoktur bu yüzden problemlerin çözümü konusunda kısıtlıdır [18]. Şekil 3’de tek katmanlı ağlarda girdi değerlerinin ve çıktının sıfır olmasını önlemek için bir eşik değeri bulunur ve her zaman 1 olarak alınır.



Şekil 3. Tek Katmanlı Algılayıcı [19]

#### 4.2.5.3. Çok Katmanlı Algılayıcılar

Yapay Sinir Ağları modelleri içerisinde çok sık kullanılan algılayıcıdır [19]. Çok katmanlı algılayıcılarda girdi sinyali her bir katman boyunca ileri giderek çıktı sonuçları üretilir. Çıktı katmanı, aktivasyon fonksiyonundan geçirerek çıktı üretmiş olur. Bu sonuçlar istenilen sonuçlar ile karşılaştırılır. Burada elde edilen hata payı ağ boyunca ağırlıklara geri yayılır. Düzenlemeler yapıldıktan sonra güncellenmiş veriler ağa tekrar verilir, süreç baştan tekrarlanır ve istenilen değerlerle karşılaştırma yapılır. Bu süreç en az hata oranına indirilinceye kadar tekrarlanır.


Çok katmanlı algılayıcılar denetimli öğrenme stratejisiyle çalışırlar. Ağlara eğitim süresi boyunca girdiler ve girdilere karşılık üretilmesi beklenen çıktılar verilir. Ağın buradaki görevi her girdiye karşılık gelen çıktı üretmektir. ÇKA öğrenme kuralı Delta Öğrenme kuralının genelleştirilmiş halidir bu sebepten Genelleştirilmiş Delta

Kuralı da denilebilir. Verilerin bir kısmı test için uygulanırken, bir kısmı da ağı eğitmek için kullanılır. Bu kurala göre ilk olarak ağın çıktısı hesaplanır daha sonra ise hata oranını en az yapacak şekilde ağırlıklar güncellenir.

#### 4.2.5.3.1. İleri Beslemeli Ağlar

İleri beslemeli ağlarda sinir hücreleri girişten çıkışa doğru düzenli şekilde ilerler. Yalnızca birbirini takip eden ağlar arasında bağ bulunur. Dış dünyadan gelen girdiler giriş katmanından hiçbir değişikliğe uğramadan ara katmana iletilir. Ara (gizli) katman bir veya birden fazla olabilir bu problem yapısı ile ilgilidir. Ara katmanda işlenen bilgi ve buradan çıkış katmanına geçirilir ve dış dünyaya verilir. Bu şekilde doğrusal olmayan bir süreç gerçekleştirir.

İleri Beslemeli Ağların en çok bilinen ve en sık kullanılan algoritmalarından biride Geriye Yayımlı Algoritmasıdır. YSA eğitiminde kullanılır. Ağa girdiler ve beklenen çıktılar verilmektedir. Ağırlık kümelerini bulmak için hataların kareleri toplamı hesaplanır. Şekil 4’de ileri beslemeli yapay sinir ağı gösterilmektedir.



Şekil 4. İleri Beslemeli Yapay Sinir Ağı [19]

Çok katmanlı ağı yapısında en küçük kareler yöntemini kullanan delta öğrenme kuralını uygulamaktadır. Öğrenme kuralında ileri yönde hesaplama ile ağı çıkışı sağlanmaktadır. Ağırlık güncellemesi ise geriye doğru hesaplama yapmaktadır [18]. Bu sayede kullandığı verilerle bir çözüm üretmektedir. İleriye doğru

hesaplama örnek girişin ağa verilmesi ile gerçekleşmektedir. Denklem 1; giriş katmanındaki ( $G_k$ ) k. Proses elemanın çıkışı  $\zeta_k^i$  için;

$$G_k = \zeta_k^i \quad (1)$$

Ara katmanda proses elemanlarına gelen net giriş ( $NET_j^a$ ) formülü ile denklem 2'de hesaplanmaktadır.  $W_{jk}$ , k. giriş katmanı elemanının j. ara katmana olan bağlantının ağırlık değerini göstermektedir. J. ara katmanın çıkışı, aktivasyon fonksiyonundan geçmesi doğrultusunda hesaplanmaktadır.

$$NET_j^a = \sum_{k=1}^n W_{jk} * \zeta_k^i \quad (2)$$

Net girişin sigmoid olarak belirlenen aktivasyon fonksiyonundan geçirilip ile oluşan çıktı ( $\zeta_j^a$ ) Denklem 3'de hesaplanmaktadır.  $b_j^a$ , ara katmanda j. elemana bağlanan eşik değerinin eleman ağırlığını ifade etmektedir.

$$\zeta_j^a = \frac{1}{1 + e^{-(NET_j^a + b_j^a)}} \quad (3)$$

Ağa verilmiş olan giriş verileri ile ağın üretmiş olduğu çıkış ( $B_m$ ) ile gerçek çıkış ( $\zeta_m$ ) değerleri arasındaki fark hata değerini oluşturmaktadır. Bu oluşan hatayı en aza indirmek için geriye doğru hesaplama yapılmaktadır. Her iterasyon ile hata ağın ağırlık değerlerine yayılmaktadır. Denklem 4, Oluşan hata ( $E_m$ ), m. proses elemanı için;

$$E_m = B_m - \zeta_m \quad (4)$$

Denklem 5'de çıkış katmanında, hataların toplanması ile oluşan toplam hata (TH) bulunmaktadır.

$$TH = \frac{1}{2} \sum_m E_m^2 \quad (5)$$

Ağırlıkların kareleri toplanarak hesaplanan sonucun kare kökünün alınması ile toplamın sıfır olması önlenmektedir. Ağırlıkları değiştirmek için ara katman ile çıkış katmanı arasındaki ağırlıkların değiştirilmesi ve ara katman giriş katmanı arasındaki ağırlıkların değiştirilmesi ile yapılabilmektedir.

Denklem 6'da, ara katmanda gerçekleşen j. elemanın çıkış katmanındaki m. proses elemanını arasındaki bağlantı değişim miktarı  $\Delta A_{jm}^\alpha$ , momentum katsayısı  $\alpha$ , m. çıktının hatasını  $\delta_m$ , öğrenme katsayısı  $\mu$ , t ise zamanı ifade etmektedir. t zamanında;  $f'(NET)$  aktivasyon fonksiyonun türevini ifade etmektedir.

$$\Delta A_{jm}^\alpha = \mu \delta_m \zeta_j^\alpha + \alpha \Delta A_{jm}^\alpha (t - 1)$$

$$\delta_m = f'(NET) \cdot E_m \quad (6)$$

Denklem 7'de Sigmoid için ise;

$$\delta_m = \zeta_m (1 - \zeta_m) \cdot E_m$$

$$A_{jm}^\alpha (t) = A_{jm}^\alpha (t - 1) + \Delta A_{jm}^\alpha (t) \quad (7)$$

Denklem 8'de eşik değerinin güncellenmesi ise;

$$\Delta b_m^\zeta (t) = \mu \delta_m + \alpha b_m^\zeta (t - 1)$$

$$b_m^\zeta (t) = b_m^\zeta (t - 1) + \Delta b_m^\zeta (t) \quad (8)$$

Denklem 9, ara katmanlar arasındaki veya giriş, ara katman arasındaki güncelleme için;

$$\Delta A_{jm}^i (t) = \mu \delta_j^\alpha \zeta_k^i + \alpha \Delta A_{kj}^i (t - 1) \quad (9)$$

Denklem 10, Sigmoid fonksiyonu için hata terimi hesaplaması;

$$\delta_j^\alpha = f'(NET) \sum_m \delta_m A_{jm}^\alpha \quad (10)$$

Denklem 11, Hata terimi hesaplaması;

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

$$A_{jm}^\alpha (t) = A_{jm}^\alpha (t - 1) + \Delta A_{jm}^\alpha (t)$$


$$\Delta b_m^\alpha (t) = \mu \delta_j^\alpha + \alpha \Delta b_m^\alpha (t - 1)$$



$$b_j^\alpha(t) = b_j^\alpha(t-1) + \Delta b_j^\alpha(t) \quad (11)$$

#### 4.2.5.3.2. Geri Beslemeli Yapay Sinir Ağları

Geri Beslemeli Yapay Sinir Ağları, İleri Beslemeli ağın tersine bir sinir hücresi çıktısı kendinden sonraki sinir hücresi katmanına girdi şeklinde verilmez. Bir önceki katmanda veya bulunduğu katmanda farklı bir nörona bağlanabilir. Bu ağ yapısında beklenen çıktı ile eğitim çıktısı karşılaştırılır. Aralarındaki fark alınarak hata değeri bulunur. Doğrusal olmayan dinamik bir davranış gösterir. Genellikle danışmansız öğrenmede tercih edilir. Şekil 5’de geri beslemeli yapay sinir ağı gösterilmektedir.




Şekil 5. Geri Beslemeli Yapay Sinir Ağı

#### 4.2.6. Öğrenme Algoritmalarına Göre Yapay Sinir Ağları

Danışmanlı öğrenme, Danışmanlı öğrenme ve takviyeli öğrenme olarak üç gruba ayrılır.


Danışmanlı Öğrenme: Şekil 6’da gösterilen danışmanlı öğrenmede ağı giriş ve çıkış değerleri verilir. Beklenen çıkışları oluşturabilmek için girdiler kendi ağırlıklarını yeniler. Beklenen çıktılar ve eğitim çıktıları arasındaki hata alınır ve yeni ağırlıklar bu hata payına bakılarak güncellenir. Buradaki amaç hesaplanan hata

değerini en aza indirmektedir. Hata en aza indiğinde sistem problem çözümü için en uygun sonuçları üretebilecek seviyeye gelir. Bu öğrenme biçimini kullanan yöntemlerden biri Çok Katmanlı Yapay Sinir Ağlarıdır.



**Şekil 6.** Danışmanlı Öğrenme [20]

Danışmansız Öğrenme: Şekil 7’de gösterilen danışmansız öğrenmede ağı eğitirken sadece girdiler verilir. Beklenen çıktılar ağı verilmez. Ağ, sınıflandırma yapmak için girişte verilen bilgiler ile kendi modelini oluşturur. Ağ bağlantı ağırlıklarını benzer özellikte olan dokulara ayırarak öğrenmeyi tamamlar. Danışmansız Öğrenme, diğer öğrenme yöntemlerine göre daha hızlıdır ve matematik algoritmaları daha basittir. Bu öğrenme tipine örnek olarak: yarışmacı öğrenme, Kohonen’in Özörgütlemeli harita ağları, Hebbian öğrenme ve Grossberg öğrenme verilebilir.



**Şekil 7.** Danışmansız Öğrenme [20]

Destekleyici Öğrenme: Destekleyici Öğrenme’de ağın her döngüyü tamamlandığında elde ettiği sonucun iyi ve kötü olduğuna bakılarak değerlendirilmesi

yapılır. Bu deęerlendirmeye gre aę kendini yeniden gnceller. Bylece aę bir girdi verisiyle hem ęrenir hem de sonu ıkararak eęitmeye devam eder.

#### 4.2.7. Levenberg - Marquardt Algoritması

Steepest descent (meyilli azalım) ve Newton algoritmaları kullanılarak Levenberg – Marquardt(LM) algoritması tretilmektedir. LM algoritmasının gncellenmesi iin kullanılan eřitlik;

$$\Delta\omega = (J^T J + \mu I)^{-1} J^T e \quad (12)$$

eřitlikte yer alan  $\omega$  aęırlık vektr,  $\mu$  kombinasyon katsayısını, I birim matrisi ifade etmektedir [22].

Jacobian matrisini J, [(Pxn), N] boyutunda, hata vektrn ise e [(Pxn),1] boyutunda gsterilmektedir.

P: eęitimdeki rnek sayısı

n: ıkıř sayısı

N: aęırlık sayısı

LM algoritmasının gncellenmesi iin tm giriř parametreleri iin Jacobian matrisi hata vektrn kullanılmaktadır. Ařaęıdaki eřitlikte yer alan  $\mu$  , ayarlanabilir bir parametredir ve deęeri byk ise Steepest descent metodu, kk ise Newton metodu zelliklerini tařımaktadır. E ise uygunluk deęerini ifade etmektedir.

$$\mu(t) = \begin{cases} \mu(t)k & E(t) > E(t-1) \\ \mu(t)/k & E(t) \leq E(t-1) \end{cases} \quad (13)$$

ęrenme zamanına gre iki farklı tipte gerekleřmektedir. Bunlar statik ve dinamik ęrenmedir.

Statik ęrenme; sistem kullanılmaya bařlamadan nce yapay sinir aęı eęitilir. Eęitim tamalandıktan sonra test yapılır. Eęitim ve test ařamaları bittikten sonra sistem kullanılabilir. Sistem kullanımında yapay sinir aęının aęırlıklarında deęiřiklik yapılamamaktadır.

Dinamik öğrenme de ise; yapay sinir ağı gerçek zamanlı olarak sistem, öğrenme işlemini sürekli olarak gerçekleştirmektedir. Öğrenme sistem kullanılırken de devam etmektedir. Yapay sinir ağının ağırlıklarını kullanım doğrultusunda değiştirmektedir.

#### 4.3. K-Means Algoritması (K-Ortalamalar Kümeleme Algoritması)

K-Ortalamalar kümeleme algoritması verilerin hangi kümeye ait olduğunu kümelerin özellikleri doğrultusunda bulmayı sağlayan gözetimsiz öğrenme yöntemidir. K-Ortalamalar veri setine ait giriş parametrelerini k adet kümeye ayırmaktadır [21]. “k” harfi kaç adet küme olduğunu belirtir. Hata hesaplamasında kullanılan Karese Hata Fonksiyonunu en aza indirecek sayıda “k” küme adedi belirlenir. Her küme için merkez olan noktaya uzaklığı (öklit uzaklığı), kümelerin oluşturulmasını sağlar. Her kümedeki verilerin ortalamaya yakınlığı ise kümenin ağırlık merkezini ifade eder.

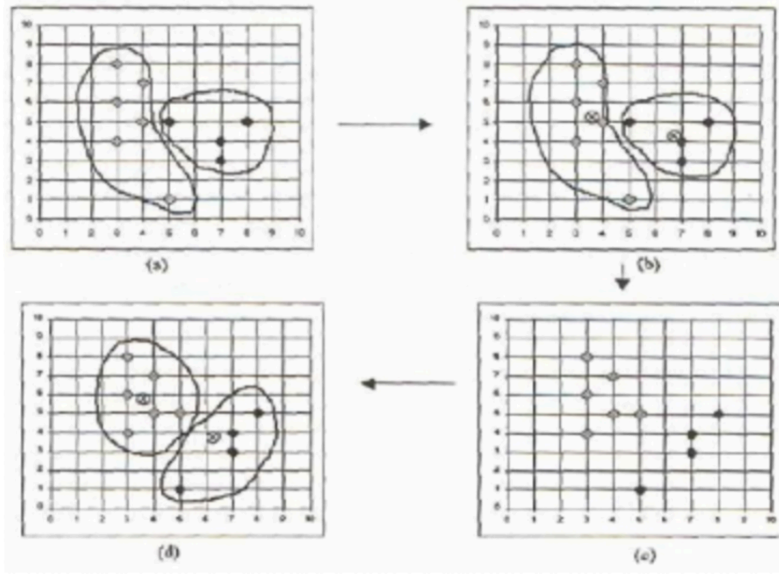
K-Ortalamalar ile kümeleme yapılırken dikkat edilmesi gereken noktalar; kümeler birbirinden farklı özellikte olmalıdır ve her küme içindeki değerler birbirine yakın olmalıdır.

Kümeleme işlemi öklit uzaklığı formülü ile hesaplanmaktadır.

$$p = (p_1, p_2, \dots, p_n) \text{ ve } q = (q_1, q_2, \dots, q_n) \quad (14)$$

$$\sqrt{\sum_{i=1}^n (p_i - q_i)^2} = \sqrt{(p_1 - q_1)^2 + (p_2 - q_2)^2 + \dots + (p_n - q_n)^2} \quad (15)$$

K-Ortalamlar algoritmasının uygulanabilmesi için öncelikle kümelerin merkezleri belirlenmelidir ve uzaklıklarına göre gruplandırılmalıdır. Bu yapılan gruplandırma doğrultusunda kümelerin tekrar merkezleri belirlenmelidir. Algoritma kararlı hale gelinceye kadar bu işlemlerin tekrarlanması gerekmektedir.



**Şekil 8.** K-Ortalamlar Kümeleme Algoritmasının Adımları

Şekil 8’da görülen k-Ortalamlar adımları;

1. k adet kümeyi seçer ve küme merkezleri hesaplanır.  $M_1, M_2, \dots, M_k$  orta noktayı ifade etmektedir.

$$M_k = \frac{1}{n_k} \sum_{i=1}^{n_k} x_{ik} \quad (16)$$

2. Karesel hata formülü ile küme içindeki değişimler hesaplanır.

$$e_i^2 = \sum_{i=1}^{n_k} (x_{ik} - M_k)^2 \quad (15)$$

Küme içindeki değişimlerin toplamı ise kare-hata formülü ile hesaplanır.

$$E_k^2 = \sum_{k=1}^k e_k^2 \quad (16)$$

3. Oluşan kümelerde veriler kendine en yakın kümeye ait olur.
4. Verilerin kümelere ait olduktan sonra tekrar küme merkezleri hesaplanır.
5. Küme merkezlerinde herhangi bir değişiklik gözlemlenmeyinceye kadar ikinci ve üçüncü basamaklar tekrar yapılması gerekmektedir.



## 5. UYGULAMA

### 5.1. VERİ

Tez çalışması Datalab TR sitesinde yer alan UCI Kardiyoloji verisetinden uyarlanmış olan tıbbi veri seti kullanılmıştır. Veriseti 300'ü sağlıklı ve 240'ı hastalık teşhisi konulmuş olan toplam 540 kişiden oluşmaktadır [23]. Veri setinin on üç giriş parametresi ve bir çıkış parametresi olarak uygulama yapılmıştır. Giriş değerleri yapay sinir ağında eğitim, çıkış değerleri ise tahmin edilecek veri olarak kullanılmaktadır. Uygulamada kullanılmış olan veri setinde yer alan giriş ve çıkış parametrelerin ve bu parametrelerin anlamları belirtilmiştir.

Giriş parametreleri;

Yaş: Kişinin yaşını gösterir.

Cins: Kişiye ait cinsiyeti verir.

Ağrı: Belirli bölgedeki sinirlerin basıncına bağlı duyulan hissi ifade eder.

Kanbas: Kişiye ait tansiyonun gösterir. Kan basıncı fazla ise artış gösterir.

Serkol: Serum kollesterolü ifade eder. HDL –LDL toplam kollesterolü verir. Kolesterol, insan vücudunun bütün hücrelerinde yer alan yağ benzeri bir maddedir.

Kansek: Kan şekerini ifade eder.

Elektro: Kalp grafisi değerlerini verir. Kalbin atmasını elektroda gözükmelerini ifade eder.

Kalphızı: Bir dakikadaki kalp atışını verir.

Egzagrı: Egzersiz ağrısını ifade eder. Efor testinde ortaya çıkar.

Stdep: ST deprezyon. Kan ile kalbin beslenmesini gösterir.

Stegım: Etap kanserinin sınıflandırılması anlamına gelmektedir.

Anadamar: Kalpten kanı alıp vücuda dağıtan ana damar (aort) ifade eder.

Talyum: Bir elementtir. Kalp kasında bulunan kan seviyesi ölçülünerek kişide koroner arter hastalığını ifade edilir.

Çıkış parametresi ise;

Hasta: Kardiyolojik veriler doğrultusunda kişinin sağlam veya hasta olarak kalp hastası olma durumunu gösterir.

Tablo 3’de örnek kardiyoloji veri seti gösterilmektedir.

YAS	CINS	AGRI	KANBAS	SERKOL	KANSEK	ELEKTRO	KALPHIZI	AGZAGRI	STDEP	STEGIM	ANADAM	TALYUM	HASTA
70	1	4	130	322	0	2	109	0	2.4	2	3	3	2
67	0	3	115	564	0	2	160	0	1.6	2	0	7	1
57	1	2	124	261	0	0	141	0	0.3	1	0	7	2
64	1	4	128	263	0	0	105	1	0.2	2	1	7	1
74	0	2	120	269	0	2	121	1	0.2	1	1	3	1
65	1	4	120	177	0	0	140	0	0.4	1	0	7	1
56	1	3	130	256	1	2	142	1	0.6	2	1	6	2
59	1	4	110	239	0	2	142	1	1.2	2	1	7	2

**Tablo 3. Örnek Kardiyoloji Veri seti**

## 5.2. ÖNERİLEN YAPI

Bu tez çalışmasında iki farklı model kullanılmaktadır. İlk model yapay sinir ağı ve ikinci model ise önerilen melez sistemden oluşmaktadır.

Yapay sinir ağları kendi kendine öğrenme yeteneği ile çıkarım yapma özelliğine sahiptir. YSA, daha çok tahmin, sınıflandırma gibi problemlerde başarılı sonuçlar üretmektedir. Çok katmanlı yapının tercih edilmesinin sebebi çok katmanlı yapıların doğrusal olmayan problemlerin çözümünde kullanılması ve öğrenme sırasında hatayı en aza indirgemesidir. İleri beslemeli yapay sinir ağlarında,

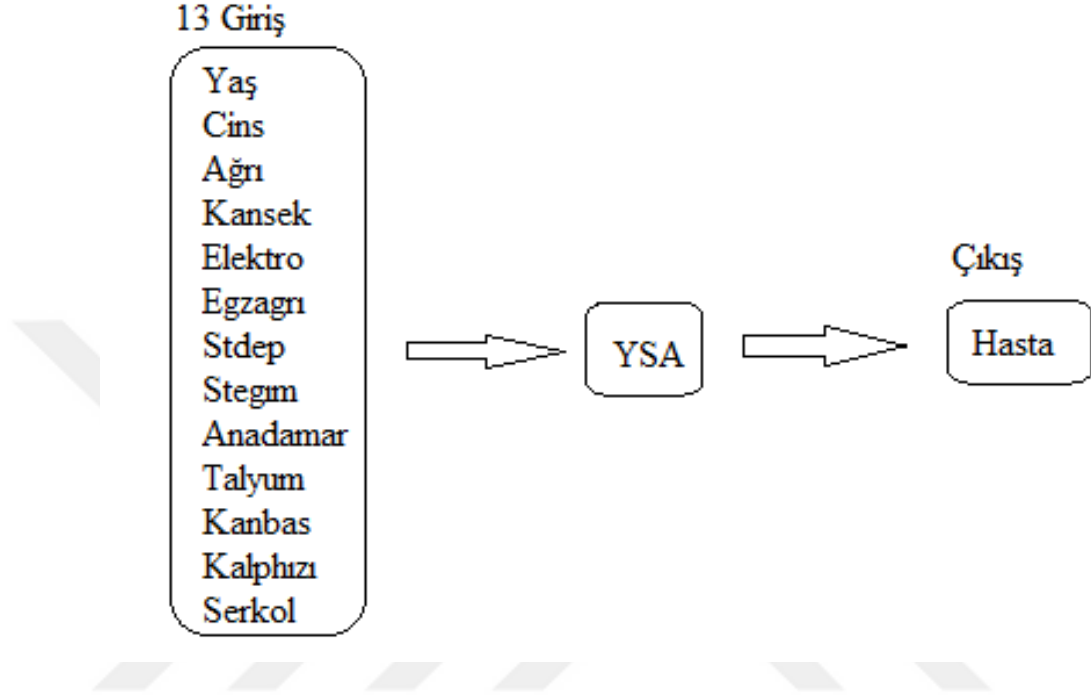


danışmanlı öğrenmenin kullanılmasının amacı literatür çalışmalarında tahmin problemlerinde daha başarılı sonuçlar verdiği belirlenmiş olup aynı zamanda hızlı ve tutarlı sonuçlar ürettiği görülmüştür. Levenberg-Marquardt eğitim algoritması ise eğitimde kararlı ve daha hızlı olmasından dolayı kullanılmaktadır.

Yapılan çalışmada veriler arasındaki veri tekrarı veya verilerin homojen olmaması durumunda eğitim, test, doğruluk performansında farklılıklar oluşmaktadır. Literatürde belirtildiği gibi melez sistemlerin tekil yöntemlere göre tahminsel modellemede daha başarılı oldukları görülmektedir. Bu yüzden Şekil 1’de kullanılan melez sistem için K-Ortalamlar kümeleme algoritması ile birlikte yapay sinir ağı kullanılmaktadır. Birbirleriyle ilişkili olan verilerin kümelenecek öğrenme işlemi için daha iyi sonuçlar üretmesine katkı bulunması düşünülerek k-ortalamlar algoritması melez sistemde ilk olarak kullanılmıştır. Yapay sinir ağı uygulanmadan önce kullanılan veri setine ait girişler k-ortalamlar ile kümeler ayrılır. Karesel hata fonksiyonun en aza indirecek sayıda küme oluşturulmuştur. Bu sayede hata payı minimum seviyeye indirilerek doğruluk artırılması sağlanmaktadır. K-ortalamlar ile her küme için merkez noktaya (öklit) uzaklığı kümelerin oluşmasını sağlamaktadır. Bu algoritma kullanıldığında kümeler birbirinden farklı özelliğe sahip olur. Küme içerisindeki değerler birbirine yakın olarak oluşturulmuştur. Kullanılan K-ortalamlar kullanılarak kümelerin özellik çıkarımı doğrultusunda oluşturulmuştur. Dikey olarak kümeleme yapılmıştır. Model kararlı hale gelince her oluşan küme için ayrı ayrı yapay sinir ağı uygulanmıştır. Yapay sinir ağı için bu çalışmada çok katmanlı ileri beslemeli geri yayımlı Levenberg-Marquardt eğitim algoritmasına sahip yapay sinir ağı modeli kullanılmıştır. Yapay sinir ağının her küme için üretmiş olduğu çıkış verisi alınarak tekrar yapay sinir ağı uygulanarak son çıkış üretilmektedir. Kullanılan yapay sinir ağı ilk modelde kullanılan ağ ile aynı özelliklere sahiptir.

### 5.3. YSA VE HİBRİT SİSTEM UYGULAMALARI

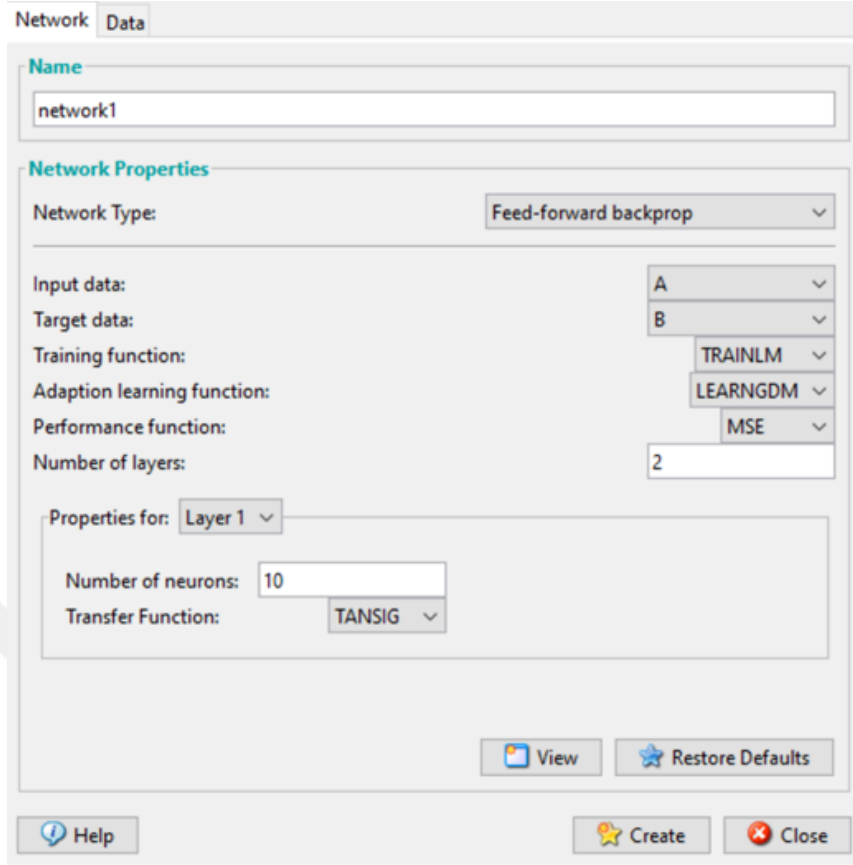
Yapay sinir ağı (YSA) uygulamasında kullanılacak model Şekil 9’de verilmiştir.



Şekil 9. Yapay Sinir Ağı Modeli

13 adet giriş verisetinde yer alan Yaş, Cins, Ağrı, Kansek, Elektro, Egzagrı, Stdep, Stegım, Anadamar, Talyum, Kanbas, Kalphızı, Serkol parametresinden oluşmaktadır. Çıkış ise Hasta parametresini vermektedir.

Giriş ve Çıkış verileriyle yapay sinir ağı mimarisini oluşturmak için Şekil 11’de belirtilen yapay sinir ağının özellikleri belirlenmesi gerekmektedir.




Şekil 11. Yapay Sinir Ağı Ayarları

Problem için oluşturulan yapay sinir ağı mimarisinde;

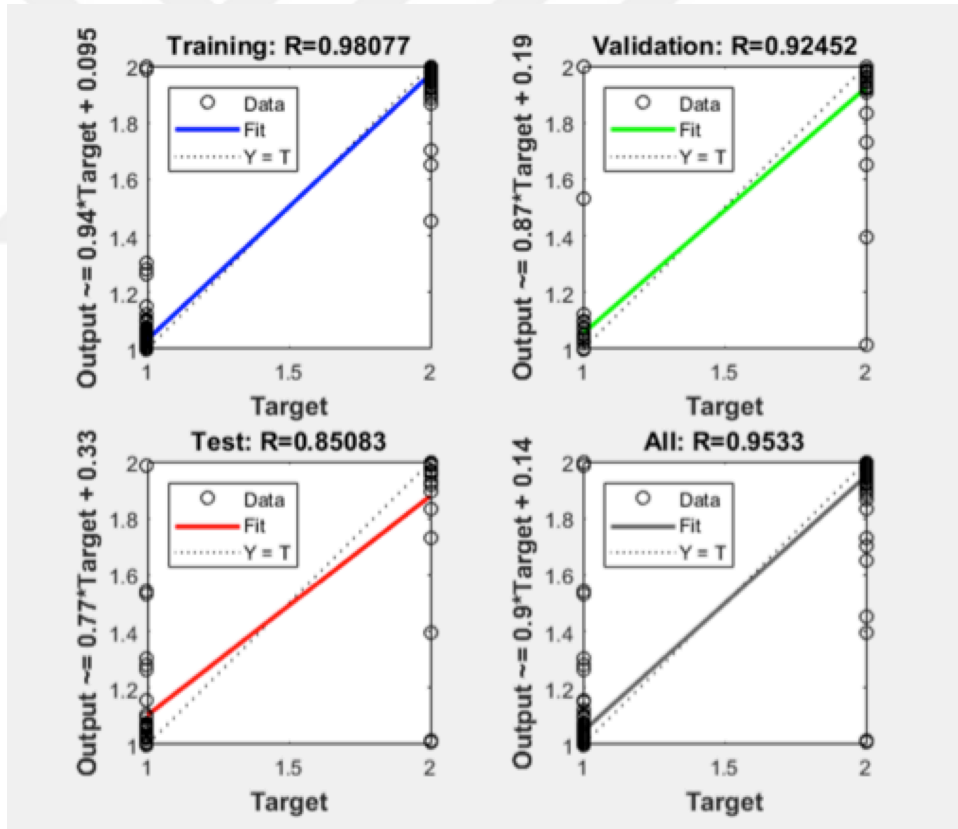
- Network Type (Ağ tipi): İleri beslemeli geri yayımlı
- Training Function (Eğitim Fonksiyonu): TRAINGDX (Gradient Descent with Momentum) (Momentum ile eğim azaltma)
- Number of Layers (Katman sayısı): 2
- Number of neurons (Gizli katmandaki nöron sayısı): 10
- Transfer Function (transfer fonksiyonu): Gizli katmandan çıkış katmanına verileri aktarma için TANSIG (Tanjant Sigmoid) transfer fonksiyonu kullanılmıştır.

Oluşturulmuş olan YSA Şekil 12’de gösterilmiştir. YSA eğitildikten sonra Şekil 13’de görülen regresyon grafiği elde edilmiştir.



Şekil 12. Yapay Sinir Ağı Yapısı

Yapay sinir ağının eğitimi 24 iterasyonda, hata eşiği 0,05 ile tamamlanmıştır. Şekil 13’de gösterilen regresyon grafiği, iki farklı değişken arasındaki ilişkiyi göstermek için kullanılan bir analiz yöntemidir. Değişkenlerden biri bağımsız iken diğeri bağımlı olarak kullanılır. Grafikte görülen Target (çıkış) diğer değişkenlerden etkilenmez.



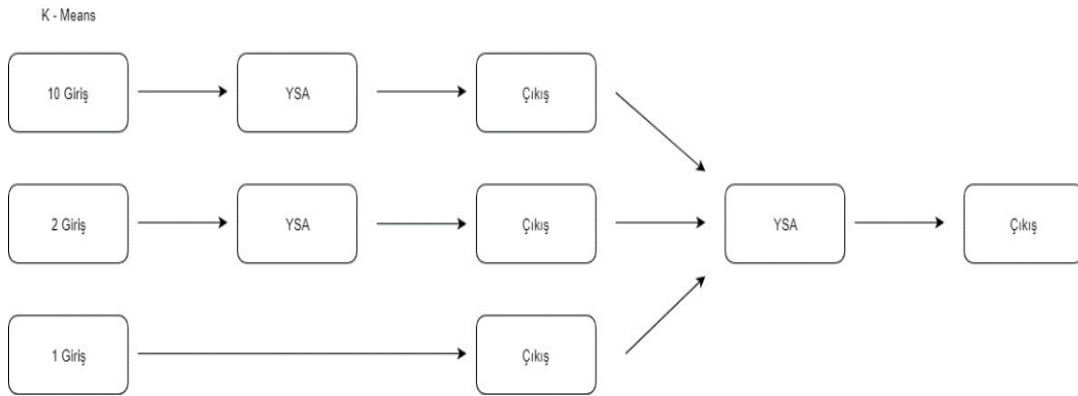
Şekil 13. Yapay Sinir Ağı Regresyon Grafiği

Şekil 13’de gösterilen yapay sinir ağı regresyon grafiğinde %98 oranında eğitim performansına, %92 oranında doğruluk performansına ve %85 oranında test performansına sahip olduğu görülmektedir. Eğitim performansında gösterilen başarı, doğruluk ve test performansında görülememektedir. Bunun sebebi olarak verisetinde veri tekrarı veya verilerin homojen dağılmamış olması gösterilebilir.

Eğitilen yapay sinir ağının üretilmiş olan çıkış değerleriyle gerçek çıkış değerleri ile hesaplama yapıldığında hata oranı 0,01; toplam karesel hata 3,39 olarak hesaplanmıştır.

Problemin çözümü için yapay sinir ağı uygulamasından sonra önerilen melez sistem uygulaması yapılmaktadır. Yapay sinir ağı performansını arttırmak için önerilen melez sistemde K-Ortalamalar Kümeleme algoritması kullanılmıştır.

Tez çalışmasının Şekil 14’de görülen melez sistem uygulaması gerçekleştirilmiştir.



**Şekil 14.** Melez Sistem Modeli


Şekil 14’de önerilen melez sistemde 13 adet giriş olan Yaş, Cins, Ağırlık, Kansek, Elektro, Egzagrı, Stdep, Stegım, Anadamar, Talyum, Kanbas, Kalphızı, Serkol parametreleri özellik çıkarımı yapılarak dikey olarak üç ayrı kümeye ayrılmıştır. K- ortalamlar ile ayrılan sistemde birinci kümede 10 giriş, ikinci kümede 2 giriş, üçüncü kümede ise bir giriş bulunmaktadır. Kümelenen verilerden oluşan yapay sinir ağları ayrı ayrı eğitildikten sonra elde edilen üç ayrı çıkış

oluşturulmuştur. Bu üç ayrı çıkış ile tekrar yapay sinir ağı eğitimi yapılarak çıkış elde edilmiştir.

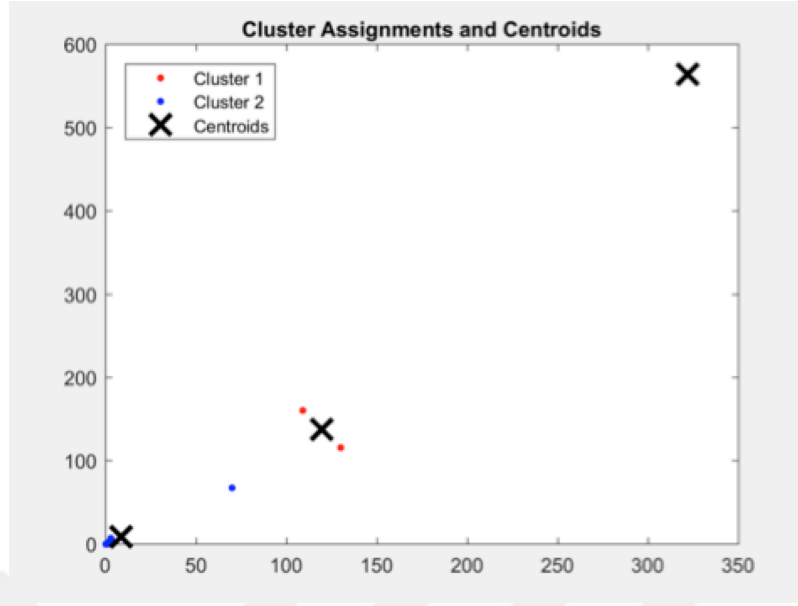
Önerilen melez sistemde öncelikle verisetinde bulunan verilerin özelliklerindeki ortaklığı kümeleme için kullanılmasında K-Ortalamlar Kümeleme algoritması kullanılmıştır. Kaç adet küme kullanılacağını belirlemek için Karesel Hata Fonksiyonunu en aza getirecek sayıda gruplama yapılmıştır.

Veri setinde bulunan giriş özelliğini K- Ortalamalar ile özellik çıkarımı yapılarak 3 ayrı kümeye ayrılmıştır. Melez sistemde veriler karesel hata fonksiyonunu en aza 3 kümede indirgediği için k-ortalamlar kümeleme algoritmasındaki küme sayısı 3 olarak belirlenmiştir. Veriler dikey olarak 3 kümeye ayrılmıştır. Şekil 15’de görülmektedir. Şekil 16’de ise K- Ortalamalar ile ayrılan kümelerin merkezleri gösterilmiştir.

idx = [1, 1, 1, 2, 3, 1, 1, 2, 1, 1, 1, 1, 1]



**Şekil 15.** Giriş Verilerinin K- Ortalamalar ile Kümelere Ayrılması




**Şekil 16.** K- Ortalamalar ile Ayrılan Kümelerin Merkezleri

İlk kümede 10 kolon, 2. Kümede 2 kolon ve 3. Küme ise tek kolon olarak ayrılmıştır.

1. Küme: Yaş, Cins, Ağrı, Kansek, Elektro, Egzagrı, Stdep, Stegım, Anadamar, Talyum
2. Küme: Kanbas, Kalphızı
3. Küme: Serkol

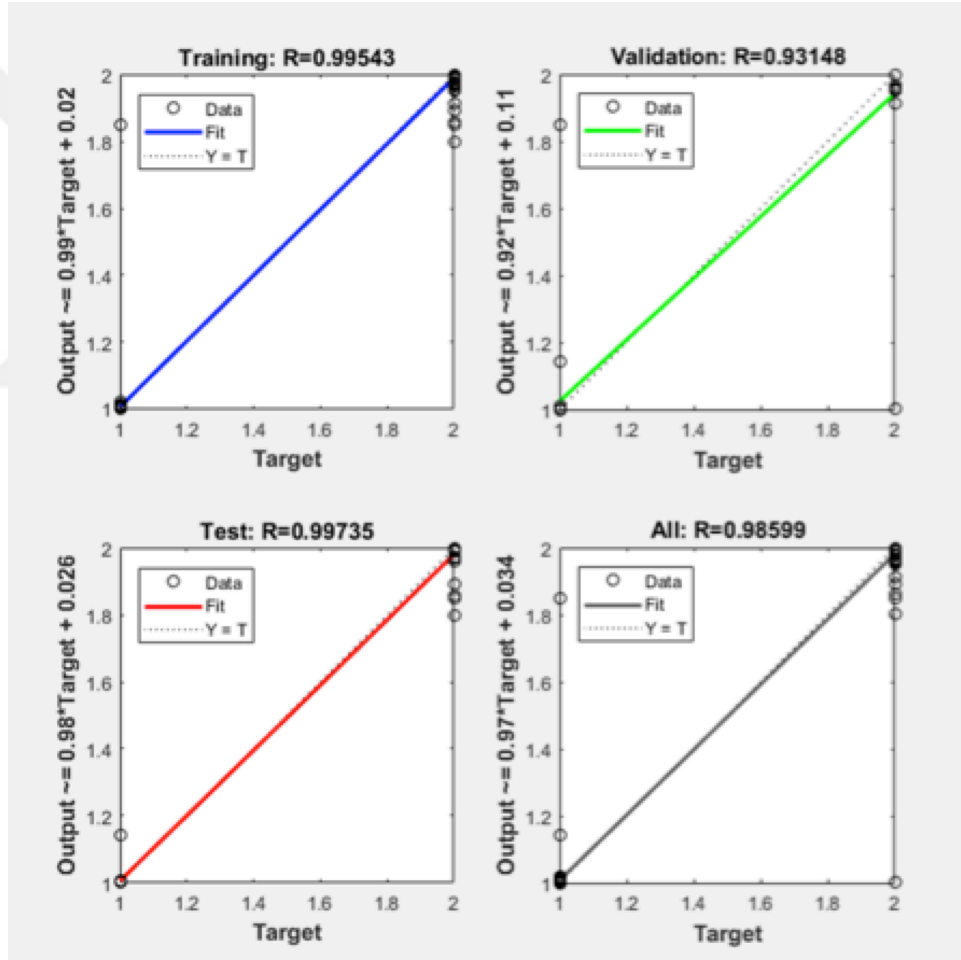
Birinci küme 10 giriş ve 1 çıkış; ikinci küme ise 2 giriş, 1 çıkış olarak YSA kullanılarak eğitilmiştir. Yapay sinir ağ ayarları her küme için ileri beslemeli geri yayımlı olarak seçilmiştir. Katman sayısı 2, nöron sayısı ise 10 olarak belirlenmiştir.

Birinci ve ikinci kümeden gelen çıkış değerleri son uygulanacak YSA uygulamasına alınır. Üçüncü küme ise tek kolondan oluştuğu için direk YSA'na katılmıştır. Katman sayısı 2, nöron sayısı ise 10 olarak verilmiştir ve ileri beslemeli geri yayımlı ağ olarak işleme alınmıştır. Şekil 17'de K-Ortalamlar algoritması ile yapılan YSA sonucunda oluşturulmuş olan 3 girişli ve 1 çıkışlı Yapay Sinir Ağı Yapısı gösterilmiştir.



Şekil 17. Melez Sistem Yapısı

Yapay sinir ağı eğitildikten sonra çıkan regresyon grafiği Şekil 18’de gösterilmiştir.



Şekil 18. Melez Sistem Regresyon Grafiği

Şekil 18’de melez sisteme ait regresyon grafiğinde %99 oranında eğitim, %93 oranında doğruluk, %99 oranında test performansı başarıları elde edilmiştir. Şekil



18'deki tekil YSA yöntemindeki regresyon grafiğine göre daha iyi doğruluk ve test performansı elde edildiđi görölmektedir.

K-Ortalamlar algoritması kullanılarak eđitilen yapay sinir ađının üretilmiř olduđu ıkıř deđerleriyle gerek ıkıř deđerleri ile hesaplama yapıldıđında hata oranı 0,003; toplam karesel hata 1,41 olarak hesaplanmıřtır.



## 6. SONUÇ

Bu çalışmada, kalp ve damar hastalıklarının önceden tespit edilebilmesi için hastalara ait çeşitli parametreler kullanılarak YSA ve melez sistem ile tahminleme yapılmış ve bu iki sistemin karşılaştırılmasından bahsedilmiştir. Bu doğrultuda ilk model olan YSA oluşturulmuş ve ağ eğitilmiştir. Eğitim sonucunda gerçek çıkışlar ile yapay sinir ağı modelinin ürettiği çıkışlar karşılaştırılmıştır. İkinci model olan melez sistemde K-Ortalamalar algoritmasıyla veriler kümelenebilir. Her bir küme için YSA oluşturulmuş ve eğitilmiştir. Çıkışlarda benzerlikler olduğu görülmüştür. Çalışmanın sonucunda YSA ve Melez Sistem modellerinin tahmin performans kriterleri karşılaştırılmaktadır.

YSA ve gerçek çıkışların karşılaştırılması Tablo 4’de gösterilmiştir.

Çıkış Verileri	YSA Sonuçları	Hata	Mutlak Hata
2,00	1,95	0,05	0,05
1,00	1,03	-0,03	0,03
2,00	1,70	0,30	0,30
1,00	2,00	-1,00	1,00
1,00	1,00	0,00	0,00
1,00	1,00	0,00	0,00
2,00	2,00	0,00	0,00
2,00	2,00	0,00	0,00
2,00	1,99	0,01	0,01
2,00	2,00	0,00	0,00
1,00	1,07	-0,07	0,07
1,00	1,07	-0,07	0,07
1,00	1,00	0,00	0,00
2,00	1,89	0,11	0,11
1,00	1,07	-0,07	0,07
1,00	1,00	0,00	0,00
2,00	2,00	0,00	0,00
2,00	2,00	0,00	0,00
1,00	1,03	-0,03	0,03
1,00	1,00	0,00	0,00

**Tablo 4.** YSA Modeli ile Elde Edilen Sonuçlar

Önerilen melez sistem ve gerçek çıkışların karşılaştırılması Tablo 5’de gösterilmiştir.

Çıkış Verileri	Melez Sistem Sonuçları	Hata	Mutlak Hata
2,00	1,999999	0,000001	0,000001
1,00	1,000001	-0,000001	0,000001
2,00	1,999958	0,000042	0,000042
1,00	1,000000	0,000000	0,000000
1,00	1,000000	0,000000	0,000000
1,00	1,000000	0,000000	0,000000
2,00	2,000000	0,000000	0,000000
2,00	2,000000	0,000000	0,000000
2,00	2,000000	0,000000	0,000000
2,00	1,999998	0,000002	0,000002
1,00	1,000000	0,000000	0,000000
1,00	1,000000	0,000000	0,000000
1,00	1,000000	0,000000	0,000000
2,00	2,000000	0,000000	0,000000
1,00	1,000000	0,000000	0,000000
1,00	1,000005	-0,000005	0,000005
2,00	2,000000	0,000000	0,000000
2,00	2,000000	0,000000	0,000000
1,00	1,000000	0,000000	0,000000
1,00	1,000000	0,000000	0,000000

**Tablo 5.** Melez Model ile Elde Edilen Sonuçlar

Yapılan çalışma doğrultusunda hangi modelin daha başarılı sonuç verdiğini belirlemek için performans kriterleri hesaplanmıştır. Performans kriterleri; ortalama karesel hata(MSE), kök ortalama karesel hata(RMSE) ve ortalama mutlak yüzde hatası(MAPE)’dan oluşmaktadır. MSE, RMSE, MAPE formüllerinde yer alan n: Toplam sayı;  $y_i$ : Gerçek çıkış;  $y_i^1$ : Yapay sinir ağının üretmiş olduğu çıkışı ifade etmektedir.

Ortalama Karesel Hata(MSE);

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - y_i^1)^2 \quad (17)$$

Kök Ortalama Karesel Hata(RMSE);

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y_i^1)^2} \quad (18)$$

Ortalama Mutlak Yüzde Hatası(MAPE);

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - y_i^1}{y_i} \right| \quad (19)$$

YSA sonucunda oluşturulan performans kriteri tablosu Tablo 6'de gösterilmiştir.

MSE	0,022
RMSE	0,15
MAPE	1,409

**Tablo 6.** YSA Performans Kriterleri Tablosu

Önerilen melez sistem sonucu oluşturulan performans kriteri tablosu ise Tablo 7'da gösterilmiştir.

MSE	0,003
RMSE	0,06
MAPE	0,371

**Tablo 7.** Melez Sistem Performans Kriterleri Tablosu

YSA ve melez sistemin karşılaştırmaları Tablo 8’de görülmektedir.

	YSA	Melez Sistem
MSE	0,022	0,003
RMSE	0,15	0,06
MAPE	1,409	0,371

**Tablo 8.** YSA ve Melez Sistem Performans Kriterleri Tablosu Karşılaştırması

YSA ile gerçekleştirilen uygulamada kalp ve damar hastalığının tahmininde Tablo 6’daki performans kriterleri tablosuna bakıldığında MSE değeri 0,022, RMSE değeri 0,15 ve MAPE değeri 1,409 olarak bulunmuştur.

Melez sistem ile gerçekleştirilen uygulamada kalp ve damar hastalığının tahmininde Tablo 7’deki performans kriterleri tablosuna bakıldığında MSE değeri 0,003, RMSE değeri 0,06 ve MAPE değeri 0,371 olarak bulunmuştur.

Tüm bu sonuçlar doğrultusunda YSA ve melez sistemin performans kriterleri tablosuna bakıldığında kalp ve damar hastalığının tahmin edilmesinde melez sistemin, ileri beslemeli geri yayımlı yapay sinir ağı modeline göre daha başarılı olduğu görülmüştür.

Kalp ve damar hastalıklarının erken teşhisi için hastalık tahmini önemli bir problemdir. Hastalıkların erken teşhisi için çeşitli alanlarda çalışmalar yapılmaktadır. Bunlardan biri de yapay zekadır. Bu çalışmada literatüre katkısı açısından kalp ve damar hastalıklarının tahmini için YSA ve melez sistem karşılaştırılmıştır. Literatürde farklı problemlerin çözümünde de melez sistemlerin tekil yöntemlere göre daha başarılı olduğu bilinmektedir. Önerilen melez sistemin YSA modeline ve literatürdeki diğer yöntemlere göre bu hastalığın tahmininde daha başarılı olduğu çalışmada gösterilmiştir. Farklı veri kümeleri ve daha büyük veri setlerinde de önerilen melez sistemin başarılı olabilmesi için geliştirilebileceği öngörülmektedir.

## KAYNAKÇA

- [1] T.C. Sağlık Bakanlığı Temel Sağlık Hizmetleri Genel Müdürlüğü, Türkiye Kalp ve Damar Hastalıklarını Önleme ve Kontrol Programı 2015-2020, Basım 2015 Ankara.
- [2] T.C. Sağlık Bakanlığı Temel Sağlık Hizmetleri Genel Müdürlüğü, Türkiye Kalp ve Damar Hastalıklarını Önleme ve Kontrol Programı 2010-2014, Basım 2010 Ankara.
- [3] Nabiyev VV. Yapay Zeka. Ankara: Seçkin Yayınları, 2003.
- [4] Babalık A, Güler İ. Boğaz Enfeksiyonlarının Teşhis ve Tedavisinde Uzman Sistem Kullanımı. Selçuk Üniversitesi, Teknik Bilimler Meslek Yüksekokulu, Teknik-Online Dergi 2007;6:2.
- [5] Etikan İ, Elbozan Cumurcu B, Çam Çelikel F, Erkorkmaz Ü, Yapay sinir ağları yöntemi ve bu yöntem kullanılarak psikiyatrik tanılarının sınıflandırılması. Tıp Bilimleri Dergisi 2009;29:2.
- [6] Cemil Çolak, M. Cengiz Çolak, M. Ali Atıcı Ateroskleroz'un tahmini için bir yapay sinir ağı, Ankara Üniversitesi Tıp Fakültesi Mecmuası 2005
- [7] Özhan Özkan, Murat Yıldız, Etem Köklükaya, Fibromiyalji Sendromunun Teşhisinde Kullanılan Laboratuvar Testlerinin Sempatik Deri Cevabı Parametreleriyle Desteklenerek Teşhis Doğruluğunun Arttırılması. SAU Fen Bilimleri Dergisi.
- [8] Esmâ Sezer. Epilepsi Teşhisi İçin EEG Sinyal Analizi. Selçuk Üniversitesi Fen Bilimleri Enstitüsü master tezi.
- [9] Fırat Hardalaç, Mustafa Poyraz. Yapay Sinir Ağları Kullanılarak EMG Sinyallerinin Sınıflandırılması ve Neuropathy Kas Hastalığının Teşhisi. Fırat Üniversitesi, Tıp Fakültesi, Politeknik Dergisi
- [10] Dr. Birgül Elbozan Cumurcu, Dr. Feryal Çam Çelikel, Dr. Ünal Erkorkmaz.

Yapay Sinir Ağları Yöntemi ve Bu Yöntem Kullanılarak Psikiyatrik Tanıların Sınıflanması. Gaziosmanpaşa Üniversitesi Tıp Fakültesi, Tokat

- [11] Nesibe Yalçın. Sezgisel Algoritma Öğrenmeli Yapay Sinir Ağları ile Epilepsi Hastalığının Teşhisi. Selçuk Üniversitesi Yüksek Lisans Tezi.
- [12] Ali Öter, Osman Aydoğan, M. Kemal Kıymık, Deniz Tuncel. Tıkayıcı Uyku pnesinin Yapay Sinir Ağları ve Morfolojik Filtreler kullanılarak Sınıflandırılması İçin Yeni Yöntem. KSU Mühendislik Bilimleri Dergisi, 19(2), 2016
- [13] Ramazan Tekin, Yılmaz KAYA, Mehmet Emin TAĞLUK. K-means ve YSA temelli Hibrit Bir Model ile Epileptik EEG İşaretlerinin Sınıflandırılması. Fırat Üniversitesi – Elazığ, TMMOB Elektrik Mühendisleri Odası, Elektrik – Elektronik ve Bilgisayar Sempozyumu, 2011.
- [14] Hasan Demir, Pakize Erdoğan, Meral Kekeçoğlu. Destek Vektör Makineleri, YSA, K-Means ve KNN Kullanarak Arı Türlerinin Sınıflandırılması. Düzce Üniversitesi Bilim ve Teknoloji Dergisi, 2018.
- [15] McCarthy J. What is artificial intelligence Computer Science Department, Stanford University, 2007.
- [16] Ayşe Demirhan, Yusuf Alper Kiliç, İnan Güler, Tıpta Yapay Zeka Uygulamaları, Yoğun Bakım Dergisi 2010
- [17] Prof.Dr. Ercan Öztemel, Yapay Sinir Ağları, Papatya Yayıncılık
- [18] Yrd. Doç. Dr. Atınç Yılmaz, Yapay Zeka, 2017
- [19] Dilek Altaş, Vildan Gülpınar, Karar Ağaçları Ve Yapay Sinir Ağlarının Sınıflandırma Performanslarının Karşılaştırılması: Avrupa Birliği Örneği Trakya Üniversitesi Sosyal Bilimler Dergisi Haziran 2012

- [20] Sađırođlu, Ő.; BeŐdok E. & Erlen, M. (2003).Mühendislikte Yapay Zeka Uygulamaları I: Yapay Sinir Ağları. Kayseri: Ufuk Kitap Kıratsiye-Yayınclık.
- [21] Mehmet Ali Çavuşlu, Geriye Yayılım ve Levenberg Marquardt Algoritmalarının YSA Eğitimlerindeki Başarımlarının Dinamik Sistemler Üzerindeki Başarımı
- [22] Güncel SARIMAN, Veri Madencilğinde Kümeleme Teknikleri Üzerine Bir Çalışma: K-Means ve K-Medoids Kümeleme Algoritmalarının Karşılaştırılması, Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü Dergisi, 15-3( 2011),192-202, 2011
- [23] DataLabTr  
<http://datalabtr.com/>  
(Erişim Tarihi: 30.01.2018)



## ÖZGEÇMİŞ

Cansu Tokyüz 01 Ocak 1993 Dinar'da doğmuştur. 2006 yılında Aydın TED Koleji'nde ilk öğretimini; 2010 yılında Aydın Atatürk Anadolu Lisesi'nde orta öğretimini tamamlamıştır. 2014 yılında İstanbul Beykent Üniversitesi Elektronik ve Haberleşme Mühendisliği bölümünü bitirmiştir. Ekim 2013 tarihinden Haziran 2016 tarihine kadar Proje Mühendisi olarak çalışmıştır. Eylül 2015 yılında İstanbul Beykent Üniversitesi Bilgisayar Mühendisliği bölümünde yüksek lisans eğitimine başlamıştır. Ekim 2017 yılından itibaren Yazılım Mühendisi olarak çalışmaktadır.

İlgi Alanları; Yapay Zeka, Ön yüz yazılım teknolojileri, C# ve JavaScript programlama dilidir.

Cansu TOKYÜZ