



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



YÜKSEK LİSANS TEZİ

Demiryolu Makas Arızalarının Yapay Zeka Yöntemleri ile Tahmini

Burak ARSLAN

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Elektrik-Elektronik Mühendisliği Programı


**DANIŞMAN
Dr. Öğr. Üyesi Hasan TIRYAKI**

Haziran, 2018


İSTANBUL

Bu çalışma, 20.06.2018 tarihinde aşağıdaki jüri tarafından Elektrik-Elektronik Mühendisliği Anabilim Dalı, Elektrik-Elektronik Mühendisliği Programında Yüksek Lisans tezi olarak kabul edilmiştir.

Tez Jürisi



Dr. Öğr. Üyesi Hasan TIRYAKI (Danışman)
İstanbul Üniversitesi
Mühendislik Fakültesi



Prof. Dr. Mukden UĞUR
İstanbul Üniversitesi
Mühendislik Fakültesi



Dr. Öğr. Üyesi Abdurrahim
AKGÜNDOĞDU
İstanbul Üniversitesi
Mühendislik Fakültesi



Dr. Öğr. Üyesi İbrahim Güneş
İstanbul Üniversitesi
Mühendislik Fakültesi



Dr. Öğr. Üyesi Cihat BOYRAZ
Marmara Üniversitesi
Teknoloji Fakültesi



20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, İstanbul Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Fen Bilimleri Enstitüsü’nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır.

ÖNSÖZ

Bu tezin hazırlanmasında ve yüksek lisans eğitimim boyunca her türlü yardımını esirgemeyen ve bana yol gösteren danışman hocam Sayın Dr. Öğretim üyesi Hasan Tiryaki'ye, göstermiş oldukları anlayıştan ve verdikleri destekten dolayı iş arkadaşlarıma ve hayatımın her döneminde bana destek olan aileme en içten teşekkürlerimi sunarım.

Haziran 2018

Burak ARSLAN



İÇİNDEKİLER

Sayfa No

ÖNSÖZ	iv
İÇİNDEKİLER.....	v
ŞEKİL LİSTESİ	vii
TABLO LİSTESİ.....	ix
SİMGE VE KISALTMA LİSTESİ	x
ÖZET	xi
SUMMARY	xiii
1. GİRİŞ	1
1.1. LİTERATÜR TARAMASI	2
2. GENEL KISIMLAR.....	4
2.1. OLUŞTURULAN SİSTEM MODELİ	4
2.2. MODEL GİRDİLERİ VE ÇIKTILARI	4
3. MALZEME VE YÖNTEM.....	8
3.1. DEMİRYOLU MAKASLARI	8
3.1.1. Makaslarla İlgili Temel Tanımlamalar	9
3.1.2. Makas Çeşitleri	11
3.1.2.1. Basit Makas	11
3.1.2.2. Birleşik Makas	11
3.1.2.3. Çapraz Makas.....	12
3.1.3. Kumanda Şekillerine Göre Makas Çeşitleri	12
3.1.4. Pençe Kilit Sistemi	13
3.1.5. Makas Motorları	15
3.2. YAPAY ZEKA	18
3.2.1. Yapay Sinir Ağları.....	20
3.2.1.1. Yapay Sinir Ağları Yapısı	21
3.2.1.2. Yapay Sinir Ağları Türleri	26
3.2.1.3. Öğrenme Algoritmalarına Göre Yapay Sinir Ağları	27
3.2.2. Destek Vektör Makinaları	28
3.2.2.1. Doğrusal Ayrılabilen Veri Kümesinin DVM ile Sınıflandırılması.....	29
3.2.2.2. Doğrusal Olarak Ayrılamayan Veri Setinin DVM ile Sınıflandırılması.....	32

3.2.2.3. Çok Sınıflı DVM.....	34
3.3. PERFORMANS DEĞERLENDİRME ÖLÇÜTLERİ.....	36
3.4. WEKA.....	39
4. BULGULAR.....	40
5. TARTIŞMA VE SONUÇ	50
KAYNAKLAR.....	52
EKLER	56
EK 1. WEKA KULLANIMI	56
ÖZGEÇMİŞ	60



ŞEKİL LİSTESİ

Sayfa No

Şekil 1: Normal bir makas hareketinin akım –zaman grafiği.	5
Şekil 2: Kilit açarken fazla akım çeken makas motoru akım-zaman grafiği.	5
Şekil 3: Hareket süresi normalden fazla olan makas motoru akım-zaman grafiği.	6
Şekil 4: Basit demiryolu makasının yapısı.	8
Şekil 5: Makasın normal pozisyonu.	10
Şekil 6: Makasın sapan pozisyonu.	10
Şekil 7: Basit sol ve sağ makas.	11
Şekil 8: Birleşik Makas [15].	11
Şekil 9: Çapraz makas.	12
Şekil 10: Toplu makas.	13
Şekil 11: Sağa kilitlemiş makas için kırlangıç kuyruğu pozisyonları.	14
Şekil 12: Hareket esnasında kırlangıç kuyruğu pozisyonları.	14
Şekil 13: Sola kilitlemiş makas için kırlangıç kuyruğu pozisyonları.	15
Şekil 14: Elektromekanik kontrollü makas motoru iç yapısı.	16
Şekil 15: Makas motoru ray bağlantısı.	16
Şekil 16: Ray açıklığı.	17
Şekil 17: Makas mutabakat (dedektör) devresi.	18
Şekil 18: Biyolojik sinir hücresi yapısı [23].	21
Şekil 19: YSA yapısı [24].	22
Şekil 20: Doğrusal aktivasyon fonksiyonu.	24
Şekil 21: Eşik aktivasyon fonksiyonu.	25
Şekil 22: Sigmoid aktivasyon fonksiyonu.	26
Şekil 23: İleri beslemeli YSA.	26

Şekil 24: Geri beslemeli YSA.....	27
Şekil 25 : Doğrusal olarak ayrılabilen (A) ve ayrılamayan (B) veri seti.	28
Şekil 26: Optimum hiper düzlem.	30
Şekil 27: Verilerin öznitelik uzayına haritalanması [26].	32
Şekil 28: Yüksek boyutlu uzayda doğrusal ayırıcı [34].	33
Şekil 29: Çok sınıflı DVM birebir yaklaşımı [37].	35
Şekil 30: Çok sınıflı DVM bire çok yaklaşımı [37].	35
Şekil 31: Örnek bir WEKA ekran görüntüsü.	39
Şekil 32: YSA modeli.	40
Şekil 33: K-katlamalı çapraz doğrulama [45].	47

TABLO LİSTESİ

Sayfa No

Tablo 1: Model çıktısı olarak kullanılan bakım önerileri.	7
Tablo 2: Toplama fonksiyonu türleri [25].	23
Tablo 3: Karmaşıklık matrisi.	36
Tablo 4: Sınıflandırılan örneklerin doğruluk yüzdeleri.	41
Tablo 5: 01A makası için sınıflandırma başarı ölçütleri.	42
Tablo 6: 01B makası için sınıflandırma başarı ölçütleri.	42
Tablo 7: 01C makası için sınıflandırma başarı ölçütleri.	42
Tablo 8: 02A makası için sınıflandırma başarı ölçütleri.	43
Tablo 9: 02B makası için sınıflandırma başarı ölçütleri.	43
Tablo 10: 02C makası için sınıflandırma başarı ölçütleri.	43
Tablo 11: DVM için tahmin sonuçları.	44
Tablo 12: YSA için tahmin sonuçları.	45
Tablo 13: Çapraz Doğrulama ile Sınıflandırılan verilerin doğruluk yüzdeleri.	47
Tablo 14: Çapraz doğrulama ile sınıflandırılan örneklerin başarı ölçütleri.	48

SİMGE VE KISALTMA LİSTESİ

Kisaltmalar	Açıklama
DC	: Doğru Akım
DVM	: Destek Vektör Makinaları
FN	: Yanlış Negatif
FP	: Yanlış Pozitif
HKOK	: Hata Karelerinin Ortalamasının Karekökü
K	: Kernel Fonksiyonu
OMH	: Ortalama Mutlak Hata
Roc Area	: Alıcı İşletim Karakteristiği Alanı
R^2	: Determinasyon Katsayısı
TP	: Doğru Pozitif
TN	: Doğru Negatif
WEKA	: Waikato Environment for Knowledge Analysis
YSA	: Yapay Sinir Ağları

ÖZET

YÜKSEK LİSANS TEZİ

DEMİRYOLU MAKAS ARIZALARININ YAPAY ZEKA YÖNTEMLERİ İLE TAHMİNİ

Burak ARSLAN

İstanbul Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik-Elektronik Mühendisliği Anabilim Dalı

Danışman : Dr. Öğr. Üyesi Hasan TİRYAKİ

Dünya genelinde birçok bölgenin birbiri ile iletişim ve sosyal ticari ilişkiler içerisinde bulunması, yolcu ve yük taşımacılığının önemini arttırmaktadır. Demiryolları güvenli ve ekonomik olması sebebiyle taşımacılıkta yoğun olarak tercih edilmektedir.

Ülkemizde ve dünyada son yıllarda demiryolları şehir içi ve şehirler arası yük ve yolcu taşımacılığında büyük önem kazanmıştır. Demiryolları işletmesinin güvenli, kesintisiz ve yüksek kapasiteli olarak sağlanabilmesi için sinyalizasyon sistemleri geliştirilmiştir. Demiryolu makasları, sinyalizasyon sistemlerinin en önemli ekipmalarından biridir. Makaslarda oluşabilecek arızalar demiryolu işletmesinin durmasına ya da aksamasına neden olmaktadır. Bu nedenle demiryolu makaslarının arıza yapmadan çalışması sağlanmalıdır.

Bu alıřmada demiryollarının nemli ekipmanlarından olan makas motorları ve ilgili ekipmanlarından veriler toplanmıř ve bu veriler analiz edilerek arızalara uygulanacak nleyici ve dzeltici zm nerileri deęelendirilmiřtir. Bu veriler yapay zeka yntemlerinden “Destek vektr makinaları” ve “Yapay Sinir Aęları” ile iřlenerek makine ęrenmesi yaptırılmıřtır. Bu ęrenme ıřıęında olası arızaları nceden tahmin ederek ilgili bakım nerileri belirleyen ve sorumlu bakım personeline gerekli mdahale uyarıları yapan bir karar destek modeli oluřturulmuřtur. Bu sayede arızanın demiryolu iřletmesini etkileyecek seviyeye ulařmadan zlmesi ve oluřmuř arızanın da mdahale sresinin kısaltılması amalanmaktadır.

Haziran 2018, 74 sayfa.

Anahtar kelimeler: Demiryolu, makas motoru, yapay zeka, yapay sinir aęları, destek vektr makinaları.

SUMMARY

M.Sc. THESIS

PREDICTION OF RAILWAY SWITCH POINT FAILURES WITH ARTIFICIAL INTELLIGENCE METHODS

Burak ARSLAN

İstanbul University

Institute of Graduate Studies in Science and Engineering

Department of Electrical and Electronic Engineering

Supervisor : Assist. Prof. Dr. Hasan TİRYAKİ

The communication and social commercial relations of many regions throughout the world increase the importance of passenger and freight transportation. By the reason of economical advantages and safety reasons, railways are mostly preferred media of transportation.

Railways have gained great importance in our country and worldwide in recent years in terms of intracity and interurban freight and passenger transportation. Railway signalling systems have been developed to ensure safe, uninterrupted and high capacity railway operation. Railway switch points are one of the most important equipments of the signalling systems. The failures which are occurred at switch points may cause railway operation stop or

interrupt. Therefore, it should be provided that railway switch points must be operated without failure.

In this study, The data were collected from the switch point machines and its related equipments which is one of the important elements of railways, and the preventive and corrective solution proposals were evaluated by analyzing the data. With using this data, machine learning was done by using "Support vector machines" and "Artificial Neural Networks" methods from artificial intelligence methods. In light of this learning, a decision support model was established which predicts possible failures and defines the relevant maintenance proposals and making necessary action warnings to responsible maintenance personnel. Thus, it is aimed that the failure is solved without affect the railway operation and the solving time of the occurred failures are shortened.

June 2018, 74 pages.

Keywords: Railway, point machine, artificial intellegence, artificial neural networks, support vector machines

1. GİRİŞ

Şehirlerde artan nüfus yoğunluğu, bu doğrultuda artan bireysel araç sayısına mevcut karayolu kapasitesinin cevap verememesinden kaynaklanan trafik sorunu, şehirler arası güvenli yolcu ve yük taşımacılığı ihtiyacı gibi nedenlerle son yıllarda ülkemizde ve dünyada demiryolu yatırımları büyük önem kazanmıştır. Demiryollarına olan bu ilgi ile demiryolu taşımacılığında kullanılan hat sayısı ile uzunluğu ve hatlarda kullanılan araç sayısı büyük oranda artış göstermiştir. Hatlarda çalışan araç sayısının ve sefer sayısının artması demiryolu trafiğinde de yoğunluk oluşturmaktadır. Bu yoğunluğu karşılamak için hattın mimarisine göre mümkün olan en sık aralıklarla tren işletmeciliğine elverişli elektronik ve elektromekanik sistemler geliştirilmiştir.

Demiryolu işletmeciliğinin güvenli ve kesintisiz olarak işletilmesi için modern sinyalizasyon sistemleri kullanılmaktadır. Trenlerin bir yoldan diğer yol veya yollara geçmesine imkan veren makasların hareketini sağlayan makas motorları da sinyalizasyon sisteminin en önemli ekipmanlarından biridir. Makasın hangi yöne tanzim edildiği, trafiği yöneten kumanda ve kontrol merkezi tarafından kesin olarak bilinmelidir. Makasın istenilen yöne tanzim edilebilmesi güvenli trafik işletmeciliğinin en önemli unsurlarındandır. Aksi takdirde trenlerin raydan çıkması ve çarpışması gibi can ve mal kaybına sebep olabilecek ağır sonuçlarla karşılaşılabilir.

Bu çalışmada demiryolu makaslarından çalışma esnasında veriler toplanmış ve her bir makas hareketi için alınan veri sektör tecrübesi ile yorumlanmış, eğer arızaya sebep olabilecek bir öngörü var ise yapılması gereken düzeltici ve önleyici bakım önerileri sunulmuştur. Toplamda 6 adet makas motoru ve çevre ekipmanlarından veriler toplanılmış ve bu veriler yapay zeka yöntemlerinden “Destek Vektör Makinaları” ve “Yapay Sinir Ağları” ile işlenerek sisteme makine öğrenmesi yaptırmak için eğitim verisi olarak kullanılmıştır. Bu eğitim ışığında işletme esnasında makasın her hareketi değerlendirilecek ve olası arıza oluşturabilecek bir durum tesbit edilirse henüz işletmeyi etkileyecek seviyeye gelmeden çözülmesi, işletmeyi etkilediği durumlarda da arızayı çözmeye gidecek olan bakım ekibine arıza ile ilgili ön bilgi vererek ekibin daha hızlı müdahale etmesi sağlanarak demiryolu işletmesinin mümkün olan

en kısa sürede normal seyrine dönmesini sağlayacak bir karar destek modeli ortaya koymak amaçlanmaktadır.

Çalışmada ilk olarak literatürde bulunan YSA ve DVM yöntemleriyle yapılmış akademik çalışmalar incelenmiştir. İkinci bölümde, kurulan arıza tahmin modeli, veri toplama yöntemi ve verilerin yorumlanması anlatılmıştır. Üçüncü bölümde çalışmada kullanılan materyeller ve matematiksel yöntemler açıklanmıştır. Dördüncü bölümde işlenen veriler sonucunda elde edilen bulgulara yer verilmiştir. Son bölümde ise bulguların yorumlanması yapılmıştır.

1.1. LİTERATÜR TARAMASI

YSA ve DVM yöntemleri bankacılıkta, finans sektöründe, savunma sanayisinde, endüstride, üretim alanında, bilişim sektöründe, sağlık alanında ve daha birçok sektörde kullanılmaktadır. Literatürde bulunan YSA ve DVM uygulamalarına bazı örnekler aşağıda verilmiştir.

YSA ekonomi, finans ve borsa tahminlerinde yaygın olarak kullanılmaktadır. Maciel ve Bellini [1] Kuzey Amerika, Avrupa ve Brezilya borsalarının tahmini ve geleneksel borsa tahmin yöntemleriyle karşılaştırmak için bir YSA modeli geliştirmişlerdir.

Budak ve Erbulak [2] bankacılık sektöründe kredi talep eden müşterinin düzenli ödeme yapip yapamayacağını tahmin etmek için YSA kullanmış ve sonuçları farklı yöntemlerle karşılaştırıp, YSA'nın daha doğru tahmin kabiliyeti olduğu sonucuna varmışlardır.

Demirhan ve diğ. [3] tıp alanında karmaşık tıbbi verileri analiz edip daha önce tedavi edilen hasta verilerini kullanarak, tedavi ve tanı önerisi sunan YSA modeli geliştirmişlerdir. Serhatlıoğlu ve Hardalaç [4] radyoloji sonuçlarının değerlendirmesi için YSA yöntemini kullanmışlardır.

Aşkın ve diğ. [5] kuru tip transformatör sargılarının termal analizini yapmak için yapay zeka yöntemlerini kullanmışlardır.

Yaghini ve diğ. [6] İran'daki demiryollarında yolcu trenlerinin gecikme olasılığını yüksek doğrulukta öngörmek için bir YSA modeli sunmuştur.

Aravindh [7] demiryolu ray devrelerinde meydana gelen arızaların analizi için YSA yöntemini kullanmıştır.

Shu ve Zhang [8] yoğun tren trafiđi altındaki demiryolu köprülerinde meydana gelebilecek hasarı önceden tespit etmek amacıyla YSA modeli kullanmıştır.

Topcu [9] demiryollarında oluşabilecek kazaların önceden tahini için YSA ve DVM kullanarak bir model geliştirmiştir.

Sun ve Zhao [10] demiryolu ray devreleri arızalarının sınıflandırılması için çok sınıflı DVM kullanmışlardır.

Eker ve diğ. [11] demiryolu makaslarındaki mekanik ekipmanlardan toplanan verilerle DVM kullanarak sınıflandırma yapmıştır.

Sandesh Nair [12] demiryolu araçlarından işletmede olduğu sürece veriler toplamış ve bu verileri DVM yöntemi ile sınıflandırarak, arıza tahmininde yüksek başarı oranı elde etmiştir.

Bhaduri [13] demiryolu ray kırıklarının tesbiti için tren üzerine yerleştirilen sensörler vasıtasıyla hat üzerinden ölçümler almış ve bu ölçümleri DVM yöntemi ile sınıflandırmıştır.


2. GENEL KISIMLAR

2.1. OLUŞTURULAN SİSTEM MODELİ


Demiryolu hattı işletmesinin sürekliliği ve emniyetli bir şekilde yapılabilmesi için makaslar ve ilgili ekipmanlarının arıza çıkarmaması büyük önem taşımaktadır. Bu çalışmada demiryolu makaslarında arızaya neden olabilecek ekipmanlardan veriler toplanmış, hangi durumlarda hangi arızaların oluşabileceği ve bu arızalarla ilgili uygulanacak önleyici ve düzeltici bakım önerileri sunulmuştur. Bu kapsamda mevcut işletmede olan üç motorlu iki adet makasın her bir hareketi için 7 adet giriş verisi ve bu verilerin yorumu sonucu 13 adet çıkış verisinden bir tanesi belirlenerek sistem çıkışı olarak verilmiştir. Toplamda 6 adet makas motorundan 1000'er adet veri toplamış bunlardan 850'si eğitim, 150'si test verisi olarak kullanılmıştır.

2.2. MODEL GİRDİLERİ VE ÇIKTILARI

Bu çalışmada kullanılan elektrik motoru, bir fazlı 2.2 kw gücünde repülsiyon AC motordur. Makasa hareketi sağlayan elektrik motorlarının güç girişine bağlanan akım sensörleri ile ölçülen akımlar üç aşamada değerlendirilmiştir. Bu 3 aşama, olası arızalar nedeni ile makasın hareketi esnasında motorun daha fazla güç çekmesini gerektirebilecek; makas motorunun kilit açması, kayma plakaları üzerinde hareket etmesi ve diğer pozisyona kilitlemesidir. Makasın kilit açma esnasında çektiği akım A1, kayma plakaları üzerinde hareketi esnasında çektiği akım A2, kilitleme sırasındaki ise A3 olarak tanımlanmıştır. Eğer motor harekete başladığı ilk anda olması gerektiğinden yüksek akım çekiyorsa kilit açma, eğer akım- zaman grafiğinin ortalarında fazla akım çekiyorsa kayma plakalarında, eğer akım- zaman grafiğinin sonlarına doğru fazla akım çekiyorsa kilitleme esnasında mekaniksel bir sorun vardır şeklinde tanımlanmıştır. Şekil 1' de örnek olarak sorunsuz bir şekilde hareketini tamamlayan makas motoruna ait akım-zaman grafiği verilmiştir.




Şekil 1: Normal bir makas hareketinin akım –zaman grafiği.



Şekil 2: Kilit açarken fazla akım çeken makas motoru akım-zaman grafiği.

Şekil 2 ‘de makas kilit açarken motor olması gerekenden fazla akım çekmiştir. Ancak zorlanarak da olsa hareketini tamamlamıştır. Bu durumda, gelecekte makas arıza yapmadan önce müdahale edilmeli ve kilit açma mekanik ayarlarının kontrol edilmesi gerekmektedir.



Şekil 3: Hareket süresi normalden fazla olan makas motoru akım-zaman grafiği.

Makas hareketine başladıktan sonra bir noktada mekanik bir sorunla karşılaşarak hareketine devam edemezse sürücü 12320 milisaniye boyunca motoru harekete zorlar ve bu süre sonunda hareketi sonlandırır. Eğer makas diğer pozisyona kilitlediğine dair indikasyon vermez ise makas arızalı durumda görülür. Bu durumda da motorun, akım zaman grafiğinin hangi safhasından itibaren yüksek akım çekmeye başladığı önemlidir ve o noktadaki mekanik ayarlar kontrol edilmelidir. Şekil 3’de görüleceği gibi motor yaklaşık olarak 2000 milisaniyeden sonra yüksek akım çekmeye başlıyor ve 12320 milisaniye boyunca akım çekiyor. Şekil 3’de akım-zaman grafiği verilen makasın, geçmişte normal olan hareketleri ile kıyasladığımızda, yaklaşık olarak 2200 milisaniyede hareketini tamamlaması gerekiyordu. Ancak Şekil 3’de verilen örnekte makas hareketin 3. bölümünden itibaren, yani kilitlemeye başladığı andan itibaren yüksek akım çekmeye başlıyor ve sürücü 12320 milisaniye sonunda motoru sürmeyi bırakıyor. Bu durumda makas kitleme esnasında mekanik bir zorlanmadan ötürü fazla akım çekmiştir. Eğer benzer senaryo makas hareketinin 1. bölümünden itibaren gerçekleşse kilit açma mekanik ayarları, 2. bölümünden itibaren gerçekleşse kayma plakaları ile ilgili bir sorun olduğu sonucuna varılır.

Makas motoruna hareket komutu gönderilir ve makas hiç akım çekmez ise, motor sürücüsü ya da güç kaynağı ile ilgili sorun vardır sonucuna varılır.

Eğer makasa hareket komutu gönderilir, makas normal akım değerleri ve normal hareket süresiyle düzgün bir şekilde hareketini tamamlar fakat yine de sinyalizasyon sisteminde arızalı durumda görülür ise mutabakat devresi ile ilgili bir sorun vardır. Bu çalışmada makasın hareketini tamamlayıp tamamlayamadığı bilgisi, makası kontrol eden sinyalizasyon sistemi loglarından alınmıştır.

Makasın bir pozisyona kilitledikten sonra, güvenlik gerekleri nedeniyle hareketli ray ve sabit ray arasındaki açıklık 1mm ‘nin altında bir değerde tutulmalıdır. Bu değerın ölçülmesi için bu çalışmada herhangi bir sensör kullanılmamış, bakım personellerinin önleyici bakımlar esnasında aldığı ve arıza esnasında yaptığı ölçümler baz alınarak, eğer 1mm altında ise”1” üzerinde ise “0 “ değeri kullanılmıştır.

Makas eğer hareketini beklenen bir şekilde tamamladıysa motor hareketi sorunsuzdur tanımı yapılmıştır. Burada anlatılan bilgiler ışığında her bir makas hareketinden toplanan girdiler yorumlanmış ve Tablo 1’de verilen bakım önerileri sonuç olarak kullanılmıştır.


Tablo 1: Model çıktısı olarak kullanılan bakım önerileri.

Öneri	Tanımlama
Motor hareketi sorunsuz	R1
Makas terse kilit açma mekanik ayarları kontrol edilmeli	R2
Makas normale kilit açma mekanik ayarları kontrol edilmeli	R3
Makas terse kilitleme mekanik ayarları kontrol edilmeli	R4
Makas normale kilitleme mekanik ayarları kontrol edilmeli	R5
Kayma plakaları kontrol edilmeli ve yağlanmalı	R6
Makas terse kilit açma mekanik ayarları ve kayma plakaları kontrol edilmeli	R7
Makas normale kilit açma mekanik ayarları ve kayma plakaları kontrol edilmeli	R8
Makas terse kilitleme mekanik ayarları ve kayma plakaları kontrol edilmeli	R9
Makas normale kilitleme mekanik ayarları ve kayma plakaları kontrol edilmeli	R10
Motor sürücüsü ve güç kaynağı kontrol edilmeli	R11
Mutabakat devresi kontrol edilmeli	R12
Ray açıklığı kontrol edilmeli	R13

3. MALZEME VE YÖNTEM

3.1. DEMİRYOLU MAKASLARI

Demiryollarında seyreden araçların karayollarında seyreden lastik tekerlekli araçlar gibi yön değiştirmesini sağlayan dümenleri yoktur. Demiryolu araçlarının bir yoldan diğer yola geçmesini sağlayan ray tertibatına makas denir. Makaslar iki rayın arasına traversler üzerine monte edilir. Makasın hareketli kısımlarının hareketini kolaylaştırmak için makas dil takımı ve traverslerin arasına monte edilmiş kayma plakaları bulunur. Makasın yönü değiştirilmek istendiğinde makas dili kayma plakaları üzerinde mevcut pozisyonunun tersi yönde hareket ettirilerek yön değişimi sağlanır. Kayma plakaları bilyeli ve bilyesiz olarak iki tiptir. Bilyeli kayma plakalarında makas dili plakaların içerisine gömülmüş bilyeler üzerinde hareket eder. Bilyesiz kayma plakalarında ise makasın işletme frekansı ve çevre koşullarına göre belli periyotlarda yağlanması gereken pürüzsüz metal yüzey üzerinde hareket eder. Basit bir makas 3 ana ray bölümünden meydana gelir. Bu bölümler Şekil 4’de gösterilmiştir.



Şekil 4: Basit demiryolu makasının yapısı.

- Dil Takımı: İki yönlü hareket ederek araçların yön değiştirmesini sağlayan bölümdür. Raylara bağlandığı kısımlara ökçe denir. Diller ökçeden hareket ediyorsa mafsallı dil, kendi esnekliği ile hareket ediyor ve ökçeden sabitse esnek dil adı verilir [14].
- Ara Raylar: Makas dilleri ile göbek kısmının birleşmesini sağlayan raylara denir.
- Göbek ve Kontraylar: Makasın doğru yol rayı ile sapan rayının birbirini kestiği noktaya göbek denir. Bu kesme noktasından tren tekerleğinin geçişini sağlamak için, iki ray kesişme noktasından başlayarak dışa doğru bükülürler ve tavşanayağı denilen eğri kısımları oluşturular. Kesişme noktasında tren tekerleklerinin serbestçe geçmesi için bir boşluk bırakılır, bu boşlukta tren tekerleğinin düşmemesi için kontray denilen destek ekipmanları bulunur [15].


3.1.1. Makaslarla İlgili Temel Tanımlamalar

Anlaşman; bir istasyon içerisindeki ve komşu istasyonlarla olan güvenli tren trafiğini yöneten sistemlerdir. Bu yönetim kapsamında anlaşman; trenlerin güzergah tanzimleri, makas tanzimleri ve bölgedeki bütün demiryolu araçlarının hareketlerini demiryolu trafik gereksinimleri ve kurallarına uygun şekilde gerçekleştirilir [16].

Makasın hareketini tamamlayıp, bir yöne kilitledikten sonra kilitlediği yön bilgisi yada kitleme sağlanamadıysa hareketini tamamlayamadığına dair bilgi sinyal sistemi tarafından bilinmelidir. Elektriksel olarak yapılan bu kontrole mutabakat denir. Sahadan gelen mutabakat bilgisinden sonra ancak anlaşman ilgili makas bölgesine rota tanzim edebilir.


Kitleme; makas istenilen pozisyona getirildiğinde üzerinden tren geçişi sırasında konum değiştirmelerine engel olmak için mekanik olarak hareket etmelerine engel olan sisteme kitleme tertibatı denir.

Makasın normal pozisyonu; trenin geldiği istikametten sapma yapmadan ilerlemesini sağlayacak şekilde makasın tanzim edilmesidir. Şekil 5 'de A noktasındaki tren makas normal pozisyonda olduğu için yön değiştirmeden B noktasına doğru gidecektir.



Şekil 5: Makasın normal pozisyonu.

Makasın sapan pozisyonu; trenin geldiği istikametten yol değiştirerek ilerlemesini sağlayacak şekilde makasın tanzim edilmesidir. Şekil 6'da A noktasındaki tren makas sapan pozisyonda olduğu için C noktasına doğru ilerleyecektir.



Şekil 6: Makasın sapan pozisyonu.


Makas bölgelerindeki tehlike noktası; aynı makas bölgesine ilerleyen demiryolu araçlarının aynı anda ilerleyebileceği son noktayı gösterir. Tehlike noktasından daha ileriye geçilmesi durumunda diğer trenin gabarisine girileceğinden çarpışma tehlikesi oluşacaktır. Bu noktayı belirlemek için iki demiryolu arasındaki tehlike noktasına limit taşı denilen işaret konulur.

3.1.2. Makas Çeşitleri

Demiryolu makasları yapıları itibarıyla üç tiptir. Bunlar; basit makas, birleşik makas ve çapraz makastır.

3.1.2.1. Basit Makas


Trenlerin yalnızca iki yol değiştirmesini sağlayan makaslardır. Trenin normal yoldan sapan yola ya da sapan yoldan doğru yola ilerlemesine imkan verir. Dil ucundan bakıldığında trenin sağa doğru ilerlemesini sağlıyorsa basit sağ makas, sola doğru ilerlemesini sağlıyorsa basit sol makas denir [17].



Şekil 7: Basit sol ve sağ makas.

3.1.2.2. Birleşik Makas

Birbiri içine geçmiş iki makastan oluşur. Bir yoldan üç yola geçmeye olanak sağlar. Bir doğru iki sapan yolu vardır. Sınırlı alanda üç yola geçmeye izin verdiğinden depo sahası ve istasyon içlerinde tercih edilirler.



Şekil 8: Birleşik Makas [15].

3.1.2.3. Çapraz Makas

Kesişen iki yolda karşılıklı geçişi sağlayan makaslardır. Büyük istasyonlarda ve gar sahalarında manevra yeteneğini arttırmak ve 3-4 manevra ile yapılacak hareketi tek makasla sağlamak amacıyla kullanılırlar



Şekil 9: Çapraz makas.

3.1.3. Kumanda Şekillerine Göre Makas Çeşitleri

Uzaktan kumandalı (motorlu) ve elle kumandalı (toplu) olmak üzere iki tür makas kumandası vardır. Uzaktan kumandalı makaslar; elektrik motoru ile kumanda merkezi tarafından hareket ettirilirler, gerektiği durumlarda kol takılarak elle tanzim edilebilirler. Tanzim edildiği pozisyon kumanda masasından izlenilebilir. Ana hatlarda ve yüksek hızlarda kullanılırlar.


Elle kumandalı makaslar devre kontrollü ve elektrik kilitli olmak üzere iki tiptir. Devre kontrollü makasların pozisyonu kumanda merkezinden görülebilir. Elektrik kilitli makaslar ise devre kontrolünün yanı sıra özel elektrik kilitlerle donatılmıştır. Kumanda merkezi elektrik kiliti serbest bırakmasından sonra bir görevli tarafından dile bağlı kolları normal ya da ters pozisyona getirmek için bu kollara bağlı ağır bir top ileri yada geri yönde itilerek makasın pozisyonu değiştirilir. Şekil 10'da toplu makasın saha uygulamasına ait örnek bir resim gösterilmiştir.



Şekil 10: Toplu makas.


3.1.4. Pençe Kilit Sistemi

Makas hareketini tamamlayıp bir pozisyona oturduğunda, üzerinden demiryolu aracı geçerken veya makas üzerine güzergah tanzimi yapıldıktan sonra pozisyonunu kaybetmemesi için kilitleme tertibatları vardır. Günümüzde demiryollarının büyük çoğunluğunda pençe kilit sistemi diye adlandırılan kilit tertibatı kullanılmaktadır. Bu sistemde makasa hareketi sağlayan tahrik çubuğunun her iki pozisyon için pençeleri bulunur. Makas bir pozisyona kilitlendiğinde kırlangıç kuyruğu diye adlandırılan metal aksam, tahrik çubuğunu sıkıştırır ve diğer pozisyonda bulunan kırlangıç kuyruğu ise tahrik çubuğu üzerindeki pençe içerisine girerek kilitleme sağlanır. Kırlangıç kuyruğu Şekil 11’de gösterilmiştir.



Şekil 11: Sağa kilitlemiş makas için kırlangıç kuyruğu pozisyonları.


Şekil 11’de sağ tarafa kilitlemiş bir makasa ait çizim verilmiştir. Sağ taraftaki kırlangıç kuyruğu tahrik çubuğunu sıkıştırmış, diğer taraftaki ise tahrik çubuğu üzerindeki pençe içerisine girmiştir.



Şekil 12:Hareket esnasında kırlangıç kuyruğu pozisyonları.


Şekil 12’de hareket halindeki bir makasa ait kırlangıç kuyruğu pozisyonları gösterilmiştir.

üzerinden geçecek tren bodenine bir etki etmeyeceği, 2 mm üzerindeki bir parçacığın ise tren aksını raydan çıkarma tehlikesi oluşturabileceğindendir. Ayrıca makas bir pozisyona kilitlediğinde Şekil 16’da gösterildiği gibi yaslanma rayı ve dil arasındaki boşluk 1 mm’nin altında olacak şekilde mekanik ayarlamalar yapılır.



Şekil 16: Ray açıklığı.

Makas’ın anlık olarak durumu anlaşılan ve kumanda merkezi tarafından bilinmelidir. Eğer makas hareketini tamamlayabildiyse hangi pozisyona kilitlendiği, herhangi bir nedenden dolayı hareket tamamlanmadıysa makas dilinden pozisyon bilgisi alınamadığına dair indikasyon bilinmelidir. Bu bilgi makasın her iki diline bağlı, dillerle beraber hareket eden ve uçları makas motoru içerisindeki mekanik kontakları hareket ettiren mutabakat çubukları ile yapılır. Bu mutabakat (dedektör) devresi için makasa sürekli olarak DC gerilim sağlanır. Makasın pozisyonuna göre hareket eden mutabakat çubukları, ilgili kontakları da hareket ettirir ve eğer makasa gönderilen DC gerilimin geri dönüşü düz polarite ile alınırsa anlaşılan makasın normal pozisyonda olduğunu, ters polarite ile alınırsa sapan pozisyonda olduğunu algılar. Eğer gönderilen DC gerilimden bir geri dönüş alınmaz ise anlaşılan makasın hareketinin tamamlayamadığını algılar. Şekil 17’de bu çalışmada kullanılan mutabakat devresinin basit bir çizimi gösterilmiştir.



Şekil 17: Makas mutabakat (dedektör) devresi.

3.2. YAPAY ZEKA

Yapay zeka insanların karşılaştığı sorunlara makinaların da insanlar gibi düşünüp çözüm üretmesini sağlamak için geliştirilmiş bir bilim dalıdır. İnsanın düşünce yapısının algoritmalara dönüştürülerek sistemlere öğretilmesine dayanır.

Yapay zeka insan düşünme yapısını taklit etme ve bu yapıyı anlayarak bir modele dönüştürme sonucunda programlanmış bir bilgisayarın düşünme girişimi olarak tanımlanabilir [18].

Nilsson'a göre yapay zeka [19]; ana hedefi doğadaki varlıkların davranışlarını yapay olarak üreten akıllı davranış üzerine bir çalışma yöntemidir.

Kurzweil'e göre yapay zeka [20]; insanların zekalarını kullanarak yaptığı işlevleri yapma kabiliyeti olan makinaları yapma sanatıdır.

Yapay zeka bilgisayarları akıllı yapma bilimidir. Bilgisayarları daha faydalı hale getirmek için zekayı taklit etmek değil zeki bir model kurulmalıdır.

Yapay zeka için en çok kabul gören tanımlar ise; insan tarafından yapıldığında zeka olarak adlandırılan akıllı işlevlerin makinalar tarafından yapılması ve insan aklının nasıl çalıştığını gösteren bilim kuramıdır.

Literatürde "Artificial Intelligence" olarak bilinen yapay zeka, insanların zihinde insanın yerini alacak robot algısı oluştursa da, bu alanda çalışma yapan ve fikir sahibi olanlar insan ve makine arasındaki farkın bilincindedir. Bilgisayarlar hiç bir zaman insanın sahip olduğu özgün fikir üretme ve duygu aktarımı gibi yetkinliklere sahip olamayacaklardır. Ancak bilgisayarların makinaları kontrol etme, mevcut girdilere göre hesap yapma, teşhis koyma gibi insan düşünme sürecinin benzeşimini yapan sistemlere beyin görevi görmesi mümkündür.

Yapay zeka ile ilgili ilk bilimsel çalışmalar Alan Turing tarafından yapılmıştır. İkinci dünya savaşında Almanların geliştirdiği enigma adlı şifreleme sistemine karşılık matematikçi Gordon Welchman ile birlikte şifreli yazıları çözümülemesi için Bombe makinasını tasarladılar. 1950 yılında Mind adlı felsefe dergisinde yayınladığı "Turing Testi" ile makinelerin ne kadar düşünebilme yetisi olduğunu sorgulamıştır.

Yapay Zeka 1956 yılında ABD'nin Dartmouth şehrinde düzenlenen konferansta ilk olarak dile getirilmiştir. Bu konferansta J. McCharty ilk olarak yapay zeka ifadesini kullandı ve J. McCharty, M. Minsky, C. Shannon, A. Newell ve H. Simon yapay zeka ile donatılmış bilgisayar programları gerçekleştirme olasılığını araştırmayı önermişlerdir.

1965-1970 arası dönemde yapılan çalışmalarda umulan başarılar elde edilemedi. Yapay zeka fikrinin ortaya atıldığı ilk dönemdeki aşırı iyimser ve aceleci tutum, bilim adamlarını akıllı bilgisayarlar üretmenin çok kolay olacağına inandırdı ancak bekledikleri başarıya ulaşamadılar.

1970-1975 arası dönemde yapay zeka ile ilgili önemli gelişmeler elde edildi. Uzmanlar özellikle hastalık teşhisi yapan sistemler gibi çalışmalar yaparak ilerisi için umut vaad eden çalışmalar ortaya koydular.

1975 sonrasında ise yapay zeka, robot biliminde kullanılmaya başlanmış ve bununla beraber sanayileşmiş ülkelerin dikkatini çekerek iktisadi hayata girişi de başlamıştır.

Yapay zekayı sistemlere uygulamak için birçok yöntem vardır. Bu çalışmada yapay zeka yöntemlerinden “Yapay Sinir Ağları” ve Destek Vektör Makinaları” kullanılmıştır.

3.2.1. Yapay Sinir Ağları


YSA insan beynindeki sinirleri modelleyerek örnekler üzerinden öğrenme ve daha sonra hiç görmediği örnekler ile ilgili öğrendikleri bilgileri kullanarak karar verme yeteneğine sahip sistemlerdir. YSA insanların ve hayvanların sahip olduğu doğal öğrenme yeteneğinin belli özelliklerinin taklit edilerek modellenmesidir [21].

YSA kendisine sunulan verileri bir algoritmaya dayanarak çözmek yerine, kendisine daha önceden verilen örnekleri inceleyerek çözüme gitmeye dayanır. Kendisine verilen girdiyi, kendisine öğretilen örneklerle karşılaştırarak aradaki benzerlik ve farklılıkları ortaya koyma ve sınıflara ayırma yetisine sahiptir.

Yapay sinir ağları paralel olarak çalışan ve nöron olarak adlandırılan çok sayıda küçük işlemci birimden oluşur. Paralel çalışma özelliği sayesinde YSA, bilgileri daha hızlı işleme özelliğine sahiptir. Bu avantajından dolayı günümüzde teşhis, sınıflandırma, kontrol, ses tanıma ve görüntü işleme gibi bir çok alanda yaygın olarak kullanılmaktadır [22].

Canlılarda bulunan sinir sistemi çok sayıda sinir hücresinin birbirine bağlanması ile meydana gelmektedir. YSA canlıların sinir sisteminin küçük ayrıntılarının ihmal edilerek bilimsel ve teknolojik modellere benzetimidir. YSA birbiri ile paralel haberleşen katmanlar ve bu katmanlarda bulunan sinir hücrelerinden oluşmaktadır. Her bir sinir hücresinin işlediği olaya göre bir ağırlık katsayısı vardır.

YSA’yı daha iyi anlamak için biyolojik sinir hücresi yapısının iyi bilinmesi gereklidir. Biyolojik sinir hücresi Şekil 18’de gösterildiği gibi hücre çekirdeği (soma), bağlantılar (snaps), girişler (dendrit) ve çıkışlardan (akson) oluşmaktadır.



Şekil 18: Biyolojik sinir hücresi yapısı [23].

Dendrit; bağlı olduğu yerlerden gelen sinyalleri sinir hücresinin çekirdeğine iletmekle görevlidir. Hücre çekirdeği ile çekirdeğe bağlı tüm dendritler arasında farklı haberleşme kanalı mevcuttur.


Soma; dendritler vasıtasıyla alınan sinyallerin toplandığı birimdir. Hücre çekirdeği olarak da adlandırılır. Üzerine gelen tüm bilgiyi diğer hücelere aktarmak üzere aksona iletir.

Akson; hücre çekirdeğinde işlenmiş olan toplam bilgiyi diğer hücelere ileten birimdir.

Sinapsis; aksondan gelen bilgiyi diğer sinir hücresinin dendritine iletmekle görevlidir. Ancak iletmeden önce bu veriyi bir ön işlem den geçirir ve ağırlığına göre ilgili sinir hücresine iletir. Bu nedenle öğrenmenin sinapsiste gerçekleştiği fikri YSA için teori haline dönüşmüştür.

3.2.1.1. Yapay Sinir Ağları Yapısı

YSA; girdi katmanı, gizli katman, çıktı katmanı, ağırlıklar, toplama fonksiyonu ve aktivasyon fonksiyonundan meydana gelmektedir.



Şekil 19: YSA yapısı [24].

Bir sinir hücresinden ya da dış dünyadan gelen bilgi girdi katmanıya ağı dahil edilir. Bir sinir hücresine çok sayıda girdi gelebilir. Girdi olarak sadece sayılar işlenir, eğer girdi sayılardan oluşmuyorsa sayısallaştırılır. Girdi katmanı verilerin ağı sunulduğu katmandır, başlangıçta girdi sayısı kadar sinir hücresi bulunur. Buradan ağı giriş yapan veriler işlenmeden gizli katmana geçiş yaparlar.

Gizli katman, ağı içerisinde temel işlevin gerçekleştirildiği katmandır. Ağdaki gizli katman sayısı ve katman içerisindeki hücre sayısı problemin özelliklerine ve ağı oluşturan kişinin sektör tecrübesine göre değişir. Burada girdi kamanında ağırlıklandırılmış veri, ortaya konulan probleme uygun bir fonksiyonla işlenilerek bir sonraki katmana iletilir.

Çıktı katmanı; ağı sonuçlarını ortaya koyan katmandır, her bir hücre bir adet çıktı üretebilir. Bu katman ağı en son katmanıdır, gizli katmandan aldığı veriyi ağı aktivasyon fonksiyonundan geçirerek sonuç verir.

Ağırlıklar; sinir hücresine gelen her bir girdinin ağı üzerindeki etkisini ve önemini gösterir. Ağlarda ağırlık değerleri değiştirilerek en uygun ağırlık değeri bulunur ve bu sayede ağı daha doğru sonuçlar verir.

Toplama fonksiyonu hücreye gelen net girdiyi hesaplayan fonksiyondur. En çok kullanılan ağırlıklı toplama fonksiyonudur. Bu fonksiyonda her bir girdi ağırlıkları ile çarpılır ve daha sonra elde edilen değerleri toplanarak ağıya gelen net girdi hesaplanır. Tablo 2 'de diğer toplama fonksiyonları gösterilmiştir.

Tablo 2: Toplama fonksiyonu türleri [25].


Toplama Fonksiyonu Türleri	
1.Toplam: $Net = \sum_{i=1}^n w_i * x_i$	Ağırlık değerleri girdiler ile çarpılır ve bulunan değerler toplanarak net girdi hesaplanır.
2.Çarpım $Net = \prod_{i=1}^n w_i * x_i$	Ağırlık değerleri birbiri ile çarpılır ve elde edilen değerler de birbiri ile çarpılarak net girdi hesaplanır
3.Maksimum $Net = Max(x_i * w_i)$	Ağırlıklar girdiler ile çarpılarak maksimumu net girdi olarak alınır.
4.Minimum $Net = Min(x_i * w_i)$	Ağırlıklar girdiler ile çarpılarak minimumu net girdi olarak alınır.
5.Çoğunluk $Net = \sum_{i=1}^n Sgn(x_i * w_i)$	Ağırlıklar girdiler ile çarpıldıktan sonra negatif ve pozitif olanların toplam sayıları bulunur, büyük olan net girdi olarak kabul edilir
6.Kümülatif Toplam $Net = Net(önceki) + \sum_{i=1}^n w_i * x_i$	Girdiler ağırlıklı olarak toplanır, daha önce nörona giren girdilere yeni değerler eklenerek net girdi hesaplanır.

Aktivasyon fonksiyonu; toplama fonksiyonun çıkışında elde edilen değeri işleyere ağı net çıktısını belirleyen fonksiyondur. Aktivasyon fonksiyonu kullanılmasının amacı, sistem sınırlarını belirleyerek çıktı olarak aşırı değerler üretilmesinin engellenmesidir. Tek katmanlı ağlarda doğrusal aktivasyon fonksiyonu seçilir. Çok katmanlı ağlarda ise genellikle doğrusal olmayan aktivasyon fonksiyonu seçilir. YSA'ların doğrusal olmama özelliği de seçilen bu aktivasyon fonksiyonlarından dolayıdır.

YSA'da aktivasyon fonksiyonu seçilirken türevi kolay alınabilir bir fonksiyon seçilmesi çok önemlidir. Geri beslemeli ağlarda fonksiyonun türevi de kullanıldığından, yapılan hesaplamaların yavaşlamaması için aktivasyon fonksiyonu seçimi önemlidir [25]. YSA'da en çok kullanılan aktivasyon fonksiyonları doğrusal aktivasyon fonksiyonu, eşik aktivasyon fonksiyonu ve sigmoid aktivasyon fonksiyonudur.

Doğrusal aktivasyon fonksiyonu; doğrusal problemlerin çözümlenmesi için hücrenin net girdisini hücre çıkışı olarak hesaplamaya yarayan fonksiyondur. α sabit bir sayı, x_i girişler, w_i ağırlıklar olmak üzere matematiksel gösterimi denklem 3.1'de verildiği gibidir.


$$f(net) = \alpha(net) \text{ ise } y = \alpha \left(\sum_{i=1}^n w_i x_i \right) \quad (3.1)$$



Şekil 20: Doğrusal aktivasyon fonksiyonu.

Eşik aktivasyon fonksiyonu; gelen girdinin değerinin belli bir eşik değerinin altında yada üstünde olmasına göre çıkışta “1” veya “0” değerini veren fonksiyondur [25]. Matematiksel gösterimi denklem 3.2 de verildiği gibidir.


$$f(net) = \alpha(net) = \begin{cases} 1 & \text{eğer } (net) \geq 0 \\ 0 & \text{eğer } (net) < 0 \end{cases} \text{ ise } y = \alpha\left(\sum_{i=1}^n w_i x_i\right) \quad (3.2)$$



Şekil 21: Eşik aktivasyon fonksiyonu.

Sigmoid aktivasyon fonksiyonu; türevinin kolay alınabilmesi, doğrusal olmaması ve sürekli olması sebebiyle YSA uygulamalarında sıkça kullanılmaktadır. Çıktı olarak “0” ile “1” arasında değerler üretir [22]. Matematiksel gösterimi denklem 3.3 de verildiği gibidir.

$$f(net) = \frac{1}{1 + e^{-\alpha(net)}} \text{ ise } y = \frac{1}{1 + e^{-\alpha\left(\sum_{i=1}^n w_i x_i\right)}} \quad (3.3)$$




Şekil 22: Sigmoid aktivasyon fonksiyonu.

3.2.1.2. Yapay Sinir Ağları Türleri


YSA yapılarına göre ileri beslemeli ve geri beslemeli ağlar olmak üzere ikiye ayrılır.

İleri beslemeli YSA'lar Şekil 23'de görüldüğü gibi üç katmandan oluşur. Veriler giriş katmanından ağı girer, elimizdeki probleme göre sistem ilgili katman veya katmanlarda eğitilir ve çıkış değerleri belirlenir. İleri beslemeli YSA'da veri akış yönü girişlerden çıkışlara doğrudur.



Şekil 23: İleri beslemeli YSA.

Geri beslemeli YSA; çıkışların veya ara katmanlardaki çıkışların girişleri ya da ara katmanlardaki nöronların girişlerini geri beslediği ağlardır. Geri besleme bir katmandaki hücreler arasında olduğu gibi, katmanlar arasında da olabilir. Bu özelliğinden dolayı dinamik davranışa sahip denilebilir. Hatayı geri besleme özelliğinden dolayı birçok uygulamada geri beslemeli ağlar tercih edilmektedir.



Şekil 24: Geri beslemeli YSA.

3.2.1.3. Öğrenme Algoritmalarına Göre Yapay Sinir Ağları

YSA'nın girilen verilere göre çıktı üretmesi için ağın eğitilmesi gerekir. Bu eğitimler danışmanlı öğrenme, danışmansız öğrenme ve takviyeli öğrenmedir.

Danışmanlı öğrenmede, ağa verilen girdilerin sonucu olarak çıktıları da verilir. Böylece ağın hangi girişe hangi çıkış vereceği öğretilir. Bu eğitimden sonra beklenen değerler ve ağın değerleri karşılaştırılır. Aradaki hataya göre ağırlıklar yeniden hesaplanır.

Danışmansız öğrenmede; ağa girdilerle beraber herhangi bir çıktı verilmez, ağa verilen girdilere göre ağ kendi kurallarına göre girdileri sınıflandırır. Ağırlıklar aynı özellikteki girdiler için aynı olacak şekilde belirlenir [26].

Takviyeli öğrenme danışmanlı öğrenmeye yakın bir metottur. Ağa bir çıkış verilmemekte ancak ağın ürettiği sonucun iyi olup olmadığı belirlenmektedir. Üretilen sonuç iyi ise ağ

kendisini güncelleyerek yeni sonuçları bu doğrultuda üretir. Yani girdilerle hem öğrenme işlemine devam eder hem de sonuç üretir.


3.2.2. Destek Vektör Makinaları

Destek vektör makinaları (DVM) istatistiksel öğrenmeye dayalı bir sınıflandırma algoritmasıdır [27]. İlk olarak Vapnik (1995) tarafından sınıflandırma problemlerinin çözümünde kullanılmıştır. DVM ilk olarak iki sınıflı doğrusal verilerin sınıflandırılma problemi için tasarlanmış, daha sonra çok sınıflı ve doğrusal olmayan verilerin sınıflandırılması için genelleştirilmiştir. DVM'nin temel prensibi iki sınıfı birbirinden ayırabilen en uygun karar fonksiyonunun bulunması, diğer bir ifade ile iki sınıfı birbirinden en uygun şekilde ayıran hiper düzlemin tanımlanmasıdır [28].

DVM verileri iki boyutlu uzayda doğrusal, üç boyutlu uzayda düzlemsel ve çok boyutlu uzayda ise hiperdüzlemler ile iki ya da daha çok sınıfa ayırma kabiliyetine sahiptir [29].

Sınıflandırılacak olan iki grubun arasına, iki grubun üyelerine de en uzak olan yerde bir sınır çizilerek gruplar birbirinden ayrılır. DVM bu sınırın nasıl çizileceğini belirler. Bu işlem için, her iki gruba en yakın noktada birbirine paralel iki doğru çizilir ve bu iki doğrunun orta noktasına bir sınır çizgisi çizilerek yeni gelen girdilerin bu çizgiye olan konumlarına göre sınıflandırılması sağlanır.

DVM hem doğrusal olarak ayrılabilen hem de ayrılamayan veri setinin sınıflandırılması için kullanılabilir. Uygun bir dönüşüm ile doğrusal olarak ayrılamayan veri seti yüksek boyutlu başka bir uzaya taşınarak uygun bir hiperdüzlem ile sınıflandırma yapılabilir [26].



Şekil 25 : Doğrusal olarak ayrılabilen (A) ve ayrılamayan (B) veri seti.

3.2.2.1. Doğrusal Ayrılabilen Veri Kümesinin DVM ile Sınıflandırılması

Doğrusal olarak ayrılabilen veri seti yüksek boyutlu uzaya taşımaya gerek kalmadan bir doğru ile birbirinden ayrılabilir. İki grubu birbirinden ayıran çok sayıda hiperdüzlem bulunur. Ancak daha iyi sonuçlar elde edebilmek için DVM ile iki veri setini birbirinden ayıran ve veri setlerine eşit uzaklıkta bulunan optimum hiperdüzlem belirlenir [30].

Şekil 26’da gösterilen H1 ve H2 hiperdüzlemleri veri setlerine en yakın noktada bulunan, diğer sınıftaki verilere ise en uzak noktada bulunan aşırı hiper düzlemlerdir. Bu iki hiper düzlemin orta noktasında ise optimum hiper düzlem bulunmaktadır.

$$x_1, x_2, \dots, x_n \in R^d \text{ ve } y_1, y_2, \dots, y_N \in \{-1, +1\} \text{ olmak üzere;} \quad (3.4)$$


H hiper düzlemi denklem 3.5 ve denklem 3.6 daki gibi tanımlanır. Burada x_i ’inci veri kümesi elemanını, w ağırlık vektörünü ve b sabit terimi gösterir.

$$y_i = +1 \text{ olduğunda } x_i * w + b \geq +1 \quad (3.5)$$

$$y_i = -1 \text{ olduğunda } x_i * w + b \leq -1 \quad (3.6)$$

Denklem 3.5 ve denklem 3.6’nın birleştirilmiş hali 3.7’de verildiği gibidir.

$$y_i(x_i * w + b) \geq 1 \quad (3.7)$$



Şekil 26: Optimum hiper düzlem.

Şekil 26’da $d +$ optimum hiperdüzlemin pozitif gruba olan en kısa mesafesini, $d -$ ise negatif gruba olan en kısa mesafesini gösterir.

Bir (x_0, y_0) noktasının , bir $Ax + By + c = 0$ doğrusuna uzaklığını bulmak için denklem 3.8’de verilen denklemin kullanıldığını hatırlayacak olursak,

$$(Ax + By + c) / \sqrt{A^2 + B^2} = 0 \quad (3.8)$$

H optimum hiperdüzlemi ve H1 aşırı hiperdüzlemi arasındaki mesafe;

$$|w^*x + b| / \|w\| = 1 / \|w\| \quad (3.9)$$

olur ve $d +$ ile $d -$ arasındaki mesafe eşit olduğundan, aşırı hiperdüzlemler H1 ve H2 arasındaki mesafe d denklem 3.10’ki gibi ifade edilir.

$$d = \frac{2}{\|w\|} \quad (3.10)$$

DVM’de amaç iki hiperdüzlem arasında elman kalmayacak şekilde d ’yi maksimum yapmaktır. Bu nedenle w minimum olmalıdır.

$$y_i(x_i * w + b) \geq 1 \quad i = 1, \dots, n \quad \text{olmak üzere,} \quad \text{Min} \frac{1}{2} \|w\|^2 \quad (d \text{ 'nin türevi}) \quad (3.11)$$

Her x örneği için karar fonksiyonu denklem 3.12 'de verildiği gibidir.

$$f(x) = \text{sgn}(w * x) + b \quad (3.12)$$

Her bir örnek veri için bu işlem gerçekleştirileceğinden denklem 3.13 deki forma dönüşür.

$y_i(w * x_i + b) - 1 \quad i = 1, \dots, n$ olmak üzere;

$$\text{Min} \frac{1}{2} \sum_{i=1}^n w_i^2 \quad (3.13)$$

Bu DVM' nin ana gösterimidir. İkinci dereceden konveks bir optimizasyon problemidir.

Problem ikinci dereceden optimizasyon problemidir ve Lagrange çarpanları yöntemi denklem 3.13'e uygulanarak çözülür. Lagrange çarpanları ile kullanılan veriyle ilgili kısıtlamalar olduğunda çok değişkenli bir fonksiyonun minimum ve maksimum değerleri kolayca bulunabilir.

$$L_p = \frac{1}{2} \sum_{i=1}^n w_i^2 - \sum_{i=1}^N \alpha_i [y_i(w * x_i + b) - 1] \quad (3.14)$$

α Lagrange çarpanları, n veri içerisindeki özellik sayısı ve N örnek sayısı olmak üzere, L_p Lagrange'inin $\alpha_i \geq 0$ şartı ile w ve b değerlerinin minimize edilmesi gerekmektedir. Bu nedenle fonksiyonun w ve b değerlerine göre türevi alınarak sıfıra eşitlenir ve problem Karush-Thun-Tucker koşulları kullanılarak dual probleme dönüşmüş olur [31][32].

$$\frac{\partial L(w, b, a)}{\partial b} = 0 \rightarrow \sum_{i=1}^N \alpha_i y_i = 0 \quad \alpha_i \geq 0, \quad i = 1, \dots, N \quad (3.15)$$

$$\frac{\partial L(w, b, a)}{\partial w} = 0 \rightarrow w = \sum_{i=1}^N \alpha_i y_i x_i = 0 \quad \alpha_i \geq 0 \quad i = 1, \dots, N \quad (3.16)$$

Türev sonuçları denklem 3.14 'e yerleştirilirse doğrusal DVM'nin formülü elde edilmiş olur.

Bu formül $\alpha_i \geq 0$ ve $\sum_{i=1}^N \alpha_i y_i = 0$ şartı ile Lagrange çarpanlarına göre en büyük değerler bulunarak çözülür.


$$L_D = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j=1}^N \alpha_i \alpha_j y_i y_j (x_i * x_j) \quad (3.17)$$

Böylece karar fonksiyonları 3.18'deki gibi olur.

$$f(x) = \text{sign} \left(\sum_{i=1}^N \alpha_i y_i * x \right) + b \quad (3.18)$$


3.2.2.2. Doğrusal Olarak Ayrılamayan Veri Setinin DVM ile Sınıflandırılması

DVM veri setlerinin büyük çoğunluğu doğrusal olarak sınıflandırılmaz. DVM doğrusal olmayan verileri yüksek boyutlarda öznitelik uzayında haritalandırma yaparak doğrusallaştırır [33]. Böylece karmaşık olan veri seti kolayca ayrılabilir bir forma sokulur.



Şekil 27: Verilerin öznitelik uzayına haritalanması [26].

Şekil 27'de iki boyutda doğrusal olarak ayrılamayan veri setinin, üç boyutlu öznitelik uzayına taşınarak uygun bir hiperdüzlemle ayrılması gösterilmiştir.



Şekil 28: Yüksek boyutlu uzayda doğrusal ayırıcı [34].

En uygun hiperdüzlemi bulmak için çekirdek hilesi (Kernel Trick) denilen yöntemle problemi doğrusallaştırmak için çekirdek fonksiyonları kullanılır. İlk olarak girdiler düşük boyutlu uzaydan çok boyutlu öznitelik uzayına denklem 3.19 daki gibi haritalanır.

$$\phi: R^d \longrightarrow R^N$$

$$\phi(x_i) = \phi_1(x_i), \phi_2(x_i), \dots, \phi_N(x_i), \quad i = 1, \dots, l \quad (3.19)$$

Artık girdi uzayındaki x vektörü, çok boyutlu uzayda $\phi(x)$ vektörüne dönüşmüştür. Böylece hiperdüzlem vektörü denklem 3.20, w vektörü ise denklem 3.21 deki gibi tanımlanabilir.

$$f(x) = w \cdot \phi(x) + b \quad (3.20)$$

$$w = \sum_{i=1}^l y_i \alpha_i \phi(x_i) \quad (3.21)$$

Denklem 3.21 deki w denklem 3.20’de yerine koyulursa; denklem 3.22 deki halini alır.

$$f(x) = \sum_{i=1}^l y_i \alpha_i (\phi(x) \cdot \phi(x_i)) + b \quad (3.22)$$

İşlemi kolaylaştırmak için $(\phi(x) \cdot \phi(x_i))$ iç çarpımı çekirdek (Kernel) fonksiyonu olarak ifade edilir. Uygun çekirdek fonksiyonunun seçimi sistem performansı için en önemli etkidir[35]. Kernel fonksiyonu gösterimi denklem 3.23’deki gibidir.

$$K(x, x_i) = \phi(x) \cdot \phi(x_i) \quad (3.23)$$

Uygulamalarda en çok kullanılan Kernel fonksiyonları doğrusal (denklem 3.24), polinom (denklem 3.25), sigmoid (denklem 3.26) ve radyal (denklem 3.27) çekirdek fonksiyonlarıdır.

$$K(x_i, x_j) = (x_i * x_j) \quad (3.24)$$

$$K(x, x_i) = (x \cdot x_i + 1)^p \quad (3.25)$$

$$K(x_i, x_j) = \tanh(\gamma x_i * x_j - \delta) \quad (3.26)$$

$$K(x, x_i) = \exp(-\gamma \|x - x_i\|^2) \quad (3.27)$$

Lagrange çarpanları kullanılarak denklem 3.22, denklem 3.28'e dönüştürülür.

$$L(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l y_i y_j \alpha_i \alpha_j \phi(x_i) \phi(x_j) \quad (3.28)$$

Denklem 3.28'de $(\phi(x_i) \cdot \phi(x_j))$ ifadesi yerine çekirdek fonksiyonu (K) denklem 3.29'daki kısıtlar göz önünde bulundurularak yazılırsa denklem 3.30 elde edilir.


$$\sum_{i=1}^l y_i \alpha_i = 0 \text{ ve } 0 \leq \alpha_i \leq C \quad i = 1, \dots, l \quad (3.29)$$

$$L(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l y_i y_j \alpha_i \alpha_j K(x_i, x_j) \quad (3.30)$$

Denklem 3.30'un türevi alınarak sifıra eşitlenirse Lagrange çarpanları bulunur ve bulunan değerler denklem 3.22 de yerine konularak optimum hiperdüzlemin fonksiyonu elde edilir.

3.2.2.3. Çok Sınıflı DVM


DVM ile sınıflandırılacak veri setinin ikiden fazla sınıfa sahip olması durumunda çok sınıflı DVM yöntemlerinden birisi tercih edilmelidir. Çok sınıflı DVM yöntemleri; birebir yaklaşımı, bire çok yaklaşımı ve çoklu sınıf sıralama yaklaşımlarıdır.



Şekil 29: Çok sınıflı DVM birebir yaklaşımı [37].

En yaygın kullanılan çok sınıflı DVM bire bir yaklaşımıdır. Bu yaklaşımda sınıflarımız A, B ve C olarak kabul edilirse, önce DVM ile ikili gruplar halinde (AB, BC, AC) eğitilir ve birbirlerine karşı ağırlık katsayıları belirlenir. Yeni bir örnek geldiğinde ise ikili olarak sorgulama yaptırılır ve bu sorgulardan hangisine daha çok cevap alınırsa örnek o sınıfa konulur. Örneğin; AB sorgusuna B, BC sorgusuna B, AC sorgusuna A cevabını alırsak, üç sorgudan ikisinde B cevabı alınmış olduğundan örnek B sınıfında konulur [36].

Bire çok yaklaşımında yeni gelen örneğin sınıflandırılacağı seçeneklerden birisi diğerine göre daha baskın olmakta ve örnek o sınıfa dahil edilmektedir. Çoklu sınıf sıralama yaklaşımında ise, sınıflar üzerinde bir DVM çalışarak bütün üyeleri kapsayan bir sınıflandırma yapmaya çalışır. Eğitim süresinin uzun olması nedeniyle bu yöntem çok tercih edilmez [36].



Şekil 30: Çok sınıflı DVM bire çok yaklaşımı [37].

1.2.3.3. PERFORMANS DEĞERLENDİRME ÖLÇÜTLERİ

Bu bölümde oluşturulan tahmin modelinin performansını değerlendirmek için kullanılan ölçütler açıklanmıştır.

İki veya daha fazla değişkenin arasındaki ilişkiyi belirlemek için korelasyon katsayısı kullanılır. Bir değişken değişirken, diğer bir değişken de buna bağlı olarak değişiyorsa ikisi arasında bir korelasyon vardır denilebilir. Korelasyon katsayısı -1 ile +1 arasında değerler almaktadır. Korelasyon katsayısının işareti değişkenler arasındaki ilişkinin yönünü belirler. Eğer katsayı değeri negatif ise değişkenler arası ters yönlü, pozitif ise doğru yönlü bir ilişki vardır. Korelasyon katsayısı değeri 1'e yaklaştıkça değişkenler arası ilişki o kadar kuvvetli olur. Eğer korelasyon katsayısı 0 ise değişkenler arasında ilişki yoktur [39]. n örnek sayısı, x ve y değişkenlerin değerleri olmak üzere, korelasyon katsayısının formülü denklem 3.31'de verilmiştir.

$$r = \frac{n \sum xy - \sum x \sum y}{\sqrt{\left[n \sum x^2 - (\sum x)^2 \right] \left[n \sum y^2 - (\sum y)^2 \right]}} \quad (3.31)$$

Korelasyon katsayısının karesi determinasyon katsayısı (R^2) olarak ifade edilir. Determinasyon katsayısı bağımlı değişkenlerdeki değişimin yüzde kaçının bağımlı değişken ya da değişkenler tarafından açıklandığını gösterir. 0 ile 1 arasında pozitif değer alır ve bu değer 1'e yaklaştıkça değişkenler arasındaki ilişki daha kuvvetli denilebilir.

Makine öğrenmesinde kullanılan sınıflandırma modelinin performansını değerlendirmek için hedeflenen ve gerçekleşen değerlerin karşılaştırıldığı karmaşıklık matrisi de kullanılmaktadır. Bu matrisin değişkenleri A1 ve A2 sınıfları için örnek olarak Tablo 3'de gösterilmiştir.

Tablo 3: Karmaşıklık matrisi.

	ÖNGÖRÜLEN SINIF		
GERÇEK SINIF		A1 Pozitif	A2 Negatif
	A1 Pozitif	Doğru-Pozitif (TP)	Doğru-Negatif (TN)
	A2 Negatif	Yanlış-Pozitif (FP)	Yanlış-Negatif (FN)

Tablo 3'te gösterilen TP; gerçek durum pozitifken sınıflandırma sonucu pozitif çıkan veri oranını, TN; gerçek durum pozitifken sınıflandırma sonucu negatif çıkan veri oranını, FP; gerçek durum negatifken sınıflandırma sonucu pozitif çıkan veri oranını, FN; gerçek durum negatifken sınıflandırma sonucu negatif çıkan veri oranını göstermektedir.

Tablo 3'de gösterilen TP, TN, FP ve FN değerleri kullanılarak kesinlik, duyarlılık, f-ölçütü ve alıcı işletim karakteristiği alanı (Roc-area) değerleri hesaplanır.

- Kesinlik: Sınıfı 1 olarak tahmin edilen TP örnek sayısının, sınıfı 1 olarak tahmin edilen tüm örnek sayısına oranıdır. 1'e yakın olması kurulan modelinin performansının iyi olduğunu göstermektedir.

$$Kesinlik = \frac{TP}{TP + FP} \quad (3.32)$$

- Duyarlılık: Doğru pozitif olarak sınıflandırılmış örnek sayısının, tüm pozitif örnek sayısına oranıdır. 1'e yakın olması kurulan modelinin performansının iyi olduğunu göstermektedir.

$$Duyarlılık = \frac{TP}{TP + FN} \quad (3.33)$$

- F-Ölçütü: Kesinlik ve duyarlılık değerlerinin harmonik ortalamasıdır. 1'e yakın olması kurulan modelinin performansının iyi olduğunu göstermektedir.

$$F - \text{Ölçütü} = \frac{2 \times Duyarlılık \times Kesinlik}{Duyarlılık + Kesinlik} \quad (3.34)$$

- ROC-Area: ROC eğrisi, sınıflandırılan verilerden doğru pozitiflerin, yanlış negatiflerin bir fonksiyonu olarak çizilmesiyle ortaya çıkar. Bu eğrinin altında kalan alan ise WEKA'da ROC-Area değeri olarak gösterilir. 1'e yakın olması kurulan modelinin performansının iyi olduğunu göstermektedir [40].


Kurulan tahmin modelinin performansını değerlendirmek için kullanılan diğer ölçütler ise ortalama mutlak hata (OMH) ve hata karelerinin ortalamasının kareköküdür (HKOK). OMH hesaplaması kolay ancak hataları doğrusal olarak hesaplayan bir yöntemdir. HKOK hataların büyüklüğünü de tanımladığı için daha çok tercih edilmektedir [41]. n örnek sayısı, $y - y'$ hata olmak üzere;

$$OMH = \frac{1}{n} \sum_{i=1}^n |y - y'| \quad (3.35)$$

$$HKOK = \sqrt{\frac{1}{n} \sum_{i=1}^n (y - y')^2} \quad (3.36)$$

3.4. WEKA

WEKA, Yeni Zelanda Waikato Üniversitesi tarafından JAVA tabanlı olarak geliştirilen açık kaynak kodlu, veri madenciliği ve makine öğrenmesi paket programıdır [38]. WEKA üzerinde makine öğrenmesi ve istatistik ile ilgili birçok kütüphane hazır olarak gelmektedir. Önizleme panelinde veri seti elle girilir ya da WEKA'ya uygun formatlarda hazırlanmış olan veri seti yüklenilebilir ve panelde bulunan filtreleme seçenekleri ile veri işlenilebilir. Sınıflandırma panelinde ise hazırlanmış verinin hangi yöntemle işleneceği ve bu yönteme ait parametreler seçilir. Seçilen yöntem YSA ya da karar ağaçları yöntemi ise modelin grafiksel gösterimi de sınıflandırma panelinde görüntülenebilir. Bu panelde test verisi ve sağlama işlemleri de yapılabilmektedir. İşlenen veri ile ilgili istatistiksel sonuçlara ve hata oranlarına da bu panelde açılan sonuç sayfasından erişilebilir. Şekil 31'de WEKA programına ait bir ekran görüntüsü verilmiştir. Ek 1'de WEKA'da izlenen adımlar sırasıyla gösterilmiştir.




Şekil 31: Örnek bir WEKA ekran görüntüsü.

4. BULGULAR

Bu çalışmada yapay zeka yöntemlerinden Destek Vektör Makinaları ve Yapay Sinir Ağları yöntemleri kullanılarak tahmin yapılmış ve elde edilen sonuçlar değerlendirilmiştir. Mevcut işletmede olan 6 adet makas motorunun her birine ait 1000'er adet olmak üzere toplam 6000 adet veri toplanmıştır. Her bir veri 7 adet giriş ve bir adet çıkış içermektedir. Her makas için toplanan 1000 adet veriden, 850'si eğitim 150'si test için kullanılmıştır.

YSA için WEKA yazılımı 3.8.2 versiyonu kullanılmıştır. WEKA yazılımında en iyi sonucu elde edebilmek için farklı parametreler kullanılarak bir çok deneme yapılmış ve en uygun değerler belirlenmiştir. Buna göre algoritma olarak YSA 'da sıkça kullanılan "Çok Katmanlı Algılayıcı" tercih edilmiştir [42]. YSA mimarisi tek giriş katmanı, tek gizli katmanda 9 adet sinir hücresi ve bir çıkış katmanından oluşmaktadır. Optimum sonucu veren değerler olarak momentum " $m=0,2$ ", öğrenme oranı " $\eta=0,3$ " seçilerek veriler normalize edilmiş ve 1000 iterasyonlu eğitim yaptırılmıştır. Kurulan YSA modeli Şekil 32'de verilmiştir.



Şekil 32: YSA modeli.

DVM yöntemi uygulaması için WEKA yazılımı 3.8.2 versiyonu kullanılmıştır. En iyi sonucu verecek parametrelerin belirlenmesi için birçok deneme yapılmıştır. Buna göre en iyi performansa sahip DVM parametreleri; karmaşıklık parametresi “ $c=1$ ”, çekirdek fonksiyonu polinom çekirdek (polynomial Kernel) , çekirdeğin üstel değeri “ $e=1$ ” optimum değerler olarak seçilmiş ve veriler normalize edilmiştir.

Tablo 4’de DVM ve YSA yöntemleri ile eldeki verilerin doğru sınıflandırılma yüzdeleri verilmiştir.

Tablo 4: Sınıflandırılan örneklerin doğruluk yüzdeleri.

	DVM		YSA	
Makas	Eğitim	Test	Eğitim	Test
01A	%99.76	%99.13	%99.52	%98.27
01B	%99.41	%97.29	%98.70	%93.69
01C	%99.76	%99.00	%99.52	%95.00
02A	%99.88	%99.04	%95.88	%99.04
02B	%98.35	%99.07	%99.29	%99.07
02C	%98.23	%94.44	%97.88	%97.22

Doğru sınıflandırılan örnek yüzdeleri; 6 makas için elde edilen sonuçların değerlendirildiğinde DVM eğitimde %98.23 ile %99.88, testte %94.44 ile %99.13 arasında değişen değerler elde edilmiştir. YSA eğitimde %95.88 ile %99.52, testte %93.69 ile %99.07 arasında değişen değerler elde edilmiştir. DVM’de başarı oranı YSA’ya göre küçük bir farkla daha yüksek elde edilmiştir.

Tablo 5, 6, 7, 8, 9 ve 10 ‘da her bir makas için TP oranı, FP Oranı, kesinlik, duyarlılık, F-ölçütü ve roc-area değerleri DVM ve YSA yöntemleri ile eğitim ve testte elde edilen sonuçlar verilmiştir.

Tablo 5: 01A makası için sınıflandırma başarı ölçütleri.

01A	TP Oranı	FP Oranı	Kesinlik	Duyarlılık	F-Ölçütü	Roc-Area
DVM Eğitim	0.998	0.002	0.998	0.998	0.998	0.999
DVM Test	0.991	0.001	0.992	0.991	0.991	0.999
YSA Eğitim	0.995	0.005	0.993	0.995	0.996	1.000
YSA Test	0.983	0.030	0.996	0.983	0.998	1.000

Tablo 6: 01B makası için sınıflandırma başarı ölçütleri.

01B	TP Oranı	FP Oranı	Kesinlik	Duyarlılık	F-Ölçütü	Roc-Area
DVM Eğitim	0.994	0.006	0.995	0.994	0.994	0.999
DVM Test	0.973	0.001	0.985	0.973	0.977	0.992
YSA Eğitim	0.987	0.024	0.979	0.987	0.961	0.999
YSA Test	0.937	0.033	0.961	0.937	0.952	0.988

Tablo 7: 01C makası için sınıflandırma başarı ölçütleri.

01C	TP Oranı	FP Oranı	Kesinlik	Duyarlılık	F-Ölçütü	Roc-Area
DVM Eğitim	0.998	0.002	0.998	0.998	0.998	1.000
DVM Test	0.990	0.001	1.000	0.990	0.995	0.998
YSA Eğitim	0.995	0.007	0.999	0.995	0.999	1.000
YSA Test	0.950	0.071	0.882	0.950	0.994	0.997

Tablo 8: 02A makası için sınıflandırma başarı ölçütleri.

02A	TP Oranı	FP Oranı	Kesinlik	Duyarlılık	F-Ölçütü	Roc-Area
DVM Eğitim	0.999	0.000	0.999	0.999	0.999	1.000
DVM Test	0.990	0.001	0.991	0.990	0.991	0.996
YSA Eğitim	0.959	0.003	0.985	0.959	0.968	0.973
YSA Test	0.990	0.001	0.991	0.990	0.991	0.995

Tablo 9: 02B makası için sınıflandırma başarı ölçütleri.

02B	TP Oranı	FP Oranı	Kesinlik	Duyarlılık	F-Ölçütü	Roc-Area
DVM Eğitim	0.984	0.001	0.986	0.984	0.984	0.998
DVM Test	0.991	0.016	0.991	0.991	0.991	0.987
YSA Eğitim	0.993	0.011	0.998	0.993	0.999	1.000
YSA Test	0.991	0.016	0.991	0.991	0.991	0.995

Tablo 10: 02C makası için sınıflandırma başarı ölçütleri.

02C	TP Oranı	FP Oranı	Kesinlik	Duyarlılık	F-Ölçütü	Roc-Area
DVM Eğitim	0.982	0.024	0.996	0.982	0.880	0.990
DVM Test	0.944	0.054	0.969	0.944	0.931	0.979
YSA Eğitim	0.979	0.030	0.997	0.979	0.900	0.998
YSA Test	0.972	0.032	0.994	0.972	0.992	0.993

Sınıflandırılan verilerin başarı ölçütlerini gösteren parametreler her bir makas için yukarıdaki tablolarda verilmiştir. Buna göre 1'e yaklaştıkça başarılı sayılan TP oranı değeri her iki yöntemde de tüm makaslar için 1'e yakın hesaplanmıştır. 0'a yaklaştıkça başarılı sayılan FP oranı değeri her iki yöntemde 0'a yakın hesaplanmış ancak DVM yönteminde çok küçük bir farkla 0'a daha yakın değerler hesaplanmıştır. 1'e yaklaştıkça başarılı sayılan kesinlik değeri her iki yöntemde 1'e yakın olarak hesaplanmış ancak DVM testte hesaplanan değer YSA teste göre 1'e daha yakın olarak hesaplanmıştır. Duyarlılık ölçütü her iki yöntemde birbirine benzer ve 1'e yakın değerler hesaplanmıştır. F-ölçütü ve Roc-area değerleride birbirine benzer ve 1'e yakın değerler olarak hesaplanmıştır. Tablo 5, 6, 7, 8, 9 ve 10'daki veriler göz önünde bulundurulduğunda YSA ve DVM yöntemleriyle hesaplanan değerlerin birbirine çok yakın olduğu ve başarılı sonuçlar elde edildiği görülmektedir.

Tablo 11'de her bir makas için YSA yöntemi ile eğitim ve test verileri ile yapılan tahminden elde edilen determinasyon katsayısı, OMH ve HKOK değerleri verilmiştir.

Tablo 11: DVM için tahmin sonuçları.

Makas	Eğitim			Test		
	R^2_{adj}	OMH	HKOK	R^2_{adj}	OMH	HKOK
01A	0.9951	0.1311	0.2479	0.9954	0.1305	0.2479
01B	0.9807	0.1302	0.2475	0.9535	0.1303	0.2468
01C	0.9961	0.1389	0.2554	0.9826	0.1389	0.2556
02A	0.9973	0.1324	0.2468	0.9837	0.1315	0.2478
02B	0.9728	0.1322	0.2470	0.9838	0.1312	0.2464
02C	0.9707	0.1337	0.2478	0.9152	0.1301	0.2481

Tablo 11’de verilen sonuçları değerlendirecek olursak, R^2 düzeyinde bir karşılaştırma yapıldığında DVM için eğitimde; 0.9707 ile 0.9973, test için 0.9152 ile 0.9954 arasında değişen değerler elde edilmiştir. Eğitim ve testte elde edilen R^2 değerleri 1’e oldukça yakındır. Bu durum kurulan modelin R^2 ölçütüne göre başarılı olduğunu göstermektedir.

OMH kriterine göre DVM sonuçlarını değerlendirildiğinde eğitim ve test için 0.1302 ile 0.1389 arasında değişen değerler elde edilmiştir. Hesaplanan OMH değerleri 0’a yakın elde edilse de, YSA ile yapılan tahminlerde daha başarılı sonuçlar elde edilmiştir.

DVM yöntemi için, HKOK bazında değerlendirme yapıldığında eğitim için 0.2468 ile 0.2554, test için 0.2464 ile 0.2556 arasında değişen değerler elde edilmiştir. 0’a yaklaştıkça başarı oranı yüksek kabul edilen HKOK için bu değerler yüksek sayılabilir.

Tablo 12’de her bir makas için YSA yöntemi ile eğitim ve test verileri ile yapılan tahminden elde edilen determinasyon katsayısı, OMH ve HKOK değerleri verilmiştir.

Tablo 12: YSA için tahmin sonuçları.


Makas	Eğitim			Test		
	R^2_{adj}	OMH	HKOK	R^2_{adj}	OMH	HKOK
01A	0.9910	0.0048	0.0225	0.9693	0.0068	0.0369
01B	0.9568	0.0036	0.0352	0.8895	0.0113	0.0786
01C	0.9921	0.0039	0.0289	0.9091	0.0120	0.0869
02A	0.9108	0.0085	0.0687	0.9837	0.0048	0.0393
02B	0.9881	0.0037	0.0208	0.9838	0.0051	0.0392
02C	0.9647	0.0068	0.0440	0.9582	0.0082	0.0565

Tablo 12’de verilen sonuçları değerlendirecek olursak, R^2 düzeyinde karşılaştırma yapıldığında, eğitimde 0.9108 ile 0.9921 arasında, testte 0.8895 ile 0.9838 arasında değişen değerler elde edilmiştir. Her iki değer de 1’e oldukça yakındır, bu da oluşturulan modelin R^2 bazında başarılı sonuçlar verdiğini göstermektedir.

YSA sonuçları OMH değerlerine göre karşılaştırıldığında, eğitimde 0.0036 ile 0.0085 testte ise 0.0048 ile 0.0113 arasında değişen değerler elde edilmiştir. Her iki değer de 0’a çok yakın olduğundan OMH bazında başarılı sonuçlar elde edilmiştir.

HKOK’a göre YSA sonuçları değerlendirildiğinde eğitimde 0.008 ile 0.0687, testte ise 0.0369 ile 0.0869 arasında değişen değerler elde edilmiştir. HKOK sonuçları, hem eğitim hem test verileri için 0’a çok yakın değerler hesaplanmıştır.

Oluşturulan modelin daha önceden görmediği veriler üzerinde nasıl performans gösterdiğini anlamak için veriler eğitim ve test verileri olarak ayrılırlar. Yukarıda elde edilen sonuçlar, verilerin 850’si eğitim 150’si test için kullanılması sonucu elde edilmiştir. Ancak eğitim ve test aşamasında dağılımdan kaynaklı bazı hatalar oluşabilir. Bu hataları minimize etmek için k katlamalı çapraz doğrulama metodu uygulanır [43]. Bu yöntemde veri seti k eşit parçaya bölünür, k-1’lik parça eğitim için geriye kalan kısım ise test için kullanılır. Bu işlem k defa, her seferinde farklı bir parça test için kullanılmak üzere tekrarlanır ve her seferde hesaplanan sistem başarısı ve hataları toplanarak ortalaması alınır. Böylece modelin başarısı daha doğru şekilde hesaplanır. Literatürde genelde 10 katlamalı çapraz doğrulama metodu kullanılmaktadır [44].



Şekil 33: K-katlamalı çapraz doğrulama [45].

Bu çalışmada eğitim ve test için kullanılan her makas için toplam 1000 adet veri birleştirilmiş ve 10 katlamalı çapraz doğrulama yöntemi uygulanmıştır. Elde edilen sonuçlar aşağıdaki tablolarda verilmiştir.

6 makas için eğitim ve test verileri birleştirilerek elde edilen 1000'er adet veri, 10 katmanlı çapraz doğrulama ile DVM ve YSA yöntemi kullanılarak sınıflandırılmıştır. Elde edilen doğru sınıflandırılan veri yüzdeleri Tablo 13'de verilmiştir.

Tablo 13: Çapraz Doğrulama ile Sınıflandırılan verilerin doğruluk yüzdeleri.

Makas	DVM	YSA
01A	%99.50	%99.20
01B	%99.20	%98.60
01C	%99.60	%98.00
02A	%99.80	%96.40
02B	%98.40	%98.30
02C	%97.90	%97.70

Çapraz doğrulama ile yapılan hesaplamalarda doğru sınıflandırılan örnek oranı DVM'de %97.90 ile %99.80 arasında değişen değerler, YSA'da ise %96.40 ile %99.20 olarak değişen değerler hesaplanmıştır. Her iki yöntemle hesaplanan ve doğru sınıflandırılan örnek sayısı oldukça yüksektir. Bu durum sınıflandırmanın başarıyla gerçekleştirildiğini göstermektedir.

Tablo 14’de her bir makas için çapraz doğrulama yöntemi ile yapılan sınıflandırmalara ait, TP oranı, FP oranı, kesinlik, duyarlılık, F-ölçütü ve roc-area değerlerine ait elde edilen sonuçlar verilmiştir.

Tablo 14: Çapraz doğrulama ile sınıflandırılan örneklerin başarı ölçütleri.

Makas/Yöntem		TP Oranı	FP Oranı	Kesinlik	Duyarlılık	F-Ölçütü	Roc Area
01A	DVM	0.995	0.002	0.995	0.995	0.995	0.998
	YSA	0.992	0.008	0.985	0.992	0.988	1.000
01B	DVM	0.992	0.000	0.993	0.992	0.992	0.999
	YSA	0.986	0.023	0.970	0.986	0.963	0.999
01C	DVM	0.996	0.000	0.995	0.996	0.997	0.998
	YSA	0.980	0.008	0.940	0.980	0.893	0.991
02A	DVM	0.998	0.000	0.998	0.998	0.998	0.999
	YSA	0.964	0.001	0.984	0.964	0.971	0.977
02B	DVM	0.984	0.003	0.986	0.984	0.984	0.997
	YSA	0.983	0.011	0.960	0.983	0.905	0.997
02C	DVM	0.979	0.027	0.993	0.979	0.960	0.988
	YSA	0.977	0.030	0.978	0.977	0.972	0.992

Tablo 14’de verilen kriterlere göre modelin performansı değerlendirildiğinde; TP oranı, kesinlik, duyarlılık, F-ölçütü ve Roc-area değerleri her iki yöntemde 1’e yakın FP oranı değeri ise 0’a yakın olarak hesaplanmıştır. Bu kriterlere göre her iki modelde elde edilen sonuçlar başarılıdır.

Tablo 15’de her bir makas için çapraz doğrulama yöntemi ile yapılan sınıflandırmalara ait R^2 , OMH ve HKOK değerleri verilmiştir.

Tablo 15: Çapraz doğrulama ile hesaplanan tahmin sonuçları.

	DVM			YSA		
Makas	R²_{adj}	OMH	HKOK	R²_{adj}	OMH	HKOK
01A	0.9906	0.1302	0.2470	0.9849	0.0034	0.0239
01B	0.9781	0.1306	0.2477	0.9613	0.0040	0.0353
01C	0.9934	0.1298	0.2480	0.9669	0.0049	0.0442
02A	0.9957	0.1303	0.2478	0.9271	0.0080	0.0666
02B	0.9741	0.1312	0.2475	0.9719	0.0055	0.0434
02C	0.9656	0.1316	0.2468	0.9622	0.0066	0.0509

Tablo 15’de verilen sonuçları değerlendirecek olursak, R^2 ölçütüne göre sistem performansı incelendiğinde ; DVM’de 0.9656 ile 0.9957 arasında değişen değerler, YSA’da 0.9271 ile 0.9849 arasında değişen değerler elde edilmiştir. Bu değerler tüm sonuçlar için 1’e yakın ve başarılıdır. DVM’de elde edilen değerler YSA’ya göre göre küçük bir farkla daha yüksektir.

OMH kriterine göre ; DVM’de 0.1298 ile 0.1316 arasında değişen , YSA’da 0.0034 ile 0.0080 arasında değişen değerler elde edilmiştir. 0’a yaklaştıkça başarı oranı artan OMH kriteri için YSA’da elde edilen değerler DVM’ye göre oldukça düşük ve 0’a daha yakın olarak hesaplanmıştır.

HKOK kriterine göre ; DVM’de 0.2477 ile 0.2480 arasında değişen değerler, YSA’da 0.0239 ile 0.0666 arasında değişen değerler elde edilmiştir. DVM ve YSA’da elde edilen değerler karşılaştırıldığında, YSA’da hesaplanan değerler DVM’ye göre çok daha düşük ve 0’a çok daha yakın olarak hesaplanmıştır.

5. TARTIŞMA VE SONUÇ

Demiryolları işletmesinin sürekliliği ve güvenliği açısından makaslar büyük önem taşımaktadır. Bu çalışmada demiryolu makas arızalarının çözüm sürelerini kısaltmak ve arızaların işletmeyi etkileyecek boyuta ulaşmadan çözülmesi amacıyla bölüm 2.1’ de belirtilen model ile arıza tahmin çalışması yapılmış ve sonuçları değerlendirilmiştir.

Tahmin çalışması için yapay zeka yöntemlerinden “Yapay Sinir Ağları” ve “ Destek Vektör Makinaları” yöntemleri kullanılmış, her iki yöntemden elde edilen sonuçlar karşılaştırılmıştır.

Tablo 4 ‘de DVM ve YSA yöntemleri kullanılarak yapılan sınıflandırma sonucu elde edilen doğru sınıflandırma yüzdeleri verilmiştir. Her iki yöntemde elde edilen sonuçlar birbirine benzer ve çok yüksektir. 6 makastan 5 tanesinde elde edilen doğru sınıflandırma yüzdesi birbirine çok yakinken, yalnızca 02A makasına ait verilerin sınıflandırmasında DVM yöntemi YSA’ya göre % 4.00 lık bir farkla daha iyi sonuç vermiştir.

Tablo 5, 6, 7, 8, 9 ve 10’da verilen sınıflandırma başarı ölçütlerine göre DVM ve YSA’da elde edilen değerler birbirine yakın hesaplanmış ve hesaplanan değerler sınıflandırmanın her iki yöntem ile başarılı bir şekilde yapıldığını göstermektedir.

Sonuçlar tablo 11 ve tablo 12 ‘ye göre karşılaştırıldığında R^2 için her iki yöntemde eğitim ve test aşamasında birbirine çok yakın ve başarılı sonuçlar elde edilmiştir. Ancak ortalama mutlak hata (OMH) ve hata karelerinin ortalamasının karekökü (HKOK) değerleri karşılaştırıldığında YSA’da DVM’ye göre çok daha başarılı sonuçlar elde edilmiştir. OMH ve HKOK dışındaki diğer performans değerlendirme ölçütleri her iki yöntemde benzer şekilde elde edilmiştir. Ancak OMH ve HKOK değerleri göz önünde bulundurulduğunda YSA’nın kurulan tahmin modeli için yüksek bir farkla daha başarılı sonuçlar verdiği görülmektedir.

Kurulan modelin performansını daha doğru sonuçlarla değerlendirebilmek için, 10 adımlı çapraz doğrulama yöntemi tüm veri seti için uygulanmıştır. Burada elde edilen sonuçlar, eğitim ve test için elde edilen değerlere benzer elde edilmiştir. Çapraz doğrulama yöntemi ile elde edilen sonuçlara göre, doğru sınıflandırılan örnek yüzdeleri için DVM ve YSA’da yaklaşık %99.00 civarında yüksek başarı elde edilmiştir. Tablo 14’de verilen sonuçlara göre

YSA ve DVM’de birbirine yakın ve başarılı sonuçlar elde edilmiştir. Tablo 15’de verilen sonuçlara göre, determinasyon katsayısı her iki yöntemde 1’e yakın hesaplanmıştır. OMH ve HKOK ise DVM yönteminde yüksek hesaplanmış, YSA yöntemi ise 0’a çok yakın ve daha başarılı sonuçlar vermiştir.

Yapılan değerlendirmelere göre çapraz doğrulama yapılarak elde edilen model performansı sonuçları, eğitim-test aşamasında elde edilen sonuçlara çok yakın elde edilmiştir. Bu sonuçlara göre OMH ve HKOK değerlerinin çok daha düşük hesaplanması nedeniyle kurulan arıza tahmin modelinin uygulamasında yapay sinir ağı yönteminin kullanılması daha başarılı sonuçlar verecektir.

Yapay zekâ yöntemlerinin her ikisinde de yüksek başarı elde edilmesi, modelin sektör tecrübesi ve doğru bir yaklaşımla oluşturulduğunu göstermektedir. Kurulan modelin başarısı göz önünde bulundurulduğunda, sisteme verilen girdiler değişse bile sistem, çıktıları doğru şekilde belirleyerek arızalarla ilgili doğru tahminde bulunacaktır. Bu sayede demiryolu makas arızalarının önüne geçilecek, oluşan arızaların çözüm süresi kısılacak, plansız tren duruşlarının önüne geçilecek ve demiryolu trafiğinin sürekliliği sağlanacaktır.

İleride yukarıda anlatılan çalışmanın bir adım öteye götürülerek sektörde aktif olarak önleyici bakım faaliyetlerinde kullanılabilecek bir ara yüz yazılımı oluşturulması ve arıza operatörleri için bir karar destek modeli olarak kullanılması planlanmaktadır.

KAYNAKLAR

- [1]. Maciel, L.S. and Ballini, R., 2008, Design A Neural Networks for Time Series Financial Forecasting: Accuracy and Robustness Analysis, *Journal of the Brazilian Neural Network Society*, 8 (1), 3-22.
- [2]. Budak, H. ve Erpolat, S., 2012, Kredi Riski Tahmininde Yapay Sinir Ağları ve Lojistik Regresyon Analizi Karşılaştırılması, *Online Academic Journal of Information Technology*, 3 (9), 23-30.
- [3]. Demirhan, A., Kılıç, Y.A., Güler, İ., 2010, Tıpta Yapay Zeka Uygulamaları, *Yoğun Bakım Dergisi*, 2010 Ankara, 9 (1), 31-41.
- [4]. Serhatlıoğlu, S. ve Hardalaç, F., 2009, Yapay Zeka Teknikleri ve Radyolojiye Uygulanması, *Fırat Tıp Dergisi*, 14 (1), 1-6.
- [5]. Aşkın, D., İskender, İ., Mamızadeh, A., 2011, Farklı Yapay Sinir Ağları Yöntemleri Kullanarak Kuru Tip Transformör Sargısının Termal Analizi, *Gazi Üniversitesi Müh. Mim. Fak. Dergisi*, 26 (4), 905-913.
- [6]. Yaghini, M., Khoshraftar, M., Seyedabadi, M., 2013, Railway Passenger Train Delay Prediction via Neural Network Model, *Journal of Advanced Transportation*, 47 (3), 355-368.
- [7]. Aravindh, P., Devakumaran, R., Gobikannan, S., Rajesh Kumar, S., 2017, Railway Track Circuits Fault Diagnosis Using Recurrent Neural Networks, *International Journal of Innovative Research in Science, Engineering and Technology*, 6 (3), 100-104.
- [8]. Shu, J. and Zhang, Z., 2012, *Damage Detection on Railway Bridges Using Artificial Neural Network and Train-Induced Vibrations*, Thesis (Master), Royal Institute of Technology.
- [9]. Topçu, N., 2016, *Demiryollarında Emniyete Etki Eden Faktörler*, Yüksek Lisans Tezi, İstanbul Üniversitesi.
- [10]. Sun, S. and Zhao, H., Fault Diagnosis in Railway Track Circuits Using Support Vector Machines, *Machine Learning Applications (ICMLA)*, 12th International Conference on, 4-7 December 2013 Miami, IEEE, ISBN: 978-0-7695-5144-9.
- [11]. Eker, O.F., Camcı, F., Kumar, U., 2012, SVM Based Diagnostics on Railway Turnouts, *International Journal of Performability Engineering*, 8 (3), 289-298.
- [12]. Sandesh Nair, E., 2016, *Predictive Maintenance in a Railway Scenario using One-Class Support Vector Machines*, Thesis (Master), Technische Universität Darmstadt.


- [13]. Bhaduri, S., 2013, *Algorithm to Enable Intelligent Rail Break Detection*, Thesis(Master), Virginia Polytechnic Institute and State University.
- [14]. Babacan,V.K.,2011, *Raylı Sistemlerde Sinyalizasyon Tekniğine Giriş*, TCDD, İstanbul.
- [15]. M.E.B, 2013,*Raylı Sistemler Tenolojisi-Makas Kontrol Sistemleri*, MEB, Ankara.
- [16]. Bellek, M., 2013, *Design and RAMS Analysis of Railway Interlocking Systems Using Formal Methods*, Thesis (Master), İstanbul Technical University.
- [17]. Lichtberger, B., 2011, *Demiryolu Cep Kitabı*, DVV Media Group, Hamburg.
- [18]. Sağiroğlu, Ş., Beşdok, E., Erler, M., 2003, *Mühendislikte Yapay Zeka Uygulamaları -I: Yapay Sinir Ağları*, Ufuk Yayıncılık, Kayseri.
- [19]. Nilsson, N.J,2009, *The Quest of Artificial Intellegence*, Cambridge University Press,Cambridge.
- [20]. Kurzweill, R, 1990, *The Age of Intelligent Machines*, MIT Press, London.
- [21]. Borgelt, C., Kruse R., 2006, Algorithms and Software in CIGR Handbook of Agricultural Engineering, *International Commission of Agricultural Engineering*,6 (1), 153-168.
- [22]. Şen, Z., 2004, *Yapay Sinir Ağları İlkeleri*, Su Vakfı Yayınları, İstanbul.
- [23]. Fausset, L., 1994, *Fundamentals of Neural Networks*, Prentice Hall,USA.
- [24]. Çuhadar, M. , 2006, *Turizm Sektöründe Talep Tahmini için Yapay Sinir Ağları Kullanımı ve Diğer Yöntemlerle Karşılaştırmalı Analizi*, Tez (Doktora), Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalı.
- [25]. Çayıroğlu, İ., 2015, *İleri Algoritma Analizi-5 Yapay Sinir Ağları*, <http://www.ibrahimcayiroglu.com/Dokumanlar/IleriAlgoritmaAnalizi/IleriAlgoritmaAnalizi5.HaftaYapaySinirAglari.pdf> , [Ziyaret Tarihi: 20.03.2018].
- [26]. Topçu, N., 2016, *Demiryollarında Emniyete Etki Eden Faktörler*, Tez (Yüksek Lisans), İstanbul Üniversitesi.
- [27]. Kavazoğlu, T. ve Çölkesen, İ. , 2010, Destek Vektör Makineleri ile Uydu Görüntülerinin Sınıflandırılmasında Kernel Fonksiyonlarının Etkilerinin İncelenmesi, *Gebze Yüksek Teknoloji Enstitüsü Harita Dergisi*, Sayı 144,74-82.

- [28]. Vapnik, V.N., 2000, *The Nature of Statistical Learning Theory*, Springer-Verlag, New York, ISBN:978-1-4757-3264-1.
- [29]. Güran, A. ve diğerleri, 2014, Destek Vektör Makinaları Parametre Optimizasyonunun Duygu Analizi Üzerinde Etkisi, *Dokuz Eylül Üniversitesi Mühendislik Bilimleri Dergisi*, 16 (48), 86-93.
- [30]. Kalkan, A. T., 2012, *Kısa Biyodizlimlerin Sınıflandırılması*, Tez (Yüksek Lisans), Başkent Üniversitesi.
- [31]. Karush, W., 1939, *Minima of Functions of Several Variables with Inequalities As Side Constraints*, Thesis (Master), University of Chicago Department of Mathematics
- [32]. Khun, H. W. ve Tucker, A. W., 1951, Nonlinear Programming, *In Proc. 2nd Berkeley Symposium on Mathematical Statistics and Probabilities*, 12 August 1950 Berkeley, University of California Press, 481-492.
- [33]. Boser, B. E., Guyon, I. M. ve Vapnik, V. N., 1992, A training algorithm for optimal margin classifiers, *In Fifth Annual Workshop on Computational learning Theory*, 22-27 July 1992 Pennsylvania , New York, ACM, ISBN: 0-89791-497-X, 144-152.
- [34]. Fang, Q., 2012, *Data Mining on Communication for Identifying Terrorists: A Case Study*, Thesis (Master), The Pennsylvania State University.
- [35]. Schölkopf, B., Simard, P., Smola, A. J. ve Vapnik, V., 1998, Prior Knowledge in Support Vector Kernels, *Advances in Neural Information Processing Systems 10*, MIT Press, Cambridge, ISBN: 0-262-10076-2.
- [36]. Şeker, E.S., 2008, *Çok Sınıflı Destek Vektör Makinaları*, <http://bilgisayarkavramlari.sadievrenseker.com/2008/12/01/cok-sinifli-dvm-multiclass-svm> , [Ziyaret Tarihi: 23.03.2018].
- [37]. Aisen, B., 2006, *A Comparison of Multiclass SVM Methods*, Massachusetts Institute of Technology, Lacture Notes.
- [38]. Şeker, E. S. , 2009, *WEKA*, <http://bilgisayarkavramlari.sadievrenseker.com/2009/06/01/weka/> [Ziyaret Tarihi: 24.03.2018].



- [39]. Shaban, N., 2005, Analysis of The Correlation and Regression Coefficients of The Interaction Between Yield and Some Parameters of Snap Beans Plants, *Trakia Journal of Sciences*, 3 (6), 27-31.
- [40]. Kaya, T., 2015, *Makine Öğrenme Yöntemleriyle Trafik Kazaları İçin Risk Tahmini Yapabilen Web Tabanlı Bir Yazılım*, Tez (Yüksek Lisans), Gazi Üniversitesi.
- [41]. Saatçioğlu, D. Ve Özçakar, N., 2016, Yapay Sinir Ağları ile Aralıklı Talep Tahmini, *Beykoz Akademi Dergisi*, 4(1), 1-25.
- [42]. Öztemel, E., 2003, *Yapay Sinir Ağları*, Papatya Yayınları, İstanbul.
- [43]. Bergmeir, C., J.Hyndman, R., Koo, B., 2017, A Note on the Validity of Cross-Validation for Evaluating Autoregressive Time Series Prediction, *Computational Statistics and Data Analysis*, 120, 70-83.
- [44]. Clarke, B., Fokoue, E., & Zhang, H. H., 2009, *Principles and Theory for Data Mining and Machine Learning*, Springer, Berlin, ISBN: 978-0-387-98134-5.
- [45]. Buhagiar, J., 2017, *Automatic Segmentation of Indoor and Outdoor Scenes from Visual Lifelogging*, Thesis (Master), ICT University.



EKLER

EK 1. WEKA KULLANIMI





EK 1. (devam):



EK 1. (devam):

EK 1. (devam):



ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı	Burak ARSLAN
Doğum Yeri	Hafik/SİVAS
Doğum Tarihi	24.12.1989
Uyruğu	☒ T.C. ☐ Diğer:
Telefon	+90 5343654113
E-Posta Adresi	barslan346@hotmail.com
Web Adresi	

Eğitim Bilgileri	
Lisans	
Üniversite	Zonguldak Karaelmas Üniversitesi
Fakülte	Mühendislik Fakültesi
Bölümü	Elektrik Elektronik Mühendisliği
Mezuniyet Yılı	15.06.2012

Yüksek Lisans	
Üniversite	İstanbul Üniversitesi
Enstitü Adı	Fen Bilimleri Enstitüsü
Anabilim Dalı	Elektrik Elektronik Mühendisliği
Programı	Elektrik Elektronik Mühendisliği