

T.C.
BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**OTOMATİK ÜRETİM TEKNOLOJİSİNE UYGUN BETONLARIN BASINÇ
DAYANIMLARININ MAKİNE ÖĞRENMESİ VE DERİN ÖĞRENME
YÖNTEMLERİ İLE TAHMİN EDİLMESİ**

YÜKSEK LİSANS TEZİ

HÜSEYİN KAYHAN

TEZ DANIŞMANI

DR. ÖĞR. ÜYESİ NİHAN KAZAK ÇERÇEVİK

İKİNCİ TEZ DANIŞMANI

DR. ÖĞR. ÜYESİ ALİ ERDEM ÇERÇEVİK

BİLECİK, 2022

10481708

T.C.
BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**OTOMATİK ÜRETİM TEKNOLOJİSİNE UYGUN BETONLARIN BASINÇ
DAYANIMLARININ MAKİNE ÖĞRENMESİ VE DERİN ÖĞRENME
YÖNTEMLERİ İLE TAHMİN EDİLMESİ**

YÜKSEK LİSANS TEZİ

HÜSEYİN KAYHAN

TEZ DANIŞMANI

DR. ÖĞR. ÜYESİ NİHAN KAZAK ÇERÇEVİK

İKİNCİ TEZ DANIŞMANI

DR. ÖĞR. ÜYESİ ALİ ERDEM ÇERÇEVİK

BİLECİK, 2022

10481708

BEYAN

“Otomatik Üretim Teknolojisine Uygun Betonların Basınç Dayanımlarının Makine Öğrenmesi ve Derin Öğrenme Yöntemleri İle Tahmin Edilmesi” adlı yüksek lisans tezi hazırlık ve yazımı sırasında bilimsel araştırma ve etik kurallarına uyduğumu, başkalarının eserlerinden yararlandığım bölümlerde bilimsel kurallara uygun olarak atıfta bulunduğumu, kullandığım verilerde herhangi bir tahrifat yapmadığımı, tezin herhangi bir kısmının Bilecik Şeyh Edebali Üniversitesi veya başka bir üniversitede başka bir tez çalışması olarak sunulmadığını, aksinin tespit edileceği muhtemel durumlarda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Bu çalışmanın, Bilimsel Araştırma Projeleri (BAP), TÜBİTAK veya benzeri kuruluşlarca desteklenmesi durumunda; projenin ve destekleyen kurumun adı proje numarası ile birlikte, ETİK KURUL onayı alınması durumunda ise ETİK KURUL tarih karar ve sayı bilgilerinin beyan edilmesi gerekmektedir.			
DESTEK ALINMIŞTIR		DESTEK ALINMAMIŞTIR	☒
Destek alındı ise;			
Destekleyen kurum;			
Desteğin Türü		Proje Numarası	
1- BAP (Bilimsel Araştırma Projesi)			
2- TÜBİTAK			
Diğer;.....			
ETİK KURUL onayı var ise;			
ETİK KURUL karar tarih/sayı:		/.....	

Hüseyin Kayhan

Tarih

.....

İmza

.....

ÖN SÖZ

Bu tez çalışmasının her adımında, çalışmamı sahiplenerek takip eden, ufkumu açan danışmanım Sayın Dr. Öğr. Üyesi Nihan Kazak Çerçevik'e değerli katkı ve emekleri için teşekkürlerimi ve saygılarımı sunarım.

Tez çalışmasının hazırlanması ve tamamlanmasında büyük emekleri olan eş danışmanım Sayın Dr. Öğr. Üyesi Ali Erdem Çerçevik'e teşekkürlerimi sunarım.

Tez çalışmasında kullanılan verilerin hazırlanmasında emeği geçen Bilecik Şeyh Edebali Üniversitesi İnşaat Mühendisliği öğrencilerinden Sayın Hicrani Daştan, Sayın Ömer Sayan ve sayın Nisa Köse'ye teşekkürlerimi sunarım.

Son olarak tez çalışmam boyunca koşulsuz olarak beni destekleyen eşime ve kızıma en içten teşekkürlerimi sunarım.

Hüseyin Kayhan

2022

ÖZET

ÖĞRENME YÖNETİM SİSTEMİ HAREKETLERİ TAKİP EDİLEREK BAŞARI NOTUNUN TAHMİNİ

Gelişen teknoloji ile yaygınlaşan otomatik yapı üretim teknolojisi sayesinde hızlı ve sağlam yapılar elde edilebilmektedir. Otomatik yapı üretim teknolojisi, tasarlanan yapı modelinin bilgisayarlar ile parçalanması, parçalanmış modellerin beton harçlar kullanılarak katmanlar şeklinde üretilmesi prensibine dayanır. Betonun önemli mekanik özelliklerinin başında gelen basınç dayanımı önemli bir araştırma konusudur. Betonun basınç dayanımının ölçülmesinde kullanılmakta olan yöntemler tahribatlı ve tahribatsız olmak üzere iki ana başlık altında incelenebilir. Bu tez kapsamında, otomatik yapı üretim teknolojisine uygun betonların basınç dayanımlarını tahmin etmek amacıyla tahribatsız yöntemlere yeni bir yaklaşım önerilmektedir.

Yapılan çalışmada otomatik yapı üretim teknolojisine uygun 24 farklı karışım oranına sahip 192 adet küp beton numunesi üretilmiştir. Karışım oranlarında değişken olarak agrega dane çapı, çimento oranı ve lif kullanılmıştır. Üretilen beton numunelerinin görüntü işleme yöntemleri ile basınç dayanımlarını tahmin etmek için görüntüleri alınmıştır. Görüntüleme işleminden sonra betonların gerçek basınç dayanım sonuçlarını elde edebilmek için basınç dayanımlarına bakılarak tahmin ve gerçek değerler karşılaştırmalı olarak sunulmuştur.

Beton görüntülerinin dokusal ve renksel bilgilerini elde etmek amacıyla Gri Seviye Eş Oluşum Matrisi ve Histogram teknikleri kullanılarak öznelilikleri çıkartılmıştır. Oluşturulan öznelilikler makine öğrenmesi algoritmalarından K En Yakın Komşu (KNN) ve Destek Vektör Makineleri (DVM) ile, ayrıca geliştirilen derin öğrenme ağ modeli ile test edilmiştir.

Yapılan çalışmalar sonucunda, makine öğrenmesi yöntemlerinden KNN algoritması ve DVM algoritmasının doğruluk oranları sırasıyla %88,44 ve %88,19 olarak gözlemlenmiştir. Otomatik üretim teknolojisiye uygun betonların basınç dayanımları önerilen derin öğrenme algoritmasıyla %90,12 oranıyla en yüksek tahmin başarımına ulaşmıştır.

Anahtar Kelimeler: Derin Öğrenme, KNN, DVM, Tahribatsız Basınç Dayanımı, 3B Beton.

ABSTRACT

PRODUCTION OF STUDENT SUCCESS GRADE BY FOLLOWING THE LEARNING MANAGEMENT SYSTEM MOVEMENTS

Due to the automatic building production technology, which has become widespread with the developing technology, fast and robust structures can be obtained. Automatic building production technology is based on the principle of breaking down the designed building model with computers and producing the disintegrated models in layers using concrete mortars. Compressive strength, which is one of the most important mechanical properties of concrete, is an important research topic. The methods used to measure the compressive strength of concrete can be examined under two main headings as destructive and non-destructive. Within the scope of this thesis, a new approach to non-destructive methods is proposed in order to estimate the compressive strength of concretes suitable for automated building production technology.

In the thesis study, 192 cube concrete samples with 24 different mixing ratios were produced in accordance with automatic construction production technology.

In this study, 192 cube concrete samples with 24 different mixing ratios in accordance with automatic construction production technology were produced. Aggregate particle diameter, cement ratio and fiber were used as variables in mixing ratios. Images were taken to estimate the compressive strength of the produced concrete samples with image processing methods. After the imaging process, the estimation and actual values are presented comparatively by looking at the compressive strengths in order to obtain the actual compressive strength results of concretes.

In order to obtain textural and color information of concrete images, their features were extracted using Gray Level Co-occurrence Matrix and Histogram techniques. The created features were tested with the machine learning algorithms K Nearest Neighbor (KNN) and Support Vector Machines (DVM) and also with the developed deep learning network model.

As a result of the studies, the accuracy rates of the KNN algorithm and SVM algorithm, which are among the machine learning methods, were observed as 88.44% and 88.19%, respectively. The compressive strength of concretes suitable for automatic production technology reached the highest estimation rate of 90.12% with the proposed deep learning algorithm.

Keywords: Deep Learning, KNN, SVM, Nondestructive Compressive Strength, Counter Crafting.

İÇİNDEKİLER

Sayfa No

ÖN SÖZ.....	i
ÖZET.....	ii
ABSTRACT	iii
İÇİNDEKİLER.....	iv
TABLolar LİSTESİ.....	vi
ŞEKİLLER LİSTESİ.....	vii
GRAFİKLER LİSTESİ	viii
KISALTMALAR VE SİMGELER LİSTESİ	ix
1. GİRİŞ.....	1
2. LİTERATÜR TARAMASI	3
2.1. Makine Öğrenmesi	3
2.2. Derin Öğrenme	5
2.3. Beton Basınç Dayanımı	7
3. MATERYALVEYÖNTEM.....	10
3.1. Öznitelik Çıkarımı.....	10
3.1.1. GLCM.....	10
3.1.2. Histogram.....	12
3.2. Makine Öğrenmesi	14
3.2.1. K En Yakın Komşuluk (KNN)	16
3.2.2. Destek Vektör Makinesi (DVM).....	19
3.2.3. Sınıflandırma Başarım Kriteri.....	22
3.3. Derin Öğrenme	24
3.3.1. TensorFlow.....	25
3.3.2. Keras.....	25

4. DENEYSEL ÇALIŞMALAR	27
4.1. Kullanılan Veri Seti.....	28
4.2. Makine Öğrenmesi ile Beton Basınç Dayanımı	34
4.2.1. KNN	35
4.2.2. DVM	38
4.3. Derin Öğrenme ile Beton Basınç Dayanımı	42
4.3.1. Nöron Sayılarının Belirlenmesi.....	43
4.3.2. Yığın Sayısının Belirlenmesi.....	44
4.3.3. Tur Sayısının Belirlenmesi	44
4.3.4. Aktivasyon Fonksiyonunun Belirlenmesi	45
5. TARTIŞMA VE SONUÇ.....	49
KAYNAKÇA	52

TABLÖLAR LİSTESİ

Sayfa No

Tablo 3.1. Keras ile Kullanılan Aktivasyon Fonksiyonlarından Bazıları.....	26
Tablo 4.1. 0,5-2mm Agregâ Çapına Sahip Beton Numunelerinin Karışım Oranları(kg/m ³)	30
Tablo 4.2. 2-4mm Agregâ Çapına Sahip Beton Numunelerinin Karışım Oranları (kg/m ³)	30
Tablo 4.3. 4-8mm Agregâ Çapına Sahip Beton Numunelerinin Karışım Oranları (kg/m ³) .	31
Tablo 4.4. GLCM-KNN Karışıklık Matrisi.....	36
Tablo 4.5. Histogram-KNN Karışıklık Matrisi	38
Tablo 4.6. GLCM-DVM Karışıklık Matrisi	40
Tablo 4.7. Histogram-DVM Karışıklık Matrisi.....	42
Tablo 4.8. Nöron Sayılarının Belirlenmesi.....	43
Tablo 4.9. Yığın Sayısının Belirlenmesi	44
Tablo 4.10. Tur Sayısının Belirlenmesi.....	45
Tablo 4.11. Aktivasyon Fonksiyonunun Belirlenmesi	46
Tablo 4.12. Beton Dayanım Tahmini İçin Belirlenen En Uygun Mimari	47
Tablo 5.1: Algoritmaların Koşturulma Süreleri	50
Tablo 5.2. Algoritmaların Tahmin Başarımları	50

ŞEKİLLER LİSTESİ

	Sayfa No
Şekil 2.1. Yapay Zeka ve Alt Dallarının Gösterimi	6
Şekil 3.1. GLCM Sonuç Matrisi Örneği	10
Şekil 3.2. Örnek Veri Seti ve Histogram Grafiği	12
Şekil 3.3. a) Gri Seviye Kameraman Görüntüsü b) Kameraman Görüntüsünün Histogramı ..	13
Şekil 3.4. KNN Çalışmasına Örnek	17
Şekil 3.5. Manhattan Metriği Ölçüm Örneği	18
Şekil 3.6. Destek Vektör Makineleri Düzlemi	20
Şekil 3.7. Doğrusal Olarak Ayrılamayan Veri Seti.....	21
Şekil 3.8. Karışıklık Matrisi Sınıflandırma Tablosu	22
Şekil 3.9. Basit YSA Yapısı.....	24
Şekil 4.1. Çalışmanın Akış Şeması	28
Şekil 4.2. Otomatik Yapı Üretimine Uygun Olarak Hazırlanmış Taze Beton Örneği.....	29
Şekil 4.3. Çalışmada Kullanılan Beton Numunelerinden Örnekler	31
Şekil 4.4. Numune Görüntülerini Elde Etmek İçin Hazırlanan Düzenek	32
Şekil 4.5. Arka Plan Görüntüsünden Arındırılmış Beton Numunesi	32
Şekil 4.6. Beton Basınç Test Cihazı.....	33
Şekil 4.7. Derin Öğrenme Mimarisi.....	48

GRAFİKLER LİSTESİ

	Sayfa No
Grafik 4.1. Beton Grupları Ortalama Basınç Dayanımları a) 0,5-2mm b) 2-4mm c) 4-8mm	33
Grafik 4.2. GLCM-KNN Doğruluk Oranları (%)	35
Grafik 4.3. Histogram-KNN Doğruluk Oranları (%).....	37
Grafik 4.4. GLCM-DVM Doğruluk Oranları	39
Grafik 4.5. Histogram-DVM Doğruluk Oranları	41



KISALTMALAR VE SİMGELER LİSTESİ

CNN : Evrişimsel Sinir Ağı (Convolutional Neural Network)

DNN : Derin Sinir Ağları (Deep Neural Network)

DVM : Destek Vektör Makineleri

GLCM: Gri Seviye Eş Oluşum Matrisi (Gray Level Co-Occurance Matrix)

KNN : En Yakın Komşuluk (K-Nearest Neighbors)

RBF : Radyal Temel İşlevi (Radial Basis Function)

RGB : Kırmızı-Yeşil-Mavi (Red-Green-Blue)

YSA : Yapay Sinir Ağları



1. GİRİŞ

Gelişen teknoloji ile insan gözlemine dayanan birçok iş günümüzde bilgisayarlar yardımıyla daha hızlı yapılabilmektedir. İş gücü süresinden kazanım veya karar vermede yardım amaçlı bilgisayar desteğinin başarımlarının tahmininin artması için geliştirilen birçok bilgisayar tekniği vardır. Son yıllarda verilere ulaşımın hızlı bir şekilde artması, problemlerin çözümünde yapay zeka tekniklerinin uygulanmasını kolaylaştırmış ve yaygınlaştırmıştır (Towbin, 2019: 1248). Verilerin kolay toplanabilmesi, kolay işlenebilmesi ve işlenen verilerin insan hayatına olumlu yansımaları hemen hemen her alan için yapay zekayı öne çıkarmaktadır.

Elde edilen verilerin kullanımı için geliştirilen bilgisayar tekniklerinin başında Makine Öğrenmesi ve Derin Öğrenme Algoritmaları yer almaktadır. Uzun yıllardır kullanılan Makine Öğrenmesi ve günümüzde giderek yaygınlaşan Derin Öğrenme teknikleri bilgisayar donanım alt yapısının farklı bakış açılarıyla kullanılması sonrası olumlu bir kırılma yaşayarak hızlı bir ilerleme sağlamıştır (Yu vd., 2021: 3).

Makine Öğrenmesi veriler yardımıyla eğitilen ve yeni gelen verileri elde ettiği eğitim sonuçlarına göre tahmin eden algoritmalarıdır. Artan veriler yardımıyla yapay zeka tıp, nesne tanıma, ses tanıma, ulaşım, pazarlama, otomotiv, insan kaynakları, satış, finans gibi birçok alanda yaygınlaşmıştır (Chang vd., 2018: 1).

Bilgisayar ve internet alanındaki popüler uygulamalardan olan Derin Öğrenme, tahminlerinin doğruluğundan dolayı makine öğrenme algoritmalarını birçok yönden geride bırakmıştır. Derin öğrenme; görüntü işleme, doğal dil işleme, ses tanıma gibi alanlarda birçok avantaj göstermiştir (Wang, 2020: 218).

Görüntü işleme teknikleri kullanılarak, son dönemde birçok alanda yapılan çalışmalarda başarı elde edilmiştir. Görüntü üzerinden elde edilen anlamlı veriler yardımıyla makine öğrenmesi algoritmaları, obje tanıma (Hou vd., 2019: 5433), yüz tanıma (Singh ve Goel 2020: 348), duygu tanıma (Rani, 2019), yaş tahmini (Huang vd., 2017: 849) gibi birçok problemde yüksek başarımlar oranları ile çözüme yardımcı olmuştur.

İnşaat mühendisliğinde pek çok problemin çözümünde görüntü verileri kullanılarak makine öğrenmesi ve derin öğrenme algoritmalarından faydalanılmıştır. Yol çatlaklarının belirlenmesi (Kang vd., 2019: 1), bina sağlamlık durumlarının tahmin edilmesi (Zhang vd., 2021: 47), betonların basınç dayanımlarının belirlenmesi (Jha vd., 2020: 70) gibi alanlarda

görüntü işleme tekniklerinin yanında makine öğrenmesi ve derin öğrenme algoritmalarından faydalanılmıştır.

Otomatik yapı teknolojisi geleneksel yapı üretim basamaklarını bilgisayar altyapısından faydalanarak sistematik üretime olanak sağlama felsefesine dayanarak tasarlanmıştır. Bu teknoloji sayesinde beton işçiliğinin yanı sıra demir, kalıp gibi beton üretimini yavaşlatan ve maliyeti arttıran etkenler azaltılmıştır. Sürekli ve esnek üretime olanak sağlayan bu teknolojinin gelecekte daha da yaygınlaşacağı düşünülmektedir (Khoshnevis vd., 2013: 1).

Bu çalışmada makine öğrenmesi ve derin öğrenme yöntemleri ileri bir beton teknolojisi olan otomatik üretim teknolojiye uygun betonların basınç dayanımlarını tahmin etmek için kullanılmıştır. Tahribatsız betonun dayanımını tahmin etmek için görüntü işleme yöntemleri kullanılarak yapılan birçok çalışma mevcuttur. Bu alanda yapılan çalışmalar genellikle betonun içindeki çimento hamuru, agrega ve boşlukların korelasyonuna odaklanmaktadır (Özen, 2007: 87). Yapılan bu çalışmalarda kullanılan beton tipleri klasik beton tipleri diye adlandırılıp agrega gradasyonları büyük dane çapları içermektedir. Ancak otomatik üretilen beton teknolojisinde kullanılan makinelerin ağzından (nozzle) betonun çıkış yapabilmesi ve katmanlı üretime uygun olması için küçük dane çaplı bir gradasyona sahip olması gerekmektedir. Agrega gradasyonunun düşük dane çaplı olması görüntüler üzerinden yapılan beton basınç dayanım tahminlerini zorlaştırmaktadır. Bu çalışma kapsamında belirtilen zorlukları ortadan kaldırmak için sınıflama performans başarımı yüksek makine öğrenme ve derin öğrenme tekniklerinin kullanıldığı bir yöntem önerilmiştir.

2. LİTERATÜR TARAMASI

Bu bölümde literatürde beton görüntüleri ile yapılan tahribatsız basınç dayanımı ile ilgili makine öğrenmesi ve derin öğrenme yöntemleri kullanılarak yapılan çalışmalar incelenmiştir. İncelenen çalışmalar makine öğrenmesi, derin öğrenme ve beton basınç dayanımları başlıkları altında toplanmıştır.

2.1. Makine Öğrenmesi

Makine öğrenmesi bilgisayarların sınıfı bilinen veriler yardımıyla, bilinmeyen verileri tahmin edebilmesini sağlar. Makine öğrenmesi algoritmalarının başarılı sonuçlar elde etmesi ve düşük hata ile tahminler yapmasının sebebi, deneyim kazandıkça gelişmeye devam etmelerindendir (Özen vd., 2021: 134). Veriler arasındaki ilişkiyi bularak bu ilişkiyi farklı başarımlar ile somutlaştırıp bilinmeyen verileri tahmin etmek amacıyla birçok çalışmada makine öğrenmesi algoritmalarından faydalanılmıştır. Bu çalışmalarda yapılan araştırmalarla sağlık (Katarya ve Srinivas, 2020: 302), ekonomi (Mou vd., 2021: 180), enerji (Bashawyah ve Qaisar, 2021: 99), eğitim (Bujang vd., 2021: 1), tarım (Jena vd., 2021: 1) gibi birçok alanda başarımların artışı sağlanmıştır.

Biyomedikal alanında makine öğrenmesi kullanılarak yapılan çalışmalara bir örnek olarak Travmatik beyin hasarı sınıflandırılması için EEG verilerini kullanarak makine öğrenmesi teknikleriyle başarımlarını değerlendiren Vivaldi ve arkadaşlarının yaptığı çalışma örnek olarak verilebilir (Vivaldi vd., 2021: 8). Vivaldi ve arkadaşları EEG verilerini sınıflandırmak için En Yakın Komşuluk (KNN) ve Destek Vektör Makineleri (DVM) gibi sınıflandırma algoritmalarını kullanmışlar ve %94'e varan başarımlar elde etmişlerdir. Katarya ve Jain'in (Katarya ve Jain, 2020: 4) Diyabet tespiti için farklı makine öğrenmesi algoritmalarının karşılaştırıldığı çalışma sağlık alanında verilebilecek bir diğer örnektir. Diyabetin erken evrelerde saptanabilmesi için yaptıkları çalışmalarda tamamı 21 yaşında olan 768 kadın bireyden oluşan veri setini kullanmışlardır. Kullandıkları farklı makine öğrenmesi teknikleri arasında KNN ve DVM vardır. Yapılan çalışma sonunda KNN algoritmasının %75, DVM algoritmasının ise %74 başarıya ulaştığı görülmüştür.

Ekonomi alanında makine öğrenmesi kullanılarak yapılan çalışmalara bir örnek olarak Mou ve arkadaşlarının (Mou vd., 2021: 180) müşteri taleplerine göre araba satın alımının makine öğrenmesi yöntemleri ile kullanımına yönelik çalışması verilebilir. Mou ve arkadaşları DVM, KNN gibi popüler makine öğrenmesi algoritmalarını Bangladeş'teki farklı araç satım

mağazalarından topladıkları veriler üzerinde denemişlerdir. Yaptıkları bu çalışmalarda DVM'nin %86'ya ulaşan başarı ile en başarılı algoritma olduğunu görmüşlerdir. İsmail ve arkadaşlarının (İsmail vd., 2021: 317) Afrika'daki insanların banka hesapları ile ilgili makine öğrenmesi teknikleri kullanarak yaptıkları çalışma ekonomi alanında yapılan çalışmalara başka bir örnek olarak verilebilir. İsmail ve arkadaşları Afrika'daki insanların banka hesaplarının olmamasını ekonomik olarak gelişmenin önündeki bir engel olduğunu görmüş ve Kenya, Ruanda, Tanzanya ve Uganda'daki bankalardan elde edilen veri üzerinden KNN ve DVM gibi algoritmaları test etmişlerdir. Yaptıkları çalışmada insanların eğitim seviyesi, cep telefonu kullanımı, iş tipi gibi özelliklerine odaklanmış ve DVM algoritmasında %86,19, KNN algoritmasında %87,14 seviyelerinde başarıya ulaşmışlardır.

Enerji alanında makine öğrenmesi kullanılarak yapılan çalışmalara Bashawyah ve Qaiser'in (Bashawyah ve Qaisar, 2021: 99) Londra'daki hanelerde bulunan akıllı sayaç verilerini kullanarak makine öğrenmesi tabanlı yaptıkları kısa vadeli yük tahminlemesi örnek olarak verilebilir. Bashawyah ve Qaiser bu çalışmada elektrik şirketlerinin yükü tahmin edebilmesi ve arzı kontrol edebilmesi için KNN ve DVM algoritmalarından faydalanmışlardır. Çalışmada eğitim amaçlı veri setini Londra'daki 5566 hanenin 2011 ve 2014 yılları arasındaki sayaç okumalarından elde etmişlerdir. Yaptıkları çalışma sonucunda DVM algoritmasıyla %86 oranında başarıya ulaşmışlardır. Raju ve arkadaşlarının (Raju vd., 2021: 600) makine öğrenmesi algoritmaları kullanılarak yaptıkları gelişmiş ev otomasyon sistemi bireylerin enerji tüketimini düşürmeyi hedeflemişlerdir. Raju ve arkadaşlarının bu çalışmada yararlandığı algoritmalar arasında KNN ve DVM algoritmaları da vardır. Tasarladıkları sistemde hava durumu, evdeki insan sayısı gibi değişkenleri algoritmalarla uygulayarak enerji tüketim yükünü dengelemiş ve enerji tüketimini azaltmayı planlamışlardır.


Eğitim alanında makine öğrenmesi kullanılarak yapılan çalışmalara Bujang ve arkadaşlarının öğrenci notu tahmini için makine öğrenimi kullandıkları çalışma örnek olarak verilebilir (Bujang vd., 2021: 1). Bujang ve arkadaşları öğrencilerin notlarını tahmin etmek için 2 zorunlu derste toplam 1282 örnek olan veri seti kullanmışlardır. Bu veriler dersin verildiği yıl, dönem, öğrencilerin not ortalaması gibi verilerden oluşmaktadır. Çalışmada veri setini farklı makine öğrenme algoritmaları ile test etmişlerdir. Bu algoritmaların içinde KNN ve DVM algoritmaları da sınıflandırma amaçlı kullanılmıştır. KNN ile %98,5 ve DVM ile %98,4 başarı elde etmişlerdir. Suzan ve arkadaşlarının (Suzan vd., 2021: 1) Bangladeşli öğrencilerin çevrimiçi eğitime adaptasyonlarının araştırdığı çalışma eğitim alanında makine öğrenmesi çalışmalarına başka bir örnek olarak verilebilir. Suzan ve arkadaşları Covid19 salgını dolayısı

ile yaygınlaşan çevrimiçi eğitimde öğrencilerin sisteme adaptasyonlarını gözlemlemek için KNN ve DVM'nin de aralarında olduğu farklı makine öğrenmesi algoritmalarını kullanmışlar ve başarılı sonuçlar elde etmişlerdir.

Tarım alanında makine öğrenmesi kullanılarak yapılan çalışmalara Jena ve arkadaşlarının buğday tanelerinin sınıflandırılması için makine öğrenme tekniklerinden faydalandıkları çalışma örnek verilebilir (Jena vd., 2021: 1). Jena ve arkadaşları buğday tanelerinin geometrik özelliklerine odaklandıkları çalışmada KNN ve DVM kullanmışlardır. KNN algoritması ile %94,3 ve DVM algoritmasında %94,2 başarı elde etmişlerdir. Tarım alanında başka bir örnek çalışma ise Gajula ve arkadaşlarının tarım ürünlerinde verimi arttırmak için yaptıkları çalışmadır (Gajula vd., 2021: 1). Bu çalışmada makine öğrenme algoritmalarından KNN kullanan Gajula ve arkadaşları toprak görüntülerine odaklanarak arazi için en verimli olabilecek mahsulü seçimi ve gerekli gübreyi çiftçilere önermeyi hedeflemişlerdir. Materne ve Inoue tarım zararlıları ve hastalıkları alanında erken uyarı sistemi kullanmak için KNN ve başka makine öğrenme algoritmalarından faydalanmışlardır (Materne ve Inoue, 2018: 1). Hazırladıkları erken uyarı sisteminde yeni gelen verilerin tahmini için KNN algoritmasından faydalanmış ve %95,9 oranında başarı elde etmişlerdir.

2.2. Derin Öğrenme

Derin öğrenme, geleneksel makine öğrenimi algoritmalarının genellikle yapamadığı yüksek ve düşük düzeyde veri soyutlamalarını açıklayan ve öğrenen algoritmalar oluşturmaya ayrılmış makine öğreniminin alt alanıdır (Beysolow, 2017: 1). Şekil 2.1'de yapay zeka, makine öğrenmesi ve derin öğrenme ilişkisini gösteren resim verilmiştir. Derin öğrenme, birden fazla katmandan oluşan, verilen veri setlerinin sonuçlarını tahmin etmek için birden fazla katmandan oluşan bir tekniktir. Diğer makine öğrenmesi algoritmaları gibi, sağlık (Roy vd., 2020: 2676), ekonomi (Nwankpa vd., 2020: 196), enerji (Paterakis vd., 2017: 1), eğitim (Ren vd., 2021: 81), tarım (Sirohi ve Malik, 2021: 58) gibi alanlarda kullanılarak tahmin, tavsiye gibi sistemlerin tasarlanmasında faydalanılmaktadır.



Şekil 2.1. Yapay Zeka ve Alt Dallarının Gösterimi

Biyomedikal alanında derin öğrenme algoritmaları kullanılarak yapılan çalışmaya Roy ve arkadaşlarının 277 akciğer ultrasonu içeren veri seti ile yaptıkları çalışma örnek olarak verilebilir (Roy vd., 2020: 2676). Roy ve arkadaşları İtalya’da bulunan 35 hastadan toplanan 277 akciğer videosu ile hazırladıkları veri setine uyguladıkları Evrişimsel Sinir Ağları (CNN) teknikleri ile COVID-19 hastalığını tahmin etmişlerdir. Bireylerin sağlıklı ve hasta oldukları zamanlarda topladıkları bu verilerle %82 oranında başarıya ulaşmışlardır.

Ekonomi alanında yapılan çalışmalarda derin öğrenme algoritmalarına örnek olarak Nwankpa ve arkadaşlarının yeniden üretim aşamasında yüzeylerin kuru, yağlı, ıslak ve kusurlu yüzey olarak sınıflandırılması için yaptıkları çalışma verilebilir (Nwankpa vd., 2020: 196). Yazarlar bu çalışmada yüzeylerin sınıflandırılması için USB Kamera üzerinden elde ettikleri video görüntülerinden faydalanmışlardır. Elde ettikleri görüntüler CNN algoritması ile sınıflandırılarak %96 oranında başarı elde etmişlerdir.

Enerji alanında yapılan derin öğrenme çalışmalarına Paterakis ve arkadaşlarının enerji tüketim tahmini üzerine yaptıkları çalışma örnek olarak verilebilir (Paterakis vd., 2017: 1). Paterakis ve arkadaşları bu çalışmada gün öncesi elektrik tahmini için Lineer Regrasyon, DVM gibi geleneksel makine öğrenmesi teknikleri ile çok katmanlı derin öğrenme algoritmalarını karşılaştırmıştır. Yapılan çalışma sonucunda derin öğrenme algoritmasının %96 oranında bir başarı göstererek diğer makine öğrenmesi algoritmalarına göre daha doğru tahmin yaptığı gözlemlenmiştir. Küçükaslan, Keras kütüphanesi kullanarak gün öncesi elektrik piyasası fiyat tahmini için çalışma yapmıştır (Küçükaslan, 2019). Çalışmada önerdikleri model %83 oranında başarı göstermiştir.

Eğitim alanında derin öğrenme ile ilgili çalışmalara Ren ve arkadaşlarının 706 derste 41343 öğrenci verisi ile yaptıkları çalışma örnek olarak verilebilir (Ren vd., 2021: 81). Ren ve arkadaşları bu çalışmada 2015 ile 2019 yılları arasında topladıkları veriler ile öğrencilerin dersten çekilmesini tahmin etmek için derin öğrenme algoritmalarından faydalanmışlardır. Bu çalışma sonucunda derin öğrenme modelinin %84,71 başarı oranıyla, klasik makine öğrenmesi algoritmalarından daha başarılı sonuçlar verdiği gözlemlenmiştir.

Tarım alanında yapılan çalışmalara örnek olarak ayçiçeği bitkisinin yaprağından hastalık teşhisi koymak için Sirohi ve Malik'in yaptığı çalışma verilebilir (Sirohi ve Malik, 2021: 58). Sirohi ve Malik ayçiçeği bitkilerinin yapraklarının görüntülerinden oluşan veri tabanı üzerinde yaptıkları çalışmada bitki hastalıklarını tespit etmeyi amaçlamışlardır. Yaptıkları çalışmada AlexNet, VGG16, Inceptionv3, MobileNet algoritmalarını test etmişlerdir. Yapılan testler sonucunda VGG16 ve MobileNet ile kurulan hibrit modelin %89 oranıyla en yüksek başarıyı elde ettiği gözlemlenmiştir.

2.3. Beton Basınç Dayanımı

Beton, birden çok malzemeden oluşan kompozit bir tasarımdır. Betonun betonarme yapılar için kullanım bölgeleri genellikle basınca en fazla maruz kalan bölgeleridir. Bu yüzden betonun basınç dayanımı, en önemli mekanik özelliklerindendir. Betonun basınç dayanımı klasik olarak, basınç test cihazı ile deney yaparak, betonu tahrip ederek belirlenebilir. Bunun yanında betonun bütünlüğünü bozmadan, tahribatsız bir şekilde basınç dayanım tahmini yapılabilir (Kabay ve Aköz, 2003: 1).

Tahribatsız deney yöntemleri içerisinde ultrasonik yöntemler, beton test çekici, penetrasyon yöntemleri, rezonant frekans yöntemleri gibi yöntemler vardır (Breysse, 2012: 139). Bu yöntemler tahribatlı yöntemler kadar betonun basınç dayanımı tam olarak vermese bile yakın tahmin sonuçları verebilmektedirler. Ancak bu yöntemleri kullanabilmek için özel cihazlara ve tecrübeli personele ihtiyaç vardır. Dayanım sonuçlarını tahmin edebilmek için teknolojinin de gelişmesiyle sürekli yeni yöntemler geliştirilmekte farklı yöntemler ortaya konulmaktadır. Bu yöntemlerden birisi de betonun görüntülerinin kullanılmasına dayanan makine öğrenmesi yöntemleridir.

Tahribatsız beton testleri kategorisinde olan görüntü ile basınç dayanım tahmini son dönemde makine öğrenmesi algoritmalarının yaygınlaşmasıyla pek çok araştırmacı tarafından daha kolay uygulanabilmektedir. Yapılan çalışmalar incelendiğinde, farklı görüntü işleme

tekniklerinin farklı algoritmalar kullanılarak klasik beton tipleri üzerinde yoğunlaştığı görülmektedir.

Shi ve Dong yaptıkları çalışmada beton görüntüsünden tahribatsız basınç dayanımı için DVM algoritmasını kullanmıştır (Shi ve Dong, 2011: 1585). Yapılan çalışmada 34 adet beton görüntüsünden oluşan veri setini sınıflandırmak için DVM algoritmasının başarımı Yapay Sinir Ağları (YSA) tekniğiyle karşılaştırılmış ve sonuç olarak DVM'in daha başarılı sonuçlar verdiği görülmüştür. YSA ile ilgili olarak performans optimizasyonu zorluğuna dikkat çekilmiştir.

Betonun hazırlandıktan sonra kürlenme süresi dayanım sonuçlarını doğrudan etkilemektedir. Keleş ve arkadaşlarının 2019'da yaptıkları çalışmada 103 beton numunesinin 28 gün bekletildikten sonra tahribatsız basınç dayanım tahminleri için makine öğrenmesi tekniklerinden faydalanılmıştır (Keleş vd., 2019: 1). Elde edilen veri setindeki beton görüntülerine ek olarak betonun içerdiği çimento, uçucu kül bilgisi, agrega tanesi gibi betonun yapısal özellikleri de makine öğrenmesi algoritmalarında başarıyı arttırmak için kullanılmıştır. Makine öğrenmesi tekniklerinden KNN, Rasgele Ormanlar ve Karar Ağaçları algoritmaları seçilmiştir. Seçilen bu tekniklerden en başarılı algoritmanın Rasgele Orman algoritması olduğu gözlemlenmiştir.

Cha ve arkadaşları derin öğrenme algoritmalarıyla beton görüntülerini kullanarak çatlakları tespit çalışması yapmışlardır (Cha vd., 2017: 361). Cha ve arkadaşları 40 bin resmi CNN algoritmasını eğitmek için kullanmışlardır. Resimleri 32 bin ve 8 bin olarak iki gruba ayırmışlar ve algoritmayı bu gruplarla ayı ayrı eğitmişlerdir. 32 bin veriden oluşan ilk grup ile %98,22 başarı sağlanırken 8 bin görüntüden oluşan veri seti ile %97,95 başarı elde edilmiştir. Yapılan bu çalışmada kullanılan sonucu algoritmanın verimli eğitilebilmesi için 10 bin üzerinde veriye ihtiyaç duyulduğunu belirtilmektedir.

Zeng ve arkadaşları tahribatsız beton dayanımı tahmini için yaptıkları çalışmada derin öğrenme algoritmalarından faydalanmışlardır (Zeng vd., 2022: 1). Yaptıkları çalışmada 28 gün kürde bekletilen betonların görüntülerini popüler olan CNN algoritmasını kullanmışlar ve %97 oranında başarı elde etmişlerdir.

Atık betonlardan elde edilen agrega ile üretilen betonlar üzerinde yapılan çalışmada derin öğrenme algoritmaları kullanılarak 1030 beton verisi ile %96 oranında başarıya ulaşılmıştır (Chen vd., 2022: 1). Çalışmada betonun agrega bilgilerinin yanında, çimento miktarı, su miktarı, uçucu kül oranı gibi bilgilerde algoritmaya eğitim amacıyla verilmiştir. Veri artırma yöntemleri kullanılarak veri sayısı artırılmış ve başarı oranı %96'ya çıkartılmıştır.

Kauçuk betonların dayanımını tahmin etmek için yapılan çalışmada Ly ve arkadaşları derin sinir ağlarının başarımını ölçmüşlerdir (Ly vd., 2021: 1). Ly ve arkadaşları 223 beton numunesinden oluşan veri seti üzerinde yaptıkları çalışmada derin sinir ağlarının %98 oranında başarıya ulaşmışlardır.

Doğan ve arkadaşlarının, beton basınç dayanımını tahribatsız olarak tahmin etmek için yapılan çalışmada 96 adet beton numunesi, görüntü işleme teknikleriyle yapay sinir ağları kullanılarak oluşturulan bir modelde test edilmiştir (Doğan vd., 2017). Yapılan çalışma sonunda %97 ile %99 oranında başarı elde edilmiştir.

Yapılan çalışmalar incelendiğinde beton basınç dayanım tahmini için makine öğrenmesi ve derin öğrenme algoritmaları, klasik betonların yanında farklı formlarda üretilen betonlarda da test edilmiş ve başarılı sonuçlar elde ettikleri gözlemlenmiştir.

Bu çalışmada otomatik üretim teknolojisine uygun betonların, basınç dayanımlarını tahribatsız yöntemlerle tahmin etmek için makine öğrenmesi ve derin öğrenme yöntemlerinin başarımını araştırılmıştır.

3. MATERYAL VE YÖNTEM

Yapılan tez çalışmasında tahribatsız basınç dayanımlarının tahmini aşamasında çeşitli makine öğrenmesi ve derin öğrenme tekniklerinden faydalanılmıştır. Elde edilen görüntüler ile başarımlar tahmini yapılabilmesi için ilk olarak öznitelik çıkarım yöntemleri ile veri seti oluşturulmuştur. Makine öğrenmesi algoritmaları ve derin öğrenme modeli bu veri seti kullanılarak eğitilmiştir.

3.1. Öznitelik Çıkarımı

Makine öğrenmesi algoritmaları doğrudan görüntü verilerini işleyemez bunun yerine görüntü verilerinden elde edilen sayısal verilerle çalışabilirler. Popüler öznitelik çıkartma tekniklerinden olan Gri Seviye Eş Oluşum Matrisi (Gray Level Co-Occurance Matrix) (GLCM) ve histogram ile görüntüler sayısal verilere dönüştürülmüştür.

3.1.1. GLCM

GLCM en bilinen öznitelik çıkartma yöntemlerindendir (Haralick vd., 1973: 610). Özellikle doku görüntülerinin özniteliklerini çıkartmada yaygın olarak kullanılır. GLCM'den elde edilen veriler makine öğrenmesi teknikleri için kullanılabilir (Mukherjee vd., 2016: 98).

Şekil 3.1'de örnek bir veri setinden GLCM algoritmasının çıkarttığı matris görülmektedir. Algoritma veri setini tarayarak belirli verilerin ne kadar tekrar ettiğini toplayarak sonuç matrisine yazdırır.

	1	2	3	4	5
1	1	2	2	0	0
2	0	0	0	1	1
3	1	0	0	0	1
4	1	0	0	0	0
5	1	1	0	0	0

Şekil 3.1. GLCM Sonuç Matrisi Örneği

Görüntü üzerinden öznitelik çıkartmada ise GLCM'nin tarama yönü belirli açılarda (0, 45, 90, 135) değiştirilerek tüm görüntü taranır. Bu tarama için farklı GLCM özellikleri kullanılır. Öznitelik çıkarma görüntülerden renk veya doku gibi özelliklerin çıkartılması anlamına gelir. Görüntülerdeki doku özellikleri GLCM yardımıyla elde edilir. İkinci dereceden istatistiksel özellikler, GLCM ile veri setinden hesaplanır. İncelenen görüntünün farklı gri seviyelerinin sayısına eşit satır ve sütun sayısıyla GLCM matrisi oluşturulur. (Mukherjee vd., 2016: 99)

GLCM görüntünün farklı türdeki özelliklerine odaklanır (Haralick vd., 1973: 611). Örneğin 'Kontrast' görüntüdeki belirgin noktalar arasındaki kontrast değerlerini inceler. Denklem 3.1'de kontrast formülü verilmiştir. Formülde i ve j sırasıyla yatay ve dikey düzlemdeki konumu, P_{ij} ise matris değerini ifade etmektedir. N ise görüntüdeki piksel sayısını ifade etmektedir.

$$Kontrast = \sum_{i,j=0}^{N-1} P_{ij}(i-j)^2 \quad (3.1)$$

Diğer GLCM özelliklerinden olan 'Farklılık' da ise olasılıkların çarpıldığı ağırlıklar, köşegenden (komşu değerlerin eşit olduğu) doğrusal olarak artar. Denklem 3.2 ile ifade edilir.

$$Farklılık = \sum_{i,j=0}^{N-1} P_{ij}|i-j| \quad (3.2)$$

Homojenlik ise GLCM'deki öğelerin dağılımının GLCM köşegenine yakınlığını ölçen bir değer döndürür. Denklem 3.3 ile ifade edilir.

$$Homojenlik = \sum_{i,j=0}^{N-1} \frac{P}{1+(i+j)^2} \quad (3.3)$$

Enerji ve ASM (Açısal İkincil Momentum), GLCM olasılığını kendisi için bir ağırlık olarak kullanır. ASM'nin adı fizikten gelir ve dönme ivmesinin bir ölçüsü olan açısal ikinci momenti hesaplamak için kullanılan benzer fizik denklemlerini yansıtır. Denklem 3.4'te ASM, Denklem 3.5'te ise Enerji formülleri verilmiştir.

$$ASM = \sum_{i,j=0}^{N-1} P_{ij}^2 \quad (3.4)$$

$$Enerji = \sqrt{ASM} \quad (3.5)$$

Korelasyon diğer GLCM özelliğidir. Bir pikselin ve komşusunun korelasyonunun hesaplanmasını tüm görüntü üzerinden geçirir. Bu gri seviyelerin komşu piksellerininkilere doğrusal bağımlılığını hesapladığı anlamına gelir. Mükemmel bir pozitif veya negatif korelasyonlu görüntüde korelasyon değeri 1 veya -1'dir. Denklem 3.6'da formülü verilmiştir. Formülde μ GLCM'ye katkıda bulunan tüm piksellerin yoğunluğunun tahminidir.


$$Korelasyon = \sum_{i,j=0}^{N-1} P_{ij} \frac{(i - \mu)(j - \mu)}{\sigma^2} \quad (3.6)$$

Yukarıda belirtilen GLCM özelliklerinin her biri 1x4 boyutunda veri dönmektedir. Belirtilen 6 GLCM özelliği sayesinde, bir adet numune görüntüsünden 6x4 boyutunda GLCM verisi elde edilmektedir.

3.1.2. Histogram

Histogram, veri veya veri setindeki dağılımı ifade eden sütun grafiğidir. Tekrarlı sayılardan oluşan verilerin, çeşitli işlemlerle önce tabloya, sonra tablodan yararlanarak grafiğe aktarılmasıdır. Histogram, rastgele bir değişkenin dağılımını tahmin etmek için istatistikte en yaygın kullanılan araçlardandır (Mezei vd., 2017: 1). Teknik olarak bir öznitelik çıkarım yöntemi olmasa da verilerin ağırlıklarını inceleyerek bir öznitelik çıkarım tekniği olarak kullanılmaktadır.

Şekil 3.2'de 0 ve 5 aralığında verilerden oluşan örnek bir veri seti ve veri setinin histogram grafiği verilmiştir. Bu veri setindeki verilerin ağırlık dağılımı histogram grafiği ile incelenebilir.



Şekil 3.2. Örnek Veri Seti ve Histogram Grafiği

Görüntü histogramı ise görüntülerdeki piksellerin renk değerlerinin bulunma olasılığını gösteren bir dağılım grafiğidir. Bunun yanında döndürmeye, ölçeklendirmeye dayanıklı olmasından ve de kolay hesaplanmasından dolayı görüntü işleme çalışmalarında öznitelik çıkartmak için sıklıkla kullanılır (Yang vd., 2013: 61). Histogram grafiğini elde edebilmek için renkli görüntülerde çalışırken 3 boyutlu uzayda çalışmak gerekir. Ancak gri seviye dönüşümü yapılmış bir resimde histogram çalışması yaparken tek boyut yeterlidir.


Gri seviyeli görüntülerde histogram için tek bir kanal oluşturulur. Bu kanal 8 bit uzunluğundadır ve en fazla $L = 2^8 = 256$ farklı değer alabilir. Denklem 3.7’de verilen eşitlik ile belirtilen aralıkta bulunan bir değerin ağırlığı bulunabilir. Bu eşitlikte i aralıkta bulunan değeri, r_i bu değerin tekrar sayısını, n ve m görüntünün boyutlarını, $p(i)$ ise bu değerin görüntüdeki ağırlığını ifade etmektedir.

$$p(i) = \frac{r_i}{n \times m}, 0 \leq i \leq L \quad (3.7)$$

Bu eşitlik tüm veri aralığındaki değerlere uygulandığında Denklem 3.8 elde edilir.

$$\sum_{i=0}^{L-1} p(i) = 1 \quad (3.8)$$

Şekil 3.3-a’da verilen kameraman görüntüsü gri seviye olarak adlandırılan, 0-255 arası tek boyutlu renk değerlerine sahip olan bir görüntüdür. Bu görüntünün histogram grafiği ise Şekil 3.3-b’de verilmiştir.



Şekil 3.3. a) Gri Seviye Kameraman Görüntüsü b) Kameraman Görüntüsünün Histogramı

Kaynak: (Erkan ve Gökrem, 2018)

Görüntü incelendiğinde kameramanın paltosunun rengi olan siyahın ve gökyüzünün rengi olan grinin yoğunlukta olan renkler olduğu görülmektedir. Görüntünün histogramı incelendiğinde ise en çok bulunan değerin siyaha yakın olan “14” olduğu ve toplamda 1732 pikselde bulunduğu görülmektedir. Yine gökyüzünün grisini ifade eden piksellerin “163” ve etrafında yoğunlaştığı görülmektedir. Buradan da anlaşılabacağı gibi bir görüntünün histogramı ile o görüntü hakkında renk yoğunluğu, renk dağılımı gibi birçok bilgi elde edilebilir.

Renkli görüntüler RGB (Kırmızı-Yeşil-Mavi) ile ifade edilen 3 kanallı renk uzayı ile oluşturulur. Yine bu renklerin kullanılmasıyla RG, RB ve GB ile oluşturulan renkli görüntüler elde etmek mümkündür. Denklem 3.9’da iki renkten oluşan görüntüdeki piksel değerlerini ifade eden eşitlik verilmiştir. Bu eşitlikte (i, j) ikili görüntü bileşenlerini, $r_{i,j}$ sayısal görüntü içerisindeki tekrar sayısını, n ve m görüntü boyutunu, L piksellerin aralığının maksimum değerini ve $p(i, j)$ i ve j değerlerinin aralığını ifade etmektedir.

$$p(i, j) = \frac{r_{i,j}}{n \times m}, 0 \leq i \leq L, 0 \leq j \leq L \quad (3.9)$$

Bu eşitlik tüm veri aralığındaki değerlere uygulandığında Denklem 3.10 elde edilir.

$$\sum_{j=0}^{L-1} \sum_{i=0}^{L-1} p(i, j) = 1 \quad (3.10)$$

Denklem 3.9 ve 3.10 RGB görüntülere uygulanmak istendiğinde sırasıyla Denklem 3.11 ve Denklem 3.12 elde edilmiştir.

$$p(i, j, k) = \frac{r_{i,j,k}}{n \times m}, 0 \leq i \leq L, \quad 0 \leq j \leq L, \quad 0 \leq k \leq L \quad (3.11)$$

$$\sum_{k=0}^{L-1} \sum_{j=0}^{L-1} \sum_{i=0}^{L-1} p(i, j, k) = 1 \quad (3.12)$$

Bu yaklaşımla, resim üzerindeki tüm piksellerin frekansları ve ağırlıkları hesaplanabilir.

3.2. Makine Öğrenmesi

Makine öğrenmesi terimi, verilerin bilgiye dönüştürülebilmesi için tahmin yaparak kendi kendini geliştirebilen yapay zekanın alt alanı olarak ortaya çıkmıştır. Bu alanda 20. yüzyılın ikinci yarısı başlayan çalışmalar teknolojiye yaşanan gelişmelerle birlikte günden güne artarak devam etmiştir. Büyük miktarda veriyi analiz etmek için insan gücünü kullanmak yerine

geliştirilen makine öğrenmesi algoritmaları ile çok daha hızlı tahmin yaparak sonuç elde etmektedir. Bunun yanında makine öğrenimi genel performansı iyileştirmek veya daha başarılı tahminlerde bulunmak için deneyimi kullanan algoritmalar olarak da adlandırılabilir. Buradaki deneyim kelimesi toplanan ve hazır hale getirilen ve algoritmalara sunulan işlemlerin tümünü ifadesidir denilebilir.

Makine öğrenimi alanının gelişmesi için yapılan çalışmalar algoritmaların tahmin başarısını ve verimliliğini arttırmaya yönelik yapılan çalışmalardır. Bilgisayar bilimlerindeki diğer alanlar gibi makine öğrenmesi alanının da kritik ölçüleri zaman ve mekan karmaşıklığıdır. Her öğrenme algoritmasının başarısı kullanılan veri setine bağlıdır. Bu yüzden doğası gereği makine öğrenimi veri analizi ve istatistikle doğrudan ilgilidir. Algoritmaların öğrenme teknikleri, istatistik, olasılık ve optimizasyondan gelen temel ile birleştirilen veriye dayanmaktadır.

Makine öğrenim algoritmaları günümüzde birçok alanda kullanılmaktadır. E-posta, web araması, sosyal medya gibi uygulamalarda tavsiye sistemi, filtreleme, reklam yerleştirme, cümle tamamlama veya dolandırıcılık tespiti gibi ihtiyaçlar için tercih edilmektedir. Bunun yanında sağlık uygulamalarında hastalık teşhisi koymakta veya bankacılık sisteminde kredi başvurusu değerlendirme gibi pek çok alanda uygulanmaktadır. Günümüzde en çok dikkat çeken uygulamalar ise Apple firmasının ürünü olan Siri, Google firmasının ürünü olan GoogleAssistan gibi uygulamalardır.

Makine öğrenmesi algoritmaları için birçok dil kullanılmaktadır. Python, R, Matlab, Scala gibi diller ağırlıklı olarak kullanılmakla birlikte farklı dillerde bu amaçla kullanılabilmektedir.

Genel olarak makine öğrenmesi algoritmaları veri setinin uygunluğuna göre iki ayrı sınıfa ayrılmaktadır. Bu sınıflardan birisi verilerin çıkış etiketlerinin belirli olduğu ve algoritmanın yeni tahminlerini bu etiketli verilere göre yaptığı gözetimli öğrenme ve veri setindeki verilerin etiketlenmeden algoritmanın verileri kümeleyerek yeni gelen verileri tahmin ettiği gözetimsiz öğrenmedir (Hussein vd., 2019: 1777).

Gözetimli öğrenmede eğitim için kullanılacak veriler algoritmaya sunulmadan önce etiketlenmelidir. Gözetimli öğrenmenin etiketi bilinmeyen yeni veriler için, önceden etiketlenmiş verileri kullanarak bir eğitim modeli oluşturmaktır. Gözetimli makine öğrenme algoritmaları temelde, sınıflandırma ve regresyon problemlerini çözmeye odaklanır.

Makine öğrenmesi algoritmaları yalnızca sayısal verilerle çalışmaktadır. Bu sebepten görüntü veya ses gibi verileri ön işlemlerden geçirilerek makine öğrenmesi algoritmaları için hazırlanmalıdır (Rong, 2017: 81).

Gözetimsiz öğrenme, veri setinin etiketlenmeden algoritmaya verildiği makine öğrenmesi tekniğidir. Öğrenici algoritma yalnızca etiketlenmemiş verilerle görünmeyen tüm noktalar için tahminde bulunur. Gözetimsiz öğrenme kümeleme, boyut azaltma gibi problemlerde kullanılır. Gözetimsiz öğrenmenin amacı birbirine benzeyen verileri kümeleyerek ayırmaktır.

Bu çalışmada beton numunelerinin basınç dayanımları makine öğrenmesinin tahmin sınıflarından biri olarak belirlenmiştir. Gözetimli öğrenme tekniklerinden sınıflandırma ile beton numunelerinin dayanımları tahmin edilmiştir.

Sınıflandırma, belirli bilgi düzenlemesini sınıflara ayırmak için verilen bilgi odaklarının sınıfını tahmin etmekle başlar. Buradaki sınıf yerine hedef, etiket gibi terimlerde kullanılmaktadır. Bu sınıflar verinin türüne göre ve hedeflenen tahmine göre değişmektedir (Bruzzone ve Persello, 2010: 3720).

Yaygın kullanılan sınıflandırma algoritmalarına örnek olarak KNN, DVM, Karar Ağaçları, Rasgele Ormanlar gibi algoritmalar örnek verilebilir.

Bu çalışmada popüler olan sınıflandırma algoritmalarından KNN ve DVM algoritmaları, veri seti ile eğitilerek tahmin başarıları gözlemlenmiştir.

3.2.1. K En Yakın Komşuluk (KNN)


KNN sınıflandırılmak istenen veriyi, etiketli verilere olan yakınlık derecesine göre sınıflandıran makine öğrenme algoritmasıdır. Sınıflandırma için yeni gelen verinin ve eğitim verilerinin özneliliklerini inceler (Soucy ve Mineau, 2001: 647). Sınıflandırma uygulamalarının yanında regresyon uygulamalarında da sıklıkla kullanılmaktadır (Pinto vd., 2018: 1). En eski yöntemlerden olmasına rağmen kullanımının kolay olması ve başarılı tahmin sonuçları vermesinden dolayı günümüzde popüler olarak kullanılmaktadır.

KNN, gözetimli etiketli verilerle çalıştığı için gözetimli öğrenme algoritmalarındandır. Yeni vakaları tespit etmek için tüm mevcut verilerle olan ilişkisini gözlemler. Algoritma çalıştırılmadan önce belirlenen K sayısı kadar komşuluk, yeni gelen verilerin etiketlenmesinde belirleyici olan faktördür. Algoritma en yakın K sayısı kadar komşuyu belirler ve yeni veriyi

en çok komşunun olduğu sınıfa atar. Burada seçilen K değeri, tahmin edilen sınıflarda eşit sayıda sonuç çıkmaması için tek sayıda seçilmelidir.

KNN eğitim sonucunda test verileri için kullanılabilecek bir model oluşturmaz. Her yeni gelen veri için tüm veri setini tekrar kullanır. Bu nedenle tembel (lazy) algoritmalarındandır. Bu özelliği KNN'in büyük verilerle tahmin yaparken yavaş tahmin yapmasına neden olur.

Şekil 3.4'te KNN algoritması için bir örnek verilmiştir. Bu örnekte yeşil ve mavi olarak işaretlenen iki ayrı sınıftan oluşan veri setinin değerlerinin kartezyen noktalara göre yerleri işaretlenmiştir. Sarı olarak işaretli sınıfı belli olmayan yeni bir veri, KNN algoritması ile sınıflandırılmak istenmektedir. Algoritmanın komşuluk sayısı 3 alındığında, algoritma en yakın 3 komşusundan en çok verisi olan sınıfa yeni gelen veriyi atayacaktır. Veriler incelendiğinde en yakın birinci komşu yeşil etiketli ve en yakın ikinci komşu yeşil ve mavi etiketlidir. Algoritma en çok komşunun olduğu yeşil sınıfa yeni gelen veriyi atayacaktır. Her yeni veri geldiğinde bu işlemler tekrar edilecektir. Algoritma çalıştırılmadan önce uygun komşuluk değerinin belirlenmesi için veriler gözden geçirilmelidir. K değerinin büyütülmesi daha çok komşuya bakarak sonucu kesinleştirebileceği gibi bazı veri setlerindeki gürültüden dolayı tahmin başarısını düşürebilir.




Şekil 3.4. KNN Çalışmasına Örnek

KNN, veriler arasında ölçüm yaparken farklı ölçüm teknikleri kullanır. Bu tekniklere metrik adı verilir. Farklı metrikler kullanarak verilere en uygun ölçüm tekniği seçilebilir.

Bu metriklerden en bilineni Öklid metriğidir. Kartezyen koordinat sisteminde X ve Y verileri arasındaki mesafeyi ölçme prensibine dayanır. Denklem 3.13'te Öklid mesafesini ifade eden eşitlik verilmiştir.

$$d_{(x,y)} = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (3.13)$$

Yaygın olarak kullanılan diğer metrik ise Manhattan mesafesidir ve taksi mesafesi ya da şehir blokları olarak da adlandırılır. Adını Manhattan şehrinin caddelerine benzeyen ölçüm tekniğinden almıştır. Şekil 3.5'te de görüldüğü gibi bu metrik ölçüm yaparken düz çizgiler şeklinde ölçüm yapmaktadır. Kartezyen koordinatlarındaki iki noktanın mutlak farklarını toplar.



Şekil 3.5. Manhattan Metriği Ölçüm Örneği

Denklem 3.14'te bu metriği ifade eden eşitlik verilmiştir.

$$d = \sum_{i=1}^n |X_i - Y_i| \quad (3.14)$$

Bir diğerk metriks olan Minkowski mesafesi, n boyutlu uzaydaki iki nokta arasında bulunan mesafenin ölçümüdür. Gerçek değerli vektör uzaylarında çalışması için hazırlanmış bir metriktir. Yalnızca normlu vektör uzayında hesaplamalar yapabilir. Denklem 3.15'te Minkowski metriğini ifade eden eşitlik verilmiştir.

$$d(X, Y) = \left(\sum_{i=1}^n |x_i - y_i|^p \right)^{\frac{1}{p}} \quad (3.15)$$

Eşitlik incelendiğinde Minkowskinin genelleştirilmiş mesafe metriği olduğu görülecektir. İki nokta arasındaki mesafeyi hesaplariken Denklem 3.15'teki p=1 Manhattan mesafesini ifade ederken, p=2 Öklid mesafesini ifade etmektedir. Yine p=∞ iken ise Chebyshev mesafesinin eşitliği olduğu görülür.

İki ayrı ikili(binary) veri dizisini karşılaştırmak için Hamming mesafesi kullanılır. Eşit uzunluktaki iki veri dizisinin karşılaştırılmasında başarılı sonuçlar verdiği görülmektedir. Denklem 3.16'da Hamming mesafesini ifade eden eşitlik verilmiştir.

$$d_H(a, b) = \{j: a_j \neq b_j, j = 0, 1, \dots, n - 1\} \quad (3.16)$$

Cossine mesafesi ise, iki vektör arasındaki benzerliği bulma temeline dayanmaktadır. İki vektör arasında bulunan açının kosinüsü hesaplanır. Bu işlem iki vektörün aynı yönü gösterip göstermediğini belirler. Denklem 3.17'de Cossine mesafesini ifade eden eşitlik verilmiştir.


$$\cos \theta = \frac{A \cdot B}{||A|| \cdot ||B||} \quad (3.17)$$

Veri setinin türüne göre komşuluk sayısının belirlenmesi gerektiği gibi ölçüm yapılacak metriğinde belirlenmesi gerekmektedir. Metriklerin başarımı veri setine olan uyumları ile doğrudan alakalıdır.

3.2.2. Destek Vektör Makinesi

DVM, yüksek boyutlu ve gürültü içeren verileri sınıflandırmadaki başarısı nedeniyle popülerlik kazanmıştır. DVM, istatistiksel bir sınıflandırma yöntemidir. Temel olarak iki sınıfa ait verileri birbirinden en uygun şekilde ayırma amacıyla tasarlanmıştır. Sınıflandırma yapmak için eğitim verilerinden faydalanan hiper düzlem çizgisi belirlenir (Osuna vd., 1997: 131). Test verileri bu düzlem çizgisinin hangi tarafında kaldığına göre sınıflandırma yapılır. En uygun hiper düzlemin çizgisinin bulunabilmesi hiper düzleme paralel ve sınırları oluşturan iki düzlem

çizgisi bulunur. Destek vektörleri bu düzlemi oluşturan noktalardır. Şekil 3.6’da DVM için çalışma görseli verilmiştir.



Şekil 3.6. Destek Vektör Makineleri Düzlemi

Şekil 3.6’da kare ve dairelerden oluşan iki sınıfa sahip bir veri setine ait görsel verilmiştir. DVM burada verileri ayıran hiper düzlemi bulmaya çalışır. Veriler arasında birden çok hiper düzlem bulunabilir. “Maksimum marj hiper düzlemi” konseptini temel alan DVM, verileri ayıran en iyi düzlemi seçer. Burada amaç her iki sınıfın verilerine de olabildiğince uzak ve dik bir düzlem seçebilmektir. Hiper düzlemlerin her biri, karar sınırına paralel olan, en yakın veri noktasından geçen destek hiper düzlemi çifti ile ilişkilidir. Destek hiper düzlemleri arasındaki mesafe “marj” olarak adlandırılır. Marj mesafesinin büyümesi bilinmeyen numunelerin sınıflandırılması aşamasında genelleme hatasını azaltmaktadır (Zhu vd., 2009: 1001).

Veri setinin doğrusal olarak ayrılabilirdiği durumlarda DVM için karar sınırının eşitliği Denklem 3.18’de verilmiştir.

$$w \cdot x + b = 0 \quad (3.18)$$

Bu eşitlikteki w ve x bilinmeyenleri vektördür ve w yönü doğrusal sınırına diktir. Eğitim seti kullanılarak vektör w belirlenir. Karar sınırının üstünde kalan herhangi bir x_i noktası için Denklem 3.19, karar sınırının altında kalan herhangi bir x_j noktası için ise Denklem 3.20’deki eşitlikler verilmiştir.

$$w \cdot x_i + b = y \quad \text{ise} \quad y > 0, \quad (3.19)$$


$$w \cdot x_j + b = y' \quad \text{ise} \quad y' < 0, \quad (3.20)$$

İki düzlem arasındaki mesafeyi ifade eden d marjı eşitliği ise Denklem 3.21 ve Denklem 3.22’de verilmiştir.

$$w \cdot (x_1 - x_2) = 2 \quad (3.21)$$

$$d = \frac{2}{\|w\|} \quad (3.22)$$

Doğrusal DVM, kolayca iki parçaya bölünebilen veri setlerinde başarılı çalışır. Buna karşılık karmaşık ve kolayca iki parçaya bölünemeyen veri setlerinde “Doğrusal Olmayan DVM” sınıflandırıcıları kullanmak gereklidir. Doğrusal DVM’ler bu veri setlerinde çalışırken doğrusal bir hiper düzlem çizemez. Doğrusal olmayan DVM’ler temel olarak veri kümesini doğrusal bir karar sınırı kullanarak verilerin ayrılabilirliği yüksek boyutlu alanlara dönüştürmeyi amaçlar. Ancak bu dönüştürme işleminde sınıflandırmanın karmaşıklığının artması asıl sorundur. Bunun yanında verileri daha yüksek boyutlu uzayda ayırabilen haritalama işlevi kesin olarak bilinmemektedir. Bu sorunu aşmak için verileri daha yüksek boyutlu uzaya dönüştürürken “çekirdek” olarak adlandırılan bir kavramdan faydalanılmıştır (Moorthi vd., 2011: 107). Şekil 3.7’de doğrusal olarak ayrılamayan veri setine örnek verilmiştir.



Şekil 3.7. Doğrusal Olarak Ayrılamayan Veri Seti

DVM algoritmaları, farklı veri setlerini sınıflandırırken farklı çekirdek olarak tanımlanan bir dizi matematiksel işlemde faydalanır. Çekirdek, girdi olarak veri setini alır ve DVM için kullanılacak forma dönüştürür. Farklı DVM algoritmaları için kullanılabilecek farklı çekirdek fonksiyonları vardır. Doğrusal, doğrusal olmayan, polinom, radyal temel işlevi (RBF) ve sigmoid gibi çekirdek fonksiyonları bulunmaktadır.

3.2.3. Sınıflandırma Başarımı Kriteri

Makine öğrenmesi algoritmalarında, tahmin başarısını ölçmek için sınıflandırma başarımları kullanılır. Popüler sınıflandırma başarımları kriterlerinden olan karışıklık matrisi bu çalışmada makine öğrenmesi algoritmalarının sonuçlarını incelemek için kullanılmıştır.

Karışıklık matrisi, gerçek değerlerin bulunduğu sınıflandırma modeli veya algoritmalarının başarımları gösteren tablodur (Ravikumar ve Saraf, 2020: 2). Makine öğrenmesinin kullanıldığı sınıflandırma modellerinin başarımları değerlendirmek için hedeflenen sonuçlara ait gerçek ve tahmin değerlerinin karşılaştırıldığı hata matrisi olarak da adlandırılabilir. Karışıklık matrisi, sınıflandırma sonuçlarını tahmin ve gerçekleşen, doğru veya yanlış olmasına göre 4 sınıfa ayırmaktadır. Şekil 3.8’de karışıklık matrisi için sınıflandırma etiketleri gösterilmiştir.

		TAHMİN	
		DOĞRU	YANLIŞ
GERÇEK	DOĞRU	TP	FN
	YANLIŞ	FP	TN

Şekil 3.8. Karışıklık Matrisi Sınıflandırma Tablosu

Şekil 3.8’de iki sınıftan oluşan bir modelin sınıflandırma başarımları örnek olarak verilmiştir. Tablodaki TP (TruePositive), veri setinde 1 olarak etiketlenen ve tahmin sonucu doğru atanan verilerin sayısını ifade eder. TN (TrueNegative) ise veri setinde 0 olarak etiketlenen aynı zamanda model tarafından da 0 olarak atanan verilerin sayısını ifade eder. TP ve TN modelin sınıflandırması sonucunda olması gereken sınıflara atanan verilerin tamamıdır. Bunun yanında FP (FalsePositive) gerçek değeri 0 olmasına rağmen modelin atamasının 1 olduğu verilerin sayısını ifade eder. FN (FalseNegative) ise veri setinde 1 olarak etiketlenen verilerin tahmin modelinin sonunda 0 olarak atananlarının sayısını ifade eder.

Denklem 3.23’te veri setinin toplam veri sayısını gösteren eşitlik verilmiştir.

$$Toplam = TP + TN + FP + FN \quad (3.23)$$

Gerçek doğruların sayısı ve gerçek yanlışların sayısı sırası ile Denklem 3.24 ve Denklem 3.25'te verilmiştir.

$$Gerçek Pozitifler = TP + FN \quad (3.24)$$

$$Gerçek Negatifler = TN + FP \quad (3.25)$$

Karışıklık matrisinin gösterdiği “Gerçek Pozitifler” sayısının artması sınıflandırma modelinin başarımının artmasını ifade ederken “Gerçek Negatifler” sayısının artması da modelin başarımının azalmasını ifade eder. Bu verilerden yola çıkarak modelin başarımını gösterecek olan “Doğruluk Oranı”, “Hata Oranı”, “Duyarlılık Oranı” ve “Özgünlük Oranı” ölçümleri yapılabilmektedir. Doğruluk oranı, hata oranı, duyarlılık oranı ve özgünlük oranı eşitlikleri sırasıyla Denklem 3.26, Denklem 3.27, Denklem 3.28 ve Denklem 3.29'da verilmiştir.

Doğruluk oranı, doğru yapılan sınıflandırmaların toplam sayıya bölümü ile bulunur. Esas köşegenin toplamı olarak da bilinir.

$$Doğruluk Oranı = \frac{(TP + TN)}{TOPLAM} \quad (3.26)$$

Hata oranı, yanlış yapılan sınıflandırmaların toplam sayıya bölümü ile bulunur. Yedek köşegenin toplamı olarak da bilinir.

$$Hata oranı = \frac{(FP + FN)}{TOPLAM} \quad (3.27)$$

Karışıklık matrisin sonuçlarından yola çıkarak modelin pozitif tahmin etmesi gereken değerlerden ne kadarının pozitif tahmin edildiğini gösteren “Gerçek Pozitif Değerlerin Oranı” ölçülebilir. Aynı zamanda “Duyarlılık” olarak da adlandırılmaktadır. Başarımlı modellerde yüksek çıkması beklenir. 0 ile 1 arasında bir değer olmalıdır. Denklem 3.28'de modelin duyarlılığını ifade eden eşitlik verilmiştir.

$$Duyarlılık = TP/(TP + FN) \quad (3.28)$$


Modelin pozitif olarak tahmin ettiği değerlerin ne kadarının gerçekten pozitif olduğunu ölçebilen “Kesinlik” değeridir. Denklem 3.29'da modelin Kesinlik değerini ifade eden eşitlik verilmiştir.

$$Kesinlik = TP/(TP + FP) \quad (3.29)$$

Veri setlerinin daha çok sınıf içerdği durumlarda karışıklık matrisinin kapsamı genişletilerek modelin başarımı incelenir.

3.3. Derin Öğrenme

Derin öğrenme, belirli bir veri kümesinin sonuçlarını tahmin edebilen yapay sinir ağının çok sayıda veri ile eğitilmesini sağlar. Daha büyük veri ve daha karmaşık yapay zeka algoritmalarıyla çalışılmasına olanak sağlar. Derin öğrenme, insan beynini taklit eden ve görsel nesne tanıma, konuşma tanıma, sinyal sınıflandırma gibi birçok alanda kullanılabilen Yapay Sinir Ağlarını (YSA) içerir. YSA, mevcut verileri analiz eden ve bu verilerden yeni bilgiler oluşturan bir bilgi işleme yapısıdır.



Şekil 3.9. Basit YSA Yapısı

Tipik bir YSA, bir veya daha fazla düğüm (nöron) içeren giriş katmanı, gizli katman ve çıkış katmanından oluşur. Nöronların yapılarını içeren YSA mimarisi Şekil 3.9'da gösterilmektedir. Nöronlar arasındaki her bağlantı, ağırlık adı verilen sayısal bir değerle ilişkilendirilir. Bu sayede verilerin nöronlar üzerindeki etkileri istenildiği gibi ayarlanabilmektedir. Yapay nörona gelen veri bir sonraki nörona ulaşmadan önce bağlantıların

ağırlıkları ile çarpılır ve aktivasyon fonksiyonuna iletilir. Aktivasyon fonksiyonu olmayan bir sinir ağı sınırlı öğrenmeye sahip olacaktır. Aktivasyon fonksiyonu kullanılarak sinir ağının lineer olmayan durumlarda öğrenilmesi sağlanır. Temel olarak, ağı gönderilen verilerin (sinyaller, resimler vb.) özelliklerini algılamak için kullanılan giriş katmanı ve çıkış katmanı sonuç değerlerini hesaplar (Okwu ve Tartibu, 2021: 133).

3.3.1. TensorFlow

TensorFlow derin öğrenme için geliştirilmiş bir matematik kütüphanesidir. Açık kaynak kodlu bir kütüphanedir. Makine öğrenmesi algoritmalarının altında geliştiği için geleneksel makine öğrenme algoritmalarını da desteklemektedir. Temelinde Python ile geliştirilse de C++, C#, Java, R gibi diller içinde desteği vardır.

3.3.2. Keras

Keras, derin öğrenme kütüphanesidir. TensorFlow üzerinde çalıştırılmak üzere tasarlanmıştır. Popüler derin öğrenme mimarilerini desteklemektedir. Derin öğrenme mimarileri tasarlamak için gereken modüller Keras ile tanımlanabilir (Karabay, 2020).

Giriş Katmanı: Veri girişlerini kabul eden ve ardından ağırlıklı toplamını hesaplayan katmandır. Giriş verisinin büyüklüğü, yığın (batch) sayısı gibi veriler bu katmanda modele bildirilir.

Gizli Katman: Verilerin herhangi bir gizli özelliğini bulmak için, ağırlıkların toplamını, bir önyargı uygulayan aktivasyon fonksiyonu girişi olarak aktarmak için kullanılır ve nöronun tetiklenip tetiklenmeyeceğini belirler.

Çıkış Katmanı: Son katman olarak da bilinen bu katman, gerçek çıktı ile kontrast oluşturan tahmin edilen çıktıyı sağlar.

Nöron: Nöronlar, insan beynindeki hücrelerden esinlenerek üretilmiş, katmanlardaki hücreleri temsil eden yapılardır. Katmanlardaki nöronlar, diğer katmandaki nöronlara ağırlıklarla bağlanır. Veriler yardımıyla ağırlıklar güncellenir ve model eğitilmiş olur.

Yığın (Batch): Yığın boyutu, güncellemelerden sonra ağı verilen veri miktarıdır. Tüm veriyi aynı anda mimariye vermek maliyetli bir işlemdir. Veriler yığın sayısı kadar bölünerek mimariye sunulur.

Tur (Epoch): Veri setinin üzerinden her geiş epoch olarak adlandırılır. Mimarının eęitiminde belirtilen tur sayısı kadar tekrar yapılır. Her eęitimde mimari aęırlıklarını gncelleyerek başarısını arttırmaya alışır.

Aktivasyon Fonksiyonu: Katmanların girdileri, aęırlık deęerleri ile iřlendikten sonra bařka bir katmana gemeden nce aktivasyon fonksiyonu ile deęerlendirilir. Aktivasyon fonksiyonu ile belirlenen deęer bařka bir katmanın giriři veya mimarının ıkıřı olabilir. İlgili katmanda aktivasyon fonksiyonu uygulanmazsa doęrusal bir ıkıř elde edilir.

Tablo 3.1’de Keras ktphanesi ile kullanılan aktivasyon fonksiyonlarından bazıları verilmiřtir.

Tablo 3.1. Keras ile Kullanılan Aktivasyon Fonksiyonlarından Bazıları

Aktivasyon Fonksiyonu	Denklem	Aralık
ReLU	$f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases}$	$[0, \infty)$
Sigmoid	$f(x) = \sigma(x) = \frac{1}{1 + e^{-x}}$	$(0, 1)$
Softmax	$f_i(x) = \frac{e^{x_i}}{\sum_{j=1}^n e^{x_j}}$	$[0, 1]$
Softplus	$f(x) = \ln(1 + e^x)$	$(-1, 1)$


Optimizasyon Algoritmaları: Derin ęrenme algoritmalarında optimizasyon algoritmalarının amacı, kayıpları azaltma ve mmkn olan en iyi sonuları vermektir. AdaGrad, Adam, Nadam, RMSDrop popler optimizasyon algoritmalarındandır.

4. DENEYSEL ÇALIŞMALAR

Bu çalışmada, otomatik üretim teknolojisine uygun betonların basınç dayanım tahminlerini yapmak amacıyla makine öğrenmesi ve derin öğrenme algoritmalarının uygunluğu araştırılmıştır. Otomatik üretim teknolojisine uygun beton karışım oranları daha önce yapılmış bir çalışmadan alınarak deney numuneleri üretilmiştir (Toklu vd., 2016: 56). Ayrıca kullanılan karışım oranları, görüntü işleme tekniklerinin başarımını araştırmak amacı ile agrega dane çapı, çimento oranı ve lif kullanımı değişkenlerini içeren 24 farklı karışım oranına sahip 192 adet küp numune hazırlanmıştır. Şekil 4.1’de yapılan çalışmanın akış şeması gösterilmiştir.

Çalışmada ilk olarak algoritmaların eğitimi ve test için deney numuneleri üretilcektir. Numuneler hazırlandıktan sonra, numunelerin görüntülerinin elde edilmesi ve ön işleme adımları vardır. Ön işleme adımları tamamlandıktan sonra görüntülerden öznitelik çıkarımı yapılacaktır. Öznitelik verileri hem makine öğrenme algoritmalarında hem de derin öğrenme ile test edilmiştir. Çalışmanın son adımında algoritmaların sonuçları karşılaştırılacaktır.

Bütün beton görüntülerinin fotoğraflaması yapıldıktan sonra numuneler beton presinde kırılarak beton basınç dayanım sonuçları elde edilmiştir. Bu basınç dayanım sonuçlarına göre betonlar sınıflandırılmıştır.



Şekil 4.1. Çalışmanın Akış Şeması

4.1. Kullanılan Veri Seti

Bu bölümde, çalışmada kullanılan veri seti için gereken beton numunelerinin hazırlanması sunulmuştur. Gerekli beton numuneler, Bilecik Şeyh Edebali Üniversitesi İnşaat Mühendisliği Bölümü Laboratuvarında hazırlanmıştır. Bu beton numuneleri 10x10x10cm küp boyutlarındadır. Hazırlanan numunelerin malzeme karışım oranlarının alındığı çalışmada

(Toklu vd., 2016: 56) 42.5 R tipi çimento, 0-2mm dane dağılımına sahip, BG-002 kirli beyaz flux kalsine edilmiş diatomit, 0-2mm, 2-4mm, 4-8mm boyutlarında dane dağılımına sahip doğal agrega, 380-650 MPa dayanımına sahip polipropilen lif, Tunçbilek Termik Santralinden elde edilmiş uçucu kül ve şehir şebekesi suyu kullanılmıştır. Şekil 4.2’de otomatik üretim teknolojisine uygun bir taze beton örneği verilmiştir.



Şekil 4.2. Otomatik Yapı Üretimine Uygun Olarak Hazırlanmış Taze Beton Örneği

Otomatik beton üretimine uygun hazırlanan beton numunelerinde farklı parametreleri sağlayabilmek için polipropilen ve uçucu kül miktarı değişken olarak belirlenmiştir. Uçucu kül ilaveli karışımlarda karışıma eklenen uçucu kül miktarı kadar çimento azaltılarak uçucu külün beton basınç dayanımına etkisi sağlanmıştır. Diğer değişken miktarını belirleyen polipropilen lif ise, hazırlanan numunelerin yarısına sabit miktarlarda eklenmiş, diğer yarısına ise eklenmemiştir.

Bu çalışma için farklı karışımlara ve farklı agrega boyutlarına sahip beton numunelerinden 192 adet üretilmiştir. Tablo 4.1, Tablo 4.2 ve Tablo 4.3’te bu beton numunelerine ait karışım oranları verilmiştir.

Tablo 4.1. 0,5-2mm Agrega Çapına Sahip Beton Numunelerinin Karışım Oranları (kg/m³)

64 Adet Küp Numune	Numune Kodu	Numune Sayısı	Çimento Dozajı	Agrega	Diatomit	Su	Uçucu Kül	Polipropilen Lif
1. Grup	U0L0	8	580	400	300	460	0	0
2. Grup	U1L0	8	516	400	300	460	26	0
3. Grup	U2L0	8	460	400	300	460	52	0
4. Grup	U3L0	8	402	400	300	460	78	0
5. Grup	U0L1	8	580	400	300	460	0	3
6. Grup	U1L1	8	516	400	300	460	26	3
7. Grup	U2L1	8	460	400	300	460	52	3
8. Grup	U3L1	8	402	400	300	460	78	3

Tablo 4.2. 2-4mm Agrega Çapına Sahip Beton Numunelerinin Karışım Oranları (kg/m³)

64 Adet Küp Numune	Numune Kodu	Numune Sayısı	Çimento Dozajı	Agrega	Diatomit	Su	Uçucu Kül	Polipropilen Lif
1. Grup	U0L0	8	580	400	300	460	0	0
2. Grup	U1L0	8	516	400	300	460	26	0
3. Grup	U2L0	8	460	400	300	460	52	0
4. Grup	U3L0	8	402	400	300	460	78	0
5. Grup	U0L1	8	580	400	300	460	0	3
6. Grup	U1L1	8	516	400	300	460	26	3
7. Grup	U2L1	8	460	400	300	460	52	3
8. Grup	U3L1	8	402	400	300	460	78	3

Tablo 4.1 ve Tablo 4.2’de görüldüğü gibi agrega boyutu 0,5-2 mm ve 2-4 mm olan gruplarda aynı oranda su ve bağlayıcı kullanılmıştır. Bu iki grup için de slump deneyi ile ilgili sonuçlara uygun şekilde yapılmış, (TS EN 12350-2) sonuçlar otomatik yapı teknolojisine uygun şekilde 2 cm’den az gelmiştir. Ancak 4-8 mm olan agrega boyutu olan grupta yapılan ilk denemeler sonucunda slump deney sonuçlarının yüksek çıkması sonucunda su düzeltmesi yapılarak Tablo 4.3’teki karışım oranları kullanılmıştır.

Tablo 4.3. 4-8mm Agrega Çapına Sahip Beton Numunelerinin Karışım Oranları (kg/m³)

64 Adet Küp Numune	Numune Kodu	Numune Sayısı	Çimento Dozajı	Agrega	Diatomit	Su	Uçucu Kül	Polipropilen Lif
1. Grup	U0L0	8	384	400	250	310	0	0
2. Grup	U1L0	8	345	400	250	310	38	0
3. Grup	U2L0	8	308	400	250	310	76	0
4. Grup	U3L0	8	267	400	250	310	114	0
5. Grup	U0L1	8	384	400	250	310	0	3
6. Grup	U1L1	8	345	400	250	310	38	3
7. Grup	U2L1	8	308	400	250	310	76	3
8. Grup	U3L1	8	267	400	250	310	114	3

Tablo 4.3'te kullanılan karışım oranları sonucunda otomatik yapı teknolojisine uygun akışkanlıkta beton harcı elde edilmiştir.

Beton karışımları laboratuvar betoniyer kullanılarak TS1247'ye uygun olacak şekilde hazırlanmıştır. 10x10x10 küp kalıplar temiz bir yağ ile yağlanmıştır. Hazırlanan numuneler bu kalıplara yerleştirilmiştir. Kalıplardaki betonlar 24 saat 22 ± 1 °C sıcaklığındaki kür havuzunda bekletilmiştir. Kür havuzunda 7 gün bekletilen numunelerin kurutulması yapıldıktan sonra görüntüleme işlemine geçilmiştir (TS1247 2018). Şekil 4.3'te hazırlanan betonların bir kısmı kurutulma aşamasında görülmektedir.



Şekil 4.3. Çalışmada Kullanılan Beton Numunelerinden Örnekler


Elde edilen deney numunelerini fotoğraflamak için Şekil 4.4'te verilen düzenek hazırlanmıştır. Bu düzenek Nikon N90 model fotoğraf makinesi ve tripod yardımıyla

oluřturulmuřtur. Nikon N90 modeli 12Mp özünürlüęe sahip 4288x2848 piksel ekim yapabilen bir fotoęraf makinesidir.



řekil 4.4. Numune Görüntülerini Elde Etmek İçin Hazırlanan Düzenek

Farklı karışımlarla hazırlanmış 192 beton numunesinin her birinin 4 yanal yüzeyi görüntülenerek 768 adet görüntü verisi elde edilmiştir. Bu görüntü verilerinden beton görüntüsü harici arka planı kaldırılmıştır. řekil 4.5'te arka planı kaldırılmış beton numunelerinden 2 tanesi verilmiştir.




řekil 4.5. Arka Plan Görüntüsünden Arındırılmış Beton Numunesi

Beton numunelerini görüntüleme aşamasından sonra TS EN 12390-3'e uygun olacak şekilde beton basın deneyleri yapılmıştır. řekil 4.6'da beton basın testleri için kullanılan test cihazının görüntüsü verilmiştir.



Şekil 4.6. Beton Basınç Test Cihazı

3 farklı agrega dane çapıyla içerisindeki uçucu kil ve lif katkıları değiştirilerek toplamda 24 farklı beton grubu oluşturulmuştur. Her gruptan 8'er adet numune üretilmiştir. Her grubun numunelerin test edildikten sonra ortalama basınç dayanımları Grafik 4.1'de verilmiştir.



Grafik 4.1. Beton Grupları Ortalama Basınç Dayanımları a) 0,5-2 mm b) 2-4mm c) 4-8mm

Beton basınç dayanım ortalamaları incelendiğinde farklı oranlardan oluşan betonların farklı dayanım ortalamalarına sahip olduğu görülmüştür.

Betonların basınç değerlerini tespit etmek için 3 sınıf belirlenmiştir. 17MPa üstü basınç dayanımına sahip olan betonlar 1. Sınıfa, 17MPa altı ve 11MPa üstü basınç dayanımına sahip betonlar 2. Sınıfa, 11MPa altı basınca sahip olanlar 3. Sınıfa atanmıştır.

4.2. Makine Öğrenmesi ile Beton Basınç Dayanımı

Bu bölümde beton numunelerinden elde edilen görüntü verilerinin makine öğrenmesi algoritmaları için kullanımı anlatılmıştır. Makine öğrenmesi algoritmalarını çalıştırmak için Acer i5 8300H işlemci ve 16GB RAM kapasitesine sahip bilgisayar kullanılmıştır. Kullanılan dil olarak PYTHON 3.7 tercih edilmiştir.

Elde edilen beton görüntüleri makine öğrenmesi algoritmaları için ön işlem adımlarında işlenmiştir. İlk olarak beton görüntülerinden numune fotoğrafları haricindeki arka plan görüntüleri kaldırılmıştır.

Bu aşamaya kadar görüntü verileri RGB olarak adlandırılan 3 kanal renkten oluşmaktadır. Bu görüntüler, makine öğrenmesi algoritmaları için tek boyutlu vektörle ifade edilebilen gri seviyeli görüntülere dönüştürülmüştür. Ayrıca görüntü veri seti boyutunu arttırabilmek için tüm görüntüler 16 eşit parçaya bölünmüştür. Bu aşama sonucunda görüntü veri seti $768 \times 16 = 12288$ veriden oluşmaktadır.


Gri seviyeye dönüştürülmüş ve 16 eşit parçaya bölünmüş bu görüntüler eğitim ve test için rasgele bölünmüştür. Eğitim için verilerin %80'i ayrılırken kalan %20'lik veri bölümü test için ayrılmıştır. Eğitim için ayrılan verilerin beton basınçlarına göre sınıf etiketlendirmesi yapılmıştır.

Görüntülerin öznitelik çıkarımı için popüler olan GLCM ve görüntüdeki veri dağılımını veren histogram tekniklerinden faydalanılmıştır. GLCM ve histogram yöntemleri kullanılarak makine öğrenmesi için görüntü öznitelikleri elde edilmiştir. GLCM ile her bir görüntüden 4×6 boyutlarında özellikler çıkartılmıştır. Elde edilen bu öznitelikler ile beton görüntüleri üzerindeki dokulara ait bilgilere ulaşılmıştır. Histogram ile görüntüdeki veri dağılımı elde edilerek 1×256 boyutlu vektörler elde edilmiştir.

Bu çalışma için seçilen popüler makine öğrenme algoritmalarından KNN ve DVM algoritmaları kolay uygulanmasına rağmen başarılı sonuçlar verebilmektedir. Yüksek konfigürasyon istemeyen bilgisayarlarda dahi kolaylıkla çalıştırılabilmektedir. İki farklı teknikte elde edilen öznitelikler KNN ve DVM algoritmalarında eğitim için kullanılmış, yine test verilerinden elde edilen öznitelikler ise algoritmaların tahmin başarısını gözlemlemek için kullanılmıştır.

4.2.1. KNN

KNN algoritmasında ilk olarak GLCM ile elde edilen öznitelik verileri test edilmiştir. Algoritmanın verilerdeki başarımını gözlemlemek için popüler metriklerden olan Öklid, Manhattan, Minkowski ve Cosine olmak üzere 4 farklı metrik test edilmiştir. Her metrikte komşuluk sayıları 3'ten 15'e kadar test edilmiştir. Her komşuluk ve metrik için eğitim ve test verileri rastgele aynı oranlarda yeniden seçilerek algoritma 100 defa koşturulmuş ve başarımları olarak bu 100 koşmanın ortalamaları alınmıştır. Grafik 4.2'de KNN algoritmasının metrik ve adım sayılarının ortalama başarımları verilmiştir.



Grafik 4.2. GLCM-KNN Doğruluk Oranları (%)

Yapılan deneyler sonucu oluşan Grafik 4.2 incelendiğinde algoritmanın metrik ve komşuluk sayılarına göre başarımın değiştiği gözlemlenmiştir. Beton görüntülerinin GLCM öznitelik çıkarım sonuçlarına göre en iyi tahmini yapan metrik “Cosine” metriği olmuştur. Yaklaşık olarak %88,44'lük tahmin başarımını 11 komşuluk sayısında vermiştir.

Test edilen diğer metriklerden olan “Minkowski” metriği ise Cosine metriğine yakın bir tahmin başarımında bulunmuştur. En yüksek tahmin başarımı 15 komşuluk sayısında %87,12 olarak ölçülmüştür. Geriye kalan metriklerden “Öklid” metriği ise en başarılı tahmin oranını 13 komşuluk sayısında yaklaşık %84,22 olarak vermiştir. Son metrik olan “Manhattan” metriği ise 9 komşuluk sayısında %83,43'lük başarıya ulaşabilmiştir.

KNN ile sınıflandırma başarımını ölçmek için Tablo 4.4'te verilen karışıklık matrisinden faydalanılmıştır. Karışıklık matrisinde en başarılı sonucu veren “Cosine” matrisinin 11 komşuluk sayısındaki sınıflandırma başarısı ölçülmüştür. Bunların haricinde Denklem 4.1, 4.2, 4.3 ve 4.4'te sırasıyla doğruluk, hata oranı, kesinlik ve duyarlılık ölçütleri de kullanılarak sonuçlar irdelenmiştir.

Tablo 4.4. GLCM-KNN Karışıklık Matrisi

Tahmin \ Gerçek	X>23	14<X<23	X<14
X>23	5138 %68,1	2366 %84,04	41 %0,54
14<X<23	2305 %2,64	73328 %84,03	11626 %13,32
X<14	76 %0,05	11995 %7,94	138925 %92,01

$$\text{Doğruluk Oranı} = \%88,44 \quad (4.1)$$

$$\text{Hata oranı} = \%11,56 \quad (4.2)$$


$$\text{Kesinlik} = 0,8140 \quad (4.3)$$

$$\text{Duyarlılık} = 0,8138 \quad (4.4)$$

Karışıklık matrisi gerçek değerlerin bilindiği tahmin sonuçlarında, sınıflandırma algoritmasının başarımını ölçmek için kullanılan tablodur. Bu tablodan yola çıkarak sonuçlar incelendiğinde modelin en başarılı tahminleri 14Mpa altı basınç değerine sahip betonlarda yaptığı görülmüştür. En başarısız tahmini ise 23Mpa üstü basınç değerine sahip betonlarda yapmıştır.

Beton numunelerinden elde edilen görüntüler için histogram yöntemi kullanılarak öz nitelik veri seti çıkartılmıştır. Histogram ile elde edilen öz nitelik verileri KNN algoritmasında popüler olan 4 metrik için komşuluk sayıları 3'ten 15'e kadar olan tek sayılarda test edilmiştir. Her parametre için 100'er tekrar alınmış, bu 100 tekrarın ortalaması değişkenlerin tahmin

başarımını gözlemlemek için kullanılmıştır. Grafik 4.3'te histogram verilerinin KNN algoritmasında sınıflandırıldıktan sonra elde edilen grafik verilmiştir.



Grafik 4.3. Histogram-KNN Doğruluk Oranları (%)

Histogram ile elde edilen öznelik verileri yukarıda bahsedilen 4 metrikte komşuluk sayıları 3'ten 15'e kadar test edilmiştir. Grafik 4.3'te bu test işleminin sonuçları gösterilmiştir. Grafik incelendiğinde algoritmanın en iyi başarı tahmin oranının K=9 ile %86,53 başarı sağlayan Öklid olduğu görülmüştür. En yüksek ikinci başarı tahmin oranını elde eden Minkowski metriği ise 7 komşuluk sayısında %85,6 tahmin başarısına ulaşmıştır. Diğer metriklerden olan Cosine 3 komşuluk sayısında %85,37 başarıya ulaşırken, Manhattan metriği ise 3 komşuluk sayısında %81,45 oranında başarı elde etmiştir.

Tablo 4.5'te verilen histogram verilerinin KNN algoritmasındaki başarımlarını gösteren karışıklık matrisi (Confusion Matrix) incelendiğinde yine en yüksek başarımlı sınıflandırmanın 14Mpa altı basınç dayanımına sahip beton verilerinde olduğu görülmektedir. En az başarımlarını gösteren sınıf yine 23Mpa üstü sınıftır. Ancak histogramdan elde edilen özneliklerin GLCM'ye göre daha az başarımlı gözlemlendiği de gözükmemektedir. Buna bağlı olarak bütün sınıfların başarımları düşmüştür. Denklem 4.5, 4.6, 4.7 ve 4.8'de sırasıyla doğruluk, hata oranı, kesinlik ve duyarlılık ölçütleri de kullanılarak sonuçlar irdelenmiştir.

Tablo 4.5. Histogram-KNN Karışıklık Matrisi

Tahmin Gerçek	X>23	14<X<23	X<14
X>23	4938 %65,43	2567 %34,01	42 %0,55
14<X<23	2317 %2,55	70330 %80,6	14610 %16,74
X<14	75 %0,05	13496 %8,94	137425 %91,01

$$\text{Doğruluk Oranı} = \%86,53 \quad (4.5)$$

$$\text{Hata oranı} = \%13,47 \quad (4.6)$$


$$\text{Kesinlik} = 0,7972 \quad (4.7)$$

$$\text{Duyarlılık} = 0,7901 \quad (4.8)$$

4.2.2. DVM

DVM veri setlerini doğrusal düzlemlere bölerek tahmin çalışması yapar. Doğrusal olmayan veri setlerini doğrusal düzlemlere dönüştürerek bölebilmek için farklı çekirdek fonksiyonlarını kullanırlar. Farklı veri setleri için farklı çekirdek fonksiyonları seçilmelidir. Bu çalışmada GLCM ve histogram teknikleri ile elde edilen veri setleri kullanılarak DVM algoritmasının en iyi başarımı verdiği çekirdek fonksiyonunun bulunması hedeflenmiştir.

Grafik 4.4'te GLCM ile üretilen öznitelik verilerinin DVM algoritmasında farklı çekirdek fonksiyonları kullanılarak elde edilen test sonuçları verilmiştir.



Grafik 4.4. GLCM-DVM Doğruluk Oranları

Grafik 4.4'te DVM algoritmasında kullanılan popüler çekirdek fonksiyonlarının betonların basınç dayanım sınıflandırma sonuçları karşılaştırılmıştır. Her çekirdek fonksiyonu için eğitim ve test verileri sırasıyla %80 ve %20 oranlarında rasgele bölünerek 100 tekrar yapılmış, bu tekrar eden işlemlerin ortalaması sonuç olarak kabul edilmiştir. Sonuçlar incelendiğinde veri setini en başarılı bölebilen çekirdek fonksiyonunun %88,19 başarıyla RBF olduğu görülmüştür. RBF fonksiyonuna en yakın çekirdek fonksiyonu ise %87,29 başarıya ulaşan Poly olmuştur. Doğrusal olmayan veriler için kullanılan Sigmoid çekirdek fonksiyonu ile ancak %55,14 oranında başarı gösterebilmiştir. Lineer çekirdek fonksiyonu ise %75,72 oranında başarı göstermiştir. Yapılan testlerin sonuçları Tablo 4.6'daki karışıklık matrisinde incelenmiştir. Denklem 4.9, 4.10, 4.11 ve 4.12'de sırasıyla doğruluk, hata oranı, kesinlik ve duyarlılık ölçütleri de kullanılarak sonuçlar irdelenmiştir

Tablo 4.6. GLCM-DVM Karışıklık Matrisi

Tahmin Gerçek	X>23	14<X<23	X<14
X>23	5849 %76,52	1795 %23,48	0 %0
14<X<23	2974 %3,41	74765 %85,71	9494 %10,88
X<14	0 %0	14756 %9,78	136167 %90,22

$$\text{Doğruluk Oranı} = \%88,19 \quad (4.9)$$


$$\text{Hata oranı} = \%11,80 \quad (4.10)$$

$$\text{Kesinlik} = 0,8064 \quad (4.11)$$

$$\text{Duyarlılık} = 0,8415 \quad (4.12)$$

Tablo 4.6’da verilen GLCM verilerinin DVM algoritmasında sınıflandırmasını gösteren karışıklık matrisi irdelendiğinde verisi çok olan sınıfın KNN algoritmasında olduğu gibi daha başarılı tahmin edildiği görülmüştür. 14 MPa altı basınç değerlerine sahip olan betonların sınıflandırma başarısı %90,22 iken, 14MPa üstü ve 23MPa altı olan betonların sınıflandırması %85,71 son olarak da 23MPa üstü dayanıma sahip betonların sınıflandırması ise %76,52’lik başarıya ulaşmıştır.

Histogram ile elde edilen verilerin DVM algoritmasında sınıflandırma başarısı ölçülürken, GLCM’de olduğu gibi farklı çekirdek fonksiyonları test edilmiş, başarımları gözlemlenmiştir. Grafik 4.5’te histogram yöntemiyle elde edilen öznel verilerinin DVM algoritmasındaki sınıflandırma başarısını gösteren grafik verilmiştir.



Grafik 4.5. Histogram-DVM Doğruluk Oranları

Her Çekirdek fonksiyonu için verilerin oranları değişmeyecek şekilde rasgele tekrar bölünmüş, çekirdek fonksiyonunun başarımı için bu tekrarların ortalaması alınmıştır. Sonuçlar incelendiğinde RBF çekirdek fonksiyonu %84,19 ile en başarılı çekirdek fonksiyon olurken, Lineer çekirdek fonksiyonu %81,86, Poly çekirdek fonksiyonu %76,21 ve Sigmoid çekirdek fonksiyonu %57,25 oranlarında başarıma ulaşabilmişlerdir.

Tablo 4.7’de histogram verilerinin DVM algoritmasındaki başarımını incelemek için oluşturulan karışıklık matrisi verilmiştir. Denklem 4.13, 4.14, 4.15 ve 4.16’da sırasıyla doğruluk, hata oranı, duyarlılık ve özgünlük ölçütleri de kullanılarak sonuçlar irdelenmiştir.

Tablo 4.7. Histogram-DVM Karışıklık Matrisi

Tahmin Gerçek	X>23	14<X<23	X<14
X>23	3299 %42,46	4436 %57,11	33 %0,42
14<X<23	1200 %1,38	68660 %79,16	16880 %19,46
X<14	3 %0,001	16320 %10,79	134969 %89,21

$$\text{Doğruluk Oranı} = \%84,19 \quad (4.13)$$

$$\text{Hata oranı} = \%15,81 \quad (4.14)$$

$$\text{Kesinlik} = 0,7964 \quad (4.15)$$

$$\text{Duyarlılık} = 0,7028 \quad (4.16)$$

Tablo 4.5'te verilen histogram verilerinin DVM algoritmasında sınıflandırılmasını gösteren karışıklık matrisi incelendiğinde, önceki çalışmalar gibi verisi en çok olan sınıfın en başarılı sonuçları elde ettiği görülse de diğer modellere nazaran daha az başarımlı gösterdiği gözlemlenmiştir. 14Mpa altı basınç dayanımına sahip betonların sınıflandırılmasında %89,21, 14Mpa üstü ve 23Mpa altı basınç dayanımına sahip betonların sınıflandırılmasında %79,16 ve son olarak 23Mpa üstü basınç dayanımına sahip betonların sınıflandırılmasında %42,46'lık bir başarımlı gözlemlenmiştir. Histogram öznelilik verileri ile test edilen DVM algoritmasının başarımlı oranlarının diğer test sonuçlarına göre daha az başarımlı sağladığı gözlemlenmiştir.

4.3. Derin Öğrenme ile Beton Basınç Dayanımı

Beton numunelerinin elde edilen görüntülerin öznelilik çıkarımları yapıldıktan sonra elde edilen veriler derin öğrenme ile test edilmiştir. Önerilen modelin eğitim ve test çalışmalarının yapıldığı bilgisayar ACER NITRO-515 model 16GB RAM ve Intel I5 8300H model işlemciye sahip Microsoft Windows 10 işlemci üzerinde çalışan bilgisayardır. Model Python 3.9 dilinde yazılmış ve JETBRAINS firmasının Pycharm IDE'si ile kodlanmıştır.

Modelde Python için popüler derin öğrenme kütüphanelerinden olan Keras kütüphanesinden faydalanılmıştır. Keras Python 2.7 ve 3.10 arasındaki sürümler ile çalışabilir.

Model mimarisinin başarısını arttırmak için, 1 ve 2 numaralı katmanların nöron sayıları, aktivasyon fonksiyonları değiştirilmiştir. Bu değerlerin yanında modelin çalışacağı adım sayısı ve yığın sayısı değiştirilerek sonuçlar gözlemlenmiştir. Sonuçlar gözlemlenir iken mimarinin loss (kayıp) ve accuracy (doğruluk) değerleri göz önünde bulundurulmuştur.

Mimarinin eğitilmesi için veri seti %80 eğitim ve %20 test olarak bölünmüştür.

4.3.1. Nöron Sayılarının Belirlenmesi

İlk olarak mimarinin nöron sayıları belirlenmiştir. Tablo 4.8’de mimarinin nöron sayılarına göre değişimi gösterilmiştir. Nöron sayıları test edilirken mimarinin diğer değerleri sabit tutulmuştur.

Tablo 4.8. Nöron Sayılarının Belirlenmesi

Katman 1	50	100	100	200	200	400
Katman 2	50	50	100	100	200	200
Yığın	20	20	20	20	20	20
Tur	50	50	50	50	50	50
Aktivasyon Fonk.	Relu	Relu	Relu	Relu	Relu	Relu
Optimizer	Nadam	Nadam	Nadam	Nadam	Nadam	Nadam
Loss	0,26	0,28	0,31	0,26	0,27	0,31
Accuracy	%86,98	%87,06	%86,73	%86,93	%86,89	%86,85

Gizli katmanların nöron sayıları için farklı değerler denendikten sonra en doğru değerlerin ilk katman için 100, ikinci katman için 50 olduğu tespit edilmiştir.

4.3.2. Yığın Sayısının Belirlenmesi

İlk katmanın ve ikinci katmanın en iyi sonuç veren değerleri tespit edildikten sonra mimarinin yığın sayısı Tablo 4.9 da verilen değerlere göre test edilmiştir. Yığın sayısı tespit edilirken mimarinin diğer değerleri sabit tutulmuştur.

Tablo 4.9. Yığın Sayısının Belirlenmesi

Katman 1	100	100	100	100	100
Katman 2	50	50	50	50	50
Yığın	10	12	15	20	25
Tur	50	50	50	50	50
Aktivasyon Fonk.	Relu	Relu	Relu	Relu	Relu
Optimizör	Nadam	Nadam	Nadam	Nadam	Nadam
Loss	0,24	0,24	0,25	0,28	0,25
Accuracy	%87,64	%88,10	%88,01	%87,05	%87,69

En başarılı yığın sayısını belirlemek için sırasıyla 10, 12, 15, 20 ve 25 değerleri test edilmiştir. En başarılı sonucun 12 değerinde elde edildiği tespit edilmiştir.

4.3.3. Tur Sayısının Belirlenmesi

Mimarinin en iyi başarımları sağladığı yığın değeri tespit edildikten sonra en başarılı tur sayısının tespit edilme adımına geçilmiştir. Tablo 4.10 da belirtildiği gibi tur sayıları 50, 100, 200, 400, 600 değerleri arasında değiştirilmiştir. Tur sayıları test edilirken mimarinin diğer değerleri sabit tutulmuştur.

Tablo 4.10. Tur Sayısının Belirlenmesi

Katman 1	100	100	100	100	100
Katman 2	50	50	50	50	50
Yığın	12	12	12	12	12
Tur	50	100	200	400	600
Aktivasyon Fonk.	Relu	Relu	Relu	Relu	Relu
Optimizer	Nadam	Nadam	Nadam	Nadam	Nadam
Loss	0,24	0,24	0,24	0,25	0,24
Accuracy	%88,10	%88,17	%88,69	%88,2	%87,79

Mimarinin en iyi sonucu için tur sayısının 200 olması gerektiği tespit edilmiştir.

4.3.4. Aktivasyon Fonksiyonun Belirlenmesi

Mimarinin en iyi başarımı 200 tur sayısında verdiği tespit edildikten sonra, aktivasyon sayısının belirlenmesi adımına geçilmiştir. Tablo 4.11 de belirtildiği gibi aktivasyon fonksiyonları değiştirilmiş ve algoritmanın başarımları ölçülmüştür. Aktivasyon fonksiyonu türleri test edilirken mimarinin diğer değerleri sabit tutulmuştur.

Tablo 4.11. Aktivasyon Fonksiyonunun Belirlenmesi


Katman 1	100	100	100	100
Katman 2	50	50	50	50
Yığın	12	12	12	12
Tur	200	200	200	200
Aktivasyon Fonk.	Relu	Sigmoid	Softmax	Softplus
Optimizer	Nadam	Nadam	Nadam	Nadam
Loss	0,24	0,24	0,242	0,25
Accuracy	%88,65	%90,12	%80,43	%88,90

Testler süresince derin öğrenme mimarisinin Loss ve Accuracy sonuçlarına göre başarımı gözlemlenmiştir. Elde edilen değerler sonucunda Tablo 4.12 de verilen değerlerin mimari için en uygun sonuçlar olduğu tespit edilmiştir.

Tablo 4.12. Beton Dayanım Tahmini İçin Belirlenen En Uygun Mimari

Katman 1 Nöron Sayısı	100
Katman 1 Aktivasyon Fonksiyonu	Sigmoid
Katman 2 Nöron Sayısı	50
Katman 2 Aktivasyon Fonksiyonu	Sigmoid
Çıkış Katmanı Nöron Sayısı	3
Çıkış Katmanı Aktivasyon Fonksiyonu	Softmax
Yığın	12
Tur	200
Optimizer	Nadam
Loss Fonksiyonu	categorical_crossentropy
Metrik	categorical_accuracy
Loss	0,24
Accuracy	%90,12

Şekil 4.7’de GLCM ile elde edilen verilerin test edildiği mimari modelinin yapısı verilmiştir.



Şekil 4.7. Derin Öğrenme Mimarisi

Mimarinin başarısını belirleyen temel değerler, GLCM ile elde edilen veri seti üzerinde test edilmiştir. Yapılan testler sonucunda mimarinin %90,12 değerinde başarıya ulaştığı gözlemlenmiştir. Mimari bu başarıya ulaşırken kayıp değeri ise 0,24'te kalmıştır.

Hazırlanan mimari histogram ile elde edilen öznitelik verileri ile test edilmiştir. Histogram ile elde edilen öznitelik verileri ile test edildiğinde başarı oranı %83,07'ye düşmüş, loss değeri 0,65'e yükselmiştir.

5. TARTIŞMA VE SONUÇ

Teknolojinin gelişmesi ile yaygınlaşan otomatik yapı üretim teknolojisine uygun betonlar, klasik betonlara göre yeni bir alandır. İlerleyen zamanda hızlı ve sağlam yapılar için önemli bir noktada olacağı düşünülen bu teknoloji betonun kalitesini değerlendirme en önemli kriterlerden olan basınç dayanım testi için farklı çözümler tartışılmaktadır.

Klasik betonlarda, betonun mukavemeti için uygulanan tahribatlı ölçüm yöntemlerinin, otomatik üretim yapı teknolojisinde kullanılan betonlarda kullanılamaması, bu betonların dayanımlarını öğrenmek için farklı teknikler geliştirilmesini gerektirmektedir.

Bu çalışmada, otomatik yapı üretim teknolojisine ait betonlar için, son yıllarda popülerleşen makine öğrenmesi ve derin öğrenme yöntemleri ile betonun basınç dayanımını tahmin edebilmek için yeni yöntemler araştırılmıştır.

Makine öğrenmesi ve derin öğrenme algoritmalarının başarımını gözlemlemek için otomatik yapı üretim teknolojisine uygun beton numuneleri hazırlanmıştır. Eğitim ve test veri setlerinin oluşturulması için 192 adet beton numunesi üretilmiştir. Numuneler üretilirken otomatik yapı üretim teknolojisine uygun agrega boyutları seçilmiştir. Agrega boyutları değiştirilerek 3 farklı beton grubu oluşturulmuş bu gruplarda kendi içlerinde karışım oranları değiştirilerek 8 farklı grup oluşturulmuştur. Böylelikle algoritmayı eğitmek için farklı türdeki beton verileri elde edilmiştir.

Klasik betonların dayanımları 28 gün kürlendikten sonra test edilmektedir. Çalışmada test edilen beton numuneleri ise otomatik yapı üretim teknolojisine uygun olarak 7 gün kürlendirilip test edilmiştir. Kürlenme süresindeki bu kısalma numunelerin basınçlarının klasik betonlara oranla daha düşük çıkmasına sebep olmuştur.

Çalışmada kullanılan algoritmaların koşturulma süreleri ölçümlenmiştir. Yapılan ölçümler sonucunda her algoritmanın çalışma süreleri Tablo 5.1’de verilmiştir.

Tablo 5.1: Algoritmaların Kořturulma Sreleri

ALGORİTMA	SRE
KNN	0,68 Saniye
DVM	5,5 Saniye
DERİN ÖĞRENME	137 Saniye

Tablo 5-1’de algoritmaların bir tekrar iin geen kořturulma sreleri verilmiřtir. Kořturulma sreleri incelendiėinde KNN algoritmasının diėer algoritmalarından daha kısa srede tamamlandığı grlr.

Yapılan alıřmalar sonucunda veri seti ile test edilen algoritmaların tahmin bařarım sonuları Tablo 5.2’de verilmiřtir.

Tablo 5.2. Algoritmaların Tahmin Bařarımları

Tahmin Gerek	GLCM	HİSTOGRAM
KNN	%88,44	%86,53
DVM	%88,19	%84,19
Derin Öėrenme	%90,12	%83,07

Yapılan alıřma sonucunda en bařarılı sonucun GLCM verileriyle eėitilen Derin Öėrenme algoritmasıyla elde edildiėi gzlemlenmiřtir. Grntnn dokularına odaklanan GLCM’nin, grntnn renk daėılımına odaklanan histogram karřısında daha iyi sonular elde ettiėi grlmřtir. Bunun nedeni histogramın ıktı boyutunun GLCM’den fazla olması ve algoritmaların eėitim sırasında girdi boyutunun ařırı olmasına sebep olmasıdır. Ařırı girdi eėitim sresini uzatmakla beraber bařarım oranını da dřrmektedir.

Yapılan testler sonucunda Derin Öėrenme algoritması ile %90,12 oranında tahmin bařarımı elde edilmiřtir. Makine ėrenmesi algoritmalarından olan KNN ile %88,44 tahmin

başarı elde edilirken, çalışmada kullanılan diğer algoritma olan DVM ile %88,19 oranında tahmin başarımı elde edilmiştir.

Yapılan testlerde gözlemlendiği gibi verilerin arttırılması algoritmaların başarısına doğrudan etki etmektedir. Gelecekteki çalışmalarda, numune sayısı ve numune türlerinin arttırılması ile daha başarılı tahmin sonuçları elde edilmesi hedeflenmektedir.



KAYNAKÇA

- Bashawyah, D. A., & Qaisar. S., M.** (2021). Machine Learning Based Short-Term Load Forecasting for Smart Meter Energy Consumption Data in London Households, 99–102. DOI: 10.1109/ELIT53502.2021.9501104.
- Beysolow, T.** (2017). Introduction to Deep Learning. *Introduction to Deep Learning Using R* 1–9. DOI: 10.1007/978-1-4842-2734-3_1.
- Breysse, D.** (2012). Nondestructive Evaluation of Concrete Strength: An Historical Review and a New Perspective by Combining NDT Methods. *Construction and Building Materials*, 33, 139–63. DOI: 10.1016/J.CONBUILDMAT.2011.12.103.
- Bruzzone, L., & Persello, C.** (2010). Recent Trends in Classification of Remote Sensing Data, Active and Semisupervised Machine Learning Paradigms. *International Geoscience and Remote Sensing Symposium (IGARSS)* 3720–23. DOI: 10.1109/IGARSS.2010.5651236.
- Bujang, S. D. A., vd.** (2021). Multiclass Prediction Model for Student Grade Prediction Using Machine Learning. *IEEE Access* 9:95608–21. DOI: 10.1109/ACCESS.2021.3093563.
- Cha, Y. J., Choi, W., & Büyüköztürk. O.** (2017). Deep Learning-Based Crack Damage Detection Using Convolutional Neural Networks. *Computer-Aided Civil and Infrastructure Engineering* 32(5):361–78. DOI: 10.1111/MICE.12263.
- Chang, S, Cohen, T., & Ostdiek. B.** (2018). What Is the Machine Learning? *Physical Review D* 97. DOI: 10.1103/PhysRevD.97.056009.
- Chen, N., vd.** (2022). Virtual Mix Design: Prediction of Compressive Strength of Concrete with Industrial Wastes Using Deep Data Augmentation. *Construction and Building Materials* 323:126580. DOI: 10.1016/J.CONBUILDMAT.2022.126580.
- Doğan, G., Arslan, M. H., & Ceylan, M.** (2017). Concrete compressive strength detection using image processing based new test method. *Measurement*, 109, 137-148.
- Erkan, U., Gökrem, L.** (2018). A new method based on pixel density in salt and pepper noise removal. *Turkish Journal of Electrical Engineering and Computer Sciences*, 26(1), 162–171. <https://doi.org/10.3906/ELK-1705-256>
- Gajula, A. K., vd.** (2021). Prediction of Crop and Yield in Agriculture Using Machine Learning Technique. 1–5. DOI: 10.1109/ICCCNT51525.2021.9579843.

- Haralick, R., M., Dinstein, I., & Shanmugam. K.** (1973). Textural Features for Image Classification. *IEEE Transactions on Systems, Man and Cybernetics* SMC-3(6):610–21. DOI: 10.1109/TSMC.1973.4309314.
- Suzan H., vd.** (2021). Students' Adaptability Level Prediction in Online Education Using Machine Learning Approaches. 1–7. DOI: 10.1109/ICCCNT51525.2021.9579741.
- Biao, H., vd.** (2019). Object Detection and Trcacking Based on Convolutional Neural Networks for High-Resolution Optical Remote Sensing Video.” *International Geoscience and Remote Sensing Symposium (IGARSS)* 5433–36. DOI: 10.1109/IGARSS.2019.8898173.
- Huang, T. W., vd.** (2017). Age Estimation from Brain MRI Images Using Deep Learning. *Proceedings - International Symposium on Biomedical Imaging* 849–52. DOI: 10.1109/ISBI.2017.7950650.
- Sarfaraz, H., vd.** (2019). Lung and Pancreatic Tumor Characterization in the Deep Learning Era: Novel Supervised and Unsupervised Learning Approaches. *IEEE Transactions on Medical Imaging* 38(8):1777–87. DOI: 10.1109/TMI.2019.2894349.
- Ismail, Q. F., vd.** (2021). Using Machine Learning Algorithms to Predict the State of Financial Inclusion in Africa. *2021 12th International Conference on Information and Communication Systems (ICICS)* 317–23. DOI: 10.1109 / ICICS52457.2021.9464590.
- Jena, L., Behera, S. K., & Sethy, P. K.** (2021). Identification of Wheat Grain Using Geometrical Feature and Machine Learning. *2021 2nd International Conference for Emerging Technology, INCET 2021*. DOI: 10.1109/INCET51464.2021.9456281.
- Jha, A. K., vd.** (2020). Evaluation of Factors Affecting Compressive Strength of Concrete Using Machine Learning. *Proceedings- 2020 Advanced Computing and Communication Technologies for High Performance Applications, ACCTHPA 2020* 70–74. DOI: 10.1109/ACCTHPA49271.2020.9213199.
- Kabay, N, & Aköz, F.** (2003). Yapıda Beton Kalitesinin Tahribatlı ve Tahribatsız Yöntemlerle Belirlenmesi. *TMMOB İnşaat Mühendisleri Odası XVII.Teknik Kongresi*.
- Kang, S. M., vd.** (2019). Real Time Image Processing System for Detecting Infrastructure Damage: Crack. *2019 IEEE International Conference on Consumer Electronics, ICCE 2019*. DOI: 10.1109/ICCE.2019.8661830.
- Karabay, A.** (2020). Keras Nedir? | Karabay Yazılım [Erişim 26.03.2020, <https://www.karabayyazilim.com/blog/keras-nedir-2020-02-08-225241>].

- Katarya, R., & Jain, S.** (2020). Comparison of Different Machine Learning Models for Diabetes Detection. *Proceedings of 2020 IEEE International Conference on Advances and Developments in Electrical and Electronics Engineering, ICADEE 2020*. DOI: 10.1109/ICADEE51157.2020.9368899.
- Katarya, R., & Srinivas, P.** (2020). Predicting Heart Disease at Early Stages Using Machine Learning: A Survey. *Proceedings of the International Conference on Electronics and Sustainable Communication Systems, ICESC 2020* 302–5. DOI: 10.1109/ICESC48915.2020.9155586.
- Keleş, M. K., Keleş, A. E., & Kılıç, Ü.** (2019). Prediction of Concrete Strength with Data Mining Methods Using Artificial Bee Colony as Feature Selector. *2018 International Conference on Artificial Intelligence and Data Processing, IDAP 2018*. DOI: 10.1109/IDAP.2018.8620905.
- Khoshnevis, B., vd.** (2013). Advances in Contour Crafting Technology for Extraterrestrial Settlement Infrastructure Buildup. *AIAA SPACE 2013 Conference and Exposition*. DOI: 10.2514/6.2013-5438.
- Küçükaslan, B.** (2019) Keras kullanarak Türkiye gün öncesi elektrik piyasası piyasa takas fiyatı tahmini (*Yüksek Lisans Tezi*) *İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü*.
- Ly, H., vd.** (2021). Development of Deep Neural Network Model to Predict the Compressive Strength of Rubber Concrete. *Construction and Building Materials* 301:124081. DOI: 10.1016/J.CONBUILDMAT.2021.124081.
- Moorthi, S. M., vd.** (2011). Kernel Based Learning Approach for Satellite Image Classification Using Support Vector Machine. *2011 IEEE Recent Advances in Intelligent Computational Systems, RAICS 2011* 107–10. DOI: 10.1109/RAICS.2011.6069282.
- Materne, N., & Inoue, M.** (2018). IoT Monitoring System for Early Detection of Agricultural Pests and Diseases.” *Proceedings - 12th SEATUC Symposium, SEATUC 2018*. DOI: 10.1109/SEATUC.2018.8788860.
- Mezei, J., Luukka, P. & Collan, M.** (2017). Similarity of Histograms and Circular Histograms from Interval and Fuzzy Data.” *IFSA-SCIS 2017- Joint 17th World Congress of International Fuzzy Systems Association and 9th International Conference on Soft Computing and Intelligent Systems*. DOI: 10.1109/IFSA-SCIS.2017.8023257.

Mou, A. D., vd. (2021). A Comprehensive Study of Machine Learning Algorithms for Predicting Car Purchase Based on Customers Demands. *2021 International Conference on Information and Communication Technology for Sustainable Development, ICICT4SD 2021-Proceedings* 180–84. DOI: 10.1109/ICICT4SD50815.2021.9396868.

Mukherjee, G., Chatterjee, A. & Tudu, B. (2016). Study on the Potential of Combined GLCM Features towards Medicinal Plant Classification. *2016 2nd International Conference on Control, Instrumentation, Energy and Communication, CIEC 2016* 98–102. DOI: 10.1109/CIEC.2016.7513746.

Nwankpa, C. E., Eze, S. C., & Lijomah, W. (2020). Deep Learning Based Visual Automated Sorting System for Remanufacturing. *IEEE Green Technologies Conference 2020-April*:196–98. DOI: 10.1109/GREENTECH46478.2020.9289823.

Okwu, M. O., & Tartibu L. K. (2021). Artificial Neural Network. *Studies in Computational Intelligence* 927:133–45. DOI: 10.1007/978-3-030-61111-8_14.

Osuna, E., Freund, R. & Girosi. F. (1997) Training Support Vector Machines: An Application to Face Detection. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition 1997*, s. 130-136, DOI: 10.1109/CVPR.1997.609310

Özen, M. (2007). Investigation of Relationship between Aggregate Shape Parameters and Concrete Strength Using Imaging Techniques. Orta Doğu Teknik Üniversitesi, Ankara

Özen, N. S., Saraç, S. & Koyuncu, M. 2021. COVID-19 Vakalarının Makine Öğrenmesi Algoritmaları ile Tahmini: Amerika Birleşik Devletleri Örneği. *European Journal of Science and Technology Special Issue* 22:134–39. DOI: 10.31590/ejosat.855113.

Paterakis, N. vd. (2017). Deep Learning versus Traditional Machine Learning Methods for Aggregated Energy Demand Prediction. *2017 IEEE PES Innovative Smart Grid Technologies Conference Europe, ISGT-Europe 2017 - Proceedings* 2018-January:1–6. DOI: 10.1109/ISGTEUROPE.2017.8260289.

Pinto, J. P., Kelur, S. & Shetty, J. (2018). Iris Flower Species Identification Using Machine Learning Approach. *2018 4th International Conference for Convergence in Technology, I2CT 2018*. DOI: 10.1109/I2CT42659.2018.9057891.

- Raju, L., vd.** (2021). Advanced Home Automation Using Raspberry Pi and Machine Learning. *Proceedings of the 7th International Conference on Electrical Energy Systems, ICEES 2021* 600–605. DOI: 10.1109/ICEES51510.2021.9383738.
- Rani, P.** (2019). Emotion Detection of Autistic Children Using Image Processing. *Proceedings of the IEEE International Conference Image Information Processing 2019-November*:532–35. DOI: 10.1109/ICIIP47207.2019.8985706.
- Ravikumar, S. & Saraf, P.** (2020). Prediction of Stock Prices Using Machine Learning (Regression, Classification) Algorithms. *2020 International Conference for Emerging Technology, INCET 2020*. DOI: 10.1109/INCET49848.2020.9154061.
- Ren, Y., Huang, S. & Zhou, Y.** (2021). Deep Learning and Integrated Learning for Predicting Student's Withdrawal Behavior in MOOC. *Proceedings- 2021 2nd International Conference on Education, Knowledge and Information Management, ICEKIM 2021* 81–84. DOI: 10.1109/ICEKIM52309.2021.00026.
- Rong, F.** (2017). Audio Classification Method Based on Machine Learning. *Proceedings- 2016 International Conference on Intelligent Transportation, Big Data and Smart City, ICITBS 2016* 81–84. DOI: 10.1109/ICITBS.2016.98.
- Roy, S., vd.** (2020). Deep Learning for Classification and Localization of COVID-19 Markers in Point-of-Care Lung Ultrasound. *IEEE Transactions on Medical Imaging* 39(8):2676–87. DOI: 10.1109/TMI.2020.2994459.
- Shi, X., & Dong Y.** (2011). Support Vector Machine Applied to Prediction Strength of Cement. *2011 2nd International Conference on Artificial Intelligence, Management Science and Electronic Commerce, AIMSEC 2011- Proceedings* 1585–88. DOI: 10.1109/AIMSEC.2011.6010708.
- Singh, G. & Goel, A. K.** (2020). Face Detection and Recognition System Using Digital Image Processing.” *2nd International Conference on Innovative Mechanisms for Industry Applications, ICIMIA 2020 - Conference Proceedings* 348–52. DOI: 10.1109/ICIMIA48430.2020.9074838.
- Sirohi, A. & Malik, A.** (2021). A Hybrid Model for the Classification of Sunflower Diseases Using Deep Learning. *Proceedings of 2021 2nd International Conference on Intelligent Engineering and Management, ICIEM 2021* 58–62. DOI: 10.1109/ICIEM51511.2021.9445342.

- Soucy, P. & Mineau, G. W.** (2001). A Simple KNN Algorithm for Text Categorization. *Proceedings - IEEE International Conference on Data Mining, ICDM* 647–48. DOI: 10.1109/ICDM.2001.989592.
- Toklu, Y. C., Çerçevik, A. E. & Şahinöz, M.** (2016). Otomatik Yapı Üretim Teknolojisinde Kullanılabilecek Malzemelerin Belirlenmesi. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi* 21(1):51. DOI: 10.19113/SDUFBED.73967.
- Towbin, A. J.** (2019). Collecting Data to Facilitate Change. *Journal of the American College of Radiology* 16(9):1248–53. DOI: 10.1016/J.JACR.2019.05.032.
- Vivaldi, N., vd.** (2021). Evaluating Performance of EEG Data-Driven Machine Learning for Traumatic Brain Injury Classification.” *IEEE Transactions on Biomedical Engineering* 68(11):3205–16. DOI: 10.1109/TBME.2021.3062502.
- Wang, P.** (2020). Research and Design of Smart Home Speech Recognition System Based on Deep Learning.” *Proceedings- 2020 International Conference on Computer Vision, Image and Deep Learning, CVIDL 2020* 218–21. DOI: 10.1109/CVIDL51233.2020.00-98.
- Yang, F., vd.** (2013). Feature Extraction and Analysis on X-Ray Image of Xinjiang Kazak Esophageal Cancer by Using Gray-Level Histograms.” *ICMIPE 2013 - Proceedings of 2013 IEEE International Conference on Medical Imaging Physics and Engineering* 61–65. DOI: 10.1109/ICMIPE.2013.6864504.
- Yu, L., vd.** (2021). Accelerating Progressive Set Similarity Join with the CPU-GPU Architecture. *Big Data Research* 26:100267. DOI: 10.1016/J.BDR.2021.100267.
- Zeng, Z., vd.** (2022). Accurate Prediction of Concrete Compressive Strength Based on Explainable Features Using Deep Learning. *Construction and Building Materials* 329:127082. DOI: 10.1016/J.CONBUILDMAT.2022.127082.
- Zhang, P., Wang, P. & Xie, G.** (2021). Recognition of Building Health Status Based on Machine Learning Algorithm. *2021 IEEE Asia Conference on Information Engineering, ACIE 2021* 47–50. DOI: 10.1109/ACIE51979.2021.9381070.
- Zhu, J., vd.** (2009). An Effective Algorithm for Inverse Problem of SVM Based on MM Algorithm. *Proceedings of the 2009 International Conference on Machine Learning and Cybernetics* 2:1000–1004. DOI: 10.1109/ICMLC.2009.5212455.