

ULUSLARARASI 3B YAZICI TEKNOLOJİLERİ  
VE DİJİTAL ENDÜSTRİ DERGİSİ

INTERNATIONAL JOURNAL OF 3D PRINTING  
TECHNOLOGIES AND DIGITAL INDUSTRY

ISSN:2602-3350 (Online)

URL: <https://dergipark.org.tr/ij3dptdi>

## 3 BOYUTLU BASKIDA KULLANILACAK MALZEMENİN MAKİNE ÖĞRENMESİ TEKNİKLERİ İLE TAHMİNLENMESİ

PREDICTION OF THE MATERIAL TO BE USED IN 3D  
PRINTING WITH MACHINE LEARNING TECHNIQUES

Yazarlar (Authors): Onur Sevli \*

**Bu makaleye şu şekilde atıfta bulunabilirsiniz (To cite to this article):** Sevli O., “3 Boyutlu Baskıda Kullanılacak Malzemenin Makine Öğrenmesi Teknikleri İle Tahminlenmesi” *Int. J. of 3D Printing Tech. Dig. Ind.*, 5(3): 596-605, (2021).

DOI: 10.46519/ij3dptdi.1026694

Araştırma Makale/ Research Article

Erişim Linki: (To link to this article): <https://dergipark.org.tr/en/pub/ij3dptdi/archive>

# 3 BOYUTLU BASKIDA KULLANILACAK MALZEMENİN MAKİNE ÖĞRENMESİ TEKNİKLERİ İLE TAHMİNLENMESİ

Onur Sevli<sup>a</sup> 

<sup>a</sup> Burdur Mehmet Akif Ersoy Üniversitesi, Mühendislik Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, TÜRKİYE

\* Sorumlu Yazar: [onursevli@mehmetakif.edu.tr](mailto:onursevli@mehmetakif.edu.tr)

(Geliş/Received: 21.11.2021; Düzeltme/Revised: 09.12.2021; Kabul/Accepted: 23.12.2021)

## ÖZ

3 boyutlu (3D) baskı Endüstri 4.0'ın önde gelen ve hızla gelişen teknolojilerinden biridir. Sanal ortamda 3 boyutlu olarak modellenen cisimler 3 boyutlu yazıcılar kullanılarak farklı teknik ve malzemelerle hızlı şekilde prototiplenebilmektedir. 3D baskıda üretilen ürünün amaca uygun, mümkün olduğunca düşük maliyetli ve ideal şekilde dayanıklı olması beklenmektedir. Üretilen çıktının nitelikleri eldeki baskı teknolojisinin kısıtlarına bağlı olarak şekillenir. Ürünün niteliğini etkileyen diğer önemli bir unsur da baskı için kullanılacak olan malzemedir. Farklı teknik özellikler, dayanım ve kullanım alanları olan ABS ve PLA malzemelerden uygun olanın seçilmesi amaca uygun çıktının elde edilmesi noktasında önem taşımaktadır. Bu çalışmada 3D yazıcılara ait çeşitli ayar parametreleri ve üretilen ürünün niteliklerini ifade eden toplam 12 öznelikten oluşan bir veri seti üzerinde basım için kullanılacak malzemenin tahminlenmesine yönelik makine öğrenmesi temelli sınıflandırmalar gerçekleştirilmiştir. Destek Vektör Makinesi (DVM), K-En yakın Komşu (KNN), Karar Ağacı (KA), Rastgele Orman (RO) ve Lojistik Regresyon (LR) olmak üzere beş ayrı yöntemle ve 5 kat çapraz doğrulama ile gerçekleştirilen sınıflandırma işlemlerinde en yüksek doğruluk %100 olarak LR algoritması ile elde edilmiştir.

**Anahtar Kelimeler:** 3 Boyutlu Baskı. Makine Öğrenmesi. Baskı Malzemesi Seçimi.

## PREDICTION OF THE MATERIAL TO BE USED IN 3D PRINTING WITH MACHINE LEARNING TECHNIQUES

### ABSTRACT

3D printing is one of the leading and rapidly developing technologies of Industry 4.0. Objects modeled in 3D in the virtual environment can be quickly prototyped with different techniques and materials using 3D printers. The output produced in 3D printing is expected to be fit for purpose, cost-effective as possible, and ideally durable. The qualities of the output to be produced are shaped by the limitations of the available printing technology. Another important factor affecting the quality of the output product is the material to be used for printing. Selecting the appropriate ABS and PLA materials, which have different technical properties, strength and usage areas, is important in terms of obtaining appropriate outputs. In this study, machine learning-based classifications for the estimation of the material to be used for printing were carried out on a data set consisting of a total of 12 attributes expressing the various setting parameters of 3D printers and the qualities of the product to be produced. In classification processes performed with five different methods namely Support Vector Machine (DVM), K-Nearest Neighbor (KNN), Decision Tree (KA), Random Forest (RO) and Logistic Regression (LR), and 5 fold cross-validation, the highest accuracy was obtained as 100% with the LR algorithm.

**Keywords:** 3D Printing. Machine Learning. Printing Material Selection.

## 1. GİRİŞ

İmalat sektöründe giderek artan talepler karşısında firmaların rekabetçi güçlerini koruyabilmeleri için yenilikçi üretim yöntemlerine yönelmeleri büyük önem taşımaktadır. Hızlı prototipleme bu dönüşüm

sürecini yapılandırmaya katkı sağlayan önemli teknolojilerden biridir. Son dönemde endüstriyel alanda hızlı prototipleme tekniklerinin kullanımı giderek yaygınlaşmaktadır [1]. Bu tekniklerin en popülerlerinden biri olan 3 boyutlu (3D) baskı bilgisayar destekli konfigürasyon modeli ile üç boyutlu bir nesne oluşturmak için malzemelerin katman katman yığılmasına dayanan bir üretim yöntemidir [2]. Diğer bir ifadeyle 3D baskı, sanal ortamda üç boyutlu olarak tasarlanmış nesnelerin polimer, reçine, kompozit gibi malzemelerden; ısı ve kimyasal işlem süreçleri ile 3D yazıcılar kullanılarak üretilmesi sürecini ifade eder. 3D baskı yeni gelişen bir teknoloji olmasına rağmen pek çok alanda yaygın olarak kullanılmaktadır [3]. 3D baskı ile makine, otomotiv, mimari, savunma, uzay, sağlık gibi pek çok alanda hızlı üretimler geliştirilebilir. 3D yazıcılar ile üretim, katman kesitlerinin belirlenen çözünürlükte bir araya getirilmesi ile oluşan eklemeli bir süreçtir. Bu imalat modeli, ürünlerin üretim sürelerini ve aynı zamanda üretim maliyetini büyük ölçüde azaltacak bir potansiyele sahiptir.

3D yazıcı teknolojisinin gelişiminde büyük ölçekte kurumsal firmalardan daha çok bireysel girişimcilerin rolü büyüktür. Bu durum 3D baskı teknolojisinin farklı amaçlar doğrultusunda çeşitlenen bir yelpazede gelişmesine olanak sağlarken diğer yandan standartlaşmayı da zorlaştırmıştır. Bu nedenle sahada kullanılan farklı üretim biçimleri, farklı malzemeler ve çözümler mevcuttur. Bu farklılıktan dolayı 3D yazıcılar ile gerçekleştirilecek iş süreçlerinde amacın doğru şekilde belirlenerek uygun çözümlerin seçilmesi büyük önem taşımaktadır. Üretim amacının belirlenmesinin ardından ikinci önemli husus üretilecek çıktının niteliğine bağlı teknik kısıtların değerlendirilmesidir. Bu kısıtlar malzemenin sıcaklık, kırılma, nem gibi durumlara karşı dayanımı, malzemenin yüzey özellikleri, ürünün boyutuna bağlı olarak artan maliyeti, bu maliyeti ürün kalitesini bozmadan azaltma, baskı süresini minimuma indirme olarak sıralanabilir.

3D üretim sürecinde farklı teknikler kullanılmaktadır. Bu tekniklerin temel farklılığı katmanların nasıl oluşturulduğu ile alakalıdır. Bunlardan en çok tercih edileni Birleştirmeli Yığıma Modeli (Fused Deposition Modelling – FDM), 3D yazıcı yazdırma başının üç eksenli hareketine dayanan bir yığıma biçimidir. Yatay ekseni temel alan baş bölmesi polimer malzemeyi eriterek üçüncü eksende üst üste yığıma yolu ile katmanları oluşturur. Bu modelde en çok tercih edilen malzemeler Polilaktik Asit (PLA) ve Akrilonitril Butadin Stiren (ABS) isimli termoplastiklerdir.

3D yazıcılar ile üretim sürecinde ilk aşama üretilecek malzemenin modellenmesidir. Bu aşamada ihtiyaca uygun üç boyutlu modelleme yazılımlarından yararlanılır. Modelleme aşamasının ardından dilimleme işlemi uygulanır ve model 3D yazıcının işleyebileceği formda katmanlara bölünür. 3D üretim için gerekli pek çok parametre bu aşamada belirlenir. Bu parametreler şu şekilde sıralanabilir [4] :

- **Katman kalınlığı:** Üretim aşamasında Z eksenindeki hassasiyeti belirler.
- **Dolgu deseni:** Parçanın iç dolgu geometrisini belirler.
- **Dolgu miktarı:** Parçanın iç hacminin ne kadarının doldurulacağını belirler.
- **Hız ve sıcaklık:** Enjektörün (nozzle) ne kadar ısıtılacağı ve ne kadar hızda hareket edeceğini belirler. Bu parametre yazdırma için kullanılacak malzeme ve üretilecek parçanın geometrisine bağlı olarak değişiklik gösterir.

3D baskıda kullanılacak olan malzemenin seçimi önemli bir husustur. Piyasadaki pek çok 3D yazıcı hem ABS hem PLA ile üretim yapabilmektedir. Bu noktada bu iki malzemenin özellikleri ve kullanım alanları hakkında bilgi sahibi olarak bir seçim yapmak gereklidir. Bir petrol ürünü olan ABS hafif ama sert bir polimerdir. ABS'nin erime başlangıç sıcaklığı 105 °C olup, 80 °C sonrasında yumuşama ve bozulmalar oluşabilir. ABS ile üretilen malzemeler için ideal kullanım sıcaklığı 20 ile 80 °C arasındadır. ABS'nin dayanıklı ve darbe direncinin yüksek olması tercih edilme sebebidir. Ancak ABS'nin basım işlemi esnasında daha yüksek sıcaklık gerektirmesi kalibrasyon sürecini zorlaştırır.

PLA geri dönüştürülebilir kaynaklardan elde edilen bir malzemedir. Çevre dostu olan PLA farklı bileşenlerle karıştırılarak değişik görünümde ürünler elde edilebilir. PLA'nın ABS'ye göre dezavantajı mukavemeti ve darbe direncinin düşük olmasıdır. Ayrıca PLA'nın ısı altındaki dayanımı da daha düşüktür. Üretim işlemi esnasında bir fan yardımı ile soğutma uygulanarak yazım hızı artırılabilir. Isı ve ışığa karşı daha yüksek dayanım sağladığı için özellikle dış mekanda kullanılacak ürünlerde

ABS'nin tercih edilmesi daha uygundur. Ancak ABS yüksek sıcaklığa maruz kalınca zehirli HCN gazı çıkışına neden olmaktadır. Bu noktada PLA'nın çevre dostu özelliği ön plana çıkmaktadır. Ayrıca PLA insan vücudunda 6 aydan 2 yıla kadar uzayan parçalanma sürecine sahip olduğu için medikal uygulamalarda da tercih edilmektedir.

3D yazdırma işlemlerinde kullanılacak baskı malzemesinin seçimi üretilecek ürünün niteliği ve eldeki yazıcının teknik özellikleri ile yakından ilgilidir. Üretilen üründe ihtiyaç duyulan dayanım gücü, kullanım alanı, çevreye duyarlılık, parçanın kalitesi, katman kalınlığı, dolgu yoğunluğu ve deseni, boşluk oranı, baskı hızı, maliyet vb. pek çok parametre baskı için kullanılacak malzemenin seçimini etkilemektedir [5]. Tüm bu etkenlerin doğru biçimde değerlendirilip ideal malzemenin seçimi tecrübe gerektirmektedir. Bu süreci daha etkin hale getirmek için farklı karar destek mekanizmalarından yararlanmak daha doğru sonuçlar elde etmeye olanak sağlar. Farklı alanlarda kullanılan yapay zekâ teknolojileri imalat endüstrisine de alternatif çözümler sunmaktadır. Yapay zekânın bir alt dalı olan makine öğrenmesi üretim süreçlerini zaman, kalite ve maliyet açısından iyileştirmek için fırsatlar sağlamaktadır.

Literatürde 3D yazıcılar ile gerçekleştirilen üretim süreçlerinde makine öğrenmesi destekli farklı çalışmalar yapılmıştır. Makine öğrenmesi yöntemleri veriler üzerinden akıllı kararlar vermeye yönelik bilgi keşifleri gerçekleştirmeyi sağlar [6]. Makine öğrenmesi algoritmaları kullanılarak belli bir probleme çözüm üretmek için o probleme özgü veri setlerinin oluşturulması gerekmektedir. Ancak imalat sektöründe bu gibi veri setlerine ulaşmada yaşanan zorluk nedeniyle yapılan araştırmalar henüz yeterli düzeyde değildir. Literatürdeki çalışmalar genel anlamda üretim sürecini izlemeye yönelik uygulamalardır.

3D üretimde kalite izleme hala çözülmeyi bekleyen bir problemdir. Baskı işlemi sırasında oluşan hataların tespiti malzeme ve zaman kaybını engellemek açısından önemlidir. Oluşan hataların erken aşamada tespiti baskının durdurulması veya duraklatılarak hatanın düzeltilmesi için bir uyarı oluşturabilir. Delli ve Chang [7] gerçekleştirdikleri çalışmada 3D baskı işleminin belirli aşamalarında bir kamera ile aldıkları görüntüleri makine öğrenmesi ile analiz ederek üretilen parçanın kalitesi hakkında bir değerlendirmede bulunmuşlardır. Destek Vektör Makinesi (DVM) kullanılarak, üretilen parçalar “iyi” ya da “hasarlı” olarak sınıflandırılmıştır.

Li vd. [8] 3D baskılarda yüzey pürüzlülüğünü makine öğrenmesi algoritmaları kullanarak tahminlemeye yönelik bir çalışma gerçekleştirmişlerdir. Gerçek zamanlı durum izleme verilerini toplamak için çok sayıda sensör kullanmışlar ve frekans alanında bir dizi özellik çıkarımı yapmışlardır. Elde ettikleri bu özellikler üzerinde Rastgele Orman (RO) algoritması kullanarak önem derecesi yüksek özelliklerin seçimini gerçekleştirmişlerdir. Ardından Karar Ağacı (KA), RO, DVM, AdaBoost gibi farklı algoritmalar kullanarak tahminlemeler gerçekleştirmişler ve algoritmaların başarılarını ortalama karesel hata (RMSE) değerleri ile raporlamışlardır. Benzer bir çalışmada Wu vd. [9], RO modeli ile birlikte 10 kat çapraz doğrulama kullanarak hata değerini %5.9'a kadar düşürmüşlerdir.

Tripathi ve Singla [10], yazdırma sürecindeki çeşitli ayar parametreleri ile basılı ürünün pürüzlülüğü arasındaki ilişkiyi derin öğrenme yöntemi ile keşfetmeyi amaçlamışlardır. Baskının katman kalınlığı, dolgu yoğunluğu, enjektör sıcaklığı, duvar kalınlığı, yatak sıcaklığı, kullanılan malzeme, fan hızı, baskı hızı, dolgu deseni, uzama, çekme dayanımı gibi özellikleri arasındaki ilişki ortaya koyarak bunlar üzerinden nihai ürünün pürüzlülüğünün basım işlemi öncesinde Yapay Sinir Ağları (YSA) ile tanminlenmesi sağlamışlardır.

İmalat endüstrisinde yapay zekâ teknolojilerinin kullanımı üretim sürecin etkin yönetimi açısından pek çok avantajlar sağlamaktadır. Ancak makine öğrenmesi, derin öğrenme gibi yapay zekâ teknolojileri ile çözümler üretmek için programlama bilgisi ve tecrübesi gerekmektedir. Bu konuda imalat sektörü çalışan ve mühendislerinin yeteri kadar tecrübe sahibi olmaması ihtiyaca uygun karar destek sistemlerinin geliştirilmesini zorlaştırmaktadır. Bu soruna bir çözüm olarak Magar vd. [11] “ManufacturingNet” adını verdikleri bir araç geliştirmişlerdir. Bu araç imalat sektöründeki mühendislerin makine öğrenmesi modellerini kolaylıkla uygulayabilmelerine olanak sağlamaktadır.

3D yazıcılar ile üretilen parçalar dışarıdan aynı görünse de iç yapıları farklılık gösterebilir. 3D baskının önemli bir özelliği, parçaların değişen derecelerde dolguya sahip olarak üretilmesidir. Üretim açısından bakıldığında mümkün olduğu kadar az doluluk olması nihai ürünün ağırlığı yanı sıra kullanılan malzeme ve maliyeti azaltır. Ayrıca baskı zamanından da tasarruf sağlar. Ancak dolguda meydana gelen kusurlar malzemenin dayanıklılığını olumsuz etkileyebilmektedir. Wu vd. [12], 3D baskı işleminden elde ettikleri bir grup kusurlu ve kusursuz dolgu görüntüsünü kullanarak bir sınıflama gerçekleştirmişlerdir. Aynı veri seti üzerinde Naive Bayes sınıflandırıcı ile %85.26 doğruluk elde ederken, J48 Karar Ağaçları ile %95.51 doğruluğa ulaşmışlardır.

Benzer bir yaklaşımla 3D baskı işlemi esnasında oluşan kusurları tespit etmek için Khan vd. [13] derin öğrenme temelli ve gerçek zamanlı bir sistem önermişlerdir. Basım işlemi esnasında belirli aralıklarla çekim yapan bir kameradan elde ettikleri görüntüler üzerinde Evrimsel Sinir Ağları (Convolutional Neural Network - CNN) kullanarak gerçekleştirdikleri sınıflandırmalarda %76 ile %84 arasında değişen oranlarda doğruluk elde etmişlerdir.

Erişilebilir veri setlerinin azlığı 3D baskı konusunda gerçekleştirilen makine öğrenmesi temelli akademik ve pratik saha çalışmalarını kısıtlamaktadır. Literatürdeki pek çok çalışma baskı sürecinde ya da üretilen ürün üzerinde gerçekleştirilen izlemelerle hata veya kalite tespitine yönelik uygulamalardır. Bu çalışmada ise 3D üretim sürecinin önemli adımlarından biri olan baskı malzemesinin seçimi konusunda, eldeki yazıcının ve üretilen ürünün nitelikleri doğrultusunda, makine öğrenmesi teknikleri kullanılarak bir tahminleme uygulaması gerçekleştirilmiştir. Kamuya açık paylaşılan bir veri seti kullanılarak farklı yöntemlerle gerçekleştirilen sınıflandırmaların performansları raporlanarak karşılaştırılmıştır.

Çalışmanın takip eden bölümlerinde kullanılan veri setinin yapısı, kullanılan yöntemler, gerçekleştirilen sınıflandırma işlemine ait detaylar, elde edilen bulgular ve sonuçlar yer almaktadır.

## 2. MATERYAL VE METOT

### 2.1. Veri Seti

Çalışmada kullanılan 3D yazıcı (3D printer– 3DP) veri seti Selçuk Üniversitesi Makine Mühendisliği bölümünde yürütülen bir araştırmanın sonucu olarak elde edilmiş ve kamuya açık şekilde paylaşımına sunulmuştur [12]. Veri seti içerisinde 3D yazıcıya ait çeşitli ayar parametreleri, kullanılan malzeme, elde edilen ürünün kalitesi ve dayanıklılığını ifade eden toplam 12 adet öznitelik ve 50 örnek yer almaktadır. Veri setindeki değerler Ultimaker S5 3-D yazıcı ayarlarına ve filamentlerine dayanmaktadır. Malzeme ve mukavemet testleri ise 20 kN çekme kapasitesine sahip bir Sincotec GMBH test cihazında gerçekleştirilmiştir. Veri setini oluşturan öznitelikler ve açıklamaları Çizelge 1’de verilmiştir.

Çizelge 1. Veri setinde yer alan öznitelikler

Öznitelik Adı	Açıklama	Türü
Layer Height	Katman yüksekliği (mm)	Sayısal – sürekli
Wall Thickness	Duvar kalınlığı (mm)	Sayısal – sürekli
Infill Density	Doluluk oranı (%)	Sayısal – sürekli
Infill Pattern	Doluluk Deseni	Kategorik
Nozzle Temperature	Enjektör sıcaklığı (°C)	Sayısal – sürekli
Bed Temperature	Yatak sıcaklığı (°C)	Sayısal – sürekli
Print Speed	Baskı hızı (mm/s)	Sayısal – sürekli
Fan Speed	Fan hız oranı (%)	Sayısal – sürekli
Roughness	Yüzey pürüzlülüğü (µm)	Sayısal – sürekli
Tensile (ultimate) Strength	Nihai çekme dayanımı (MPa)	Sayısal – sürekli
Elongation	Kopma noktasına kadar esneme oranı (%)	Sayısal – sürekli
Material	Baskı için kullanılan malzeme	Kategorik

Çizelge 1’de yer alan doluluk deseni ve malzeme dışındaki öznitelikler sayısal türde değerlerden oluşmaktadır. Doluluk deseni ızgara (grid) ve bal peteği (honeycomb) olmak üzere iki farklı değer

içermektedir. Benzer şekilde malzeme özneteliği de ABS ve PLA olmak üzere iki farklı değere sahiptir. Sayısal özneteliklerin istatistiki karakteristikleri ise Çizelge 2’de verilmiştir.

Bu çalışmanın amacı 3DP veri setinde yer alan ve Tablo 1’de verilen ilk 11 parametreyi girdi olarak kabul edip, baskı için kullanılacak malzemenin tahminlemesini gerçekleştirmektir.


**Çizelge 2.** Veri setindeki sayısal özneteliklerin istatistiki karakteristikleri

Öznetelik Adı	Minimum	Maksimum	Ortalama	Standart Sapma
Layer Height	0.02	0.20	0.11	0.06
Wall Thickness	1.00	10.00	5.22	2.92
Infill Density	10.00	90.00	53.40	25.36
Nozzle Temperature	200.00	250.00	221.50	14.82
Bed Temperature	60.00	80.00	70.00	7.14
Print Speed	40.00	120.00	64.00	29.69
Fan Speed	0.00	100.00	50.00	35.71
Roughness	21.00	368.00	170.58	99.03
Tensile Strength	4.00	37.00	20.08	8.93
Elongation	0.40	3.30	1.67	0.79

## 2.2. Sınıflandırmada Kullanılan Makine Öğrenmesi Algoritmaları

Bu çalışmada sınıflandırma için Destek Vektör Makinesi (DVM), K-En yakın Komşu (KNN), Karar Ağacı (KA), Rastgele Orman (RO) ve Lojistik Regresyon (LR) olmak üzere 5 farklı makine öğrenmesi algoritması kullanılmıştır.

DVM algoritması, Vapnik vd. [14] tarafından literatüre kazandırılan, istatistiksel öğrenme teorisine dayalı bir yöntemdir. DVM, her biri ayrı kategorilere ait olarak işaretlenmiş eğitim setinden öğrenerek, yeni örnekleri bu sınıflardan birine olasılıklı olmayacak şekilde atayan bir model oluşturur. Veri örneklerinin yer aldığı düzlemde, sınıfları birbirinden ayırmak için, iki sınıfın üyelerinden en uzak mesafede olacak şekilde bir karar sınırının çizilmesi sağlanır (Şekil 1).



**Şekil 1.** Destek Vektör Makinesi

Verinin her bir noktası Eşitlik 1’de verilen şekilde tanımlanır.

$$\{ (x_i, y_i) \mid x_i \in \mathbb{R}^d, y_i \in \{-1, 1\} \}_{i=1}^n \quad (1)$$

Formülde  $x$  bir girdiyi,  $y$  ise -1 ve 1 ile temsil edilen bir sınıfı belirtir. Düzlemde her bir nokta  $wx-b$  şeklinde ifade edilir. Burada  $w$  düzleme dik olan normal vektörü,  $b$  ise kayma miktarıdır. DVM, karesel optimizasyon yöntemi ile ayırma sınırının bulunmasını sağlar [15]. DVM’nin, aşırı uydurma problemi

(overfitting) karşısındaki hassasiyetinin düşük olması ve yüksek doğruluk sağlaması kullanım yaygınlığını arttırmaktadır.

KNN algoritması, literatüre Fix ve Hodges [16] tarafından kazandırılan, daha sonra Cover [17] tarafından geliştirilen parametrik olmayan bir metottur. Sınıflandırma ve regresyon problemleri için yaygın olarak kullanılan bir yöntemidir. Sınıfı belirlenmek istenen nokta K adet en yakın komşunun oyuyla en yaygın olan sınıfa atanır. KNN mesafeye dayalı ve en temel makine öğrenmesi algoritmalarından biridir. KNN ile gerçekleştirilen sınıflandırmada çıktı, bir sınıfın üyeliğidir.

KA algoritması, sınıflama ve regresyon için kullanılan, parametrik olmayan denetimli bir öğrenme algoritmasıdır. Amaç veri özelliklerinden çıkarılan basit karar kurallarını öğrenerek hedef değişkenin değerini tahmin eden bir model oluşturmaktır. KA, her bir dahili düğümün verinin öznitelikleri üzerinde bir testi temsil ettiği akış diyagramı benzeri bir yapıdır. Her dal testin sonucunu temsil ederken her yaprak düğüm de bir sınıf etiketini temsil etmektedir. Kökten yaprağa giden yollar ise sınıflandırma kurallarını ifade eder. KA, anlaşılması ve yorumlanması kolay bir modeldir. Küçük veri kümeleriyle dahi bir sonuca ulaşılabilir.

RO algoritması, eğitim esnasında çok sayıda karar ağacı oluşturarak, her bir ağacın ürettiği sonuçların modu veya ortalamasını alıp çıktı sınıfın belirlenmesini sağlayan kolektif bir öğrenme algoritmasıdır. Ho [18] tarafından oluşturulan yöntemeye dayanan RO, daha sonra Breiman [19] tarafından geliştirilerek literatüre kazandırılmıştır. RO, geleneksel karar ağaçlarında yaygın problemlerden biri olan aşırı uydurma sorununa hem veri seti, hem de öznitelikleri çok sayıda parçaya bölüp birden çok ağaç üzerinde işleyerek çözüm getirir.

LR, adına rağmen regresyondan ziyade sınıflandırma için kullanılan doğrusal bir modeldir. Bağımlı değişkenin süreksiz olduğu ikili sınıflama (0 ve 1) durumlarında tercih edilir. Makine öğrenmesi alanı dışında, diğer uygulamalı bilimlerde, gerçek dünya problemlerinde yaygın olarak kullanılmaktadır [20]. LR ikili (binary) bağımlı değişken ile bir dizi bağımsız değişken arasındaki ilişkiyi açıklamaya yönelik tahminleyici bir analizdir. Bu modelde, tek bir denemenin olası sonuçlarını tanımlayan olasılıklar, bir lojistik fonksiyon kullanılarak modellenmiştir. Bir  $a+bx$  denklemi için olayın gerçekleşme olasılığı Eşitlik 2'deki gibidir.

$$P = \frac{e^{a+bx}}{1+e^{a+bx}} \quad (2)$$

Olayın gerçekleşmeme olasılığı  $1-p$  olmak üzere logit fonksiyonu Eşitlik 3'te verilmiştir.

$$\text{logit}(p) = \ln\left(\frac{p}{1-p}\right) \quad (3)$$

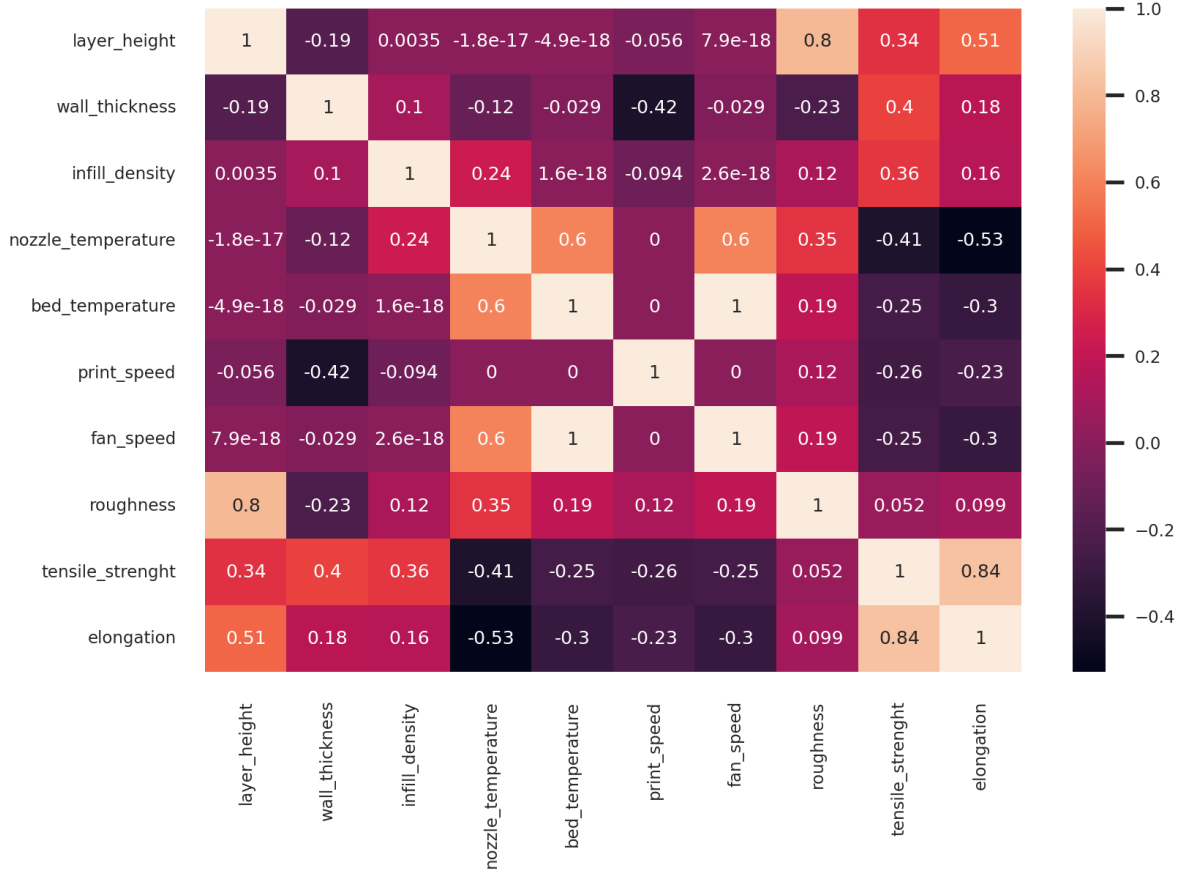
LR, logit dönüşümünü tahminlemek için bir formülün katsayılarını üretir.

### 3. DENEYSEL ÇALIŞMA VE BULGULAR

Bu çalışmada içerisinde 3D yazıcıya ait ayar parametreleri ve çıktı üründe beklenen niteliklere ilişkin toplam 12 adet öznitelik içeren 3DP veri seti üzerinde DVM, KNN, KA, RO ve LR olmak üzere 5 farklı makine öğrenmesi algoritması kullanılarak sınıflandırmalar gerçekleştirilmiştir. 11 adet özellik girdi olarak kullanılmış ve yazdırmada kullanılacak malzemeyi ifade eden “material” özniteliği tahminlenecek hedef olarak belirlenmiştir. Veri seti içerisindeki özniteliklerin 10 adedi sayısal değerlerden oluşmaktadır. Bu öznitelikler arasındaki korelasyonu gösteren matris Şekil 2’de verilmiştir. Korelasyon matrisinde koyu renkler düşük korelasyonu, açık renkler ise yüksek korelasyonu ifade etmektedir.

Tahminlenecek hedef öznitelik olan “material” iki farklı kategorik değere sahiptir. Bunlar “abs” ve “pla” üzere iki sınıftan oluşmaktadır. Her bir sınıfta yer alan örnek sayıları eşittir. Bu nedenle veri seti tahminlenecek hedef sınıf değerleri açısından dengeli bir yapıya sahiptir.

Veri seti içerisindeki kategorik olan diğer bir özellik ise dolgu desenini gösteren “infill pattern” özneliğidir. Bu öznelik de “grid” (ızgara) ve “honeycomb” (bal peteği) olmak üzere iki farklı değere sahiptir. Sınıflandırma işlemi öncesinde “material” ve “infill pattern” özneliklerinin değerleri yeniden kodlanmıştır. Kodlanan değerler Çizelge 3’te verilmiştir.



Şekil 2. Korelasyon matrisi

Çizelge 3. Kodlanan etiket değerleri

Öznelik	<i>material</i>		<i>infill pattern</i>	
Etiket	abs	pla	grid	honeycomb
Kodlanmış etiket	0	1	0	1

Sınıflandırma işleminde kullanılan 5 adet algoritmaların parametreleri ise Çizelge 4’te verilmiştir.

Çizelge 4. Kullanılan sınıflandırıcıların parametreleri

Sınıflandırıcı	Parametreler
DVM	kernel='rbf', C=4
KNN	n_neighbors=8
KA	criterion='gini'
RO	n_estimators =100
LR	penalty='l2', C=1.0

Sınıflandırma işlemlerinin performansını ölçmek için kullanılan metrikler karmaşıklık matrislerinden elde edilen parametreler doğrultusunda hesaplanmıştır. Bir karmaşıklık matrisi veri setindeki doğru ve yanlış sınıflandırılan örnekler, birbiriyle karıştırılan sınıflar ile ilgili detaylı bilgiler elde edebilmeyi sağlar. Tahminlemede bulunacağımız sınıf etiketlerinden 0 değerine sahip “abs”yi negatif, 1 değerine sahip “pla”yı ise pozitif olarak nitelendirirsek, bir karmaşıklık matrisinin genel yapısı Şekil 3’teki gibidir.




		<b>Gerçek sınıf</b>	
		Pozitif	Negatif
<b>Tahmin edilen sınıf</b>	Pozitif	Doğru Pozitif (DP)	Yanlış Pozitif (YP)
	Negatif	Yanlış Negatif (YN)	Doğru Negatif (DN)

Şekil 3. Karmaşıklık matrisi

Sınıflandırıcı tarafından pozitif olarak tahmin edilen ve gerçek sınıfı da pozitif olan örnek Doğru Pozitif (DP), gerçek sınıfı negatif ise Yanlış Pozitif (YP) olarak isimlendirilir. Benzer şekilde sınıflandırıcının negatif olarak tahmin ettiği örnek gerçekte pozitif ise Yanlış Negatif (YN), gerçek sınıfı da negatif ise Doğru Negatif (DN) olarak isimlendirilir. Bu değerlerden yola çıkarak üretilen performans metrikleri ve formülleri ise Çizelge 5'te verilmiştir.

Çizelge 5. Model performans metrikleri

<b>Metrik</b>	<b>Matematiksel ifadesi</b>
Doğruluk	$(DP + DN) / (DP + YP + YN + DN)$
Kesinlik	$DP / (DP + YP)$
Duyarlılık	$DP / (DP + YN)$
F1 Skoru	$2 * kesinlik * duyarlılık / (kesinlik + duyarlılık)$



Doğruluk metriği modelin genel başarısını ifade eder. Doğruluk değeri, doğru sınıflandırılmış örnek sayısının, tüm örnek sayısına bölümü ile elde edilir. Kesinlik, pozitif olarak tahmin edilen değerlerin gerçekten ne kadarının pozitif olduğunu gösteren metriktir. Aynı zamanda kesinlik metriği sınıflandırıcının yanlış pozitifleri eleme kabiliyetinin de göstergesidir. Duyarlılık, pozitif olarak tahmin edilmesi gereken değerlerin ne kadarının pozitif olarak tahmin edildiğini gösteren bir metriktir. Duyarlılık, sınıflandırıcının doğru pozitifleri tahmin etmedeki kabiliyetinin ölçütüdür. Kesinlik ve duyarlılık arasındaki dengeyi ifade etmek için F1 skoru kullanılır. F1 skoru, hesaplanan kesinlik ve duyarlılık değerlerinin harmonik ortalamasıdır. Alıcı işlem karakteristiği (Receiver Operating Characteristic - ROC) eğrileri, farklı sınıflar için bir olasılık eğrisidir. X ekseninde yanlış pozitif oranı, Y ekseninde ise doğru pozitif oranının yer aldığı bu eğri, kullanılan sınıflandırıcının tahminde ne kadar iyi olduğunu açıklar. Eğrinin altında kalan alan (Area Under Curve - AUC) [0,1] aralığında değer alır ve model performansının bir özeti kabul edilir. AUC değerinin 1'e yaklaşması veri setindeki sınıfların daha başarılı şekilde ayırt edildiğini gösterir.

Her bir sınıflandırma işleminde 5 kat çapraz doğrulama uygulanmıştır. Sınıflandırıcıların performansları yukarıda bahsi geçen metrikler açısından raporlanmıştır. Elde edilen sonuçlar Çizelge 6'da verilmiştir.

Çizelge 6. Sınıflandırıcıların performans ölçümleri

<b>Sınıflandırıcı</b>	<b>Doğruluk</b>	<b>Kesinlik</b>	<b>Duyarlılık</b>	<b>F1 skoru</b>	<b>AUC</b>
DVM	0.8	0.714286	1.0	0.833333	0.8
KNN	0.7	0.666667	0.8	0.727273	0.7
KA	0.9	1.0	0.8	0.888889	0.9
RO	0.96	0.96	0.96	0.96	0.96
LR	1.0	1.0	1.0	1.0	1.0

Çizelgede verilen sonuçlar incelendiğinde en başarılı sınıflandırıcının LR olduğu görülmektedir. Bu sınıflandırıcı ile tüm örnekler doğru şekilde sınıflandırılmış, doğruluk değeri ve diğer tüm metrikler %100 olarak elde edilmiştir. LR'den sonra ikinci sırada RO sınıflandırıcı gelmektedir. Bu sınıflandırıcının genel başarısı %96 olarak elde edilmiştir. KA sınıflandırıcı %90 doğruluk ile üçüncü başarılı model olmuştur. Kesinlik değeri %100 olarak elde edilirken duyarlılık değeri %80 olarak ölçülmüştür. İki ayrı sınıfı ayırt etmedeki başarı dengesi ise %88.88 olarak elde edilmiştir. Başarı sıralamasında dördüncü model %80 doğruluk ile DVM sınıflandırıcıdır. Bu sınıflandırıcının duyarlılık değeri %100 olarak elde edilmiş, sınıfları ayırt etme dengesini gösteren F1 skoru ise %83.33 olarak ölçülmüştür. En düşük başarıyı gösteren model ise %70 doğruluk ile KNN olmuştur.

Bu çalışmanın kaleme alındığı tarihte, bu çalışma ile aynı veri setini kullanan literatürdeki makine öğrenmesi temelli tek tahminleme çalışması Tripathi ve Singla [10] tarafından gerçekleştirilmiştir. Araştırmacılar veri seti içerisinde yer alan pürüzlülük parametresini (roughness) tahminlenecek hedef değişken olarak kullanıp diğer 11 özneliği girdi olarak kullanmışlardır. YSA ile gerçekleştirdikleri sınıflandırma çalışmasında elde ettikleri doğruluk %89.37'dir. Her ne kadar farklı parametreler üzerinde tahminleme gerçekleştirilmiş olsa da elde ettikleri doğruluk bu çalışmadaki KA, RO ve LR modellerinden daha düşüktür.

#### 4. SONUÇ

Bu çalışmada 3D imalatta önemli karar noktalarından biri olan kullanılacak baskı malzemesinin doğru şekilde seçilmesi konusunda makine öğrenmesi temelli bir tahminleme çalışması gerçekleştirilmiştir. 3D imalat konusundaki erişilebilir veri setlerinin kısıtlılığı nedeni ile literatürde bu konuda yapılan tahminleme çalışmalarının sayısı henüz yeterli miktarda değildir. Bu çalışmada kullanılan veri seti 3D yazıcının çeşitli ayar parametreleri ve üretilecek ürünün farklı niteliklerinden oluşan 11 adet girdi özneliği ve kullanılacak malzeme türünü ifade eden 1 adet hedef öznelik olmak üzere toplam 12 öznelikten oluşmaktadır. Bu veri seti üzerinde DVM, KNN, KA, RO ve LR olmak üzere 5 farklı makine öğrenmesi algoritması ve 5 kat çapraz doğrulama ile gerçekleştirilen tahminleme çalışmalarında en yüksek doğruluk %100 olarak LR algoritması ile elde edilmiştir. Bu çalışma ve benzeri yapay zekâ destekli tahminleme çalışmalarıyla, 3D imalat sektöründe isabetli öngörüler sağlamak, üretim sürecini daha etkin hale getirip ideal maliyetlerle kaliteli ürünler oluşturma konusunda yol gösterici sonuçlar ortaya koymak amaçlanmaktadır. Gelecekteki çalışmalarda farklı veri setleri ve örneklerle ürün kalitesi ve süreç konusunda farklı tahminleme çalışmalarının gerçekleştirilmesi hedeflenmektedir.

#### KAYNAKLAR

1. Günay, M., Gündüz, S., Yılmaz, H., Yaşar, N., Kaçar, R., "PLA esaslı numunelerde çekme dayanımı için 3D baskı işlem parametrelerinin optimizasyonu", *Politeknik Dergisi.*, Cilt 23, Sayı 1, Sayfa 73-79, 2020.
2. Bourell, D. L., Leu, M. C., Rosen, D. W., "Roadmap for additive manufacturing: identifying the future of freeform processing", *Univ. Tex. Austin Austin TX*, Vol. 32, Issue 1, Pages 11-15, 2009.
3. Özsoy, K., Aksoy, B., Yücel, M., "Design and Manufacture Of Continuous Automatic 3D Printing Device With Conveyor System By Image Processing Technology", *Erzincan Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, Cilt 13, Sayı 2, Sayfa. 392-403, 2020.
4. Şahin, K., Turan, B.O., "Üç Boyutlu Yazıcı Teknolojilerinin Karşılaştırmalı Analizi", *Strat. ve Sos. Araştırmalar Dergisi*, Cilt 2, Sayı 2, Sayfa 97-116, 2018.
5. Tymrak, B., Kreiger, M., Pearce, J. M. , "Mechanical properties of components fabricated with open-source 3-D printers under realistic environmental conditions", *Mater. Des.*, Vol. 58, Issue 1, Pages 242-246, 2014.
6. Aksoy, B., Selbaş, R., "Estimation of Wind Turbine Energy Production Value by Using Machine Learning Algorithms and Development of Implementation Program", *Energy Sources Part Recovery Util. Environ. Eff.*, Vol. 43, Issue 6, Pages 692-704, 2021.
7. Delli, U., Chang, S., "Automated Process Monitoring in 3D Printing Using Supervised Machine Learning", *Procedia Manuf.*, Vol. 26, Issue 1, Pages 865-870, 2018.

8. Li, Z., Zhang, Z., Shi, J., Wu, D., "Prediction of surface roughness in extrusion-based additive manufacturing with machine learning", *Robot. Comput.-Integr. Manuf.*, Vol. 57, Issue 1, Pages 488-495, 2019.
9. Wu, D., Wei, Y., Terpenney, J., "Surface roughness prediction in additive manufacturing using machine learning", *International Manufacturing Science and Engineering Conference*, Vol. 3, Pages 51371, 2018.
10. Tripathi A., Singla, R., "Surface Roughness Prediction of 3D Printed Surface Using Artificial Neural Networks", *Advances in Interdisciplinary Engineering Conference*, Pages 09-120., Singapore, 2021.
11. Magar, R., Ghule, L., Doshi, R., Khalid, A., Seshadri, S., Farimani, A. B., "ManufacturingNet: A Machine Learning Toolbox for Engineers", *Workshop on machine learning for engineering modeling, simulation and design*, 2020.
12. Wu, M., Phoha, V. V., Moon, Y. B., Belman, A. K., "Detecting Malicious Defects in 3D Printing Process Using Machine Learning and Image Classification", *ASME 2016 International Mechanical Engineering Congress and Exposition*, Vol. 14, Arizona, 2016.
13. Farhan Khan M., "Real-time defect detection in 3D printing using machine learning", *Second Int. Conf. Recent Adv. Mater. Manuf.*, Vol. 42, Pages 521-528, 2021.
14. Vapnik, V., Golowich, S. E., Smola, A., "Support vector method for function approximation, regression estimation, and signal processing", *Adv. Neural Inf. Process. Syst.*, Pages 281-287, 1997.
15. Shen L., "Evolving support vector machines using fruit fly optimization for medical data classification", *Knowl.-Based Syst.*, Vol. 96, Pages 61-75, 2016.
16. Fix E., Hodges Jr J. L., "Discriminatory analysis-nonparametric discrimination: Small sample performance", *California Univ Berkeley*, 1952.
17. Altman, N.S., "An Introduction to Kernel and Nearest-Neighbor Nonparametric Regression", *Am. Stat.*, Vol. 46, Issue 3, Pages 175-185, 1992.
18. Ho, T. K., "Random decision forests", *Proceedings of 3rd international conference on document analysis and recognition*, Vol. 1, Pages 278-282, 1995.
19. Breiman, L., "Random forests", *Mach. Learn.*, Vol. 45, Issue 1, Pages 5-32, 2001.
20. Yang Y., Loog M., "A benchmark and comparison of active learning for logistic regression", *Pattern Recognit.*, Vol. 83, Pages 401-415, 2018.