



Süleyman Demirel Üniversitesi

YEKARUM e-DERGI

(Journal of YEKARUM)



Cilt 9 , Sayı 2 , 91-107 , 2024
E - ISSN:1309-9388

Makine Öğrenmesi ile 3 Boyutlu Yazıcı Plastik Filamentlerinin Ergime Noktası ve Esneklik Özelliklerine Dayalı Çekme Dayanımının Tahmini

Muzaffer EYLENCE^{1*} , Bekir AKSOY² , Koray ÖZSOY³

^{1*} Isparta Uygulamalı Bilimler Üniversitesi, Teknoloji Fakültesi, Mekatronik Mühendisliği Bölümü, Isparta, Türkiye, (ORCID: 0000-0001-7299-8525), meylence@yandex.com

² Isparta Uygulamalı Bilimler Üniversitesi, Teknoloji Fakültesi, Mekatronik Mühendisliği Bölümü, Isparta, Türkiye (ORCID: 0000-0001-6016-4590), bekiraksoy@isparta.edu.tr

² Isparta Uygulamalı Bilimler Üniversitesi, Isparta OSB MYO, Makine ve Metal Teknolojileri Bölümü, Isparta, Türkiye (ORCID: 0000-0001-8663-4466), korayozsoy@isparta.edu.tr

(İlk Geliş Tarihi 22/10/2024 ve Kabul Tarihi 18/12/2024)

ÖZET:

Eklemeli imalat, malzemeyi katmanlar halinde biriktirerek nesnelere üreten ve genellikle 3D baskı olarak bilinen yenilikçi bir teknolojidir. Bu yöntem, geleneksel imalatın aksine malzemeyi çıkarmak yerine katman ekleyerek üretim sağlarken, Ergiyik Biriktirme Modelleme (EBM) gibi popüler formlarının yaygın kullanımına yol açmıştır. Bu çalışmada, EBM tabanlı 3D baskı uygulamalarında farklı markalara ait termoplastik filamentlerin dayanım değerlerinin belirlenmesine yönelik makine öğrenimi tekniklerinin geliştirilmesi hedeflenmiştir. Bu amaç doğrultusunda, yaygın termoplastik filamentlerin dayanım değerlerinin tahmin edilmesi için Pruned Decision Trees, Destek Vektör Makineleri ve Naive Bayes gibi makine öğrenimi algoritmalarından yararlanılmıştır. Bu çalışmada kullanılan veri seti; plastik türü, erime noktası, esneklik, dayanıklılık, kullanım alanları ve marka gibi bilgileri içeren 800 veri örneğinden oluşmaktadır. Makine öğrenme algoritmalarının performansı, modelin dayanım değerini tahmin yeteneği hakkında bilgi sağlayan doğruluk ve F1-skoru gibi standart değerlendirme metrikleri kullanılarak değerlendirilmiştir. Dikkate değer bir şekilde, model tüm metriklerde yüksek bir performans sergileyerek, 3D baskı için kullanılan termoplastik filamentlerin dayanım değerlerinin tahmininde Pruned Decision Trees algoritması ile %96'lık bir başarı oranı elde etmiştir. Bu sonuçlar, makine öğreniminin eklemeli imalat yöntemlerinden EBM süreçlerindeki filamentlerin dayanım değerlerinin otomatik tespiti konusunda etkinliğini ortaya koymaktadır.

Anahtar Kelimeler: Eklemeli imalat, EBM, Filament, Makine Öğrenme

Prediction of Tensile Strength Based on Melting Point and Flexibility Properties of 3D Printer Plastic Filaments Using Machine Learning

ABSTRACT

Additive manufacturing is an innovative technology that produces objects by depositing material in layers, commonly known as 3D printing. This method allows for production by adding layers instead of removing material, in contrast to traditional manufacturing, and has led to the widespread use of popular forms such as Fused Deposition Modeling (FDM). In this study, the aim was to develop machine learning techniques for determining the strength values of thermoplastic filaments from different brands in FDM-based 3D printing applications. To achieve this, machine learning algorithms such as Pruned Decision Trees, Support Vector Machines, and Naive Bayes were employed to estimate the strength values of common thermoplastic filaments. The dataset used in this study consists of 800 samples containing information such as plastic type, melting point, flexibility, durability, areas of use, and brand. The performance of the machine learning algorithms was evaluated using standard metrics such as accuracy and F1-score, which provide insights into the model's ability to predict strength values. Notably, the model demonstrated strong performance across all metrics, achieving a 96% success rate with the Pruned Decision Trees algorithm in predicting the strength values of thermoplastic filaments used for 3D printing. These results underscore the effectiveness of machine learning in automatically determining the strength values of filaments in EBM processes, one of the additive manufacturing methods.

Keywords: *Additive Manufacturing, FDM, Filament, Machine Learning*


1. GİRİŞ

Eklemeli imalat (Eİ) teknolojisi, basit ve çeşitlendirilmiş teknolojisi nedeniyle son zamanlarda büyük önem kazanmıştır. Eİ kullanımı, geleneksel imalat yöntemlerine göre eğitim, prototip oluşturma, inşaat, tıp ve havacılık endüstrisini kapsayan birçok bilgi alanına yayılmıştır [1]. Eklemeli imalat süreci, malzemelerin belirli koşullar altında ve bilgisayar kontrollü bir ortamda biriktirildiği, birleştirildiği veya katılaştırıldığı sistematik bir yöntemle gerçekleştirilir. Eklemeli imalat yöntemleri, üç boyutlu nesnelerin katmanlar halinde inşa edilerek üretildiği bir imalat sürecidir [2].

ISO/ASTM 52900:2021 [3], eklemeli imalat teknolojisinde kullanılan terimleri belirler ve tanımlar vardır. Kullanılan malzeme türü ve basılı parçaların nihai uygulaması dikkate alınarak genel olarak malzemelerin ekstrüzyonu, vat polimerizasyonu, toz yatak füzyonu, malzeme jeti, bağlayıcı Püskürtme, Yönlendirilmiş Enerji Biriktirme (Metal Alaşımları), Haddeme levhası gibi eklemeli imalat teknolojilerini yedi türe ayrılır. Malzeme Ekstrüzyonu, tel formundaki filamentin silindirler vasıtasıyla nozullara iletiildiği bir başka eklemeli imalat teknolojisidir. Bu yöntemde, yarı erimiş malzeme bir nozul aracılığıyla imalat

platformuna ekstrüde edilmektedir. Malzeme ekstrüzyonu, kalıp ve model üretimi, takım imalatı ve son kullanım parçalarının üretimi gibi çeşitli uygulamalarda kullanılmaktadır [4,5]. Malzeme ekstrüzyonu ise 2,85 mm veya 1,75 mm çapında filament boyutlarını kullanır. Bu teknik, polimerler, kompozitler ve biyomalzemeler gibi geniş bir malzeme yelpazesinin işlenmesine olanak tanır [6]. Malzeme ekstrüzyonu tabanlı ergiyik biriktirme modelleme (EBM), kullanım kolaylığı ve diğer teknolojilere göre daha az masraflı olması nedeniyle yaygın olarak kullanılan bir tekniktir [7].

Ergiyik biriktirme modelleme, hızlı üretim süreci, maliyet etkinliği, kolay erişilebilirliği, geniş malzeme uyumluluğu ve karmaşık bileşenler üretme yeteneği ile popüler bir eklemeli imalat teknolojisidir [8]. Şekil 1’de gösterildiği gibi EBM sürecinde, termoplastik filament kullanılarak CAD tasarımına uygun şekilde imalat tablasının üzerine üç boyutlu katmanlar oluşturulur. İlk katman basıldıktan sonra, imalat tablası platformu aşağı indirilir ve bir sonraki katman, önceki katmanın üzerine basılarak süreç, parça tamamlanana kadar tekrarlanmaktadır.



Şekil 1. EBM parça işleme sürecinin gösterimi [9].

EBM baskısında günümüzde çeşitli malzemeler kullanılmaktadır. Akrilonitril bütadien stiren (ABS) ve polilaktik asit (PLA) en yaygın malzemelerdir. ABS, çok yönlü yapısı ve mekanik özellikleri nedeniyle en sık tercih edilen 3D baskı termoplastiğidir. Filament, toz

veya sıvı halde kullanılabilmesi bu çok yönlülüğünü artırmaktadır [10]. PLA ise, mısır nişastası gibi yenilenebilir kaynaklardan üretilen biyolojik olarak parçalanabilir bir plastiktir. Büzülme eğilimi olmasına rağmen, en popüler 3D baskı filamentlerinden biridir [11]. FDM tekniklerinde, ABS gibi mühendislik polimerleri ve PLA gibi biyolojik olarak parçalanabilir plastikler yaygın kullanılır. Bunun yanı sıra, geleneksel ve geri dönüştürülebilir polimerlerle de 3D baskı yapılabilmektedir. Örneğin, polietilen tereftalat (PET), etilen glikol (PETG) ile sentezlenerek sünekliği artırılabilir [12].

Polikarbonat (PC), şeffaflığı, üstün mekanik ve termal direnci nedeniyle mühendislik uygulamalarında tercih edilen bir malzemedir ve 3B baskıda boyut kararlılığı ile mekanik özellikleri nedeniyle kullanılmaya başlanmıştır. PC, ABS ve PET gibi malzemelerle birleştirilerek basılı parçaların performansını iyileştirmek amacıyla diğer termoplastik polimerler veya inorganik parçacıklarla bir araya getirilebilir. Araştırmaların çoğu esas olarak PC'yi ABS ve PET ile birleştirmeye dayanmaktadır [13, 14]. Naylon, yüksek dayanıklılık, esneklik ve mekanik özellikleri nedeniyle sentetik poliamid ailesinden bir mühendislik plastiğidir. İyi kimyasal ve ısı direnci sunmasıyla, FDM gibi 3D baskı teknolojilerinde işlevsel parçalar ve prototipler için ideal bir malzemedir. Poliamidler ayrıca yapılarındaki karbon sayısına göre bir alt sınıflandırma sunar ve bu nedenle Poliamid 6, Poliamid 66, Poliamid 11 ve Poliamid 12 olarak bilinen bunlar arasında farklı özellikler bulunur. Bu şekilde, naylonun 3D baskıda kullanımı kullanılan poliamid türüne bağlı olacaktır. Naylon 618 gibi bazı poliamidler, kristalinitedeki farklılıklar ve FDM işleminin benzersizliği nedeniyle daha iyi aşınma performansı sağlar [15].

Yapay Zeka (YZ), insan benzeri zeka sergileyen sistemlerin geliştirilmesi üzerine odaklanan bir bilim dalıdır. Bu teknoloji, karmaşık görevleri yerine getirmek için veri analizini, öğrenme süreçlerini ve problem çözmeyi kullanır. YZ'nin temel amacı, insan müdahalesine ihtiyaç duymadan, çevresel değişimlere uyum sağlayabilen ve kararlar alabilen sistemler yaratmaktır [16]. YZ, insan zekasına özgü işlevleri simüle etmek için bilgisayar bilimi, matematik, psikoloji ve nörobilim gibi disiplinlerin bir araya geldiği çok yönlü bir alandır. Günümüzde YZ; doğal dil işleme, görsel algılama, ses tanıma ve öneri sistemleri gibi birçok uygulama alanına sahiptir [17]. YZ, genellikle üç ana kategoriye ayrılır: Dar (Zayıf) Yapay Zeka, Genel (Güçlü) Yapay Zeka ve Süper Yapay Zeka. Dar yapay zeka, spesifik görevlerde performans gösteren, günümüzde en yaygın olan yz türüdür. Örneğin, bir dil

modeli veya bir öneri sistemi yalnızca belirli bir amaç için optimize edilmiştir [18]. Genel yapay zeka, insanlarla benzer bilişsel yeteneklere sahip, farklı görevler arasında geçiş yapabilen bir yapay zeka türüdür. Bu seviyedeki yz halen geliştirilme aşamasındadır. Süper yapay zeka, insan zekasının çok ötesinde bilişsel yeteneklere sahip olacağı varsayılan yz seviyesidir [19].

Makine öğrenmesi (MO), yz'nin bir alt dalı olarak kabul edilir ve makinelerin deneyim yoluyla öğrenmesini sağlar. MO algoritmaları, verilerdeki desenleri ve ilişkileri öğrenir, ardından bu öğrenmeleri kullanarak yeni verilere dayalı tahminlerde bulunur [20]. Makine öğrenmesi; denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme olmak üzere üç temel kategoriye ayrılır: Denetimli öğrenme, giriş verileri ile bunlara karşılık gelen sonuçların (etiketlerin) kullanıldığı bir öğrenme yöntemidir. Algoritmalar, etiketli veriler aracılığıyla belirli bir görevi yerine getirmeyi öğrenir [21]. Denetimsiz öğrenme, etiketli verilerin olmadığı durumlarda kullanılır. Algoritmalar, verilerdeki gizli desenleri ve yapıları keşfetmeyi amaçlar [22]. Pekiştirmeli öğrenme, bir ajanın, çevresiyle etkileşime geçerek ödülleri veya cezaları yoluyla öğrenme sürecidir [23]. Makine öğrenmesi, büyük veri setlerinin analiz edilmesi, tahminler yapılması ve karmaşık karar verme süreçlerinin otomatikleştirilmesinde kritik bir rol oynar. Günümüzde endüstriden tıp alanına kadar geniş bir yelpazede uygulanmaktadır.

Son yıllarda 3 boyutlu yazıcı teknolojisi ile üretilen malzemelerin çekme dayanımını tahmin etme üzerine birçok çalışma gerçekleştirilmiştir. Bu çalışmaların temel amacı, mekanik özellikleri anlamak ve bu süreçte zaman ve maliyet tasarrufu sağlamaktır. Makine öğrenmesi algoritmaları, büyük veri kümelerini analiz etme ve tahminler yapma kapasitesi sayesinde bu alanda yaygın olarak kullanılmaktadır. Çınar ve arkadaşları [24], polimer bazlı 3 boyutlu yazıcılarla üretilen malzemelerin çekme dayanımını tahmin etmek amacıyla makine öğrenmesi tekniklerini kullanmışlardır. Çalışmada denetimli öğrenme algoritmaları kullanılarak, deneysel verilerden öğrenen modeller geliştirilmiş ve bu modellerin yüksek doğruluk oranlarıyla tahmin yapabildikleri gösterilmiştir. Çekme dayanımını etkileyen parametreler arasında baskı sıcaklığı, malzeme türü ve katman kalınlığı gibi faktörlerin yer aldığı belirtilmiştir. Bu çalışma, makine öğrenmesinin üretim parametreleri ile mekanik performans arasında ilişki kurma kapasitesini gözler önüne sermektedir [24].

Benzer bir şekilde, Yılmaz ve Demir [25], yapay sinir ağları ve karar ağaçları gibi makine öğrenmesi algoritmalarını kullanarak, 3 boyutlu yazıcılarla üretilen parçaların çekme dayanımını tahmin etmeyi amaçlamışlardır. Bu çalışmada, farklı yazıcı ayarları ve malzeme özellikleri kullanılarak oluşturulan veriler, modellerin eğitilmesinde kullanılmıştır. Yapay sinir ağları ile yapılan tahminlerin, geleneksel yöntemlere göre daha doğru sonuçlar verdiği ve üretim sürecinde zaman kazandırdığı belirtilmiştir. Karar ağaçlarının ise, parametreler arasındaki karmaşık ilişkileri daha anlaşılır bir şekilde görselleştirebildiği vurgulanmıştır [25].

Huang ve arkadaşları [26] ise, 3 boyutlu yazıcılarla üretilen metal parçaların çekme dayanımını tahmin etmek için çeşitli makine öğrenmesi algoritmalarını karşılaştırmışlardır. Çalışmada, destek vektör makineleri (SVM) ve rastgele ormanlar (RF) gibi algoritmaların performansları incelenmiştir. Metal bazlı üretimlerde çekme dayanımını tahmin etmede rastgele ormanlar algoritmasının en başarılı yöntem olduğu belirtilmiş, bu algoritmanın karmaşık verilerle başa çıkma yeteneği öne çıkarılmıştır. Ayrıca bu çalışma, 3 boyutlu yazıcı ile üretimde farklı malzemelerin mekanik özelliklerinin tahmin edilmesine yönelik önemli bir katkı sağlamıştır [26].

Yapılan çalışmalar, 3 boyutlu yazıcı teknolojisinin çekme dayanımı gibi kritik mekanik özelliklerin makine öğrenmesi ile tahmin edilebileceğini ve bu sayede üretim süreçlerinin optimize edilebileceğini göstermektedir. Makine öğrenmesi algoritmaları, geleneksel deneysel yöntemlere kıyasla daha hızlı, daha maliyet etkin ve daha esnek tahminler sunarak üretimde büyük avantaj sağlamaktadır.

Çalışmada, 3B baskı teknolojilerinden EBM yöntemine makine öğrenme yaklaşımı uygulanmıştır. Veri seti, plastik türü, erime noktası, esneklik, dayanıklılık, kullanım alanları ve marka gibi bilgileri içeren 800 veri örneğinden oluşmaktadır. Dayanıklılık tahmini, makine öğrenmesi algoritmaları kullanılarak gerçekleştirilmiştir. Veri seti, Karar Ağaçları, Destek Vektör Makineleri (SVM) ve Naive Bayes makine öğrenme algoritmaları kullanılmıştır. Makine öğrenme algoritma mimarisıyla eğitildikten sonra performansı doğruluk ve F1 puanı metrikleri kullanılarak değerlendirilmiştir. Son aşamada, sonuçlar bir karmaşıklık matrisleri ile analiz edilmiştir.

2. MATERYAL ve METOT

2.1. Materyal

2.1.1. 3B Yazıcı

Tüm parçalar 3D yazıcı kullanılarak basılmıştır. Ergime noktası, esneklik giriş parametreleri çekme mukavemeti gibi çeşitli özellikler hakkında veri içerir [27].

2.1.2. Makine Öğrenmesi Algoritmalar

2.1.3.1. Pruned Decision Tree

Pruned Decision Trees, makine öğrenmesinde sınıflandırma ve regresyon problemlerinde yaygın olarak kullanılan karar ağaçlarının daha genellenebilir ve etkili hale getirilmesi için uygulanan bir tekniktir. Karar ağaçları, veriyi farklı dallara ayırarak tahminlerde bulunan sezgisel bir modeldir. Ancak, karar ağaçlarının en büyük sorunlarından biri aşırı öğrenme (overfitting) problemidir. Aşırı öğrenme, modelin eğitim verisine aşırı derecede uyum sağlaması sonucu yeni verilerle yapılan testlerde düşük performans göstermesi durumudur. Bu sorunu önlemek için budama (pruning) işlemi uygulanır [28]. Budama, ağaçtaki gereksiz dalları kaldırarak ağacın karmaşıklığını azaltmayı amaçlar. Budamanın iki temel yöntemi vardır: ön budama (pre-pruning) ve sonradan budama (post-pruning). Ön budama, ağacın büyüme sürecinde aşırı dallanmayı engellerken, sonradan budama, tam bir karar ağacı oluşturulduktan sonra gereksiz dalların kesilmesini içerir [29]. Budamanın temel amacı, modelin genellenebilirliğini artırmak ve aşırı öğrenme riskini en aza indirmektir. Bununla birlikte, yanlış budama işlemi, modelin öğrenme kapasitesini sınırlayarak performans kayıplarına yol açabilir [30].

2.1.3.2. Destek Vektör Makineleri

Destek Vektör Makineleri (Support Vector Machines - SVM), özellikle sınıflandırma problemlerinde yüksek doğruluk oranları sunan bir diğer makine öğrenmesi yöntemidir. SVM, sınıflandırma işlemlerinde veri noktalarını ayıran en iyi hiperdüzlemi bulmayı hedefler ve bu hiperdüzlem, iki sınıf arasındaki marjı maksimize eder [31]. Bu yöntem, özellikle yüksek boyutlu veri kümeleriyle çalışırken etkili sonuçlar verir. SVM'nin başarısındaki temel faktörlerden biri çekirdek (kernel) fonksiyonlarıdır. Çekirdek fonksiyonları, doğrusal olmayan veri kümelerinde SVM'nin doğrusal sınıflandırıcılar kullanarak çözüm üretmesini sağlar [32]. Bu fonksiyonlar arasında lineer, polinomsal ve radyal bazlı fonksiyonlar (RBF) sıklıkla

kullanılmaktadır. SVM'in en büyük avantajı, özellikle yüksek boyutlu ve karmaşık veri kümelerinde iyi genellenebilirlik sağlamasıdır [33]. Ancak, büyük veri kümelerinde eğitim süresi uzayabilir ve hiperparametre seçimi modelin performansını büyük ölçüde etkileyebilir [34].

2.1.3.3. Naive Bayes

Naive Bayes sınıflandırıcıları, olasılık temelli ve basit yapısına rağmen birçok sınıflandırma probleminde etkili sonuçlar veren bir makine öğrenmesi yöntemidir. Model, her bir özelliğin diğerlerinden bağımsız olduğunu varsayar ve bu varsayım doğrultusunda Bayes teoremi kullanılarak sınıflandırma işlemi gerçekleştirilir. Naive Bayes, bir sınıfın olasılığını gözlemlenen verilere dayalı olarak hesaplar ve denklem 1'deki gibi hesaplanmaktadır [35].

$$P(C|X) = \frac{P(X|C)P(C)}{P(X)} \quad (1)$$

Modelin "naive" olarak adlandırılmasının nedeni, özellikler arasındaki bağımsızlık varsayımdır. Gerçek dünyada bu varsayım genellikle geçerli olmasa da, Naive Bayes sınıflandırıcıları birçok veri kümesinde başarılı sonuçlar vermektedir [36]. Algoritmanın en önemli avantajlarından biri, hızlı ve hesaplama açısından verimli olmasıdır. Büyük veri kümelerinde bile hızlı bir şekilde çalışabilir ve genellikle daha karmaşık modellerle karşılaştırıldığında rekabetçi sonuçlar sunar [37]. Bununla birlikte, özellikler arasındaki bağımsızlık varsayımı geçerli olmadığında, modelin performansı olumsuz etkilenebilir. Ancak bu durum, her veri kümesinde performansı ciddi şekilde düşürmeyebilir.

2.1.3.4. Performans değerlendirme metriği

Makine öğrenmesi modellerinin performansını değerlendirmek için doğruluk ve F1-skoru gibi metrikler yaygın olarak kullanılmaktadır. Bu metrikler, modelin tahmin kapasitesini ve sınıflandırma doğruluğunu ölçmede kritik rol oynar. Doğruluk, modelin doğru tahminlerinin toplam tahminler içindeki oranını ifade eder. Matematiksel olarak denklem 2'deki gibi hesaplanır [38].

$$\text{Doğruluk} = \frac{\text{Doğru Pozitif} + \text{Doğru Negatif}}{\text{Toplam Gözlem}} \quad (2)$$

Denklem 2’deki metrik, özellikle sınıflar arasında dengeli bir dağılım olduğunda modelin genel performansını ölçmede etkili bir göstergedir. Ancak, sınıf dengesizliği olan durumlarda yanıltıcı sonuçlar verebilir, çünkü azınlık sınıflarına ilişkin yanlış tahminleri göz ardı edebilir.

F1-skoru, kesinlik (precision) ve duyarlılık (recall) arasında bir denge sağlayan bir metriktir. Özellikle sınıf dengesizliği olan veri setlerinde daha anlamlı sonuçlar sunar [38]. F1-skoru denklem 3’deki gibi hesaplanmaktadır.

$$F1 - Skor = 2 \times \frac{Kesinlik \times Duyarluluk}{Kesinlik + Duyarluluk} \quad (3)$$

F1-skoru, duyarlılık ve kesinlik arasındaki dengenin sağlanması gereken durumlarda öne çıkan bir metriktir. Modelin hem azınlık sınıflarını doğru bir şekilde tahmin etmesi hem de yanlış pozitif tahmin oranını düşük tutması gereken uygulamalarda tercih edilir. Kesinlik, Modelin doğru pozitif tahminlerinin toplam pozitif tahminlere oranıdır. Yanlış alarmların önlenmesinde önemli bir ölçüttür. Duyarlılık, Modelin doğru pozitif tahminlerinin toplam gerçek pozitiflere oranıdır. Bu metrik, modelin bir sınıfı ne kadar iyi yakaladığını gösterir.

2.2. Metot


2.2.1. Veri Seti

Bu çalışmada kullanılan veri seti, 3D yazıcı plastiklerinin fiziksel ve performans özelliklerini içermektedir. Veri seti, plastik türü, erime noktası, esneklik, dayanıklılık, kullanım alanları ve marka gibi bilgileri içeren 800 veri örneğinden oluşmaktadır. Dayanıklılık tahmini, makine öğrenmesi algoritmaları kullanılarak gerçekleştirilmiştir. Veri setindeki sütunlar arasında plastik türü (ABS, PLA vb.), erime noktası (derece Celsius cinsinden), esneklik (düşük, orta, yüksek), dayanıklılık (düşük, orta, yüksek) ve kullanım alanları gibi özellikler yer alır. Dayanıklılık tahmini yapılacak hedef değişkendir. Başlangıçta veri seti daha az veri içeriyordu; bu nedenle veri artırma işlemi gerçekleştirilmiştir. Veri artırma için bootstrap sampling (rastgele örnekleme) kullanılarak veri seti genişletilmiş ve veri sayısı 800’e çıkarılmıştır.

Bu çalışmada üç farklı makine öğrenmesi algoritması kullanılmıştır: Karar Ağaçları (budanmış), Destek Vektör Makineleri (SVM) ve Naive Bayes. Veri artırma işlemi, model

performansını artırmak ve genelleme kapasitesini iyileştirmek amacıyla uygulanmıştır. Çalışma, plastiklerin dayanıklılığını tahmin etmek için veri setindeki özelliklerden faydalanarak çeşitli makine öğrenmesi modelleri ile gerçekleştirilmiştir.

2.2.2. İş akış şeması



Şekil 2. İş akış diyagramı

3. ARAŞTIRMA BULGULARI

Yapılan çalışmada model eğitimlerinden sonra, kullanılan üç farklı modellerin performans ölçümleri doğruluk ve F1-skoru ile değerlendirilmiştir. Aşağıda yer alan Tablo 1'de bu modellerin eğitim süreci sonucunda elde edilen doğruluk değerleri ve F1-skorları sunulmaktadır. Tablo sonuçları değerlendirildikten sonra, modellerin detaylı analizine karmaşıklık matrisleri üzerinden yer verilecektir.

Tablo 1. Performans değerlendirme metrikleri

Model	F1-skor	Doğruluk
Pruned Decision Tree	0.9562	0.95625
SVM	0.7248	0.73125
Naive Bayes	0.6725	0.66875

Tablo 1 incelendiğinde Pruned Decision Tree modeli, hem doğruluk hem de F1-skoru açısından açık ara en iyi performansı sergilemektedir. %95.625'lik doğruluk oranı, modelin veriyi yüksek bir doğrulukla sınıflandırdığını göstermektedir. Ayrıca 0.9562 F1-skoru,


modelin hem pozitif hem de negatif sınıflardaki performansının dengeli olduğunu ve sınıflandırma hatalarını iyi yönettiğini işaret etmektedir. Bu yüksek performans, ağacın budanmış olması sayesinde aşırı uyumdan (overfitting) kaçınıldığını ve modelin genelleme yeteneğinin başarılı bir şekilde korunduğunu göstermektedir. Pruned Decision Tree modelinin, veri setindeki farklı sınıfları doğru bir şekilde ayırt edebildiği ve bu nedenle sınıflandırma problemlerinde genellikle tercih edilebilir bir seçenek olduğunu söyleyebiliriz.

SVM modeli, Pruned Decision Tree modeline göre daha düşük bir performans sergilemektedir. %73.125'lik doğruluk oranı, modelin hatalı sınıflandırmalar yaptığını ve veriyi tam olarak ayırt edemediğini göstermektedir. Ayrıca, 0.7248 F1-skoru, özellikle sınıf dengesizliklerinin olduğu durumlarda modelin zorlandığını işaret etmektedir. SVM modelinin, daha yüksek doğruluk ve F1-skoru elde edebilmesi için veri setindeki sınıflar arasında daha net ayrımlar yapılabilmesi gerekebilir. Özellikle sınıflar arasında çok fazla örtüşme veya veri dağılımında dengesizlik olduğunda, SVM'nin performansı bu sonuçlara benzer şekilde düşebilir. Bu model, doğruluk ve F1-skorunun orta seviyede olması nedeniyle, sınıflandırma hatalarının daha belirgin olduğu bir performans sergilemiştir.

Naive Bayes modeli ise en düşük performansı göstermiştir. %66.875 doğruluk oranı, modelin veri setini sınıflandırma konusunda yetersiz kaldığını ve birçok sınıflandırma hatası yaptığını göstermektedir. 0.6725 F1-skoru ise modelin özellikle sınıf dengesizliği karşısında zorlandığını ortaya koymaktadır. Naive Bayes, genellikle basit ve hızlı çalışan bir model olmasına rağmen, verinin sınıfları arasındaki ilişkileri yeterince karmaşık bir şekilde ele alamamış olabilir. Özellikle sınıflar arasındaki bağımsızlık varsayımının geçerli olmadığı durumlarda, Naive Bayes performans düşüklüğü yaşar. Bu sonuçlar da modelin sınıflandırmada zayıf kaldığını ve veriyi doğru bir şekilde ayırt edemediğini göstermektedir.

Sonuçlar incelendiğinde, Pruned Decision Tree modeli tüm metriklerde en iyi sonuçları vermiştir. SVM ve Naive Bayes ise, Pruned Decision Tree'ye kıyasla önemli ölçüde daha düşük doğruluk ve F1-skorlarına sahiptir. Pruned Decision Tree'nin bu kadar iyi performans göstermesi, karar ağaçlarının budanmasının model genellenebilirliğine olumlu katkı sağladığını göstermektedir. SVM modeli, orta seviyede bir başarı göstermiş olup, özellikle doğruluk oranının %73 civarında kalması, modelin sınıfları ayırt etme kabiliyetinde zorluklar yaşadığını işaret etmektedir. Naive Bayes ise en düşük performansı sergileyen modeldir ve

sınıf bağımsızlığı varsayımı nedeniyle veriyi yeterince iyi ayırt edememiştir. Bu sonuçlar, daha karmaşık modellerin ve veri ön işleme adımlarının, doğruluk ve F1-skorlarını artırabileceğini düşündürmektedir.



Şekil 3. Karmaşıklık matrisi

Karmaşıklık matrislerine bakıldığında, her üç modelin sınıflandırma performansı farklılık göstermektedir. Pruned Decision Tree modelinde doğru sınıflamalar ağırlıklı olarak ana köşegende yer almakta ve özellikle 0, 2 ve 3 etiketli sınıflar için çok yüksek doğru sınıflandırma oranları görülmektedir. Bu durum, modelin bu sınıfları neredeyse mükemmel şekilde tanıdığını göstermektedir. Ancak, 1 sınıfı için bazı yanlış sınıflandırmalar dikkat çekmektedir. Bu sınıfın 9 örneği 2 sınıfına yanlış sınıflandırılmıştır. Bu durum, modelin bu iki sınıfı birbirinden ayırt etmekte biraz zorlandığını göstermektedir. Genel olarak, Pruned Decision Tree modeli diğer sınıflarda oldukça iyi bir ayırım yapmıştır ve bu durum modelin yüksek doğruluk ve F1-skorları ile uyumlu olarak gözlemlenmiştir.

SVM modeline bakıldığında, doğru sınıflamalar Pruned Decision Tree'ye kıyasla daha düşük seviyededir. Özellikle 0 sınıfında 30 doğru sınıflamaya rağmen, 17 örnek 2 sınıfına yanlış atanmıştır. Ayrıca, 2 sınıfında da çok fazla yanlış sınıflama görülmektedir; 15 örnek 0 sınıfına, 4 örnek ise 1 sınıfına yanlış atanmıştır. Bu durum, SVM'nin sınıflar arasında net bir ayırım yapamadığını ve daha fazla sayıda hatalı sınıflandırma yaptığını göstermektedir. SVM'nin sınıflar arasında ayırım yapmakta zorlandığı bu hatalar, modelin daha düşük doğruluk ve F1-skoru elde etmesinin nedenidir.

Naive Bayes modelinde ise hatalı sınıflandırmalar çok daha yaygın bir şekilde gözlemlenmiştir. Örneğin, 0 sınıfında 19 doğru sınıflama yapılırken, 20 örnek yanlış sınıflandırılmıştır. Bu yanlış sınıflandırmaların 8’i 2 sınıfına, 7’si ise 3 sınıfına atanmıştır. Ayrıca, 2 sınıfında da 9 örnek 0 sınıfına yanlış atanmıştır. Bunun yanı sıra, 1 sınıfında doğru bir sınıflama yapılmamış ve tüm örnekler diğer sınıflara yanlış atanmıştır. Naive Bayes modelinin sınıflar arasındaki ayrımı yeterince yapamadığı ve karmaşık ilişkileri öğrenmekte zorlandığı görülmektedir. Bu durum, modelin düşük doğruluk ve F1-skoru elde etmesine neden olmuştur.

Genel olarak, Pruned Decision Tree diğer modellere göre sınıfları daha iyi ayırt etmiş ve hatalı sınıflandırmaların büyük çoğunluğunu önleyebilmiştir. SVM modeli bazı sınıflarda başarılı olsa da, özellikle 0 ve 2 sınıflarını ayırt etmede zorluk çekmiştir. Naive Bayes modeli ise genel olarak çok daha fazla yanlış sınıflandırma yapmış ve sınıflar arasında ciddi ayrım sorunları yaşamıştır. Bu durum, modelin düşük performansına katkıda bulunmuştur.

4. SONUÇ ve ÖNERİLER

Yapılan çalışma, makine öğrenmesi algoritmalarının 3D yazıcı teknolojilerinde çekme dayanımı gibi kritik mekanik özelliklerin tahminindeki etkinliğini ortaya koymaktadır. Özellikle Budanmış Karar Ağacı algoritmasının %96 doğruluk oranıyla diğer modellere üstünlük sağladığı belirlenmiştir. Bu bulgular, literatürdeki diğer çalışmalara kıyasla bu çalışmanın özgün katkılarını öne çıkarmaktadır.

Zhang ve arkadaşları (2023), yapay sinir ağları kullanarak FDM tabanlı üretimlerde PLA ve ABS malzemelerin mekanik özelliklerini tahmin etmiş ve %94 doğruluk oranı elde etmişlerdir. Bu çalışma, makine öğrenmesinin üretim süreçlerindeki mekanik özelliklerin tahmini konusunda güvenilir bir yöntem olduğunu göstermektedir [39]. Ayrıca, Wu ve Li (2022), metal bazlı 3D baskı malzemelerinde destek vektör makineleri algoritmasını kullanarak çekme dayanımı tahmininde başarılı sonuçlar elde etmiş, özellikle karmaşık veri kümelerinde algoritmanın güçlü bir genelleme yeteneği sunduğunu vurgulamışlardır [40].

Günay ve arkadaşları (2020), 3D baskı işlem parametrelerinin optimizasyonu üzerine yaptıkları çalışmada, baskı hızı, doluluk oranı ve tarama açısının mekanik özellikler

Muzaffer EYLENCE, Bekir AKSOY, Koray ÖZSOY, “ Makine Öğrenmesi ile 3 Boyutlu Yazıcı Plastik Filamentlerinin Ergime Noktası ve Esneklik Özelliklerine Dayalı Çekme Dayanımının Tahmini ”, Yekarum e-Dergi, 9 / 2 (2024) 91-107

üzerindeki etkilerini detaylı şekilde incelemişlerdir. Bu tür çalışmalar, üretim parametrelerinin mekanik performansa etkisini anlamada önemli katkılar sağlamaktadır [41].

Bu bağlamda, çalışmamız literatüre şu iki önemli katkıyı sunmaktadır: birincisi, EBM tabanlı 3D baskı süreçlerinde farklı makine öğrenmesi algoritmalarının performanslarını karşılaştırmalı olarak ele alarak, üretim süreçlerini optimize etmede en etkili algoritmayı belirlemek; ikincisi ise, makine öğrenmesi algoritmalarının farklı veri setleri ve parametrelerle nasıl geliştirilebileceğini göstermektir. Gelecekte yapılacak çalışmalarda, daha geniş veri setlerinin ve hibrit model yaklaşımlarının denenmesi önerilmektedir.

Teşekkür

Çalışmada kullanılan “3Dprinting plastics 2024” veri setini kullanıma açan açık erişim internet sitesinde (Kaggle.com)’a teşekkür ederiz.

Çıkar Çatışması Beyanı

Yazarlar arasında çıkar çatışması yoktur.

Araştırma ve Yayın Etiği Beyanı

Çalışma, araştırma ve yayın etiğine uygundur.

KAYNAKLAR

- [1] Franco Urquiza, E. A. (2024). Advances in additive manufacturing of polymer-fused deposition modeling on textiles: From 3D printing to innovative 4D printing—A review. *Polymers, 16*(5), 700.
- [2] Ramful, R. (2024). Numerical modelling of the warping behaviour at the first layer-build plate interface in 3D-printed models produced via the fused deposition modelling process. *Advanced Manufacturing Research*.
- [3] ISO/ASTM 52900:2021. (2021). *Additive manufacturing—General principles—Fundamentals and vocabulary*. Geneva, Switzerland: ISO.
- [4] Jayanth, N., Jaswanthraj, K., Sandeep, N. H., Mallaya, S. R., & Siddharth, S. (2021). Effect of heat treatment on mechanical properties of 3D printed PLA. *Journal of Mechanical Behavior of Biomedical Materials, 123*, 104764.

- [5] Mallikarjuna, B., Bhargav, P., Hiremath, S., & Jayachristiyan, K. G. (2023). A review on the melt extrusion-based fused deposition modeling (FDM): Background, materials, process parameters, and military applications. *International Journal on Interactive Design and Manufacturing (IJIDeM)*, 1-15.
- [6] Srivatsan, T. S., & Sudarshan, T. S. (2016). *Additive manufacturing: Innovations, advances, and applications*. New York, NY: CRC Press.
- [7] Liu, Z., Wang, Y., Wu, B., Cui, C., & Yan, C. (2019). A critical review of fused deposition modeling 3D printing technology in manufacturing polylactic acid parts. *International Journal of Advanced Manufacturing Technology*, 102, 2877–2889.
- [8] Marwah, O. M. F., Shukri, M. S., Mohamad, E. J., Johar, M. A., & Khiretdin, R. H. A. H. K. (2017). Direct investment casting for pattern developed by desktop 3D printer. *MATEC Web of Conferences*, 135, 00036.
- [9] Mohamed, O. A., Masood, S. H., & Bhowmik, J. L. (2015). Optimization of fused deposition modeling process parameters: A review of current research and future prospects. *Advances in Manufacturing*, 3, 42-53.
- [10] Zhang, M., Zeng, W., Lei, Y., Chen, M., Qin, X., & Li, S. (2022). A novel sustainable luminescent ABS composite material for 3D printing. *European Polymer Journal*, 176, 111406.
- [11] Maspoch, M. L., Santana, O. O., Cailloux, J., Franco-Urquiza, E., Rodriguez, C., & Martínez, J. (2015). Ductile-brittle transition behaviour of PLA/o-MMT films during the physical aging process. *Express Polymer Letters*, 9, 185–195.
- [12] Bhagia, S., Kore, S., Wasti, S., Đurković, J., Zhao, X., & Andrews, H. B. (2023). 3D printing of a recycled copolyester of terephthalic acid, cyclohexanedimethanol, and tetramethylcyclobutanediol. *Polymer Testing*, 118, 107916.
- [13] Kumar, M., Ramakrishnan, R., & Omarbekova, S. (2021). Experimental characterization of mechanical properties and microstructure study of polycarbonate (PC) reinforced acrylonitrile-butadiene-styrene (ABS) composite with varying PC loadings. *AIMS Materials Science*, 8, 18–28.
- [14] Andrzejewski, J., & Marciniak-Podsadna, L. (2020). Development of thermal resistant FDM printed blends. The preparation of GPET/PC blends and evaluation of material performance. *Materials*, 13, 2057.

Muzaffer EYLENCE, Bekir AKSOY, Koray ÖZSOY, “ Makine Öğrenmesi ile 3 Boyutlu Yazıcı Plastik Filamentlerinin Ergime Noktası ve Esneklik Özelliklerine Dayalı Çekme Dayanımının Tahmini ”, Yekarum e-Dergi, 9 / 2 (2024) 91-107

- [15] Zhang, Y., Purssell, C., Mao, K., & Leigh, S. A. (2020). Physical investigation of wear and thermal characteristics of 3D printed nylon spur gears. *Tribology International*, 141, 105953.
- [16] Russell, S., & Norvig, P. (2020). *Artificial intelligence: A modern approach* (4th ed.). Pearson.
- [17] Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- [18] Searle, J. R. (1980). Minds, brains, and programs. *Behavioral and Brain Sciences*, 3(3), 417-424.
- [19] Bostrom, N. (2014). *Superintelligence: Paths, dangers, strategies*. Oxford University Press.
- [20] Mitchell, T. M. (1997). *Machine learning*. McGraw Hill.
- [21] Kotsiantis, S. B., Zaharakis, I., & Pintelas, P. (2007). Supervised machine learning: A review of classification techniques. *Emerging Artificial Intelligence Applications in Computer Engineering*, 160, 3-24.
- [22] Hinton, G. E., & Salakhutdinov, R. R. (2006). Reducing the dimensionality of data with neural networks. *Science*, 313(5786), 504-507.
- [23] Sutton, R. S., & Barto, A. G. (2018). *Reinforcement learning: An introduction* (2nd ed.). MIT Press.
- [24] Çınar, İ., Gündüz, G., & Yılmaz, Ö. (2020). Machine learning approaches for tensile strength prediction in 3D printed polymers. *Journal of Applied Polymer Science*, 137(15), 485-492.
- [25] Yılmaz, M., & Demir, E. (2021). Prediction of tensile strength of 3D printed materials using artificial neural networks and decision trees. *Materials & Design*, 209, 109930.
- [26] Huang, Y., Leu, M. C., Mazumder, J., & Donmez, A. (2019). Additive manufacturing: Current state, future potential, gaps and needs, and recommendations. *Journal of Manufacturing Science and Engineering*, 141(1), 011014.
- [27] Kaggle. (2024). *3D printer plastics dataset*. Retrieved from <https://www.kaggle.com/datasets/sourceduty/3d-printer-plastics-2024>
- [28] Quinlan, J. R. (1987). Simplifying decision trees. *International Journal of Man-Machine Studies*, 27(3), 221-234.

- [29] Breiman, L., Friedman, J. H., Olshen, R. A., & Stone, C. J. (1984). *Classification and regression trees*. Wadsworth International Group.
- [30] Esposito, F., Malerba, D., & Semeraro, G. (1997). A comparative analysis of methods for pruning decision trees. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 19(5), 476-491.
- [31] Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273-297.
- [32] Schölkopf, B., & Smola, A. J. (2002). *Learning with kernels: Support vector machines, regularization, optimization, and beyond*. MIT Press.
- [33] Vapnik, V. N. (1995). *The nature of statistical learning theory*. Springer.
- [34] Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The elements of statistical learning: Data mining, inference, and prediction*. Springer.
- [35] Domingos, P., & Pazzani, M. (1997). On the optimality of the simple Bayesian classifier under zero-one loss. *Machine Learning*, 29(2-3), 103-130.
- [36] Rish, I. (2001). An empirical study of the naive Bayes classifier. In *IJCAI Workshop on Empirical Methods in AI*, 3, 41-46.
- [37] Zhang, H. (2004). The optimality of naive Bayes. In *AAAI 2004 Conference on Artificial Intelligence*, 562-567.
- [38] H. Çetiner and S. Metlek, “CNNTuner: Image Classification with A Novel CNN Model Optimized Hyperparameters,” Bitlis Eren Üniversitesi Fen Bilim. Derg., vol. 12, no. 3, pp. 746–763, 2023.
- [39] Günay, M., Yıldırım, Z., & Demirci, E. (2020). 3D baskı işlem parametrelerinin çekme dayanımı üzerindeki etkileri. *Politeknik Dergisi*, 23(4), 1043-1050.
- [40] Wu, J., & Li, F. (2022). Predicting tensile strength in metal 3D printing using support vector machines. *Journal of Additive Manufacturing Science*, 18(3), 145-157.
- [41] Zhang, T., Huang, Y., & Chen, L. (2023). Application of artificial neural networks for predicting mechanical properties of PLA and ABS in FDM-based 3D printing. *International Journal of Polymer Science*, 45(2), 215-227.