





Düzce Üniversitesi Bilim ve Teknoloji Dergisi

Araştırma Makalesi

Eklemeli İmalat ile Üretilen PLA Esaslı Malzemenin Çekme Dayanımının Makine Öğrenmesi Algoritmaları Kullanarak Tahmini¹

 Koray ÖZSOY^{a,*},  Hamdi SAYIN^b

^a *Isparta Uygulamalı Bilimler Üniversitesi Isparta OSB Meslek Yüksekokulu Makine ve Metal Teknolojileri Bölümü, Isparta, TÜRKİYE*

^b *Isparta Uygulamalı Bilimler Üniversitesi Teknoloji Fakültesi Mekatronik Mühendisliği Bölümü, Isparta, TÜRKİYE*

* Sorumlu yazarın e-posta adresi: korayozsoy@isparta.edu.tr

DOI: 10.29130/dubited.1012892

ÖZ

Endüstri 4.0'ın önemli bileşenlerinden olan eklemeli imalat ve yapay zekâ teknikleri günümüzde birçok alanda sıklıkla kullanılmaktadır. Eklemeli imalat yöntemleri kendi içerisinde yedi sınıfa ayrılmaktadır. Eriyik yığma modelleme eklemeli imalat yönteminin sıklıkla tercih edilen yöntemlerinden birisidir. Eriyik yığma modelleme imalat tablası üzerinde kullanılan filament malzemenin katman katman birleşimi ile parça üretimi gerçekleştirilir. Çalışmada eriyik yığma modelleme yönteminde farklı işleme parametreleri kullanılarak çekme numuneleri üretilmiştir. Çekme numuneleri ASTM standartlarına göre çekme deneyi yapılarak, çekme dayanımına ait değerler ile veri seti oluşturulmuştur. Malzeme üretim sürecinde toplanan sıcaklık, hız, katman özelliklerine dair veri seti kullanılarak üretilen malzemenin çekme dayanımı değerleri üç farklı makine öğrenmesi modeli kullanılarak tahmin edilmiştir. Sonuçlar, makine öğrenmesi algoritmaları kullanılarak çekme dayanımını Kısmi En Küçük Kareler algoritması ile %98,3 doğrulukla tahminlediğini göstermiştir.

Anahtar Kelimeler: Eklemeli imalat, Makine öğrenmesi, Eriyik yığma modelleme

Estimation of Tensile Strength of PLA Based Material Produced by Additive Manufacturing Using Machine Learning Algorithms

ABSTRACT

Additive manufacturing and artificial intelligence techniques, which are important components of Industry 4.0, are frequently used in many areas today. Additive manufacturing methods are divided into seven classes within themselves. The fused deposition method is one of the most preferred methods of additive manufacturing. The part is produced by the layer-by-layer combination of the filament material used on the fused deposition method (FDM) manufacturing table. In the study, tensile samples were produced by using different processing parameters in the FDM method. Tensile samples were tested according to ASTM standards, and a data set was created with the values of tensile strength. The tensile strength values of the material produced using the data set on temperature, velocity, layer properties collected during the material production process were estimated using three different machine learning models. The results showed that using machine learning algorithms, the tensile strength can be predicted with an accuracy of 98,3% by the Partial Least Squares algorithm.

Keywords: Additive manufacturing, Machine learning, Fused deposition modelling

I. GİRİŞ

İmalat, bir ürüne değer katan süreçtir. İmalat sistemi ise genel olarak, kâr sağlamak amacıyla bir ürüne değer katmak için hammaddenin içinde bulunduğu şekilden başka bir şekle dönüştürüldüğü sistem olarak tanımlanabilir. İmalat işlemi çeşitli yöntemlerle gerçekleştirilmektedir. İmalat yöntemleri talaşlı, talaşsız ve modern imalat yöntemleri olarak uygulanmaktadır. Talaşlı imalat [1] tornalama, frezeleme yöntemleri kullanılırken talaşsız imalat [2] döküm ve kaynak alt süreçleri kullanılmaktadır. Modern imalat yöntemlerinde ise CNC makineler ve 3 boyutlu yazıcılardan yararlanılmaktadır.

Üç boyutlu yazıcılar, bilgisayar destekli tasarım programlarıyla çizimi gerçekleştirilen nesnelerin hammaddenin üst üste tabakalanmasıyla üç boyutlu olarak üretilmesine imkân sağlayan teknolojidir. 3B yazıcılarda günümüzde sıklıkla kullanılan EBM (Eriyik Biriktirme Modelleme/Fused Deposition Modelling) teknolojisi, sıcak bir başlık vasıtasıyla eritilen termoplastik malzemenin baskı tablası üzerine katmanlar halinde akıtılıp eklenmesiyle üretim yapılan 3D baskı teknolojisidir. Ergiyik Biriktirme Modelleme yönteminde kullanılan hammaddeler ABS (Akrilonitril Butadien Stiren), PLA (Polylactic Acid), PCABS (Polikarbonat Akrilonitril Butadien Stiren), ABS+, TPU (Termoplastik Poliüretan), PC (Polikarbonat), PEEK (Polieter Eter Keton), PEI (Polyetherimide), PP (Polipropilen) termo plastiklerdir [3,4].

Üç boyutlu (3B) yazıcılar tüm üretim alanlarında hızlı prototipleme, yedek parça üretimi, mimari modeller, tıbbi protezler, inşaat projeleri ve eğitim süreçlerinde sıklıkla kullanılmaktadır. Eriyik yığıma yönteminde birçok farklı işleme parametreleri vardır. Bu parametreler parçanın görsel ve işlevsel özelliklerini etkilemektedir. Karaman vd. (2019) çalışmalarında ABS-plus termoplastik malzemeli farklı doluluk oranı ve farklı yönlendirme açısı ile çekme testi numunesi EYM yöntemiyle üretilmiş ve çekme teste tabi tutulmuştur. Doluluk oranındaki artış ve farklı yönlendirme mekanik özellikleri önemli oranda değiştirmiştir [5]. Zhang vd., (2019) çalışmasında, EYM yöntemi kullanarak derin öğrenme ağ yapısındaki 3B baskı sürecini dikkate alarak veriye dayalı bir tahmine dayalı model sunmuştur [6]. Rajpurohit vd., (2019) çalışmasında PLA malzemeli numuneleri EYM yöntemiyle üretilmiştir. Çekme deney sonuçları deneysel değerler ile ölçülüp analiz edilmiştir. Çekme testi sonuçları, parça oryantasyonu, dolgu modeli ve doluluk oranının çekme mukavemetini önemli ölçüde etkilediğini göstermiştir. Düz parça oryantasyonu ve eş merkezli desen ile basılan parçaların maksimum çekme mukavemeti sergilediği gözlemlenmiştir. Doluluk oranı artması ile çekme mukavemeti artmıştır [7].

Bir süreç ya da sistemin girdilerinde değişiklik yapılarak çıktıların gözlemlenmesi ve analiz edilmesini sağlayan deney tasarımı metodları, en uygun üretim faktörlerini belirlemek için kullanılan etkin istatistiksel metotlardandır [8]. Endüstride sıklıkla gördüğümüz bu uygulamalar hem işletmelerin iş akışlarında iyileşme hem de kaynakların verimli kullanılmasını sağlamaktadır [9]. Farklı alanlarda kullanımı yaygınlaşan 3B yazıcılarda üretilen nesnelerin sağlam ve uzun ömürlü olacak şekilde üretilmesi dikkatli bir üretim sürecini gerektirmektedir. Üretim sürecinde kullanılan hammadde türü ve diğer üretim parametreleri ürün kalitesini doğrudan etkilemektedir. Sistematik olmayan deneme yanılma yöntemleri ve hata metodu gibi tekniklerin kullanılması optimal kombinasyonlu üretim parametrelerini bulmayı oldukça zorlaştırmaktadır [10]. Seri üretim için çok önemli olan ve ürün kalitesini etkileyen termal proseslerin deneysel çalışmalarda elde edilen büyük veriler ile derin öğrenme yöntemleri kullanılarak tahmin edilmesi de oldukça önemlidir [11]. Derin öğrenme uygulamalarında biri olan makine öğrenmesi özellikle sanayide üretim kademesinde işlerin hızlandırılması, ürün kalitesinin artırılması, ürünlerin sınıflandırılması vb. gibi işlemleri hızlıca yapması nedeniyle sıklıkla tercih edilmektedir [12].

Bu çalışma eklemeli imalat yöntemlerinden EBM 3B baskı yönteminin işleme parametreleri ve malzeme özelliklerinin incelenmesi ile ilgilidir. Deney numuneleri plastikler için ISO standartlarına göre çizilmiştir. EBM 3B Baskı yöntemiyle deney standartlarına göre PLA malzemeli çekme deney numuneleri üretilmiştir. Üretim parametreleri fan hızı %0 ve %100, katman kalınlığı 0,2, 0,3 ve 0,4 mm, doluluk oranı %30, %65 ve %100, baskı hızı 75, 125 ve 175 mm/sn, tabla sıcaklığı 30°C, 50°C ve 80°C

olacak biçimde seçilmiştir. PLA malzemeden her bir işleme parametresi için 12 adet çekme deneyleri gerçekleştirilmiştir. Elde edilen bulgular literatürle karşılaştırılmıştır.

II. MATERYAL ve METOT

A. MATERYAL

A. 1. Üç Boyutlu (3B) Yazıcı

Eklemeli imalat olarak da bilinen 3 Boyutlu (3B) yazdırma işlemi, parçaların dijital bir ortamda katmanlar halinde tablaya yerleştirilmesi ile imal edilen bir süreçtir [13]. 3B katı model. STL dosya formatında elde edilmiştir. Şekil 1’de çalışmada kullanılan EBM tip 3B yazıcı ile numuneler PLA malzeme kullanılarak imal edilmiştir. Tablo 1’de çalışmada kullanılan 3B yazıcının sabit parametreleri ve teknik özellikleri verilmiştir.



Şekil 1. Çalışmada kullanılan 3B yazıcı çekme numune imalat görüntüsü

Tablo 1. EBM tipi 3B yazıcının sabit parametreleri ve teknik özellikleri

Özellik	Birimi	Ölçü
Baskı Alanı	cm	22x22x25
Yazıcı Boyutları	cm	44x41x46,5
Ağırlık	Kg	8,6
Maksimum Hareket Hızı	mm/s	180
Filament	1,75 mm	PLA,TPU,ABS
Katman Kalınlığı	mm	0,1-0,4
Nozzle	mm	0,4
Hassasiyet	Mm	+0,1
Max Nozzle Sıcaklığı	°C	255
Max Tabla Sıcaklığı	°C	110
Baskı Dosya Biçimi		STL,OBJ,G-CODE

A. 2. Çekme Test Numuneleri

Çekme test numuneleri Solidworks programı ile ISO 527: 1993 çekme testi standartlarına göre 122 mm uzunluğunda, 20 mm genişliğinde ve 2,4 mm kalınlığında çizilmiştir. Eklemeli imalat EBM yöntemiyle dolgu oranı, fan hızı, katman kalınlığı ve baskı hızı gibi farklı işleme parametreleri ile çekme testi numuneleri üretilmiştir. Eklemeli imalat EBM yöntemiyle üretilen çekme test numunesi örnekleri Şekil 2'de gösterilmiştir.



Şekil 2. Eklemeli imalat ile üretilen çekme test numunelerinin görüntüsü

A. 3. Veri Seti

Çalışmada kullanılan veri seti için 36 adet çekme testi numunesi EBM tipi 3B yazıcı ile üretilmiştir. Daha sonra Taguchi deney tasarımı ile çekme deney maliyetini en aza indirmek için optimum 12 adet numune çekme testine tabi tutulmuştur. Böylece veri seti üretim sürecine ait fan hızı, tabla sıcaklığı, katman kalınlığı, dolgu yüzde oranı, baskı hızı ve numunelere ait çekme dayanımı sonuç verilerinden oluşmaktadır. İmalat parametreleri; nozzle fanı açık (%0)-kapalı (%100), tablanın sıcaklığı değerleri 30 °C- 80 °C, katman kalınlığı 0,2- 0,4 mm değer aralıkları arasında değişmektedir. Dolgu oranı %30-%100 arasında değişim gösterirken, baskı hızı ise 75 mm/sn ile 175 mm/sn arasında değişim göstermiştir. Bu üretim değerleri ile üretilen numunelere ait çekme dayanımı sonuçları ise 24-45 MPa arasında tespit edilerek veri setine dahil edilmiştir.

Tablo 2. Veri seti

Numune No	Fan Hızı	Tabla Sıcaklığı (°C)	Katman Kalınlığı (mm)	Dolgu Oranı (%)	Baskı Hızı (mm/sn)	Çekme Dayanımı (MPa)
3	0	80	0.4	100	175	36
7	0	30	0.2	30	175	29
8	0	50	0.3	65	75	33
9	0	80	0.4	100	125	37
10	0	30	0.2	30	125	33
11	0	50	0.3	65	175	31
12	0	80	0.4	100	75	44
19	100	80	0.2	65	175	32
20	100	30	0.3	100	75	46
21	100	50	0.4	30	125	31
34	100	80	0.2	100	125	45
36	100	50	0.4	65	75	28

A. 4. Kısmi En Küçük Kareler Regresyon (PLS) Algoritması

Kısmi en küçük kareler regresyonu hem yüksek boyutlu hem de çoklu doğrusallık problemlerini çözmek için istatistiksel prosedürleri kullanan ana regresyonlardan biridir [14]. PLS'de çıktı değişkeni, girdi değişkenlerinin bir fonksiyonu olarak modellenir. Tipik bir regresyon modelinde çıktılar, girdilerin doğrusal bir kombinasyonu olarak ifade edilir. Gerçek sonuçlar ile Denklem 1'deki model tarafından tahmin edilen sonuçlar arasındaki fark, OLS (Olağan En Küçük Kareler) yöntemi kullanılarak, ikinci dereceden hataların toplamını en aza indiren bir model katsayısı sağlar [15].

$$Y_i = \beta_{01} + \beta_{11} X_1 + \beta_{21} X_2 + \beta_{31} X_3 + \dots + \beta_{81} X_8 + \varepsilon_1 \quad (1)$$

PLS regresyonu, giriş ve çıkış değişkenlerini kullanarak doğrudan regresyon gerçekleştirmez. Bunun yerine, modeli oluşturmak için özel değişkenler (gizli değişkenler) kullanır. Denklem 2'de verilen matriste n girdi değişkenleri, m çıktı değişkenleri, N veri noktaları, X girdi değerleri ve Y veri matrisleridir [16].

$$X = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1n} \\ x_{21} & x_{22} & \dots & x_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ x_{N1} & x_{N2} & \dots & x_{Nn} \end{bmatrix} \quad Y = \begin{bmatrix} y_{11} & y_{12} & \dots & y_{1m} \\ y_{21} & y_{22} & \dots & y_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ y_{N1} & y_{N2} & \dots & y_{Nm} \end{bmatrix} \quad (2)$$

A. 5. Rastgele Orman Regresyon (RFR) Algoritması

Breiman tarafından önerilen rastgele orman regresyon algoritması, tahmine dayalı analitik sonuçlar için en etkili makine öğrenme modellerinden biridir [17]. Basit kavramlarla ilgili denetimli bir öğrenme algoritmasıdır. Algoritma, eğitim zamanında bir dizi karar ağacıyla bir orman oluşturarak çalışır. Her ağaç, karar ağacının tahmini olan sonlandırma noktasına (yaprak) ulaşana kadar ağacın farklı dallarına ayrıldığı bir karar düğümleri düzenlemesi içerir. Her bir karar düğümü, girdi özelliklerinin değerinin belirli bir eşliğin üzerinde olup olmadığına bağlıdır. Her orman ağacı, farklı bir model yaklaşımı sağlamak için bağımsız olarak eğitilir. Nihai tahmin, ağaç tahminlerinin her birinin ortalaması alınarak elde edilir [18].

A. 6. Theil-Sen Regresyon (TSR) Algoritması

Theil-Sen regresyon algoritması, verilerde mevcut olan aykırı değerlere karşı dayanıklı, parametrik olmayan bir tahmin yöntemidir [19]. Theil-Sen regresyonu, yalnızca aykırı değerlerin varlığında tutarlı performans göstermekle kalmaz, aynı zamanda normal veriler için de diğer regresyon algoritmalarının rakibidir. Bir doğrunun eğrisini tahmin etmek için kullanılan Theil'in yöntemi, (x_i, y_i) ve (x_j, y_j) gözlem çiftlerinin medyanının hesaplanmasına dayanmaktadır [20]. Denklem 3'de verilen β_1 değeri son parametrik olmayan eğim, hesaplanan tüm eğimlerin uzaysal medyanı olarak tanımlanır. β_0 kesişimi Denklem 3'e verilen matematiksel ifade ile hesaplanır.

$$\beta_0 = Y_{medyan} - \beta_1 * X_{medyan} \quad (3)$$

Denklemden X_{medyan} giriş değişkenlerine ait ölçümlerin ve Y_{medyan} ise yanıt değişkenlerinin medyanlarıdır.

A. 7. Performans Başarı Ölçütleri

Makine öğrenmesi modeli hazırlandıktan sonra modelin performansı değerlendirilmelidir. Makine öğrenmesi uygulamalarında performans değerlendirme kriterleri, uygulamanın türüne göre değişiklik göstermektedir. Regresyon analizi için kullanılan değerlendirme kriterleri ile bir sınıflandırmanın veya

kümelmiş bir uygulamanın değerlendirme kriterleri farklı olacaktır. Regresyon analizinde, performans değerlendirmesi için belirleme katsayısı (R^2), Ortalama Kare Hata (MSE), Kök Ortalama Kare Hata (RMSE) ve Ortalama Mutlak Yüzde Hata (MAPE) gibi çeşitli regresyon kriterleri kullanılabilir. Bu değerlerin hesaplanmasını sağlayan denklemler Denklem 4 ile Denklem 7 arasında verilmiştir [21].

$$R^2 = (y, \hat{y}) = 1 - \frac{\sum_{i=0}^{n_{samples}-1} (y_i - \hat{y}_i)^2}{\sum_{i=0}^{n_{samples}-1} (y_i - \bar{y})^2}$$

Burada: $\bar{y} = \frac{1}{n_{samples}} \sum_{i=0}^{n_{samples}-1} y_i$ (4)

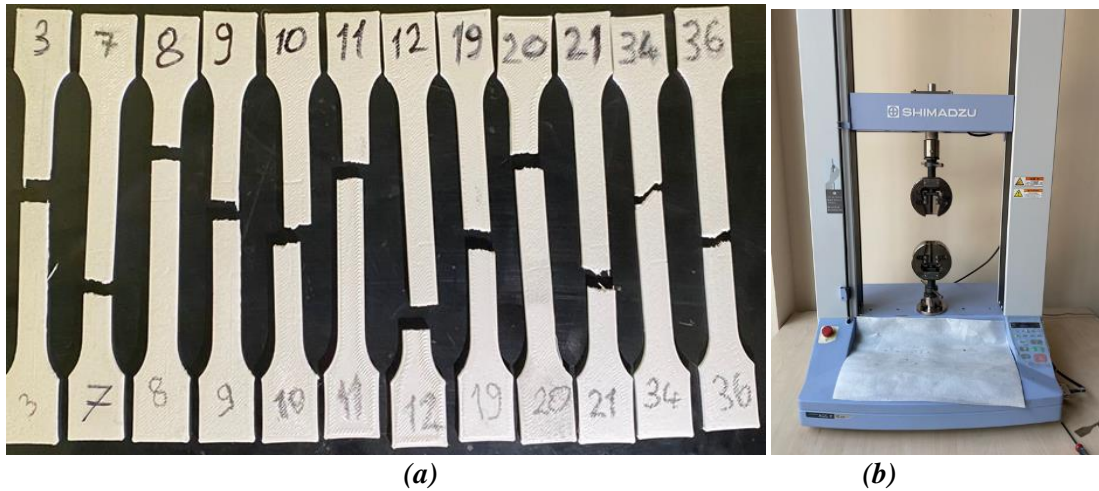
$$MSE(y, \hat{y}) = \frac{1}{n_{samples}} \sum_{i=0}^{n_{samples}-1} (y_i - \hat{y}_i)^2$$
 (5)

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}}$$
 (6)

$$MAPE = \frac{100}{n} \sum_j \frac{|e_j|}{|A_j|}$$
 (7)

B. METOT


Üç boyutlu yazıcıda imalatı yapılan 12 adet numunelere çekme testi uygulanmıştır. Çekme testi, Şekil 3'te gösterildiği gibi 10 kN kuvvet dönüştürücü kapasiteli bir test makinesinde (AGS-X, Shimadzu Co., Kyoto, Japonya) gerçekleştirildi. Numunelerde, çekme testi için özel test parametreleri 1 mm/s'lik bir çekme hızında gerçekleştirilmiştir. Deneysel hataları en aza indirmek için her koşul için üç adet test numunesi test edilmiş ve elde edilen çekme dayanımı değerlerinin ortalaması alınarak değerlendirmeler yapılmıştır. Farklı imalat parametreleri ile üretimi yapılan numune örneklerine çekme dayanımı testi uygulanarak sonuçlar kayıt altına alınmıştır.



Şekil 3. Çekme testi (a) numunelerin görüntüsü (b) deneysel düzenek

Çekme dayanımı testleri sonucunda elde edilen veriler bir araya getirilerek çalışmanın veri seti oluşturulmuştur. Numune sayısının kısıtlı olması, numune üretim ve test süreçlerinin uzun zaman gerektirmesi nedeniyle veri seti sınırlı sayıda numuneye ait veri ile oluşturulmuştur. Bu durum mevcut veri seti ile oluşturulan regresyon modellerinin tahmin başarı oranının düşük, hata oranlarının ise yüksek sonuçlar vermesine yol açmaktadır. Makine öğrenmesi uygulamalarında ihtiyaç duyulan büyük

miktarda veri gereksinimini karşılamak için mevcut verilerden bilgi aktarılabilir ya da gerçek örneklerle dayalı yapay veri üretme uygulaması gerçekleştirilir [16]. Bu nedenle çalışmada ortalama hesabına dayalı veri artırımı gerçekleştirilmiştir. 36 satırdan oluşan veri seti 2 ila 5 arasında rastgele seçilen deney verilerine ait ortalama değerler hesaplanarak yeni değerler veri setine eklenmiştir. Bu işlemler sonucunda veri seti 108 satıra yükseltilerek, mevcut verilerin üç katı regresyon modellemesinde kullanılarak model tahmin başarısı arttırılmıştır. Literatürde makine öğrenmesi ve derin öğrenme uygulamalarında sıklıkla kullanılan açık kaynak kodlu python programlama dili, çalışmanın yazılımsal aşamalarında tercih edilmiştir. Çalışmada hazırlanan yazılımda Python programlama dilindeki numpy, pandas, scikit-learn ve kütüphaneleri kullanılmıştır. Numpy, N boyutlu dizi ve matrisleri üzerinde hesaplamalar yapmanıza imkân sağlayacak bir kütüphanedir. Pandas kütüphanesi ise verileri yeniden şekillendirme, dilimleme, birleştirme vb. gibi çeşitli özelliklerin kullanılmasını sağlar. Scikit-learn kütüphanesi iki boyutlu olarak oluşturulmuş dizilerin bir veya daha çok veri kümesinden gelen makine öğrenme bilgileriyle ilgilenir. Test süreci sonrasında elde edilen sayısal verilerin işlenmesinde numpy ve pandas kütüphanelerinden faydalanılmıştır. Makine öğrenmesi süreçlerinde scikit-learn kütüphanesi kullanılmıştır. Çalışmanın iş akış diyagramı Şekil 4.'de verilmiştir.




Şekil 4. İş Akış Diyagramı

III. BULGULAR ve TARTIŞMA

Çalışmada EBM tipi 3B yazıcı eklemeli imalat yöntemi ile farklı proses parametreleri ile üretilen çekme test sonuçları analiz edilmiş ve tablolar halinde verilmiştir. Çalışmadan elde edilen çekme testi sonuçları Tablo 3'de verilmiştir. Tablo 3. incelendiğinde; PLA malzemeli numunelerin en yüksek dayanım değerlerine 24 nolu numunede sahip olduğu görülmektedir. Bunun nedeni; numune imalat sürecinde katmanlar arasında sağladığı bağın PLA malzemeli numunelerin daha iyi olmasından kaynaklanmaktadır. Ayrıca en yüksek dayanım değeri elde edilmesinin diğer bir sebebi ise, fan hızının %100, katman kalınlığının düşük değerde olması ve en önemli faktör olan dolgu oranının %100 olmasındandır. Şekil 5 incelendiğinde numunelerin doluluk oranı arttıkça PLA malzemeli numunelerin çekme dayanımı kısmen arttığı gözlemlenmiştir.

Tablo 3. PLA malzemeli çekme deneyi sonuçları

PLA	Elastikiyet Modülü (GPa)	Çekme dayanımı (MPa)	Gerinim (%)
3	0,992	36,04	5,7
7	0,852	29,22	4,5
8	0,943	33,70	4,93
9	1,020	36,91	5,07
10	0,929	32,96	4,9
11	0,909	30,66	4,67
12	1,100	43,59	6,13
19	0,973	32,89	4,53
20	1,208	44,64	5,46
21	0,741	23,74	4,45
24	1,195	44,61	4,98
36	0,868	27,83	4,48
Ortalama	0,977	34,73	4,98
Standart Sapma	138	6,76	0,53



Şekil 5. Çekme deneyi numunelerinin gerilme-gerinim grafiği

Uygulamada, veri setinde bulunan imalat parametrelerine ait veriler %80 eğitim-%20 test verisi olarak belirlenerek model eğitimi gerçekleştirilmiştir. Eğitim sonrasında mevcut verilerin %20'sini içeren test verileri kullanılarak regresyon modelleri test edilmiştir. Farklı algoritmalarla oluşturulan modellerin başarımları karşılaştırılmış, hata değerleri hesaplanarak sonuçlar Tablo 4'de sunulmuştur.

Tablo 4. Modellere ait başarımları ve hata oranları

Regresyon Türü	R ²	MSE	RMSE	MAPE
Kısmi en küçük kareler regresyonu(PLS)	%98,3	1,26	1,12	4,70
Rastgele Orman Regresyonu	%94,9	0,83	0,79	9,36
Theilsen Regresyonu	%88,1	0,68	0,37	1,32

Literatürde eklemeli imalat yöntemiyle çekme dayanımı tahminlenmesine yönelik birçok araştırmanın konusu olmuştur. Hooda vd., (2019) çalışmasında, EBM yöntemiyle ensemble ratgele orman makine öğrenme algoritmasıyla baskı biriktirme açısını tahmin ve %94,57 doğrulama gerçekleştirmiştir [22]. Pazhamannil vd. (2021), çalışmalarında EBM 3B baskı yöntemi ile üretilen PLA numunelerin çekme dayanımı sonuçlarını yapay sinir ağları kullanarak tahmin etmişlerdir. Elde edilen sonuçlar değerlendirildiğinde deneysel değerler ile tahmin değerleri arasında %99 oranında tutarlı bir benzerlik olduğu tespit edilmiştir [23]. Samykano (2021), çalışmasında EBM 3B baskı yöntemindeki baskı parametrelerine göre çekme dayanımı tahmini için istatistiksel bir model önermiştir. 27 farklı baskı parametresi kombinasyonuna sahip 81 numune ile gerçekleştirilen deneysel çalışmada dolgu yoğunluğunu çekme dayanımını etkileyen birincil faktör olarak belirlenmiştir. İstatistiksel Response Surface Methodology (RSM) yöntemi ile tahmin edilen çekme dayanımı değerlerinin %80 oranında gerçek değerler ile uyumlu olduğu belirlenmiştir [24]. Goudswaard vd. (2021), çalışmalarında EBM 3B baskı yöntemi için kapsamlı bir yetenek profilinin oluşturulmasını, profilin uygulanmasını ve üretken bir tasarım metodolojisi (Generative Manufacturing) içinde faydasının değerlendirilmesini amaçlamışlardır. Çalışmada giriş için kullanılan beş üretim parametresine karşılık çekme dayanımı değerlerinin yapay sinir ağları ile tahmini gerçekleştirilmiştir. Hazırlanan YSA modelinin %98,9 başarı oranında çekme dayanımı sonuçlarını tahmin ettiği gözlemlenmiştir [25]. Srinivasan vd. (2020), çalışmalarında EBM 3B baskı yöntemi ve ABS malzeme kullanılarak üretilen numunelerin dolgu yoğunluğu, dolgu deseni ve katman kalınlığı giriş parametreleri ile numunelere ait çekme dayanımı ve sertlik değerlerini istatistiksel Response Surface Methodology (RSM) yöntemi ile tahmin etmişlerdir. Çalışmada geliştirilen modelin tahmin ettiği çekme dayanımı değerlerinin %95,22 oranında gerçek değerler ile uyduğu tespit edilmiştir [26].

Panda vd. (2015), çalışmalarında EBM tipi 3B baskı yöntemi ile üretilen prototipe ait üç üretim parametresinin giriş değerleri olarak kullanıldığı iki farklı algoritmayı deneyimlemişlerdir. Çalışmada kullanılan Çok genli genetik programlama (MGGP) ve genel regresyon sinir ağı (GRNN) algoritmalarından elde edilen değerler karşılaştırıldığında GRNN algoritması ile hesaplanan çekme dayanımı değerlerinin %97,7 oranında gerçek ölçüm değerlerine yakın sonuçlar ürettiği tespit edilmiştir [27]. Çalışmada elde edilen bulgular literatür ile uyumludur. Çalışmada ortaya çıkan sonuçlar incelendiğinde kullanılan giriş parametrelerine göre çekme dayanımı sonuçlarını %98,3 ile en başarılı olarak tahminleyen Kısmi En Küçük Kareler(PLS) algoritması olmuştur. Bu sonuçları %94,9 ile Rastgele Orman ve %88,1 ile Theilsen Regresyon algoritması takip etmiştir. Algoritmalar için hesaplanan hata değerlerinin de benzer şekilde sıralandığı görülmektedir.

IV. SONUÇLAR

Günümüzde birçok alanda kullanılan ve kullanımı giderek yaygınlaşan 3B yazıcılar tarafından üretilen nesnelerin dayanıklılık ve kalite özellikleri önem arz etmektedir. Eklemeli imalat EBM teknolojisi ile yapılan üretim, parça büyüklüğü ve baskı parametrelerine bağlı olarak uzun saatler alabilmektedir. Bu uzun bekleme süreleri sonunda kaliteli ürün ortaya çıkarmak hem hammadde israfının önüne geçilmesi hem de zaman kaybının önlenmesinde en önemli faktörlerden birisidir. Bu nedenle en uygun baskı parametrelerini önceden tespit etmek amacıyla üretilen numuneler çekme dayanımı testlerine tabi tutulmuştur. Elde edilen veriler bir araya getirilerek makine öğrenmesi modelleri yardımıyla en uygun üretim parametreleri baskı öncesinde tahmin edilebilmesi için bu çalışma gerçekleştirilmiştir.

Çalışmada, PLA malzemeli EBM yöntemi ile standartlara uygun çekme test numuneleri üretilmiştir. Katman kalınlığı, doldurma oranı, fan hızı ve baskı hızı gibi parametrelerin mekanik özelliklere doğrudan etkileri araştırılmıştır. PLA malzemelerinin çekme dayanımı özellikleri de karşılaştırılmıştır. Deneysel sonuçlardan elde edilen bulgulara göre, dolgu hızındaki artışın mekanik özellikleri iyileştirdiği gözlemlenmiştir. En iyi mekanik özellikler PLA malzemedeki yapılmış test numunelerinde 24 numaralı numunede gerçekleştirilmiştir. Baskı parametrelerine bağlı olarak çekme dayanımı sonuçlarının önceden tahmin edilebilmesi amacıyla veri artırımı gerçekleştirilmiştir. Elde edilen bu veriler kullanılarak eğitimi gerçekleştirilen üç regresyon modeli arasında Kısmi En Küçük Kareler (PLS)

algoritmasının çekme dayanımı sonuçlarını %98,3 oranında başarı ile tahmin ettiği belirlenmiştir. Hazırlanan bu çalışma ile numune üretimi ve test süreci çeşitli zorluklar içeren çekme dayanımı tespit sonuçlarını yüksek doğruluk oranında gerçeğe en yakın olarak tahmin edilmiştir. Bu sayede çekme dayanımının tespitine yönelik süreçlerde hem zamandan hem maliyetten hem de iş gücünden kazanç sağlanacağı öngörülmektedir.

V. KAYNAKLAR

- [1] A. Erçetin, K. Aslantaş and Ö. Özgün, “Micro-end milling of biomedical TZ54 magnesium alloy produced through powder metallurgy,” *Machining Science and Technology*, vol. 24, no. 6, pp. 924-947, 2020.
- [2] A. Erçetin, “Sıcak presleme yöntemiyle üretilen Nb takviyeli Mg matrisli kompozitlerin mikroyapı ve mekanik özellikleri,” *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, c. 9, s. 5, ss. 2116-2127, 2021.
- [3] W. Wu, J. Jiang, H. Jiang, W. Liu, G. Li, B. Wang, M. Tang and J. Zhao, “Improving bending and dynamic mechanics performance of 3D printing through ultrasonic strengthening,” *Materials Letters*, vol. 220, pp. 317–320, 2018.
- [4] O.A. Mohamed, S.H. Masood, J.L. Bhowmik and A.E Somers, “Investigation on the tribological behavior and wear mechanism of parts processed by fused deposition additive manufacturing process,” *Journal Manufacturing Process*, vol. 29, pp. 149–159, 2017.
- [5] E. Karaman ve O. Çolak, “Eriyik biriktirme yönteminde farklı üretim parametrelerinin mekanik özelliklere etkisi,” *ALKÜ Fen Bilimleri Dergisi*, c. 1, s. 2, ss. 90-99, 2019.
- [6] J. Zhang, P. Wang and R.X. Gao, “Deep learning-based tensile strength prediction in fused deposition modeling,” *Computers in Industry*, vol. 107, pp. 11-21, 2019.
- [7] H. K. Dave, N.H. Patadiya, A.R. Prajapati and S.R. Rajpurohit, “Effect of infill pattern and infill density at varying part orientation on tensile properties of fused deposition modeling-printed poly-lactic acid part,” *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*, vol. 235, no. 10, pp. 1811-1827, 2021.
- [8] F.G. Aytakin, “Fotolitografi işleminde uv sertleştirme parametrelerinin deney tasarımı ile eniyilenmesi,” Yüksek Lisans tezi, Fen Bilimleri Enstitüsü, Kocaeli Üniversitesi, Kocaeli, Türkiye, 2014.
- [9] G. Zhiqiang, S. Zhihuan, X.D. Steven and H. Biao, “Data mining and analytics in the process industry: the role of machine learning,” *IEEE Access*, vol. 5, pp. 20590–20616, 2017.
- [10] N.M. Mehat, S.M. Kassim and S. Kamaruddin, “Investigation on the effects of processing parameters on shrinkage behaviour and tensile properties of injection moulded plastic gear via the taguchi method,” *In Journal of Physics: Conference Series*, vol. 908, no. 1, pp. 12-49, 2017.
- [11] B. Aksoy and M. Koru, “Estimation of casting mold interfacial heat transfer coefficient in pressure die casting process by artificial intelligence methods,” *Arabian Journal for Science and Engineering*, vol. 45, pp. 8969-8980, 2020.
- [12] M.I. Jordan and T.M. Mitchell, “Machine learning: Trends, perspectives, and prospects,” *Science*, vol. 349, no. 6245, pp. 255-260, 2015.

- [13] M.B. Tümer, “Üç boyutlu yazıcılar ve günümüz mimarisinde kullanımı,” Yüksek Lisans tezi, Fen Bilimleri Enstitüsü, Işık Üniversitesi, İstanbul, Türkiye, 2020.
- [14] M. Vohland, J. Besold, J. Hill and H.C. Fründ, “Comparing different multivariate calibration methods for the determination of soil organic carbon pools with visible to near infrared spectroscopy,” *Geoderma*, vol. 166, no. 1, pp. 198-205, 2011.
- [15] K. Kavaklioglu, “Robust modeling of heating and cooling loads using partial least squares towards efficient residential building design,” *Journal of Building Engineering*, vol. 18, pp. 469, 2018.
- [16] C. Summers and M.J. Dinneen, “Improved mixed-example data augmentation,” in *2019 IEEE Winter Conference on Applications of Computer Vision (WACV)*, Waikoloa Village, Hawaii, 2019, pp. 1262-1270.
- [17] L. Breiman. “Random forests,” *Machine Learning*, vol. 45, no. 1, pp. 5–32, 2001.
- [18] M.A. Pillai, A. Ghosh, J. Joy, S. Kamal, C.C. Satheesh, A.A. Balakrishnan and M.H. Supriya, “Acoustic source localization using random forest regressor,” in *2019 International Symposium on Ocean Technology (SYMPOLO)*, 2019, pp. 191-199.
- [19] P.K. Sen, “The theil-sen estimator in genomic high dimensional measurement error models perspectives,” *Calcutta Statistical Association Bulletin*, vol. 63, pp. 37-50, 2011.
- [20] S.S. Hussain and P. Sprent, “Non-parametric regression,” *Journal of the Royal Statistical Society: Series A (General)*, vol. 146, no. 2, pp. 182-191, 1983.
- [21] A. Zheng, *Evaluating Machine Learning Models*, Farnham, UK: O’Reilly Media, 2015, ch. 2, pp. 7-18.
- [22] N. Hooda, J. S. Chohan, R. Gupta, and R. Kumar, “Deposition angle prediction of Fused Deposition Modeling process using ensemble machine learning,” *ISA transactions*, vol. 116, pp. 121-128, 2021.
- [23] R. V. Pazhamannil, P. Govindan and P. Sooraj, “Prediction of the tensile strength of polylactic acid fused deposition models using artificial neural network technique,” *Materials Today: Proceedings*, vol. 46, pp. 9187-9193, 2021.
- [24] M. Samykano, “Mechanical property and prediction model for FDM-3D printed polylactic acid (PLA),” *Arabian Journal for Science and Engineering*, vol. 46, pp. 7875–7892, 2021.
- [25] M. Goudswaard, B. Hicks and A. Nassehi, “The creation of a neural network based capability profile to enable generative design and the manufacture of functional FDM parts,” *The International Journal of Advanced Manufacturing Technology*, vol. 113, no. 9, pp. 2951-2968, 2021.
- [26] R. Srinivasan, T. Pridhar, L.S. Ramprasath, N.S. Charan and W. Ruban, “Prediction of tensile strength in FDM printed ABS parts using response surface methodology (RSM),” *Materials Today: Proceedings*, vol. 27, pp. 1827-1832, 2020.
- [27] B.N. Panda, M.R. Bahubalendruni and B.B. Biswal, “A general regression neural network approach for the evaluation of compressive strength of FDM prototypes,” *Neural Computing and Applications*, vol. 26, no. 5, pp. 1129-1136, 2015.