


# Makina Mühendisliğinde Güncel Yaklaşımlar: Teori, Tasarım, Analiz ve Üretim Perspektifleri

**Editör: Yusuf FEDAI**



# Makina Mühendisliğinde Güncel Yaklaşımlar: Teori, Tasarım, Analiz ve Üretim Perspektifleri

**Editör:**

Yusuf FEDAI



Published by

**Özgür Yayın-Dağıtım Co. Ltd.**

Certificate Number: 45503

📍 15 Temmuz Mah. 148136. Sk. No: 9 Şehitkamil/Gaziantep

☎ +90.850 260 09 97

📞 +90.532 289 82 15

🌐 www.ozguryayinlari.com

✉ info@ozguryayinlari.com

---

## Makina Mühendisliğinde Güncel Yaklaşımlar: Teori, Tasarım, Analiz ve Üretim Perspektifleri

Editör: Yusuf FEDAI

---

Language: Turkish-English

Publication Date: 2026

Cover design by Mehmet Çakır

Cover design and image licensed under CC BY-NC 4.0

Print and digital versions typeset by Çizgi Medya Co. Ltd.

**ISBN (PDF):** 978-625-8998-24-5

**DOI:** <https://doi.org/10.58830/ozgur.pub1238>

---



This work is licensed under the Creative Commons Attribution-NonCommercial 4.0 International (CC BY-NC 4.0). To view a copy of this license, visit <https://creativecommons.org/licenses/by-nc/4.0/>  
This license allows for copying any part of the work for personal use, not commercial use, providing author attribution is clearly stated.

---

Suggested citation:

Fedai, Y. (ed) (2026). *Makina Mühendisliğinde Güncel Yaklaşımlar: Teori, Tasarım, Analiz ve Üretim Perspektifleri*.

Özgür Publications. DOI: <https://doi.org/10.58830/ozgur.pub1238>. License: CC-BY-NC 4.0

---

*The full text of this book has been peer-reviewed to ensure high academic standards. For full review policies, see <https://www.ozguryayinlari.com/>*

---



## Ön Söz

Makine mühendisliği, fiziksel dünyanın temel yasalarını uygulayarak insanlığa hizmet eden en köklü disiplinlerden biri olmakla birlikte, günümüzde tarihteki en radikal dönüşümlerden birini yaşamaktadır. Geleneksel mekanik sistemler artık yalnızca statik yapılar olmaktan çıkmış; sensörlerle donatılmış, veri üreten ve yapay zekâ aracılığıyla optimize edilen akıllı yapılara dönüşmüştür. Endüstri 4.0 ve ötesinin şekillendirdiği bu yeni çağda mühendislik başarısı yalnızca teorik hesaplama gücüne değil, aynı zamanda elde edilen verinin ileri üretim teknolojileri ve dijital sistemlerle ne derece uyumlu biçimde bütünleştirilebildiğine bağlıdır. Yirmi birinci yüzyılın makine mühendisi, atomik düzeydeki malzeme kusurlarından bulut tabanlı otonom sistem mimarilerine kadar uzanan geniş bir yelpazede uzmanlaşmak durumundadır.

Bu kitap bölümü, makine mühendisliğinin değişmeyen temel bileşenleri olan teori, tasarım, analiz ve üretim kavramlarını modern teknolojinin sunduğu en güncel yaklaşımlar çerçevesinde yeniden yorumlamaktadır. Çalışma kapsamında yer alan bölümler, akademik disiplin ile endüstriyel uygulamalar arasındaki köprüyü güçlendirmeyi amaçlamaktadır.

Çalışmanın kapsamı; düz dişli sistemlerinde Hertz temas gerilmelerinin analitik ve sayısal (Sonlu Elemanlar Yöntemi – FEM) analizinden, önde gelen eklemeli imalat teknolojilerinden biri olan Laser Powder Bed Fusion (LPBF) sürecinde gözeneklilik mekanizmalarının sistematik olarak değerlendirilmesine kadar uzanmaktadır. Ayrıca, Fused Deposition Modelling (FDM) yöntemiyle üretilen kompozit malzemelerde yüzey kalitesinin makine öğrenmesi algoritmaları kullanılarak tahmin edilmesi ve endüstriyel dijital dönüşüm bağlamında Nesnelerin İnterneti (IoT) ile yapay zekâ entegrasyonu da ayrıntılı biçimde ele alınmaktadır. Teori ile uygulamayı sentezleyen bu bölüm, hem geleneksel mekanik sistemlerin optimizasyonu hem de geleceğin otonom ve akıllı üretim sistemlerinin geliştirilmesi açısından kapsamlı bir rehber niteliği taşımaktadır.

Sonuç olarak bu eser, teorik derinliği ileri düzey simülasyon teknikleri ve dijital üretim modelleriyle bir araya getiren kapsamlı bir çalışmadır. Çalışmanın akademik dünyaya yeni bir bakış açısı kazandıracağına, makina mühendisliği literatürüne kalıcı katkılar sağlayacağına ve sektör profesyonelleri için önemli bir başvuru kaynağı olacağına inanılmaktadır. Modern mühendislik vizyonu doğrultusunda hazırlanan bu bölümlerin, gelecekte gerçekleştirilecek yenilikçi projelere ışık tutması en büyük temennimizdir.



# İçindekiler

Ön Söz iii

## Bölüm 1

---

Lazer Toz Yataklı Füzyon (LPBF) Sürecinde Gözeneklilik Oluşum Mekanizmalarının Sistematik Değerlendirilmesi ve Mekanik Performans Üzerindeki Etkileri 1

*Nafel Dogdu*

## Bölüm 2

---

Eriyik Yığıma Modelleme Yönteminde PLA-CF Kompozitlerinin Yüzey Pürüzlülüğünün ve Boyutsal Doğruluğunun Deneysel Analizi ve Makine Öğrenmesi ile Tahmini 17

*Yunus Kartal*

## Bölüm 3

---

Düz Dişli Çark Sistemlerinde Hertz Basınç Değerlerinin Analizi 35

*Ramazan Çalışkan*

*Ali Osman Kurban*

## Bölüm 4

---

Digital Transformation in Mechanical Engineering: Internet of Things, Machine Learning, and Autonomous Systems 55

*Mustafa Çakır*



# Lazer Toz Yataklı Füzyon (LPBF) Sürecinde Gözeneklilik Oluşum Mekanizmalarının Sistemik Değerlendirilmesi ve Mekanik Performans Üzerindeki Etkileri

Nafel Dogdu<sup>1</sup>

## Özet

Lazer Toz Yataklı Füzyon (LPBF), yüksek hassasiyet ve tasarım serbestliği sayesinde karmaşık metal bileşenlerin üretiminde öne çıkan bir eklemeli imalat yöntemidir. Buna karşın süreç sırasında ortaya çıkan gözeneklilik; yoğunluk, tekrarlanabilirlik ve servis ömrü üzerinde doğrudan etkili olduğundan, endüstriyel uygulamaların güvenilirliğini sınırlayan temel sorunlardan biri olarak görülmektedir. Bu çalışmada LPBF’de gözeneklilik oluşumu, sistemik literatür analizi yaklaşımıyla; hacimsel enerji yoğunluğu (VED) rejimleri, ergitme havuzu faz dinamikleri ve mekanik performans ilişkisi bağlamında bütüncül biçimde ele alınmıştır. Elde edilen bulgular, gözeneklerin çoğunlukla üç ana mekanizma üzerinden geliştiğini göstermektedir: düşük VED koşullarında iz ve katman bağlanmasının yetersiz kalmasına bağlı füzyon eksikliği (LOF) gözenekleri, yüksek VED rejiminde derin buhar çukurunun kararsız çökmesiyle oluşan anahtar deliği (keyhole) gözenekleri ve toz içi gaz kapanımları ile proses atmosferindeki akış düzensizliklerinden kaynaklanan gaz gözenekleri. LOF gözenekleri keskin kenarlı ve düzensiz morfolojileri nedeniyle gerilme yığılmalarını artırarak yorulma çatlaklarının başlatılmasında kritik rol oynarken, keyhole gözenekleri daha küresel yapıda olmalarına rağmen boyutları büyüdüğünde taşıyıcı kesiti azaltarak dayanımı düşürebilmektedir. Gaz kaynaklı gözenekler ise enerji girdisinden bağımsız bir kontrol boyutu sunmakta ve toz kalitesi ile atmosfer yönetiminin önemini açık biçimde ortaya koymaktadır. Sonuç olarak gözenekliliğin etkin biçimde kontrolü, yalnızca parametre ayarıyla sınırlı kalmamalı; enerji rejiminin yönetildiği, ergitme havuzu kararlılığının sağlandığı ve in-situ izleme temelli kalite güvencesiyle desteklenen bütüncül bir süreç optimizasyonu yaklaşımıyla ele alınmalıdır.

1 Öğr. Gör. Dr. Akdeniz üniversitesi, Teknik Bilimler Meslek Yüksekokulu, Antalya, Türkiye ndogdu@akdeniz.edu.tr, <https://orcid.org/0000-0001-8172-0832>

## 1. Giriş

Lazer Toz Yataklı Füzyon (LPBF), yüksek hassasiyetli ve karmaşık metal bileşenlerin üretimine imkân tanıyan en gelişmiş eklemeli imalat teknolojilerinden biridir. Süreç sırasında lazer enerjisinin toz yatağı ile etkileşimi sonucunda oluşan ergitme havuzu; buhar, sıvı ve katı fazların eş zamanlı olarak bulunduğu son derece dinamik ve çok fazlı bir ortamdır. Bu çok fazlı etkileşimin gözenek oluşumunun temel fiziksel kaynağını oluşturduğu deneysel olarak gösterilmiştir. Literatürde, Bitharas ve ark. [1], LPBF sırasında buhar-sıvı-katı faz geçişlerinin doğrudan gözlemlenebildiğini ve gözenek başlangıcının faz geçiş dinamikleriyle yakından ilişkili olduğunu ortaya koymuştur. Huang ve ark. [2], anahtar deliği dalgalanmalarının kararsız çökmesi sonucu gözenek oluştuğunu gösterirken, Leung ve ark. [3] X-ışını görüntüleme destekli çok-fizikli modelleme ile ergitme havuzundaki akış ve kusur dinamiklerini nicel olarak analiz etmiştir.

LPBF'nin karakteristik özelliği olan yüksek soğuma hızları ve hızlı katılaşma koşulları, denge dışı mikro yapı oluşumuna yol açmaktadır. Ren ve ark. [4], hızlı katılaşma sırasında solüt kapanması ve mikro yapısal heterojenliğin geliştiğini göstermiştir. Gözenek oluşum mekanizmaları ve kontrol yaklaşımları ise kapsamlı biçimde sınıflandırılmıştır [5,6]. Süreç atmosferi ve gaz akışı da porozite üzerinde belirleyici rol oynamaktadır. Avegnon ve ark. [7], gaz akışı bozulmalarının 316L üretiminde gözenek oluşumunu tetikleyebildiğini göstermiştir. Benzer şekilde Wu ve ark. [8] ile Stwora ve ark. [9], süreç parametreleri ile porozite oluşumu arasındaki ilişkiyi deneysel ve teorik yaklaşımlarla incelemiştir. Sıcaklık kaynaklı porozite oluşumu ise alaşım özelinde değerlendirilmiştir [10].

Gözeneklilik yalnızca oluşum anıyla sınırlı değildir; işlem sonrası evrim süreçleri de kritik öneme sahiptir. Schröder ve ark. [11], HIP sonrası yeniden ısıtma sırasında belirli gözenek tiplerinde yeniden büyüme gözlenebileceğini bildirmiştir. Katmanlı üretim süreçlerinde gözenek evrimi, yönlendirilmiş enerji biriktirme çalışmalarında da detaylı biçimde incelenmiştir [12]. Darbeli lazer modunda gözenek oluşum dinamikleri in-situ olarak karakterize edilmiş [13], morfolojik sınıflandırma yaklaşımları geliştirilmiş [14] ve optimize edilmiş enerji yoğunluğunun boşluk morfolojisi üzerindeki kritik rolü gösterilmiştir [15].

Gözenekliliğin öngörülmesi ve kontrolü amacıyla sayısal modelleme ve optimizasyon yaklaşımları geliştirilmiştir. Rafine edilmiş hacimsel enerji yoğunluğu ve FEM tabanlı tahmin modelleri [16], çok ölçekli porozite kontrol çalışmaları [17] ve Bayes temelli optimizasyon yöntemleri [18], süreç parametrelerinin daha sistematik biçimde belirlenmesine katkı

sağlamıştır. Fizik-temelli ergitme havuzu modelleri ile in-situ izleme tabanlı kusur tahmini yaklaşımları gerçek zamanlı kalite kontrol potansiyelini ortaya koymaktadır [19-21]. Ayrıca morfoloji-temelli çok faktörlü optimizasyon çalışmaları [22], özellikle AlSi10Mg gibi mühendislik uygulamalarında yaygın olarak kullanılan alaşımlarda porozite kontrolüne yönelik uygulanabilir sonuçlar sunmuştur.

Gözenekliliğin malzeme performansı üzerindeki etkileri geniş kapsamda değerlendirilmiştir. 316L çelikte hidrojen alımı ve gevrekleşme davranışı [23], AlSi10Mg'de yüzey altı porozite ve yorulma ömrü ilişkisi [24], genel yorulma performansı [25] ve süreç kaynaklı porozitenin mekanik özelliklere etkisi [26] bu kapsamda ele alınmıştır. Özellikle havacılık ve savunma uygulamalarında yorulma yükleri altında çalışan yapısal bileşenlerde, mikron mertebesindeki gözeneklerin dahi servis ömrünü belirleyici hâle gelmesi, porozitenin kontrolünü doğrudan güvenlik meselesi hâline getirmektedir. Biyomedikal Ti alaşımlarında üretilebilirlik ve mekanik özellik porozite ilişkisi de detaylı biçimde incelenmiştir [27]. Bununla birlikte, kontrollü porozitenin implant ve biyomalzeme uygulamalarında fonksiyonel avantaj sağlayabildiği gösterilmiştir [28-31].

Mikroyapı geliştirme ve mekanik özellik optimizasyonuna yönelik çalışmalar da gözeneklilik ile yakından ilişkilidir. Dispersiyon sertleştirme yaklaşımları [32], istatistiksel ve makine öğrenmesi temelli sertlik tahmini [33], Taguchi yöntemi ile çekme dayanımı optimizasyonu [34], saf molibden için sayısal optimizasyon [35] ve boyutsal doğruluk ile termomekanik özelliklerin deneysel-simülasyon karşılaştırmaları [36], süreç-mikroyapı-performans ilişkisinin bütüncül değerlendirilmesi gerektiğini göstermektedir. Endüstriyel uygulamalar bağlamında topoloji optimizasyonu [37], sağlık ve ilaç alanındaki gelişmeler [38] ve hacimsel kusurların özellik-temelli sınıflandırılması [39], LPBF'de gözenekliliğin yalnızca bir kusur değil, mühendislik tasarımında dikkate alınması gereken kritik bir parametre olduğunu ortaya koymaktadır.

Bununla birlikte, eklemeli imalatta kullanılan tozların üretim ve ön-işleme yöntemleri de mikroyapı ve faz dönüşüm davranışı üzerinde belirleyici olabilmektedir. Özellikle mekanik alaşımlama ile modifiye edilmiş toz sistemlerinde faz oluşumu ve dönüşüm karakterinin önemli ölçüde değişebildiği, Zr katkılı NiTi tozlarında R-faz oluşumu ve östenitik dönüşüm davranışı üzerinden gösterilmiştir [40].

Mevcut literatür, LPBF'de gözenekliliğin; enerji yoğunluğu rejimi, faz dönüşüm dinamikleri, gaz akış davranışı ve mikro yapısal evrimin birlikte şekillendirdiği çok ölçekli ve çok-fizikli bir süreç sonucu geliştiğini göstermektedir.

Bu çerçevede LPBF’de gözenekliliğin sistematik olarak incelenmesi; süreç parametrelerini belirleyen araştırmacılar, sayısal model geliştiren akademisyenler, kalite güvence mühendisleri ve kritik sektörlerde sertifikasyon süreçlerini yöneten endüstri profesyonelleri için doğrudan önem taşımaktadır.

Bu çalışma, LPBF’de gözeneklilik türlerini enerji yoğunluğu rejimleriyle ilişkilendirerek; LOF–keyhole–gaz kaynaklı gözeneklerin ayırt edici oluşum koşullarını, karakterizasyon yaklaşımlarını ve mekanik kritiklik düzeylerini tek bir çerçevede birleştirmektedir. Böylece süreç parametre seçimi ve kalite güvencesi için uygulanabilir bir referans haritası sunulmaktadır.

## 2. Çalışma Metodolojisi ve Analiz Çerçevesi

Bu çalışma, LPBF sürecinde gözeneklilik oluşum mekanizmalarının fiziksel temellerini, süreç parametreleri ile ilişkisini ve performans etkilerini ortaya koymak amacıyla sistematik literatür analizi yaklaşımına dayanmaktadır.

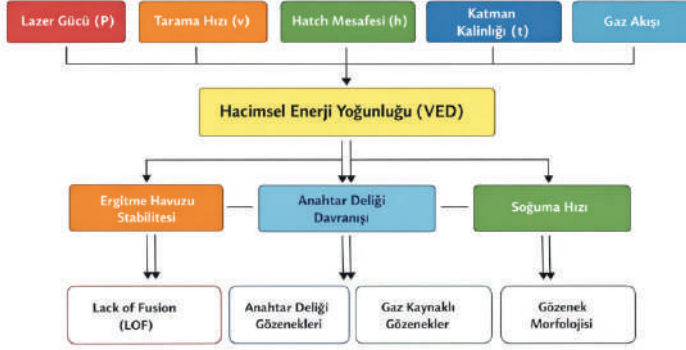
### 2.1. Süreç Parametre Çerçevesi

LPBF sürecinde gözeneklilik oluşumunu etkileyen temel parametreler lazer gücü (P), tarama hızı (v), hatch mesafesi (h), katman kalınlığı (t) ve gaz akış koşullarıdır. Bu parametrelerin birleşik etkisi genellikle hacimsel enerji yoğunluğu (Volumetric Energy Density, VED) ile tanımlanmaktadır.

$$VED=P/(v \cdot h \cdot t)$$

Enerji yoğunluğu; anahtar deliği oluşumu, eriyik havuzu stabilitesi ve lack-of-fusion kusurlarının gelişimi üzerinde belirleyici bir rol oynamaktadır. Literatürde VED aralığının doğrudan gözenek morfolojisi ve dağılımı ile ilişkili olduğu rapor edilmiştir [5,15,16].

Lazer gücü, tarama hızı, hatch mesafesi ve katman kalınlığının birleşik etkisinin hacimsel enerji yoğunluğu üzerinden ergitme havuzu davranışına ve gözenek oluşumuna nasıl yansıdığı Şekil 1’de kavramsal bir çerçevede gösterilmektedir.



*Şekil 1. LPBF sürecinde temel parametreler, enerji yoğunluğu ve gözenek oluşum mekanizmaları arasındaki etkileşim şeması*

## 2.2. Gözenek Karakterizasyon Yöntemleri

LPBF’de oluşan gözeneklerin fiziksel kökenini, morfolojisini ve hacimsel dağılımını belirlemek amacıyla literatürde farklı deneysel ve sayısal karakterizasyon yöntemleri kullanılmaktadır [1–3,5,6,12,14].

Bu kapsamda yüksek hızlı X-ışını görüntüleme teknikleri ergitme havuzu dinamiklerinin doğrudan gözlemlenmesine olanak sağlamaktadır [1–3]. İn-situ melt pool izleme sistemleri süreç sırasında ışınım ve termal sinyalleri analiz ederek kusur oluşumunu gerçek zamanlı olarak izleyebilmektedir [13,20]. mikro-CT üç boyutlu analiz yöntemleri gözenek hacmi ve dağılımının nicel belirlenmesini mümkün kılmaktadır [8,12]. SEM morfoloji analizi özellikle kırık yüzey karakterizasyonunda kullanılmaktadır [7,26]. Çok-fizikli modelleme ve FEM tabanlı yaklaşımlar ise gözenek oluşumunun öngörülmesine yönelik sayısal altyapı sunmaktadır [3,16–19].

Bu çalışmada referans alınan karakterizasyon yöntemleri ve sağladıkları temel analiz çıktıları Tablo 1’de özetlenmiştir.

*Tablo 1. Kullanılan Analiz Yöntemleri ve Sağladıkları Bilgiler*

Yöntem	Ölçülen Parametre	Amaç
X-ışını görüntüleme	Ergitme havuzu dinamiği	Gözenek başlangıcı
Mikro-CT	3B gözenek hacmi	Yoğunluk analizi
SEM	Morfoloji	Kırık yüzeyi inceleme
FEM modelleme	Isı dağılımı	Gözenek tahmini
İn-situ sensör	Işınım sinyali	Kapalı çevrim kontrol

Bu metodolojik çerçeve doğrultusunda, bir sonraki bölümde gözenek oluşumu enerji rejimlerine göre sınıflandırılarak mekanizmalar sistematik biçimde tartışılmıştır.

### **3. LPBF’de Gözenek Oluşum Mekanizmalarının Sistematik Değerlendirilmesi**

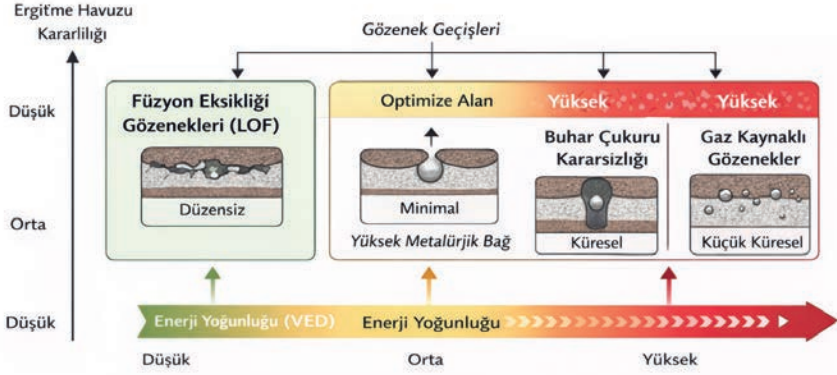
#### **3.1. Enerji Yoğunluğu Rejimine Bağlı Gözenek Oluşum Geçişleri**

LPBF sürecinde gözenek oluşumu, büyük ölçüde hacimsel enerji yoğunluğu (VED) ile belirlenen ergitme havuzu kararlılığına bağlıdır. Literatür değerlendirmesi, enerji yoğunluğu rejimindeki değişimin gözenek türlerinde belirgin bir geçişe neden olduğunu göstermektedir [5,6].

Düşük VED koşullarında, ergitme havuzu derinliği ve genişliği azalmakta; komşu izler ve katmanlar arasında yeterli metalürjik bağ oluşmamaktadır. Bu durum füzyon eksikliği (lack-of-fusion, LOF) gözeneklerinin gelişimine yol açmaktadır [9,16]. LOF gözenekleri genellikle düzensiz ve keskin kenarlı morfolojiye sahip olup gerilme yığılması açısından en kritik kusur türü olarak değerlendirilmektedir [24–26].

Enerji yoğunluğunun artmasıyla birlikte ergitme havuzu derinleşmekte ve buharlaşma etkisi belirgin hâle gelmektedir. Yüksek VED rejiminde derin bir buhar çukuru (keyhole) oluşmakta; bu çukurun kararsız çökmesi sonucu küresel boşluklar meydana gelmektedir [1,2]. Bu mekanizma, anahtar deliği (keyhole) gözeneklerinin temel oluşum yoludur. Optimize edilmiş enerji yoğunluğu aralıklarında ise ergitme havuzu daha kararlı davranmakta ve gözenek oluşumu minimize edilmektedir [15].

Dolayısıyla LPBF’de gözenek türleri, yalnızca rastlantısal kusurlar değil; enerji girdisi ile ergitme havuzu dinamikleri arasındaki fiziksel denge durumunun bir sonucu olarak ortaya çıkmaktadır. Bu geçiş davranışı Şekil 2’de şematik olarak gösterilmiştir.



*Şekil 2. LPBF’de düşük, orta ve yüksek hacimsel enerji yoğunluğu (VED) rejimlerinde oluşan gözenek türlerinin (LOF, keyhole ve gaz kaynaklı) ergitme havuzu stabilitesi ile ilişkili geçiş mekanizmasının kavramsal gösterimi.*


### 3.2. Füzyon Eksikliği (Lack-of-Fusion) Gözeneklerinin Oluşum Mekanizması

Füzyon eksikliği (LOF) gözenekleri, LPBF sürecinde düşük hacimsel enerji yoğunluğu koşullarında ortaya çıkan en kritik kusur türlerinden biridir. Bu gözenekler, komşu tarama izleri ve katmanlar arasında yeterli metalürjik bağ oluşmaması sonucu gelişmektedir [9,16]. Enerji girdisinin yetersiz olduğu durumlarda ergitme havuzu derinliği azalmakta, iz örtüşmesi sınırlanmakta ve katmanlar arası boşluklar meydana gelmektedir.

Çok-fizikli modelleme ve FEM tabanlı çalışmalar, düşük VED rejiminde ısı girdisinin lokal olarak yetersiz kaldığını ve eriyik metalin önceki katmanla tam birleşemediğini göstermektedir [16,17]. Bu durum, düzensiz ve keskin kenarlı morfolojiye sahip gözeneklerin oluşmasına yol açmaktadır. Nudelis ve Mayr [14] tarafından önerilen morfolojik sınıflandırma yaklaşımı, LOF gözeneklerinin tipik olarak düzlemsel ve uzamış karakter gösterdiğini ortaya koymuştur.

Mekanik açıdan değerlendirildiğinde, LOF gözenekleri gerilme yığılması açısından en kritik kusur türü olarak rapor edilmektedir. Özellikle yorulma yükleri altında, keskin kenarlı yapıları nedeniyle çatlak başlangıç noktası olarak davranmaktadır [24–26]. Bu nedenle düşük enerji yoğunluğu rejimi, yalnızca yoğunluk kaybı değil, aynı zamanda servis ömrü açısından ciddi bir risk oluşturmaktadır.

Şekil 3’te LOF gözenek morfolojisinin şematik temsili sunulmaktadır.



Şekil 3. LOF gözenek morfolojisinin şematik temsili

Şekil 3’de katmanlar arası yetersiz iz örtüşmesi sonucu gelişen düzensiz ve keskin kenarlı düzlemsel boşluk yapıları gösterilmektedir.


### 3.3. Anahtar Deliği (Keyhole) Gözenek Oluşum Mekanizması

Anahtar deliği (keyhole) gözenekleri, LPBF sürecinde yüksek hacimsel enerji yoğunluğu (VED) koşullarında ortaya çıkan tipik kusur türlerinden biridir. Enerji girdisinin artmasıyla birlikte lazer–malzeme etkileşimi yoğunlaşmakta ve buharlaşma etkisi belirgin hâle gelmektedir. Yüksek güç yoğunluğu altında eriyik havuzunun merkezinde derin bir buhar çukuru oluşmakta; bu çukurun dinamik kararsızlığı gözenek oluşumunun temel mekanizmasını oluşturmaktadır [1,2].

Bitharas ve ark. [1], buhar–sıvı–katı faz etkileşiminin gerçek zamanlı gözlemlerle anahtar deliği stabilitesini doğrudan etkilediğini göstermiştir. Huang ve ark. [2], anahtar deliği duvarlarında oluşan dalgalanmaların ani çökme ile sonuçlanabildiğini ve bu çökme sırasında küresel boşlukların hapsoldüğünü ortaya koymuştur. Çok-fizikli simülasyon ve X-ışını destekli çalışmalar ise buhar çukuru derinliği ile gözenek oluşum sıklığı arasında doğrudan bir ilişki olduğunu göstermektedir [3].

Yüksek enerji yoğunluğu rejiminde oluşan bu gözenekler genellikle küresel morfolojiye sahiptir ve LOF gözeneklerine kıyasla daha düzgün kenarlı yapı gösterir [15]. Ancak hacimsel olarak daha büyük olmaları nedeniyle yapısal bütünlük açısından yine önemli bir risk faktörü oluşturmaktadır. Enerji yoğunluğunun kritik eşik değerin üzerine çıkması, ergitme havuzu stabilitesini azaltmakta ve keyhole çökme olasılığını artırmaktadır.

Şekil 4’te anahtar deliği oluşumu ve kararsız çökme süreci şematik olarak gösterilmektedir.



*Şekil 4. Keyhole çökme mekanizması ve gaz hapsolmesiyle küresel gözenek oluşumunun şematik gösterimi [1-3,15].*

Lazer–malzeme etkileşimi ile gelişen buhar çukuru, dinamik dalgalanmalar nedeniyle kararsız hâle gelmekte ve çökme sırasında gaz hapsolmesiyle gözenek oluşmaktadır.

### 3.4. Gaz Kaynaklı Gözenek Oluşum Mekanizması

Gaz kaynaklı gözenekler, LPBF sürecinde anahtar deliği veya füzyon eksikliği mekanizmalarından farklı olarak, genellikle toz partikülleri içerisinde hapsolmüş gazların veya süreç atmosferindeki akış düzensizliklerinin etkisiyle oluşmaktadır. Bu tür gözenekler çoğunlukla küçük ve küresel morfolojiye sahip olup, eriyik metal içerisinde çözünmüş gazın katılma sırasında dışarı atılamaması sonucu gelişmektedir [7,8].

Avegnon ve ark. [7], gaz akışındaki yerel bozulmaların ergitme havuzu üzerinde türbülans oluşturabildiğini ve bunun da porozite oluşumuna katkı sağlayabileceğini göstermiştir. Wu ve ark. [8] ise hidrid–dehidrid (HDH) Ti-6Al-4V tozlarında partikül içi gaz kapanımlarının baskılanabilirlik ve gözenek oluşumu üzerinde belirleyici rol oynadığını rapor etmiştir. Bu durum, yalnızca enerji yoğunluğunun değil, aynı zamanda toz kalitesi ve proses atmosferinin de porozite kontrolünde kritik parametreler olduğunu göstermektedir.

Gaz kaynaklı gözenekler genellikle daha küçük boyutlu ve daha düzgün yüzeyli olmalarına rağmen, yüksek yoğunluklu uygulamalarda birikimli etki oluşturabilmektedir. Özellikle hidrojen gibi difüzyona açık gazların varlığında, gözenekliliğin hidrojen alımı ve gevrekleşme davranışı üzerinde etkili olabileceği gösterilmiştir [23]. Bu nedenle gaz kaynaklı porozite, tek başına düşük kritik

gibi görünse de, servis koşullarına bağlı olarak performans üzerinde önemli rol oynayabilmektedir.

Bu bağlamda, gaz akışı optimizasyonu, toz ön işleme ve atmosfer kontrolü, LPBF’de gözenekliliğin azaltılmasına yönelik tamamlayıcı stratejiler olarak değerlendirilmektedir.

LPBF’de gözlenen başlıca gözenek türleri, oluşum mekanizması, morfolojik karakteri ve görel mekanik kritiklik seviyesi açısından Tablo 2’de karşılaştırmalı olarak özetlenmiştir

*Tablo 2. LPBF’de gözlenen gözenek türlerinin oluşum mekanizması, morfolojik karakteri ve görel mekanik kritiklik seviyesinin karşılaştırılması.*

Gözenek Türü	Oluşum Nedeni	Tipik Morfoloji	Görel Mekanik Kritiklik
Füzyon Eksikliği (LOF)	Düşük enerji yoğunluğu, yetersiz iz örtüşmesi	Düzensiz, keskin kenarlı, uzamış	Çok yüksek
Anahtar Deliği (Keyhole)	Yüksek enerji yoğunluğu, buhar çukuru kararsızlığı	Küresel, düzgün kenarlı	Orta-Yüksek
Gaz Kaynaklı	Toz içi gaz kapanımı, atmosfer düzensizliği	Küçük, küresel	Düşük-Orta

Gaz kaynaklı gözenekler enerji yoğunluğu ile doğrudan ilişkili olmamakla birlikte, özellikle düşük yoğunluklu yapı gerektiren uygulamalarda toplam porozite oranını belirgin biçimde etkileyebilmektedir.

### 3.5. Porozite Türlerinin Karşılaştırmalı Değerlendirilmesi

LPBF sürecinde gözlenen gözenek türleri, yalnızca oluşum mekanizmaları bakımından değil; morfoloji, hacimsel dağılım ve mekanik performans üzerindeki etkileri açısından da belirgin farklılıklar göstermektedir. Literatür bulguları, füzyon eksikliği (LOF), anahtar deliği (keyhole) ve gaz kaynaklı gözeneklerin farklı enerji rejimlerine ve süreç koşullarına karşılık geldiğini ortaya koymaktadır [5,6].

LOF gözenekleri, düşük enerji yoğunluğu rejiminde ortaya çıkmakta ve genellikle düzensiz, uzamış ve keskin kenarlı morfoloji göstermektedir. Bu geometri, yerel gerilme yığılmalarını artırmakta ve özellikle yorulma yükleri altında çatlak başlangıç noktası olarak davranmaktadır [24–26]. Bu nedenle LOF gözenekleri mekanik açıdan en kritik kusur türü olarak değerlendirilmektedir.

Anahtar deliği gözenekleri ise yüksek enerji yoğunluğu koşullarında buhar çukuru kararsızlığından kaynaklanmakta ve çoğunlukla küresel morfolojiye sahiptir [1–3]. Kenar keskinliğinin LOF'a kıyasla daha düşük olması gerilme yoğunlaşmasını nispeten azaltmakla birlikte, hacimsel büyüklükleri nedeniyle taşıyıcı kesit alanını azaltarak mukavemeti düşürebilmektedir [15].

Gaz kaynaklı gözenekler genellikle küçük ve küresel olup toz içi gaz kapanımları veya süreç atmosferi kaynaklıdır [7,8]. Tekil olarak düşük kritik seviyede kabul edilseler de, yüksek yoğunluklu dağılımlarda birikimli etki oluşturabilmektedir. Ayrıca hidrojen gibi difüzyon gazlarının varlığında gevrekleşme riskini artırabileceği rapor edilmiştir [23].

Bu karşılaştırmalı değerlendirme, LPBF'de gözenekliliğin tek bir kusur tipi olarak ele alınamayacağını; enerji yoğunluğu, ergitme havuzu dinamikleri ve malzeme-atmosfer etkileşiminin birlikte değerlendirilmesi gerektiğini göstermektedir. Süreç parametrelerinin optimize edilmesi, yalnızca toplam porozite oranının azaltılmasına değil, aynı zamanda kritik gözenek morfolojilerinin önlenmesine odaklanmalıdır.

Bu bütüncül yaklaşım, LPBF'de kalite güvence stratejilerinin geliştirilmesi ve kritik sektörlerde (havacılık, savunma ve biyomedikal uygulamalar) sertifikasyon süreçlerinin daha güvenilir biçimde yürütülmesi açısından doğrudan önem taşımaktadır.

#### 4. Sonuçlar

Bu çalışmada LPBF sürecinde gözeneklilik oluşum mekanizmaları; hacimsel enerji yoğunluğu rejimleri, ergitme havuzu faz dinamikleri ve mekanik performans ilişkisi bağlamında sistematik olarak değerlendirilmiştir. Literatür temelli analizler, gözenek oluşumunun yalnızca basit bir üretim kusuru değil; lazer enerjisi girdisi, ısı transferi, buharlaşma davranışı ve hızlı katılma kinetiğinin eş zamanlı etkileşimi sonucu ortaya çıkan çok-fizikli bir süreç olduğunu ortaya koymaktadır.

Düşük enerji yoğunluğu koşullarında füzyon eksikliği (LOF) gözeneklerinin baskın olduğu ve keskin kenarlı, düzensiz morfolojileri nedeniyle en kritik gerilme yığılması kaynağını oluşturduğu belirlenmiştir. Bu nedenle LOF gözenekleri, özellikle yorulma kontrollü tasarım gerektiren uygulamalarda birincil risk faktörü olarak değerlendirilmelidir. Yüksek enerji yoğunluğu rejiminde ise anahtar deliği mekanizmasına bağlı küresel gözenekler oluşmakta; bu gözenekler daha düzgün morfolojiye sahip olmakla birlikte, hacimsel büyüklüklerinin artması durumunda taşıyıcı kesit alanını azaltarak mukavemeti düşürebilmektedir. Gaz kaynaklı gözenekler ise çoğunlukla toz kalitesi ve

atmosfer koşulları ile ilişkili olup, yoğunluklarının artması hâlinde malzeme bütünlüğünü zayıflatabilmektedir.

Elde edilen bütüncül değerlendirme, LPBF’de optimum enerji yoğunluğu aralığının yalnızca yüksek yoğunluk elde etmek için değil; aynı zamanda kritik gözenek morfolojilerinin önlenmesi ve gerilme–yorulma davranışının kontrolü açısından belirlenmesi gerektiğini göstermektedir. Süreç parametrelerinin dengeli şekilde ayarlanması, ergitme havuzu kararlılığının sağlanması ve in-situ izleme sistemlerinin entegrasyonu gözenek oluşumunun minimize edilmesinde temel stratejiler olarak öne çıkmaktadır.

Sonuç olarak LPBF’de gözeneklilik kontrolü, parametrik ayarlamaların ötesinde; enerji rejimi yönetimi, faz dinamiklerinin anlaşılması ve malzeme–atmosfer etkileşiminin birlikte ele alındığı bütüncül bir süreç optimizasyonu yaklaşımı gerektirmektedir. Bu yaklaşım, özellikle havacılık, savunma ve biyomedikal uygulamalar gibi yüksek güvenilirlik gerektiren alanlarda üretim kalitesinin sürdürülebilirliği ve sertifikasyon süreçlerinin güvenilirliği açısından kritik önem taşımaktadır.

## Kaynaklar

- [1] I. Bitharas, N. Parab, C. Zhao, T. Sun, A. D. Rollett, and A. J. Moore, "The interplay between vapour, liquid, and solid phases in laser powder bed fusion," *Nat Commun*, vol. 13, no. 1, p. 2959, May 2022, doi: 10.1038/s41467-022-30667-z.
- [2] Y. Huang *et al.*, "Keyhole fluctuation and pore formation mechanisms during laser powder bed fusion additive manufacturing," *Nat Commun*, vol. 13, no. 1, p. 1170, Mar. 2022, doi: 10.1038/s41467-022-28694-x.
- [3] C. L. A. Leung *et al.*, "Quantification of Interdependent Dynamics during Laser Additive Manufacturing Using X-Ray Imaging Informed Multi-Physics and Multiphase Simulation," *Advanced Science*, vol. 9, no. 36, p. 2203546, Dec. 2022, doi: 10.1002/advs.202203546.
- [4] N. Ren *et al.*, "Solute trapping and non-equilibrium microstructure during rapid solidification of additive manufacturing," *Nat Commun*, vol. 14, no. 1, p. 7990, Dec. 2023, doi: 10.1038/s41467-023-43563-x.
- [5] C. Du *et al.*, "Pore defects in Laser Powder Bed Fusion: Formation mechanism, control method, and perspectives," *Journal of Alloys and Compounds*, vol. 944, p. 169215, May 2023, doi: 10.1016/j.jallcom.2023.169215.
- [6] L. Wang *et al.*, "Porosity defects in additively manufactured metal materials: Formation mechanisms, impact on performance and regulation," *International Materials Reviews*, p. 09506608251371459, Sep. 2025, doi: 10.1177/09506608251371459.
- [7] K. L. M. Avegnon, A. Menendez, J. Liu, J. Soost, T. Houle, and M. P. Sealy, "Porosity formation from disrupted gas flow in laser powder bed fusion of 316 stainless steel," *Journal of Manufacturing Processes*, vol. 90, pp. 333–340, Mar. 2023, doi: 10.1016/j.jmapro.2022.12.032.
- [8] Z. Wu *et al.*, "Study of printability and porosity formation in laser powder bed fusion built hydride-dehydride (HDH) Ti-6Al-4V," *Additive Manufacturing*, vol. 47, p. 102323, Nov. 2021, doi: 10.1016/j.addma.2021.102323.
- [9] A. Stwora, R. Teimouri, and J. Habel, "Role of Laser Powder Bed Fusion Process Factors in Determining the Porosity Formation in 3D Printing of Stainless Steel 316L: Theoretical Modeling and Experimental Verification," *Materials*, vol. 18, no. 24, p. 5490, Dec. 2025, doi: 10.3390/ma18245490.
- [10] H. Karimialavijeh, W. N. Khan, M. Moradi, M. Proebstle, and E. Martin, "Temperature induced porosity in laser powder bed fusion fabricated A20X alloy," *Manufacturing Letters*, vol. 46, pp. 148–151, Dec. 2025, doi: 10.1016/j.mfglet.2025.11.007.
- [11] J. Schröder, T. Fritsch, B. Ferrari, M. L. Altmann, G. Bruno, and A. Tonjes, "Laser powder bed fusion: Defect type influences critical porosity re-growth during reheating after hot isostatic pressing," *Journal of Mate-*

- rials Processing Technology*, vol. 340, p. 118839, Jun. 2025, doi: 10.1016/j.jmatprotec.2025.118839.
- [12] K. Zhang *et al.*, “Pore evolution mechanisms during directed energy deposition additive manufacturing,” *Nat Commun*, vol. 15, no. 1, p. 1715, Feb. 2024, doi: 10.1038/s41467-024-45913-9.
- [13] S. M. H. Hojjatzadeh *et al.*, “In-Situ Characterization of Pore Formation Dynamics in Pulsed Wave Laser Powder Bed Fusion,” *Materials*, vol. 14, no. 11, p. 2936, May 2021, doi: 10.3390/ma14112936.
- [14] N. Nudelis and P. Mayr, “A Novel Classification Method for Pores in Laser Powder Bed Fusion,” *Metals*, vol. 11, no. 12, p. 1912, Nov. 2021, doi: 10.3390/met11121912
- [15] S. Trithepchunlayakoon *et al.*, “The critical role of optimized energy density in controlling void morphology and enhancing mechanical properties of L-PBF Ti-6Al-4V ELI alloy,” *PLoS One*, vol. 20, no. 6, p. e0325276, Jun. 2025, doi: 10.1371/journal.pone.0325276.
- [16] M. A. Mahmood, K. Ishfaq, M. Oane, and F. Liou, “Porosity prediction in LPBF of AISI 316L stainless steel: Refined volumetric energy density and FEM simulation approach,” *Optics & Laser Technology*, vol. 188, p. 113015, Oct. 2025, doi: 10.1016/j.optlastec.2025.113015.
- [17] A. Qadeer, A. S. Lone, S. S. Akhtar, A. F. M. Arif, A. A. Abubakar, and A. J. Qureshi, “Prediction and control of structured porosity in laser powder bed fusion (LPBF) additive manufacturing using multi-scale modeling,” *Materials & Design*, vol. 258, p. 114627, Oct. 2025, doi: 10.1016/j.matdes.2025.114627.
- [18] Y. Chen, D. Gu, K. Shi, Y. Li, and W. Chen, “A novel dual-phase Bayesian estimation and multi-task learning method for process optimization for reducing lack-of-fusion defects during laser powder bed fusion,” *Additive Manufacturing*, vol. 110, p. 104926, Jul. 2025, doi: 10.1016/j.addma.2025.104926.
- [19] İ. Ülke, O. Yılmaz, and M. Mollamahmutoglu, “DEVELOPMENT OF A PHYSICS-INFORMED MELT POOL MODEL FOR POROSITY PREDICTION IN ADDITIVE MANUFACTURING,” *International Journal of 3D Printing Technologies and Digital Industry*, vol. 9, no. 3, pp. 488–502, Dec. 2025, doi: 10.46519/ij3dptdi.1789827.
- [20] L. Cao, J. Li, Q. Zhou, W. Cai, B. He, and Y. Zhang, “In-Situ monitoring of porosity based on static and dynamic molten pool features in laser powder bed fusion,” *Optics & Laser Technology*, vol. 187, p. 112872, Sep. 2025, doi: 10.1016/j.optlastec.2025.112872.
- [21] Z. Zou, K. Zhang, R. Chen, T. Liu, J. Li, and W. Liao, “Defect prediction of localized regions in laser powder bed fusion based on multi-layer

- photodiode image fusion,” *Measurement*, vol. 252, p. 117413, Aug. 2025, doi: 10.1016/j.measurement.2025.117413.
- [22] K. Korobov *et al.*, “MORPHOLOGY-AWARE MULTI-FACTOR OPTIMIZATION OF POROSITY IN ALSI10MG LASER POWDER BED FUSION,” *International Journal of Lightweight Materials and Manufacture*, p. S2588840426000065, Jan. 2026, doi: 10.1016/j.ijlmm.2026.01.006.
- [23] A. Nabizada, L. Claeys, P. J. Jacques, K. Verbeken, and T. Depover, “The role of porosity on the hydrogen uptake, diffusivity and embrittlement in laser powder bed fusion manufactured 316L,” *International Journal of Hydrogen Energy*, vol. 215, p. 153766, Mar. 2026, doi: 10.1016/j.ijhydene.2026.153766.
- [24] C. Van Der Rest, R. A. Manzano Navarrete, A. Simar, and O. Poncelet, “Influence of roughness and subsurface porosity on the fatigue life of AlSi10Mg produced by Laser Powder Bed Fusion,” *Materials Science and Engineering: A*, vol. 944, p. 148885, Nov. 2025, doi: 10.1016/j.msea.2025.148885.
- [25] M. M. Butt *et al.*, “Fatigue performance in additively manufactured metal alloys,” *Prog Addit Manuf*, vol. 10, no. 4, pp. 1809–1841, Apr. 2025, doi: 10.1007/s40964-024-00738-2.
- [26] W. H. Kan *et al.*, “A critical review on the effects of process-induced porosity on the mechanical properties of alloys fabricated by laser powder bed fusion,” *J Mater Sci*, vol. 57, no. 21, pp. 9818–9865, Jun. 2022, doi: 10.1007/s10853-022-06990-7.
- [27] M. Rehman *et al.*, “Manufacturability study in laser powder bed fusion of biomedical Ti alloys for orthopedic implants: an investigation of mechanical properties, process-induced porosity and surface roughness,” *RPJ*, vol. 29, no. 6, pp. 1299–1323, Jun. 2023, doi: 10.1108/RPJ-02-2022-0042.
- [28] C. N. Kelly *et al.*, “High-strength, porous additively manufactured implants with optimized mechanical osseointegration,” *Biomaterials*, vol. 279, p. 121206, Dec. 2021, doi: 10.1016/j.biomaterials.2021.121206.
- [29] X. Wang *et al.*, “Additively Manufactured Zn-2Mg Alloy Porous Scaffolds with Customizable Biodegradable Performance and Enhanced Osteogenic Ability,” *Advanced Science*, vol. 11, no. 5, p. 2307329, Feb. 2024, doi: 10.1002/advs.202307329.
- [30] Y. Sun, Z. Yu, Q. Liu, L. Ren, X. Zhao, and J. Wang, “The Anisotropic Osteoinductive Capacity of a Nickel–Titanium Alloy Fabricated Through Laser Powder Bed Fusion,” *IJMS*, vol. 26, no. 10, p. 4640, May 2025, doi: 10.3390/ijms26104640.
- [31] H. Wang *et al.*, “Laser powder bed fusion printed poly-ether-ether-ketone/bioactive glass composite scaffolds with dual-scale pores for enhanced

- osseointegration and bone ingrowth,” *Acta Biomaterialia*, vol. 189, pp. 605–620, Nov. 2024, doi: 10.1016/j.actbio.2024.09.055.
- [32] G. Wang *et al.*, “Dispersion hardening using amorphous nanoparticles deployed via additive manufacturing,” *Nat Commun*, vol. 16, no. 1, p. 3589, Apr. 2025, doi: 10.1038/s41467-025-58893-1.
- [33] İ. B. Toprak, “Prediction and optimization of hardness in AlSi10Mg alloy produced by laser powder bed fusion using statistical and machine learning approaches,” *Sci Rep*, vol. 15, no. 1, p. 17966, May 2025, doi: 10.1038/s41598-025-03307-x.
- [34] İ. B. Toprak and N. Dogdu, “Optimization of tensile strength of Al-Si10Mg material in the powder bed fusion process using the Taguchi method,” *Sci Rep*, vol. 14, no. 1, p. 31172, Dec. 2024, doi: 10.1038/s41598-024-82541-1.
- [35] İ. B. Toprak, N. Dogdu, and M. U. Salamci, “Numerical Optimization of Laser Powder Bed Fusion Process Parameters for High-Precision Manufacturing of Pure Molybdenum,” *Applied Sciences*, vol. 15, no. 10, p. 5485, May 2025, doi: 10.3390/app15105485.
- [36] N. Dogdu, “Experimental and Simulation-Based Assessment of Dimensional Accuracy and Thermomechanical Properties of AlSi10Mg Cubes Produced by LPBF,” *Materials & Design*, vol. 261, p. 115351, Jan. 2026, doi: 10.1016/j.matdes.2025.115351.
- [37] M. Tok and Y. Fedai, “Topology optimization for manufacturing aircraft bearing brackets via laser powder bed fusion,” *Sādhanā*, vol. 50, no. 3, p. 139, Jul. 2025, doi: 10.1007/s12046-025-02810-1.
- [38] A. Awad, F. Fina, A. Goyanes, S. Gaisford, and A. W. Basit, “Advances in powder bed fusion 3D printing in drug delivery and healthcare,” *Advanced Drug Delivery Reviews*, vol. 174, pp. 406–424, Jul. 2021, doi: 10.1016/j.addr.2021.04.025.
- [39] A. Poudel *et al.*, “Feature-based volumetric defect classification in metal additive manufacturing,” *Nat Commun*, vol. 13, no. 1, p. 6369, Oct. 2022, doi: 10.1038/s41467-022-34122-x.
- [40] Ü. Zeybek, “Mechanically alloyed Zr-doped NiTi powders: A study on R-Phase formation and austenitic transformation behavior,” *Canadian Metallurgical Quarterly*, pp. 1–11, Oct. 2025, doi: 10.1080/00084433.2025.2575229

# Eriyik Yığıma Modelleme Yönteminde PLA-CF Kompozitlerinin Yüzey Pürüzlülüğünün ve Boyutsal Doğruluğunun Deneysel Analizi ve Makine Öğrenmesi ile Tahmini

Yunus Kartal<sup>1</sup>

## Özet

Ekleme imalat teknolojileri, karmaşık geometrilerin hızlı ve düşük maliyetle üretilmesine olanak sağlayarak mühendislik uygulamalarında yaygın şekilde kullanılmaktadır. Bu teknolojiler arasında yer alan eriyik yığıma biriktirme (EBM) yöntemi, özellikle polimer ve polimer esaslı kompozit malzemelerin üretiminde en yaygın kullanılan tekniklerden biridir. Ancak EBM yöntemi ile üretilen parçaların yüzey kalitesi ve boyutsal doğruluğu, üretim parametrelerinden önemli ölçüde etkilenmektedir.

Bu çalışmada karbon fiber takviyeli polilaktik asit (PLA-CF) kompozit polimeri kullanılarak EBM yöntemi ile farklı üretim parametrelerinin numunelerin kalitesi üzerindeki etkileri araştırılmıştır. Deneysel çalışmada dört farklı katman kalınlığı (0.1, 0.15, 0.2 ve 0.25 mm) ve dört farklı nozul sıcaklığı (220, 225, 230 ve 235 °C) kullanılarak toplam 16 adet numune üretilmiştir. 30 × 50 × 3 mm boyutlarında üretilen numunelerin yüzey pürüzlülük değerleri farklı yüzey bölgelerinden alınan on ölçümün ortalaması alınarak belirlenmiştir. Boyutsal doğruluk ise numunelerin nominal ölçüleri ile gerçek ölçümleri arasındaki fark hesaplanarak değerlendirilmiştir.

Deneysel sonuçlar incelendiğinde en düşük yüzey pürüzlülük değerinin 0.1 mm katman kalınlığı ve 225 °C nozul sıcaklığında elde edildiği ve bu değer 0.78 µm olduğu belirlenmiştir. Katman kalınlığının artması ile yüzey pürüzlülük değerlerinin arttığı gözlemlenmiştir. Ayrıca nozul sıcaklığının 230 °C değerine kadar yüzey kalitesini iyileştirdiği, bu değer üzerinde ise yüzey kalitesinin olumsuz yönde etkilendiği belirlenmiştir. En yüksek yüzey

1 Doktor öğretim üyesi, Kırıkkale Üniversitesi, y.kartal@kku.edu.tr, 0000-0002-5102-7655

pürüzlülük değeri ise 0.25 mm katman kalınlığı ve 235 °C nozul sıcaklığında 6.67  $\mu\text{m}$  olarak ölçülmüştür.

Elde edilen yüzey pürüzlülüğü ve boyutsal doğruluk verileri ayrıca makine öğrenmesi algoritmalarının performansını değerlendirmek amacıyla veri seti olarak kullanılmıştır. Bu kapsamda farklı makine öğrenmesi algoritmalarının tahmin performansları karşılaştırılarak en uygun algoritmanın belirlenmesi amaçlanmıştır.

## 1. Giriş

Ekllemeli imalat teknolojileri son yıllarda üretim sektöründe önemli bir dönüşüm oluşturmuş ve geleneksel üretim yöntemlerine alternatif olarak geniş bir kullanım alanı bulmuştur. Bu teknolojiler arasında yer alan eriyik yığıma modelleme (EBM) yöntemi, düşük maliyetli ekipman gereksinimi ve kullanım kolaylığı sayesinde en yaygın kullanılan ekllemeli imalat tekniklerinden biri olarak öne çıkmaktadır (Ceylan ve ark., 2024).

EBM yöntemi, termoplastik filament malzemelerin eritilerek katman katman biriktirilmesi prensibine dayanmaktadır. Bu süreçte katman kalınlığı, nozul sıcaklığı, yazdırma hızı ve doluluk oranı gibi birçok üretim parametresi nihai parçanın mekanik özelliklerini ve yüzey kalitesini doğrudan etkilemektedir (Kam ve ark., 2018).

Literatürde yapılan çalışmalar incelendiğinde, EBM yöntemi ile üretilen parçaların yüzey pürüzlülüğünün özellikle katman kalınlığı ve üretim sıcaklığı gibi parametrelerden önemli ölçüde etkilendiği görülmektedir. Katman kalınlığının azalması genellikle daha düşük yüzey pürüzlülüğü ve daha iyi yüzey kalitesi ile sonuçlanmaktadır (Ceylan ve ark., 2024; Sasany ve ark., 2024).

Ayrıca nozul sıcaklığının filament malzemesinin akış özelliklerini ve katmanlar arası bağlanma kalitesini etkilediği, bu durumun da yüzey kalitesi ve mekanik özellikler üzerinde önemli rol oynadığı belirtilmektedir (Megersa ve ark., 2025; Pang ve ark., 2025).

Son yıllarda karbon fiber takviyeli polimer filamentler (CF-PLA gibi) yüksek mekanik dayanım, düşük yoğunluk ve iyi termal özellikleri sayesinde mühendislik uygulamalarında yaygın olarak kullanılmaya başlanmıştır. Bu kompozit malzemeler, standart PLA malzemesine kıyasla daha yüksek dayanım ve rijitlik sağlayabilmektedir (Naidu ve ark., 2025).

EBM yöntemi ile üretilen parçaların kalite özelliklerini iyileştirmek amacıyla üretim parametrelerinin optimize edilmesi büyük önem taşımaktadır. Özellikle yüzey pürüzlülüğü ve boyutsal doğruluk, mühendislik parçalarının performansını ve kullanılabilirliğini doğrudan etkileyen kritik kalite parametreleri arasında

yer almaktadır. Yapılan arařtırmalar katman kalınlığı ve üretim sıcaklığının yüzey pürüzlülüğünü önemli ölçüde etkilediğini göstermektedir (Chacón ve ark., 2017; Ahn ve ark., 2002; Domingo-Espín ve ark., 2015).

Günümüzde eklemeli imalat süreçlerinin analizi ve optimizasyonunda makine öğrenmesi yöntemleri giderek daha fazla kullanılmaktadır (Tok M. ve ark., 2025). Makine öğrenmesi algoritmaları, üretim parametreleri ile ürün kalitesi arasındaki ilişkileri modelleyerek daha doğru tahminler yapılmasına olanak sağlamaktadır. Özellikle yüzey pürüzlülüğünün tahmin edilmesi ve üretim parametrelerinin optimize edilmesi amacıyla çeşitli makine öğrenmesi modellerinin kullanıldığı çalışmalar literatürde yer almaktadır (García-Martínez ve ark., 2024; Faidallah ve ark., 2024).

Bu çalışmada karbon fiber takviyeli PLA (PLA-CF) kompozit malzemesi kullanılarak EBM yöntemi ile üretilen numunelerde katman kalınlığı ve nozul sıcaklığı parametrelerinin yüzey pürüzlülüğü ve boyutsal doğruluk üzerindeki etkileri deneysel olarak incelenmiştir. Ayrıca elde edilen deneysel veriler kullanılarak farklı makine öğrenmesi algoritmalarının performansları karşılaştırılmış ve en uygun algoritmanın belirlenmesi amaçlanmıştır.


## 2. Materyal ve Yöntem

### 2.1. Materyal

Bu çalışmada üretim malzemesi olarak karbon fiber takviyeli polilaktik asit (PLA-CF) filament kullanılmıştır. PLA-CF kompozit malzemeler, PLA matris içerisine dağıtılmış kısa karbon fiber takviyeleri sayesinde yüksek mekanik dayanım ve boyutsal kararlılık sağlamaktadır. Ayrıca düşük yoğunlukları ve iyi baskı kabiliyetleri nedeniyle EBM tabanlı eklemeli imalat uygulamalarında yaygın olarak tercih edilmektedir.

### 2.2. Yöntem

Deneysel çalışmada numuneler Elegoo marka Neptun Pro 4 model EBM tabanlı üç boyutlu yazıcı kullanılarak üretilmiştir (Şekil 1). Numune geometrisi  $30 \times 50 \times 3$  mm boyutlarında dikdörtgen plaka şeklinde tasarlanmıştır. Çalışmada iki farklı üretim parametresi değiştirilmiştir. Bu parametreler ve seviyeleri Tablo 1'de verilmiştir.



Şekil 1. Üretimde kullanılan üç boyutlu eklemeli imalat cihazı

Tablo 1. Üretim parametreleri ve seviyeleri

Değişen parametreler	Seviye
Katman kalınlığı (mm)	0.1, 0.15, 0.2 ve 0.25
Nozul sıcaklığı (°C)	220, 225, 230 ve 235

Çalışmada sabit tutulan parametreler Tablo 2’de verilmiştir.

Tablo 2. Çalışmadaki sabit parametreler

Değişen parametreler	Seviye
Tabla sıcaklığı	60
Alt/üst desen	Eş merkezli
Fan hızı (%)	100
Doluluk oranı (%)	100
Malzeme	PLA-CF

### 2.2.1. Yüzej Pürüzlülüğü Ölçümleri

Numunelerin yüzej kalitesini belirlemek amacıyla yüzej pürüzlülük ölçümleri gerçekleştirilmiştir. Ölçümler TMR marka 120 model yüzej pürüzlülük ölçüm cihazı kullanılarak yapılmıştır. Her numune için farklı yüzej bölgelerinden 10 adet pürüzlülük ölçümü alınmış ve bu ölçümlerin

ortalaması hesaplanarak numunenin ortalama yüzey pürüzlülük değeri (Ra) belirlenmiştir.

### 2.2.2. Boyutsal Doğruluk Analizi

Numunelerin boyutsal doğruluğu dijital kumpas kullanılarak ölçülmüştür. Ölçümler numunenin dış ölçülerini oluşturan: uzunluk (50 mm), genişlik (30 mm) ve kalınlık (3 mm) değerleri için gerçekleştirilmiştir. Boyutsal doğruluk, nominal tasarım ölçüleri ile ölçülen gerçek değerler arasındaki farkın hesaplanması ile belirlenmiştir.

### 2.2.3. Makine Öğrenmesi Analizi

DeneySEL çalışmadan elde edilen 16 adet yüzey pürüzlülük ve boyutsal doğruluk verisi, makine öğrenmesi analizlerinde veri seti olarak kullanılmıştır. Makine öğrenmesi analizinin amacı: üretim parametreleri ile yüzey kalitesi arasındaki ilişkiyi modellemek, en yüksek tahmin doğruluğunu sağlayan makine öğrenmesi algoritmasını belirlemek olarak belirlenmiştir. Bu kapsamda veri seti farklı makine öğrenmesi algoritmaları kullanılarak analiz edilmiş ve algoritmaların performansları karşılaştırılmıştır.


## 3. Sonuçlar

EBM yönteminde PLA-CF kompoziti kullanılarak gerçekleştirilen çalışmada ölçülen sonuçlar Tablo 3'te verilmiştir.

*Tablo 3. Gerçekleştirilen testler ve ölçülen sonuçlar*

Katman kalınlığı (mm)	Nozul sıcaklığı (°C)	Yüzey pürüzlülüğü (Ra)	Boyutsal fark (%)
0.1	220	0.81	1.14
0.1	225	0.78	1.07
0.1	230	0.8	2.12
0.1	235	0.94	2.11
0.15	220	1.14	2.16
0.15	225	1.06	2.14
0.15	230	1.23	2.47
0.15	235	1.35	2.56
0.2	220	2.68	2.74
0.2	225	2.46	2.47
0.2	230	3.84	2.83
0.2	235	4.42	3.11
0.25	220	5.17	3.07
0.25	225	4.86	3.04
0.25	230	5.56	3.56
0.25	235	6.67	4.12


Çalışma kapsamında üretilen numunelerin görüntüsü Şekil 2’de verilmiştir.



Şekil 2. Üretilen numuneler

### 3.1. YüzeY Pürüzlülüğü Sonuçlarının Değerlendirilmesi

EBM yöntemi ile üretilen PLA-CF numunelerin yüzeY pürüzlülüğü sonuçları incelendiğinde, üretim parametreleri arasında özellikle katman kalınlığının yüzeY kalitesi üzerinde belirleyici bir etkiye sahip olduğu görülmektedir. Deneysel sonuçlara göre en düşük yüzeY pürüzlülüğü değeri 0.1 mm katman kalınlığı ve 225 °C nozul sıcaklığında 0.78  $\mu\text{m}$  olarak ölçülmüştür. Buna karşılık en yüksek yüzeY pürüzlülüğü değeri 0.25 mm katman kalınlığı ve 235 °C sıcaklıkta 6.67  $\mu\text{m}$  olarak elde edilmiştir. Katman kalınlığına göre ortalama pürüzlülük değerleri incelendiğinde 0.10 mm katman kalınlığında yaklaşık 0.83  $\mu\text{m}$ , 0.15 mm’de 1.19  $\mu\text{m}$ , 0.20 mm’de 3.35  $\mu\text{m}$  ve 0.25 mm’de 5.56  $\mu\text{m}$  seviyesine yükseldiği görülmektedir. Bu durum katman kalınlığındaki artışın yüzeY pürüzlülüğünü önemli ölçüde artırdığını göstermektedir (Şekil 3).



Şekil 3. Katman kalınlığı ve nozul sıcaklığına bağlı olarak ölçülen yüzey pürüzlülüğü değerleri

Bu sonuçlar literatürdeki birçok çalışma ile uyum göstermektedir. EBM üretiminde katman kalınlığının artması, katmanlar arasındaki basamak (stair-stepping) etkisini artırarak yüzey pürüzlülüğünün yükselmesine neden olmaktadır. Bu etki özellikle düşük eğimli yüzeylerde daha belirgin hale gelmektedir (Boschetto & Bottini, 2014). Benzer şekilde Juan M. Chacón ve arkadaşları (2017) tarafından yapılan çalışmada da katman kalınlığının azaltılması ile yüzey pürüzlülüğünün önemli ölçüde iyileştiği ve daha düzgün yüzeylerin elde edildiği rapor edilmiştir.

Nozul sıcaklığının yüzey kalitesi üzerindeki etkisi incelendiğinde ise sıcaklığın belirli bir değere kadar yüzey pürüzlülüğünü iyileştirdiği, ancak daha yüksek sıcaklıklarda yüzey kalitesinin yeniden bozulduğu görülmektedir. Bu çalışmada yüzey pürüzlülüğünün 230 °C sıcaklığa kadar iyileştiği, ancak 235 °C'de tekrar kötüleştiği belirlenmiştir. Bunun temel nedeni yüksek sıcaklıklarda filament malzemesinin viskozitesinin azalması ve ekstrüzyon sırasında daha kontrolsüz bir akış sergilemesidir. Bu durum katmanlar arasında düzensiz birikmelere ve yüzey dalgalanmalarına neden olabilmektedir.

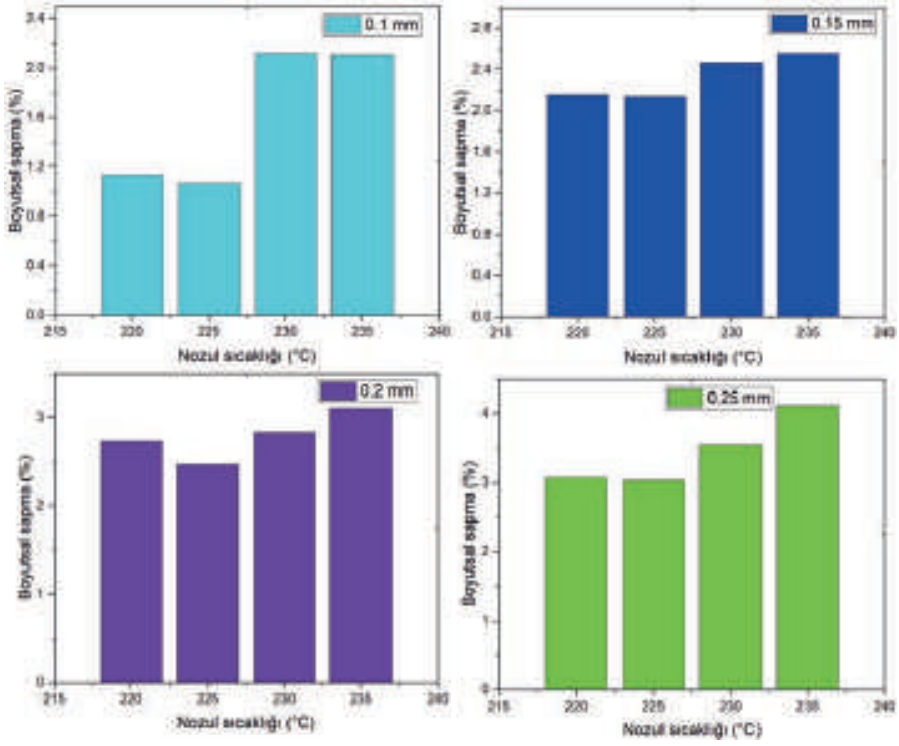
Benzer bulgular Suraj Singh ve arkadaşları (2020) tarafından yapılan çalışmada da rapor edilmiştir. Araştırmacılar, optimum ekstrüzyon sıcaklığının üzerinde gerçekleştirilen baskılarda malzemenin aşırı akışkan hale geldiğini ve bunun yüzey kalitesini olumsuz etkilediğini belirtmiştir. Ayrıca Bryan Tımrak ve arkadaşları (2014) tarafından yapılan çalışmada da uygun sıcaklık değerlerinde katmanlar arası bağlanmanın iyileştiği, ancak aşırı sıcaklıkların yüzey pürüzlülüğünü artırabildiği ifade edilmiştir.

Karbon fiber takviyeli filamentlerin yüzey pürüzlülüğü üzerinde ek bir etkisi de bulunmaktadır. Karbon fiber parçacıkları, polimer matris içerisinde heterojen bir yapı oluşturduğu için ekstrüzyon sırasında yüzeyde mikro düzensizliklere neden olabilmektedir. Bununla birlikte uygun baskı parametreleri kullanıldığında bu etkinin minimize edilebildiği belirtilmektedir (Khalili et al., 2023).

Sonuç olarak elde edilen bulgular, EBM üretiminde yüzey kalitesinin iyileştirilmesi için düşük katman kalınlığı ve optimum nozul sıcaklığı değerlerinin tercih edilmesi gerektiğini göstermektedir. Bu çalışma kapsamında elde edilen sonuçlar literatürde rapor edilen eğilimlerle büyük ölçüde uyum göstermektedir.

### 3.2. Boyutsal Doğruluk Sonuçlarının Değerlendirilmesi

EBM yöntemi ile üretilen numunelerin boyutsal doğruluk sonuçları incelendiğinde, üretim parametrelerinin parçaların geometrik doğruluğu üzerinde önemli bir etkisi olduğu görülmektedir. Deneysel sonuçlara göre boyutsal hata değerleri katman kalınlığının artması ile birlikte artış göstermiştir. Ortalama boyutsal fark değerleri incelendiğinde 0.10 mm katman kalınlığında yaklaşık %1.61, 0.15 mm'de %2.33, 0.20 mm'de %2.79 ve 0.25 mm'de %3.44 seviyesine yükseldiği görülmektedir. Bu sonuçlar katman kalınlığının artmasının parçaların boyutsal doğruluğunu olumsuz etkilediğini ortaya koymaktadır. Üretim parametrelerine bağlı olarak ölçülen boyutsal sapma değerinin yüzdesel farkı Şekil 4'te verilmiştir.



Şekil 4. Ölçülen boyutsal sapma değerinin yüzdesel farkı

Katman kalınlığının boyutsal doğruluğa etkisi literatürde de geniş şekilde incelenmiştir. Katman kalınlığının artması, her katmanda ekstrüde edilen malzeme miktarının artmasına neden olmakta ve bu durum katmanların kenarlarında taşmalara yol açabilmektedir. Bu taşmalar özellikle küçük boyutlu parçalarda ölçüsel hataların artmasına neden olmaktadır (Dudescu & Raghavan, 2020). Ayrıca kalın katmanlar, soğuma sırasında daha fazla büzülme etkisi oluşturabilmekte ve bu durum parçaların nominal ölçülerden sapmasına yol açabilmektedir.

Nozul sıcaklığı da boyutsal doğruluğu etkileyen önemli parametrelerden biridir. Yüksek sıcaklık değerlerinde filamentin akışkanlığı artmakta ve ekstrüzyon sırasında malzemenin kontrolü zorlaşabilmektedir. Bu durum özellikle kenar bölgelerinde malzeme birikmesine neden olarak parçaların gerçek ölçülerinin tasarım ölçülerinden sapmasına yol açabilmektedir (Chacón et al., 2017). Bununla birlikte çok düşük sıcaklıklarda ise katmanlar arası bağlanma zayıflamakta ve bu durum da parçanın yapısal bütünlüğünü olumsuz etkileyebilmektedir.

EBM üretiminde boyutsal doğruluğun iyileştirilmesi için uygun katman kalınlığı ve ekstrüzyon sıcaklığı kombinasyonunun belirlenmesi büyük önem taşımaktadır. Bu çalışmada elde edilen sonuçlar, düşük katman kalınlıklarının hem yüzej kalitesi hem de boyutsal doğruluk açısından daha avantajlı olduğunu göstermektedir. Benzer sonuçlar Michael Dudescu ve Nishanth Raghavan (2020) tarafından yapılan çalışmada da rapor edilmiştir. Araştırmacılar düşük katman kalınlığı değerlerinin daha hassas ölçüler elde edilmesini sağladığını belirtmiştir.

Sonuç olarak elde edilen bulgular, EBM yöntemi ile üretilen PLA-CF kompozit parçaların boyutsal doğruluğunun üretim parametrelerine güçlü şekilde bağlı olduğunu göstermektedir. Özellikle katman kalınlığının azaltılması, hem yüzej kalitesini iyileştirmekte hem de parçaların tasarım ölçülerine daha yakın sonuçlar elde edilmesini sağlamaktadır.

### 3.3. Makine Öğrenmesi Algoritmalarının Karşılaştırılması

Çalışma kapsamında farklı üretim parametrelerinde ölçülen yüzej pürüzlülükleri ve boyutsal sapmanın yüzdesel farkı makine öğrenmesi algoritmaları ile değerlendirilmiş ve en uygun tahmini gerçekleştiren algoritma belirlenmeye çalışılmıştır (Tablo 4).

*Tablo 4. Makine öğrenmesi algoritmaları ve tahminlerinin değerleri*

Yüzej pürüzlülüğü				Boyutsal sapma			
Algoritma	MAE	RMSE	Coefficient	Algoritma	MAE	RMSE	Coefficient
GP	1.5299	1.679	0.6857	GP	0.5148	0.6941	0.6616
LR	0.8009	0.9278	0.8862	LR	0.2157	0.2704	0.9352
MLP	0.4375	0.5651	0.958	MLP	0.324	0.3948	0.8592
SLR	0.7317	0.8258	0.9082	SLR	0.3657	0.4302	0.8272
SMOreg	0.7089	0.8343	0.9062	SMOreg	0.2464	0.3008	0.9261
IBK	1.2887	1.6016	0.6694	IBK	0.6913	0.7498	0.5171
KStar	0.8188	0.9665	0.9597	KStar	0.2855	0.4168	0.9264
LWL	0.8983	1.2447	0.7919	LWL	0.5271	0.5719	0.6976
AR	0.5735	0.6562	0.9446	AR	0.2644	0.3071	0.9203
Bagging	0.7042	0.9585	0.8798	Bagging	0.4065	0.554	0.6988
CVPS	1.8308	2.0366	-0.5347	CVPS	0.5952	0.7939	-0.6135
RC	0.4315	0.603	0.9559	RC	0.3434	0.4722	0.8383
RFC	0.9744	1.3428	0.8276	RFC	0.3658	0.4858	0.7926
RBD	0.7935	1.0509	0.8517	RBD	0.4897	0.5423	0.7306
Stacking	1.8308	2.0366	-0.5347	Stacking	0.5952	0.7939	-0.6135

DT	0.5017	0.7135	0.9328	DT	0.436	0.4971	0.7701
M5P	0.6396	0.7572	0.9245	M5P	0.2157	0.2704	0.9352
RF	0.4004	0.5817	0.9555	RF	0.2963	0.3752	0.8719
RT	0.4315	0.603	0.9559	RT	0.3434	0.4722	0.8383

### 3.2.1. Boyutsal Sapma Tahminine Yönelik Makine Öğrenmesi Modellerinin Performans Analizi

Bu çalışmada, katman kalınlığı ve nozul sıcaklığı gibi proses parametreleri kullanılarak elde edilen boyutsal sapma değerlerinin tahmini amacıyla farklı makine öğrenmesi algoritmalarının performansı karşılaştırılmıştır. Model performanslarının değerlendirilmesinde MAE, RMSE ve korelasyon katsayısı metrikleri kullanılmıştır. MAE ve RMSE değerlerinin düşük olması model tahminlerinin gerçek değerlere daha yakın olduğunu gösterirken, korelasyon katsayısının 1'e yaklaşması modelin açıklayıcılığının yüksek olduğunu ifade etmektedir.

Elde edilen sonuçlar incelendiğinde bazı algoritmaların boyutsal sapma tahmininde diğerlerine göre daha başarılı olduğu görülmektedir. Özellikle linear regression (LR) ve M5P model tree algoritmalarının en yüksek performansı gösterdiği belirlenmiştir. Her iki algoritma için MAE değeri 0.2157, RMSE değeri 0.2704 ve korelasyon katsayısı 0.9352 olarak elde edilmiştir. Bu sonuçlar, söz konusu modellerin deneysel veriler ile tahmin edilen değerler arasında oldukça güçlü bir ilişki kurabildiğini göstermektedir. M5P algoritmasının karar ağacı temelli bir model olması ve doğrusal regresyonu ağaç yapısı içerisinde kullanması, küçük veri setlerinde yüksek tahmin doğruluğu sağlayabilmesini açıklamaktadır.

Benzer şekilde SMOreg algoritması da yüksek tahmin performansı sergileyen modeller arasında yer almaktadır. Bu model için MAE değeri 0.2464, RMSE değeri 0.3008 ve korelasyon katsayısı 0.9261 olarak hesaplanmıştır. Destek vektör regresyonu temelli bu yaklaşım, doğrusal olmayan ilişkilerin modellenmesinde etkili olduğundan proses parametreleri ile boyutsal sapma arasındaki ilişkiyi başarılı bir şekilde temsil edebilmiştir.

Orta düzey performans sergileyen modeller arasında random forest (RF), multilayer perceptron (MLP) ve KStar algoritmaları yer almaktadır. Bu modeller için korelasyon katsayısı değerleri sırasıyla 0.8719, 0.8592 ve 0.9264 olarak elde edilmiştir. Özellikle KStar algoritmasının korelasyon katsayısı yüksek olmasına rağmen hata değerlerinin (MAE=0.2855, RMSE=0.4168) nispeten daha büyük olması, tahminlerde belirli sapmaların oluşabildiğini

göstermektedir. Benzer şekilde MLP algoritması karmaşık doğrusal olmayan ilişkileri modelleyebilmesine rağmen veri setinin sınırlı büyüklüğünden dolayı beklenen düzeyde performans sergileyememiş olabilir.

Diğer taraftan bazı algoritmaların tahmin performanslarının oldukça düşük olduğu görülmektedir. Özellikle CVparameterselection ve stacking yöntemlerinde korelasyon katsayısının  $-0.6135$  gibi negatif bir değer alması, model tahminlerinin gerçek değerlerle tutarsız olduğunu göstermektedir. Bu durum, söz konusu yöntemlerin veri setinin boyutu veya dağılımı açısından uygun bir modelleme yaklaşımı olmadığını göstermektedir. Benzer şekilde IBk algoritmasının da yüksek hata değerleri (MAE=0.6913, RMSE=0.7498) ve düşük korelasyon katsayısı (0.5171) nedeniyle zayıf performans sergilediği belirlenmiştir.

Genel olarak değerlendirildiğinde, boyutsal sapma tahmini için doğrusal model tabanlı yaklaşımların veri setine daha iyi uyum sağladığı görülmektedir. Özellikle linear regression ve M5P algoritmalarının düşük hata değerleri ve yüksek korelasyon katsayıları sayesinde en başarılı tahmin modelleri olduğu sonucuna ulaşılmıştır. Bu durum, incelenen proses parametreleri ile boyutsal sapma arasındaki ilişkinin büyük ölçüde doğrusal karakterde olduğunu göstermektedir.

Sonuç olarak, katman kalınlığı ve nozul sıcaklığı gibi üretim parametreleri kullanılarak boyutsal sapmanın tahmin edilmesinde M5P ve linear regression algoritmaları en uygun modeller olarak belirlenmiştir. Bu modellerin kullanılması, FDM tabanlı üretim süreçlerinde boyutsal doğruluğun önceden tahmin edilmesine ve üretim parametrelerinin optimize edilmesine katkı sağlayabilir.

### **3.2.2. Yüzey Pürüzlülüğü Tahminine Yönelik Makine Öğrenmesi Modellerinin Performans Analizi**

Çalışmada farklı makine öğrenmesi algoritmalarının yüzey pürüzlülüğünü tahmin etme performansı MAE (mean absolute error), RMSE (root mean square error) ve korelasyon katsayısı (coefficient) kriterleri kullanılarak karşılaştırılmıştır. Elde edilen sonuçlar, modellerin tahmin doğruluğu açısından önemli farklılıklar gösterdiğini ortaya koymaktadır.

Genel olarak değerlendirildiğinde, RMSE ve MAE değerlerinin düşük, korelasyon katsayısının ise yüksek olması model performansının daha iyi olduğunu göstermektedir. Bu bağlamda sonuçlar incelendiğinde, RF (random forest) algoritmasının en iyi performansı sergilediği görülmektedir. RF modeli 0.4004 MAE, 0.5817 RMSE ve 0.9555 korelasyon katsayısı ile en düşük hata değerlerinden birine ve yüksek bir doğruluk seviyesine sahiptir. Benzer şekilde

MLP (multilayer perceptron) modeli de 0.4375 MAE, 0.5651 RMSE ve 0.9580 korelasyon katsayısı ile oldukça başarılı sonuçlar üretmiştir. Bu durum, yapay sinir ağlarının doğrusal olmayan ilişkileri modellemedeki etkinliğini göstermektedir.

Bunun yanı sıra RC, RT ve AR algoritmaları da yüksek korelasyon katsayıları ( $\approx 0.94-0.96$ ) ve düşük hata değerleri ile güçlü tahmin performansı sergileyen modeller arasında yer almaktadır. Bu modeller, yüzey pürüzlülüğünü etkileyen parametreler arasındaki karmaşık ilişkileri başarılı şekilde yakalayabilmektedir.

Doğrusal modeller incelendiğinde ise LR (linear regression) ve SLR (simple linear regression) algoritmalarının hata değerlerinin nispeten daha yüksek olduğu ve korelasyon katsayılarının diğer gelişmiş yöntemlere kıyasla daha düşük kaldığı görülmektedir. Bu durum, yüzey pürüzlülüğü gibi üretim süreçlerinde ortaya çıkan değişkenlerin çoğunlukla doğrusal olmayan ilişkiler içerdiğini ve basit doğrusal modellerin bu ilişkileri tam olarak temsil etmekte sınırlı kalabileceğini göstermektedir.

Öte yandan bazı algoritmaların (örneğin GP, IBK, CVPS, Stacking, RFC, RBD ve LWL) MAE ve RMSE değerlerinin oldukça yüksek olduğu dikkat çekmektedir. Bu durum iki şekilde yorumlanabilir: ilgili algoritmaların veri setine uygun hiper parametrelerle eğitilmemiş olması, veri ölçeklendirme veya model kurulum sürecinde ortaya çıkabilecek hesaplama veya veri işleme hataları.

Özellikle CVPS ve Stacking modellerinde korelasyon katsayısının negatif ( $-0.5347$ ) olması, modelin gerçek değerlerle ters yönlü bir ilişki kurduğunu ve tahmin performansının oldukça zayıf olduğunu göstermektedir.

Sonuçlar bütüncül olarak değerlendirildiğinde, topluluk tabanlı yöntemler ve yapay sinir ağı modellerinin yüzey pürüzlülüğü tahmininde daha yüksek doğruluk sağladığı görülmektedir. Özellikle random forest ve MLP algoritmaları, düşük hata değerleri ve yüksek korelasyon katsayıları ile diğer yöntemlere kıyasla daha başarılı performans göstermiştir. Bu durum, karmaşık üretim parametrelerinin etkilediği yüzey pürüzlülüğü gibi problemlerde doğrusal olmayan ve topluluk (ensemble) tabanlı yöntemlerin daha etkin sonuçlar sağlayabileceğini ortaya koymaktadır.

Dolayısıyla, ileri çalışmalar için model optimizasyonu ve hiperparametre ayarlamaları yapılarak özellikle RF ve MLP tabanlı modellerin geliştirilmesi, yüzey pürüzlülüğü tahmin doğruluğunu daha da artırabilecek potansiyel bir araştırma yönü olarak değerlendirilebilir.

#### 4. Sonuçlar ve Öneriler

Bu çalışmada, FDM yöntemi ile üretilen parçaların boyutsal doğruluğunu etkileyen temel proses parametrelerinden katman kalınlığı ve nozul sıcaklığının boyutsal sapma üzerindeki etkisi deneysel olarak incelenmiş ve elde edilen veriler farklı makine öğrenmesi algoritmaları kullanılarak modellenmiştir. Makine öğrenmesi modellerinin performansları MAE, RMSE ve korelasyon katsayısı gibi istatistiksel performans ölçütleri kullanılarak değerlendirilmiştir.

Deneysel sonuçlar incelendiğinde, katman kalınlığının artmasıyla birlikte boyutsal sapma değerlerinin belirgin şekilde arttığı gözlemlenmiştir. Bu durum, katman kalınlığının büyümesiyle birlikte eriyik polimerin katmanlar arasında daha düzensiz bir şekilde birikmesi ve katmanlar arası geometrik hassasiyetin azalması ile açıklanabilir. Özellikle yüksek katman kalınlıklarında malzemenin katılma sürecindeki büzülme ve geometrik kararsızlıkların artması, parçaların nominal ölçülerden daha fazla sapsmasına neden olmuştur. Bu sonuç, FDM üretiminde boyutsal doğruluğun sağlanabilmesi için düşük katman kalınlıklarının tercih edilmesinin önemli olduğunu göstermektedir.

Nozul sıcaklığının boyutsal sapma üzerindeki etkisi incelendiğinde ise sıcaklığın artmasıyla birlikte boyutsal sapma değerlerinde belirli bir değişim eğilimi gözlenmiştir. Daha yüksek nozul sıcaklıklarında polimer eriyiğinin akışkanlığının artması, katmanlar arasında daha iyi bir yayılma sağlamasına rağmen bazı durumlarda malzemenin kontrolsüz akmasına ve geometrik doğruluğun azalmasına neden olabilmektedir. Bu nedenle optimum nozul sıcaklığının belirlenmesi, boyutsal doğruluk açısından kritik bir parametre olarak değerlendirilmektedir.

Makine öğrenmesi algoritmalarının performansları karşılaştırıldığında, linear regression ve M5P algoritmalarının en düşük hata değerlerine ve en yüksek korelasyon katsayısına sahip olduğu belirlenmiştir. Bu durum, çalışmada kullanılan proses parametreleri ile boyutsal sapma arasındaki ilişkinin büyük ölçüde doğrusal bir karakter sergilediğini göstermektedir. Buna karşılık bazı algoritmaların daha yüksek hata değerleri üretmesi, veri setinin sınırlı büyüklüğü ve parametre sayısının az olması ile ilişkilendirilebilir. Özellikle karmaşık model yapısına sahip algoritmaların küçük veri setlerinde beklenen performansı gösteremediği görülmüştür.

Elde edilen bulgular doğrultusunda, FDM üretim süreçlerinde boyutsal doğruluğun artırılabilmesi için düşük katman kalınlığı ve uygun nozul sıcaklığı kombinasyonlarının tercih edilmesi gerektiği sonucuna ulaşılmıştır. Ayrıca makine öğrenmesi tabanlı tahmin modellerinin kullanılması, üretim sürecinde

deneySEL deneme sayısını azaltarak üretim parametrelerinin daha hızlı ve etkin bir şekilde optimize edilmesine katkı sağlayabilir.

Bu çalışma kapsamında elde edilen sonuçlara dayanarak gelecekte yapılacak çalışmalar için bazı öneriler sunulabilir. Öncelikle, model doğruluğunu artırabilmek amacıyla veri setine baskı hızı, dolgu oranı, soğutma fan hızı ve baskı yönü gibi ek proses parametrelerinin dahil edilmesi önerilmektedir. Ayrıca farklı polimer malzemeler kullanılarak gerçekleştirilecek deneySEL çalışmalar, makine öğrenmesi modellerinin genellebilirliğinin değerlendirilmesine katkı sağlayacaktır. Bunun yanı sıra, daha büyük veri setleri ile gerçekleştirilecek çalışmaların derin öğrenme tabanlı yöntemlerin performansının değerlendirilmesine olanak sağlayacağı düşünülmektedir. Son olarak, çok amaçlı optimizasyon yaklaşımlarının kullanılması ile hem mekanik özelliklerin hem de boyutsal doğruluğun aynı anda optimize edilmesi mümkün olabilir.

Sonuç olarak, bu çalışma FDM üretim süreçlerinde boyutsal sapmanın tahmin edilmesinde makine öğrenmesi yöntemlerinin etkili bir araç olduğunu ortaya koymakta ve uygun proses parametrelerinin belirlenmesine yönelik önemli bir referans sunmaktadır.

## Kaynakça

- Alberto Boschetto, & Luca Bottini. (2014). Roughness prediction in fused deposition modelling by neural networks. *The International Journal of Advanced Manufacturing Technology*, 67, 2727–2742.
- Bryan Tımrak, Mark Kreiger, & Joshua M. Pearce. (2014). Mechanical properties of components fabricated with open-source 3-D printers under realistic environmental conditions. *Materials & Design*, 58, 242–246.
- Ceylan, Mert & şahin, İsmail & Top, Neslihan. (2024). Ekstrüzyon Tabanlı Metal Eklemeli İmalat (EBAM): Teknoloji, Avantajlar ve Kısıtlar. *İmalat Teknolojileri ve Uygulamaları*. 5. 10.52795/mateca.1580405.
- Faidallah, R. F., Hanon, M. M., Salman, N. D., Ibrahim, Y., Babu, M. N., Gaaz, T. S., Szakál, Z., & Oldal, I. (2024). Development of Fiber-Reinforced Polymer Composites for Additive Manufacturing and Multi-Material Structures in Sustainable Applications. *Processes*, 12(10), 2217. <https://doi.org/10.3390/pr12102217>
- Hwan Jin Ahn, Michael Montero, Dan Odell, & Shad Roundy. (2002). Anisotropic material properties of fused deposition modeling ABS. *Rapid Prototyping Journal*, 8(4), 248–257.
- Ian Gibson, David W. Rosen, & Brent Stucker. (2021). *Additive manufacturing technologies: 3D printing, rapid prototyping, and direct digital manufacturing* (3rd ed.). Springer.
- Juan M. Chacón, Miguel A. Caminero, Enrique García-Plaza, & Pedro J. Núñez. (2017). Additive manufacturing of PLA structures using fused deposition modelling: Effect of process parameters on mechanical properties and surface quality. *Materials & Design*, 124, 143–157.
- Kam, Menderes & Saruhan, Hamit & İpekci, Ahmet. (2018). Investigation of surface treatment effect on mechanical properties of printed products by fused deposition modelling method.
- Khalili, Ali & Kami, Abdolvahed & Abedini, Vahid. (2023). Tensile and Flexural Properties of 3D-Printed Polylactic Acid/Continuous Carbon Fiber Composite. *Mechanics of Advanced Composite Structures*. 10. 10.22075/macs.2023.29500.1466.
- Luis García-Martínez, Carlos Fernández, & Daniel Pérez. (2024). Machine learning prediction of surface roughness in fused deposition modelling processes. *Additive Manufacturing*, 80, 103975.
- Manuel Domingo-Espín, Jordi Puigoriol-Forcada, Agustín A. Garcia-Granada, & Jose Lluma. (2015). Mechanical property characterization and simulation of fused deposition modeling Polycarbonate parts. *Materials & Design*, 83, 670–677.

- Megersa, Getu & Sitek, Wojciech & Nowak, Agnieszka. (2025). Investigation of nozzle temperature impact on surface roughness and mechanical properties of FDM-printed CF-PEEK components.
- Michael Dudesco, & Nishanth Raghavan. (2020). Optimization of FDM process parameters using Taguchi method for improved mechanical performance. *Rapid Prototyping Journal*, 26(6), 1123–1134.
- Naidu, Challa & Ramana, Challa & Yarraguntla, Srinivasa Rao & Rao, Kollabathula & Vasudha, Dadi & Anusha, Gandhi & Rajeshbabu, Koppisetty. (2023). A Concise Review on Carbon Fiber-Reinforced Polymer (CFRP) and Their Mechanical Significance Including Industrial Applications. 10.5772/intechopen.109339.
- Pang, R., Lai, M. K., Teo, H. H., & Yap, T. C. (2025). Influence of Temperature on Interlayer Adhesion and Structural Integrity in Material Extrusion: A Comprehensive Review. *Journal of Manufacturing and Materials Processing*, 9(6), 196. <https://doi.org/10.3390/jmmp9060196>
- Sasany Rafat & Jamjoom Faris & Kendirci, Merve & Yilmaz, Burak. (2024). Effect of Printing Layer Thickness on Optical Properties and Surface Roughness of 3D-Printed Resins: An In Vitro Study. *The International journal of prosthodontics*. 37. 165-173. 10.11607/ijp.8965.
- Suraj Singh, Seeram Ramakrishna, & Raghvendra Singh. (2020). Material issues in additive manufacturing: A review. *Journal of Manufacturing Processes*, 25, 185–200.
- Tok Mustafa & Fedai Yusuf, (2025). Topology optimization for manufacturing aircraft bearing brackets via laser powder bed fusion. *Sādhanā*, 50.3: 139. <https://doi.org/10.1007/s12046-025-02810-1>



## Düz Dişli Çark Sistemlerinde Hertz Basınç Değerlerinin Analizi

Ramazan Çalışkan<sup>1</sup>

Ali Osman Kurban<sup>2</sup>

### Özet

Mekanik güç iletim sistemlerinde dişli çarkların operasyonel ömrünü sınırlayan temel faktörün, yapısal kırılmalardan ziyade yüzeylerde meydana gelen tribolojik aşınmalar olduğu bilinmektedir. Bu aşınma süreci, etkileşim halindeki diş profilleri arasında oluşan yüksek temas basınçlarının yol açtığı elastik ve plastik deformasyonların bir sonucudur. Bu çalışmada Hertzian temas gerilmelerinin analitik hesabı ve bu gerilmelerin tetiklediği deformasyon karakteristikleri araştırılmaktadır. Elastisite teorisi temel alınarak gerçekleştirilen modellemede, önce temas geometrisi tanımlanmış, ardından iletilen momentin oluşturduğu kuvvetlerin basınç dağılımı üzerindeki etkileri sayısal olarak analiz edilmiştir. Geliştirilen hesaplama algoritması sayesinde; basınç açısı, Eğrilik yarıçapı, Elastisite modülü ve Poisson oranı, gibi tasarım parametrelerinin sistem performansı üzerindeki etkileri parametrik olarak incelenmiştir. Dış dişli tasarımlarında kritik öneme sahip olan temas gerilmesi, deformasyon parametrelerini minimize etmeye odaklanmaktadır. Dişli hasarlarının temel nedeni olan gerilme aşımını engellemek amacıyla, üç farklı malzeme ve üç farklı Tork seçeneğiyle oluşturulan dokuz farklı kombinasyon ileri düzey simülasyon teknikleriyle incelenmiştir. Solidworks 2020 programının Simulation ortamında yürütülen iki boyutlu sonlu elemanlar (FEM) çalışmaları, Hertz basınç değerleriyle karşılaştırmalı olarak analiz edilmiştir. Burada Tork ve Elastisite modülündeki artış Hertz basıncı değerini de arttırmaktadır. Teorik ve nümerik sonuçlar arasındaki tutarlılık, analiz metodolojisinin doğruluğunu ortaya koymakta ve tasarım sürecinde güvenle kullanılabileceğini göstermektedir. Mekanik sistemlerde çeliğin vazgeçilmez bir bileşen olarak öne çıkmasının temel nedeni, yüksek hacimsel

1 Makine Mühendisliği Yüksek Lisans Öğrencisi, Kırşehir Ahi Evran Üniversitesi Fen Bilimleri Enstitüsü, ramazancaliskan879@gmail.com, 0009-0008-3527-2336

2 Prof. Dr., Kırşehir Ahi Evran Üniversitesi, alikurban@ahievran.edu.tr, 0000-0003-0537-3896

mukavemet, verimlilik ve ekonomik olmasıdır. Endüstriyel dişli imalatında; Karbon bazlı alaşımlardan, karmaşık metalürjik kompozisyonlara sahip alaşımlı çeliklere kadar geniş bir alanda seçim yapılmaktadır. Malzeme seçim sürecini belirleyen temel parametreler; dinamik yükler altındaki yorulma direnci, kopma mukavemeti ve malzemeye uygulanan ısıtma işlemidir.

## 1. Dişli Çarkların Gelişim Süreci

(Chacón ve ark., 2010) Dişli çarklar, üzerlerinde geometrik olarak şekillendirilmiş dişler bulunan ve iki dönen shaft arasında güç (tork ve açılma hız) aktarmak amacıyla tasarlanmış temel makine elemanlarıdır. İnsanlığın teknik gelişim sürecindeki en kadim buluşlar arasında yer alan dişliler, antik dönemlerden bu yana önemini korumuştur. En basit mekanizmalardan en karmaşık endüstriyel sistemlere kadar, hareketin olduğu her noktada bu sistemlerin temel bir rol oynadığı görülmektedir. Dişli çarklar Hertz basıncından kaynaklı deformasyona uğramaktadır. Hertz Basıncı (Hertzian Pressure), Makine Mühendisliği ve özellikle Temas Mekanikliği alanında kullanılan temel kuramsal büyüklüktür. Bu değer, elastik iki cismin normal kuvvet etkisinde teması sonucu, temas yüzeyinde oluşan maksimum basma gerilmesini tanımlar. Hertz basıncından kaynaklı diş dibi gerilmelerinin analizi yapılmıştır. İletim, bir dişliden diğerine diş profillerinin birbirine temas etmesi ve mekanik olarak kenetlenmesi sayesinde gerçekleşir. Dişli çarkların birincil görevi, aktarılan torkun seviyesini değiştirmek ve/veya dönüş hızını (devir sayısını) sabit bir oranla iletmektir. Bu sayede mekanik sistemlerde hız ve tork gereksinimleri hassasiyetle yönetilebilir. (Kapelevich & Shekhtman, 2003) tarafından hazırlanan “Asimetrik İnvölüt Dişliler için Doğrudan Dişli Tasarımı.” üzerine araştırma makalesinde; dişli çarklarda geometrik parametrelerin seçimi, sistemin taşıyabileceği yük kapasitesini ve dayanıklılığını doğrudan etkiler. Tasarım sürecinde, dişli çarkın temas alanındaki gerilme dağılımı dikkate alınarak optimizasyon çalışmaları yapılmakta, bu sayede hem mukavemet hem de verimlilik artırılmaktadır. Özellikle yüksek tork altında çalışan dişli sistemlerinde, dişlerin dayanımının yetersiz kalması sistemin tamamen devre dışı kalmasına neden olabileceğinden, tek bir dişin dahi eksikliği tüm mekanizmanın işleyişini bozabilmektedir. Bu bağlamda kavrama halindeki pinyon ve dişli bileşenlerinin mekanik direnç seviyelerinin dengelenmesi gerekliliği vurgulanmıştır. (Bibel ve ark., 1994) dişli sistemlerinde diş dibi mukavemeti ile eğilme gerilmelerinin dengelenmesinin, dişli çiftlerinin ömrünü artırdığı sonucuna ulaşımlardır. Dişli çarklar, çalışma sırasında iki ana gerilme türüne maruz kalmaktadır: diş yüzeyinde oluşan temas basıncı (contact pressure) ve diş dibinde meydana gelen eğilme gerilmesi. Tork altında çalışan dişlilerde bu iki gerilme türü birlikte etkili olur. Özellikle diş dibi gerilmesi, sertleştirilmiş dişlilerde kırılma riskini artıran kritik bir faktördür. Bu nedenle, diş dibi kırılması dişli mekanizmalarındaki en yaygın ve tehlikeli


hasar türlerinden biri olarak kabul edilmektedir. (Goss & Hoepfner, 1974) Dişli çarkların temas bölgelerinde oluşan Hertz basıncının, yüzeyde mikro çatlakların başlaması ardından pitting (yüzey çukurlaşması) gibi yorulma hasarlarını tetiklediğini belirtmiştir. Bu tür yüzey hasarları, dişli çarkın kullanım ömrünü önemli ölçüde kısaltmakta ve sistemin genel verimini düşürmektedir. Dolayısıyla, Hertz basıncının doğru biçimde hesaplanması, yorumlanması ve sınırlandırılması, dişli sistemlerin güvenilirliği açısından kritik bir öneme sahiptir. (Akkurt M., 2005) Dişli çarkların mukavemet ve yüzey basınca karşı dayanımını geniş ölçüde etkileyen en temel etken malzemedir. Bu nedenle malzeme tercihi, tasarımın en kritik adımlarından biridir. Genellikle yüksek kuvvet aktaran dişlilerde çelik esas alınırken; yalnızca devir iletimi gerektiren duyarlı cihazlarda kullanılan çarklar için bronz, naylon, teflon ve sinterlenmiş malzemeler gibi alternatifler seçilir. Önemsiz olan ve çok düşük devirlerde faaliyet gösteren dişliler ise dökme demir esaslı alaşımlardan imal edilmeye uygundur. (Zhao & Maietta, 1992,) Dişli çark temaslarını sonlu elemanlar yöntemi (FEM) kullanarak modellemiş ve klasik Hertz teorisinin yalnızca ideal koşullarda geçerli olduğunu, gerçek temas davranışının ise diş geometrisi, malzeme anizotropisi ve yükleme koşulları gibi faktörlerle önemli ölçüde değiştiğini vurgulamıştır. Bu nedenle, modern tasarım yaklaşımlarında Hertz teorisinin sayısal analizlerle desteklenmesi gerektiği önerilmiştir.

### 1.1. Dişli çarklarda Hertz basıncının hesaplanması

1882 yılında Alman fizikçi Heinrich Hertz tarafından ortaya atılmıştır. Dişli çarklar, rulmanlar ve kam mekanizmaları ve demiryolu tekerlekleri gibi yuvarlanma ve kayma temasının bulunduğu tüm sistemlerin yüzey mukavemeti ve yorulma ömrü analizleri için başlangıç noktasını oluşturur. Bu gerilme, özellikle dişli çarklarda meydana gelen yüzey yorulması (pitting) hasarının başlangıcını ve öngörülmesini sağladığı için mühendislik analizlerinde hayati öneme sahiptir.

Çalışmada ele alınan dişli çarkların yorulma oluşumunda meydana gelen Hertz basınçları doğrudan ölçülmez, söz konusu gerilmeler genellikle gelişmiş analitik bağlantılar veya dolaylı test yöntemleriyle değerlendirmeler yapılabilir. Ancak Hertz gerilmelerinin tetiklediği yorulma etkisini ve malzeme ömrü üzerindeki tahribatını daha somut verilerle ortaya koyabilmek adına, gelişmiş simülasyon sistemlerinden ve kontrollü test düzeneklerinden faydalanılmaktadır. Deneysel olarak yüksek basınç altında meydana gelen mikroskobik çatlak oluşumu, aşınma belirtileri ve yüzey yorulması (pitting) gibi kritik hasar mekanizmalarını derinlemesine gözlemleyebilmek için, gerçek çalışma şartlarını laboratuvar ortamında simüle edebilen spesifik malzeme çiftleri ve özel numune kombinasyonları tercih edilmektedir. Tekrarlı yüksek temas gerilmelerinin bir

sonucu olan pitting, henüz tam olarak tanımlanamamış bir yüzey yorulma mekanizmasıdır. Bu hasarın temel nedeni, gerilmeleri kritik limitlerin üzerine çıkaran aşırı yüklemelerdir. Mevcut çalışmada, tork etkisi altındaki bir sonlu elemanlar modeli kullanılarak temas gerilmeleri analiz edilmiştir. Analiz kapsamı, dişli çiftinin temas noktasındaki Hertz basınçları hesaplanıp daha sonra Solidworks 2020 programının Simulation Komutu sayesinde bu değerler ile kıyaslama yapılmıştır. Modellemede ise temas halindeki dişli çiftleri aynı malzemelerden seçilmiştir.



Şekil 1: Temas halindeki dişli çifti

Şekil 1 de verildiği üzere temas halindeki dişli çiftlerinin dişleri arasındaki güç aktarımı, çalışan dişlerin temas noktasında gerçekleşir. Temas noktasındaki gerilmeler, Hertz teorisi kullanılarak hesaplanır. Bu teori, temas halindeki eğri cisimlerin gerilmeleri ve şekil değiştirmelerini ifade eder.

Genel itibariyle, diş köklerinde gerilim giderme ve temas noktalarında ısınma sırasında yorulma sonucu oluşan hasarların önlenmesi gerekir. Bu değerlendirmeler, belirli parametreler yardımıyla gerçekleştirilmektedir. İncelenen bu parametrelere örnek olarak temas noktasındaki maksimum basınç  $\rho_{max}$  değeri Bağıntı 1'de verilmiştir.

$$\rho_{max} = \sqrt{\frac{F_n \cdot E}{\pi \cdot L \cdot R}} \quad (1)$$

$F_n$ : Dişlilerin birbirine uyguladıkları Normal Kuvvet

E: İki silindirik malzemenin elastikiyet modülü

R: İndirgenmiş Eğrilik Yarıçapı

L: Silindirlerin eksenel uzunluğu

Tasarımda ve gerilme analizinde kritik öneme sahip olan indirgenmiş eğrilik yarıçapı (R) ve indirgenmiş Young modülü (E) olacak biçimde Bağıntı 2 ve 3'te verilmiştir:

$$\frac{1}{R} = \frac{1}{R_1} + \frac{1}{R_2} \quad (2)$$

$$\frac{1}{E} = \frac{1 - \nu_1^2}{E_1} + \frac{1 - \nu_2^2}{E_2} \quad (3)$$

Bağıntıdaki indeksler sırasıyla cisim 1 ve 2'yi ifade eder.

Verilen 2 ve 3 Nolu bağıntılarda düzenleme yapılırsa;

$$\rho_{max} = \sqrt{\frac{F_n \cdot \left(1 + \frac{r_{b1}}{r_{b2}}\right)}{r_{b1} \cdot \pi \cdot L \cdot \left[\frac{(1 - \nu_1^2)}{E_1} \mp \frac{(1 - \nu_1^2)}{E_2}\right] \sin \emptyset}} \quad (4)$$

4 Nolu  $\rho_{max}$  elde edilir. Burada;

$\nu_1, \nu_2$  = İki silindir malzemesinin Poisson oranı

$\rho_{max}$  değerinin hesabında paydadaki (-) işareti iç dişlide, (+) işareti de dış dişli çark hesabında kullanılmaktadır.

$r_{b1}$  ve  $r_{b2}$ , pinyon ve dişlinin adım yarıçapları ve  $\emptyset$  ise basınç açısıdır.

Hesaplamalarda kullanılan dişli çarklara ait boyutlandırma Tablo 1' de verilmiştir.

**Tablo 1: Hesaplamalarda kullanılan dişli çarkların boyutları**

Sembol	Anlamı	Birimi	Değeri
Z	Diş Sayısı	-	27
D	Adım Daire Çapı	mm	36.26
$\emptyset$	Basınç Açısı	Derece	20
L	Diş Genişliği	mm	7
$R_s$	Şaft Çapı	mm	18
$R_{b1}$	Diş Dibi Çapı	mm	15.31

Hertz basıncının hesabı için 2 adet dişli çark çiftinden alttaki dişli çarkın iç kenarına sabit destek uygulanmıştır. Üsteki dişli çarkın iç kenarına, teğetsel dönüşüne izin veren ancak radyal hareketine engel olan sürtünmesiz destek uygulanmıştır. Üst dişlinin iç kenarına saat yönünde, 25 N-m, 50 N-m ve 75 N-m momenti tahrik torkları olarak uygulanır. Teorik hesaplamaların ardına aynı şartlar altındaki dişli çarkların Solidworks 2020 Programının Simulation komutuyla elde ettiğimiz çalışmalar verilecektir. Dişli takımı, orijinal dişlinin bir kopyasının çevrilmesi ve birbirine geçen iki dişlinin merkez mesafesine eşit bir boşluk bırakılmasıyla oluşturulur.

Burada 25 N-m, 50 N-m ve 75 N-m moment etkisi altında boyutları eşit olan gri dökme demir, 1060 alüminyum alaşımı ve AISI 1035 çelik malzemelerinden 2'şer adet imal edilerek toplamda 6 adet dış dişli çarkı malzemelerindeki zorlanmanın etkisinde diş dibi gerilmesi incelenmektedir.

Dişli malzemelerine ait Elastisite modülleri ve Poisson oranları da Tablo 2'de verilmiştir.

**Tablo 2: Dişli malzemelerinin Elastisite modül ve Poisson oranları**

Malzeme	Elastisite modülü (N/mm <sup>2</sup> )	Poisson oranı
AISI 1035 Çelik	$2.05 \cdot 10^5$	0.29
Gri Dökme Demir	$6.62 \cdot 10^4$	0.27
1060 Alüminyum Alaşımı	$6.9 \cdot 10^4$	0.33

Dişli çark dişlerine etki eden Hertz Basınçlarını hesaplayabilmek için kullanacağımız dişli çarka ait değerler Tablo 1 ve Tablo 2'de verilmiştir. Bağını 4'deki ifadesi kullanılarak Hertz basıncı elde edilir.

25 N-m döndürme torku etkisi altındaki dış dişli ile sabit dış dişli çarkların Gri Dökme Demir için hesabı;

25 N-m tork etkisi altındaki dişli çarkların dönme esnasındaki uyguladığı noktasal kuvvet;

Tork = Kuvvet \* Diş dibi çapı


$$25 \times 10^3 \text{ (N-mm)} = F_n \text{ (N)} * 15,31 \text{ (mm)}$$

$$F_n = 1632,92 \text{ N}$$

$$\rho_{max} = \sqrt{\frac{1632,92 \cdot \left(1 + \frac{15,31}{15,31}\right)}{15,31 \cdot \pi \cdot 7 \cdot \left[\frac{(1-0,27^2)}{6,62 \cdot 10^4} + \frac{(1-0,27^2)}{6,62 \cdot 10^4}\right] \sin 20}}$$

$\rho_{max} = 615,91 \text{ MPa}$  değeri elde edilmiştir

Hesaplamalarda kullanmış olduğumuz dişli çarkların 25 N-m tork etkisinde Solidworks 2020 Programının Simulation Komutu ile Hertz Basıncına ait değerleri Şekil 2 'de verilmiştir.




Şekil 2: 25 N-m tork etkisi altındaki dişli çark (Gri Dökme Demir)

Solidworks 2020 Programı yardımıyla simülasyonu yapılan ve Şekil 2'de görünen dişli çarkların döndüren ve sabit dış dişli çark olan Gri Dökme Demir'in 25 N-m tork etkisi altındaki Hertz Basıncı değeri 639,4 MPa olduğu görülmektedir.

Sabit dişli çark ile döndürme etkisindeki dış dişli çark 1060 Alüminyum Alaşımı için hesaplama yapılırsa;

$$\rho_{max} = \sqrt{\frac{1632,92 \cdot \left(1 + \frac{15,31}{15,31}\right)}{15,31 \cdot \pi \cdot 7 \cdot \left[\frac{(1-0,33^2)}{6,9 \cdot 10^4} + \frac{(1-0,33^2)}{6,9 \cdot 10^4}\right]} \sin 20}$$

$\rho_{max} = 641.38$  MPa değeri elde edilmiştir.




Şekil 3: 25 N-m tork etkisi altındaki dişli çark (1060 Alüminyum Alaşımı)

Şekil 3'te yukarıdaki görünen döndürme etkisindeki ve sabit dış dişli çarklar 1060 Alüminyum Alaşımının 25 N-m tork etkisi altındaki Hertz Basıncı değeri 656,6 MPa olduğu görülmektedir.

Döndüren ve Sabit dişli AISI 1035 Çelik'ten imal edilmiş Dişli sistemindeki hesaplamada;

$$\rho_{max} = \sqrt{\frac{1632,92 \cdot \left(1 + \frac{15,31}{15,31}\right)}{15,31 \cdot \pi \cdot 7 \cdot \left[\frac{(1-0,29^2)}{2,05 \cdot 10^5} + \frac{(1-0,29^2)}{2,05 \cdot 10^5}\right]} \sin 20}$$

$\rho_{max} = 1090.44$  MPa değeri elde edilmiştir.



řekil 4: 25 N-m tork etkisi altındaki diřli çark (AISI 1035 Çelik)

řekil 4'te Döndürme etkisinde ve sabit diřli çarkların her ikisi de AISI 1035 Çelik'in 25 N-m tork etkisi altındaki Hertz Basıncı deđeri 1113 MPa olduđu görölmektedir.

50 N-m tork etkisi altındaki diřli çarkların dönme esnasındaki uyguladıđı noktasal kuvvet;

$$\text{Tork} = \text{Kuvvet} * \text{Diř dibi çapı}$$


$$50 \times 10^3 \text{ (N-mm)} = F_n \text{ (N)} * 15,31 \text{ (mm)}$$

$$F_n = 3265,84 \text{ N}$$

Hesaplamaya 50 N-m döndürme torku etkisi altındaki diř diřli ile sabit diř diřli çarkların Gri Dökme Demir için hesabı yapılırsa;

$$\rho_{max} = \sqrt{\frac{3265,84 \cdot \left(1 + \frac{15,31}{15,31}\right)}{15,31 \cdot \pi \cdot 7 \cdot \left[\frac{(1-0,27^2)}{6,62 \cdot 10^4} + \frac{(1-0,27^2)}{6,62 \cdot 10^4}\right]} \sin 20}$$

$$\rho_{max} = 871,02 \text{ MPa deđeri elde edilmiřtir.}$$




Şekil 5: 50 N-m tork etkisi altındaki dişli çark (Gri Dökme Demir)

Şekil 5'te görünen dişli çarkların döndüren ve sabit dış dişli çark olan Gri Dökme Demir'in 50 N-m tork etkisi altındaki Hertz Basıncı değeri 908.1 MPa olduğu görülmektedir.

Sabit dişli çark ile döndürme etkisindeki dış dişli çark 1060 Alüminyum Alaşımı olup hesaplama yapılırsa;

$$\rho_{max} = \sqrt{\frac{3265,84 \cdot \left(1 + \frac{15,31}{15,31}\right)}{15,31 \cdot \pi \cdot 7 \cdot \left[\frac{(1-0,33^2)}{6,9 \cdot 10^4} + \frac{(1-0,33^2)}{6,9 \cdot 10^4}\right]} \sin 20}$$

$\rho_{max} = 907.04$  MPa değeri elde edilmiştir.




Şekil 6: 50 N-m tork etkisi altındaki dişli çark (1060 Alüminyum Alaşımı)

Şekil 6'da yukarıdaki görünen döndürme etkisindeki ve sabit dişli çarklar 1060 Alüminyum Alaşımının 50 N-m tork etkisi altındaki Hertz Basıncı değeri 928.7 MPa olduğu görülmektedir.

Döndüren ve Sabit dişli AISI 1035 Çelik'ten imal edilmiş dişli çarkın hesabı yapılırsa;

$$\rho_{max} = \sqrt{\frac{3265,84 \cdot \left(1 + \frac{15,31}{15,31}\right)}{15,31 \cdot \pi \cdot 7 \cdot \left[\frac{(1-0,29^2)}{2,05 \cdot 10^5} + \frac{(1-0,29^2)}{2,05 \cdot 10^5}\right] \sin 20}}$$

$\rho_{max} = 1542.11$  MPa değeri elde edilmiştir.



Şekil 7: 50 N-m tork etkisi altındaki dişli çark (AISI 1035 Çelik)

Şekil 7'de Döndürme etkisinde ve sabit dişli çarkların AISI 1035 Çelik'in 50 N-m tork etkisi altındaki Hertz Basıncı değerinin 1574 MPa olduğu görülmektedir.

75 N-m tork etkisi altındaki dişli çarkların dönme esnasındaki uyguladığı noktasal kuvvet;

Tork = Kuvvet \* Diş dibi çapı


$75 \times 10^3$  (N-mm) =  $F_n$  (N) \* 15,31 (mm)

$F_n = 4898.76$  N

Hesaplamaya 50 N-m döndürme torku etkisi altındaki dış dişli ile sabit dış dişli çarkların Gri Dökme Demirden imal edilmiş olarak hesaplanırsa;

$$\rho_{max} = \sqrt{\frac{4898.76 \cdot \left(1 + \frac{15.31}{15.31}\right)}{15.31 \cdot \pi \cdot 7 \cdot \left[\frac{(1-0.27^2)}{6,62 \cdot 10^4} + \frac{(1-0.27^2)}{6,62 \cdot 10^4}\right]} \sin 20}$$

$\rho_{max} = 1066,77$  MPa değeri elde edilmiştir.




Şekil 8: 75 N-m tork etkisi altındaki dişli çark (Gri Dökme Demir)

Şekil 8'de görünen dişli çarkların döndüren ve sabit dış dişli çark olan Gri Dökme Demir'in 75 N-m tork etkisi altındaki Hertz Basıncı değeri 1096 MPa olduğu görülmektedir.

Sabit dişli çark ile döndürme etkisindeki dış dişli çark 1060 Alüminyum Alaşımı olup hesaplama yapılsa;

$$\rho_{max} = \sqrt{\frac{4898.76 \cdot \left(1 + \frac{15.31}{15.31}\right)}{15.31 \cdot \pi \cdot 7 \cdot \left[\frac{(1-0.33^2)}{6,9 \cdot 10^4} + \frac{(1-0.33^2)}{6,9 \cdot 10^4}\right]} \sin 20}$$

$\rho_{max} = 1110.89$  MPa değeri elde edilmiştir.




Şekil 9: 75 N-m tork etkisi altındaki diřli çark (1060 Alüminyum Alařımı)

Şekil 9’da yukarıdaki görünen döndürme etkisindeki ve sabit diřli çarklar 1060 Alüminyum Alařımının 75 N-m tork etkisi altındaki Hertz Basıncı deęeri 1137 MPa olduđu görölmektedir.

Döndüren ve Sabit diřli AISI 1035 Çelik’ten imal edilmiř olup hesabı yapılırsa;

$$\rho_{max} = \frac{4898.76 \cdot \left(1 + \frac{15.31}{15.31}\right)}{\sqrt{15.31 \cdot \pi \cdot 7 \cdot \left[\frac{(1-0.29^2)}{2.05 \cdot 10^5} + \frac{(1-0.29^2)}{2.05 \cdot 10^5}\right]} \sin 20}$$

$\rho_{max} = 1888.69$  MPa deęeri elde edilmiřtir.



Şekil 10: 75 N-m tork etkisi altındaki diřli çark (AISI 1035 Çelik)

Şekil 10’da Döndürme etkisinde ve sabit diřli çarkların her ikisi de AISI 1035 Çelik’in 75 N-m tork etkisi altındaki Hertz Basıncı deęeri 1925 MPa olduđu görölmektedir.

Bu araştırma kapsamında; evolvent profilli diş dişlilerde meydana gelen Hertzian temas gerilmeleri üzerine basınç açısı, Elastisite modülü, Poisson oranı ve iletilen torklar parametrik olarak incelenmiştir. Temas noktasının malzemelerin Elastisite modülleri ve Poisson oranlarının farklılığından sebep her ne kadar aynı tork ile kuvvet uygulanırsa da Hertz basınç değerleri değişiklik göstermektedir. Özellikle diş dibine yakın temas bölgelerinde torkun artması, gerilme yığılmasını en üst seviyeye taşır. Literatürde bu nokta genellikle en büyük zorlanma bölgesi olarak tanımlanır. Diş temasının başladığı veya yükün tam kapasiteyle bindiği en kritik bölge genellikle yuvarlanma (pitch) noktası civarında gerçekleşir. Bu kinematik gerekçelerle, gerçekleştirilen analizlerde yuvarlanma noktasındaki temas koşulları referans alınmıştır.

Araştırmada kullanılan dişli çarklara etki eden Hertz basınç değerlerini Solidworks uygulaması yardımıyla bulunan değerlerle kıyaslayıp aradaki farkı yüzdelik hata şeklinde hesaplayabiliriz. Burada 25 N-m tork etkisindeki Gri Dökme Demir değerleri için;

Hertz bağıntısı ile hesaplanan basınç değeri: 615.91 MPa

Solidworks programı ile bulunan Hertz basıncı değeri: 639.4 MPa

Solidworks ve Hertz değerlerindeki yüzdelik hata payı;

$$\frac{(639,4 - 615,91) * 100}{615,91} = \%3.81 \text{ olarak elde edilmiştir.}$$

25 N-m, 50 N-m ve 75 N-m Tork etkisinde hesaplanan ve Solidworks programından elde edilen basınç değerleri Tablo 3 - 4 ve 5'te verilmiştir.

**Tablo 3: 25 N-m Tork Etkisindeki Basınç Değerleri ve Hata Payı**

Döndüren ve Sabit Dişli Çarklar	Tork : 25 N-m		Yüzdelik Hata (%)
	Hertz Basıncı (MPa)	SOLIDWORKS (MPa)	
Gri Dökme Demir	615.91	639.4	3.81
1060 Alüminyum Alaşımı	641.38	656.6	2.37
AISI 1035 Çelik	1090.44	1113	2.06

Tablo 4: 50 N-m Tork Etkisindeki Basınç Değerleri ve Hata Payı

Döndüren ve Sabit Dişli Çarklar	Tork : 50 N-m		Yüzdellik Hata ( % )
	Hertz Basıncı (MPa)	SOLIDWORKS (MPa)	
Gri Dökme Demir	871.02	908.1	4.26
1060 Alüminyum Alaşımı	907.04	928.7	2.38
AISI 1035 Çelik	1542.11	1574	2.26

Tablo 5: 75 N-m Tork Etkisindeki Basınç Değerleri ve Hata Payı

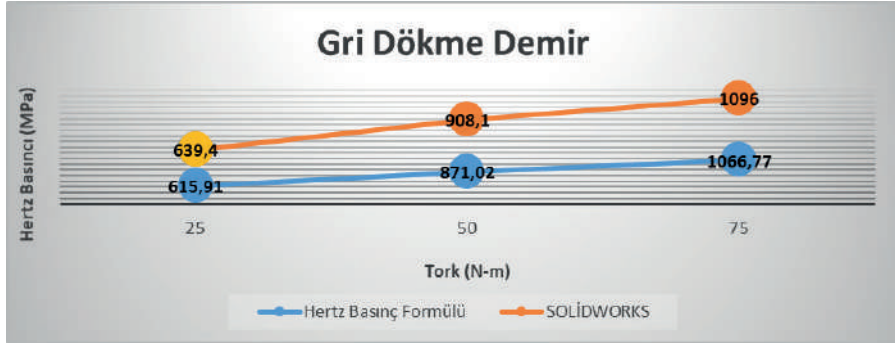
Döndüren ve Sabit Dişli Çarklar	Tork : 75 N-m		Yüzdellik Hata ( % )
	Hertz Basıncı (MPa)	SOLIDWORKS (MPa)	
Gri Dökme Demir	1066.77	1096	2.74
1060 Alüminyum Alaşımı	1110.89	1137	2.35
AISI 1035 Çelik	1888.69	1925	1.92

Dişli çarkların Hertz basınç değerleriyle Solidworks uygulaması arasındaki hata payı % 1,92 ÷ 4,26 arasında değişmektedir.

Tablo 3 - 4 ve 5'te verilen değerler dikkate alınarak, Gri Dökme Demir – Alüminyum ve Çelik için  $\rho_{max}$  basınç değerleriyle – Tork değişim diyagramları; Şekil 11 - 12 ve 13'te verilmiştir.

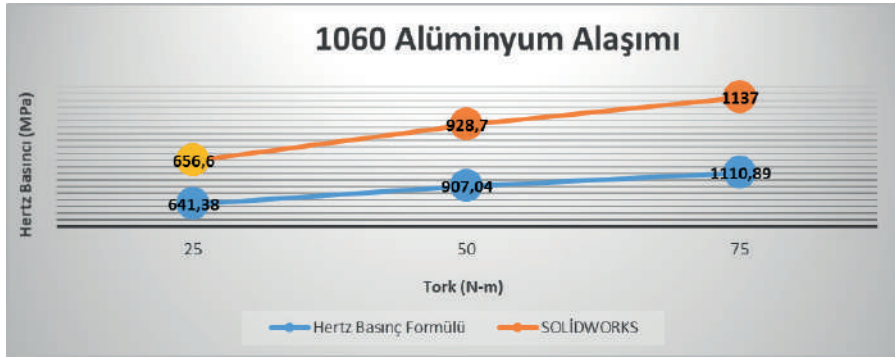
Burada dişli çark hesap ve uygulamalarında döndüren (Pinyon) ve sabit dişlilerin tasarım parametreleri özdeş seçilmiştir.

Yapılan bu örnek çalışmada, gerilme ve deformasyon özellikleri, sistemin tek dişli (noktasal temas) üzerinden yük aktarımı esas alınmıştır.




Şekil 11: Basıncı Değerleri - Tork Değişimi

Şekil 11’de Hertz basınç değerleriyle Solidworks’teki değerler mukayese edilmiş olup Gri Dökme Demirin 3 farklı Torktaki basınç değerleri grafiği verilmiştir.



Şekil 12 Basıncı Değerleri - Tork Değişimi

Şekil 12’de 1060 Alüminyum Alaşımının Hertz basınç değerleri ile Solidworks’teki değerlerin Tork ile değişim grafiği verilmiştir.



Şekil 13 Basıncı Değerleri - Tork Değişimi

Şekil 13'te AISI 1035 Çeliğinin Hertz basınç değerleriyle Solidworks'teki değerlerin mukayesesi yapılmıştır.

Şekil 11, Şekil 12 ve Şekil 13'teki dişli çark parametreleri kullanılarak yapılan değerlendirmelerde; uygulanan tork, yüzey basınçları üzerinde etkili olmaktadır. İletilen momentteki artış temas kuvvetini etkilemekte olup Hertz gerilmelerinde de artışa neden olmaktadır. Kullanılan malzemenin özelliklerine bağlı Elastisite Modülündeki değişim Hertz basıncını etkilemektedir. Basıncı açısının ve Poisson oranının, yüzey temas gerilmelerini (Hertzian stress) minimize edici bir etki oluşturmaktadır.

Dişli çark sisteminin birbiri üzerindeki basınç değerleri incelenmiş olup, 3 farklı malzeme esas alınarak Hertz basıncı ve Solidworks'te elde edilen sonuçların mukayesesi yapılmıştır. Burada diş kalınlığının artışı, temas basınçlarını ve elastik şekil değişimlerini minimize etmektedir. Diş kalınlığının artması dişli çarkın ve mekanik sistemin ağırlığını da etkilemekte olup, temas geometrisindeki küçülme, Hertz basıncı ve deformasyon değerlerinde artışa neden olmaktadır.

Gri Dökme Demir ve 1060 Alüminyum Alaşımından imal edilen dişli sistemlerindeki basınç ve deformasyon değerleri birbirine yakınken AISI 1035 Çeliğinden imal edilen dişli sisteminde daha yüksek değerler görülmektedir. Bunun nedeni çelikte kullanılan malzemelerin Elastisite modül değerinin yüksek olmasıdır. Endüstriyel uygulamalarda farklı metalürjik özelliklere sahip karbon bazlı alaşımlı çelik türlerinden yararlanılmaktadır.

Birim hacim başına düşen yüksek mukavemet performansı ve optimum temin maliyeti çeliği dişli mekanizmalarının vazgeçilmez bir bileşeni haline getirmektedir.

Dişli mekanizmalarında belirlenen geometrik değişkenlerin işletme koşulları, dişli çarkın dayanıklılığı üzerinde etkili olmaktadır. Dişli çarkların temas noktalarında oluşan Hertz basıncından kaynaklı yorulmaların zamanla nasıl ilerlediği ve mikro (kılcal) çatlaklıkların ardından daha büyük hasarlar oluşabilmektedir. Buna karşılık dişli çark seçiminde sistemin gücüne esas alan tasarım ve yüksek kaliteli malzeme seçimi, Hertz basıncının oluşturduğu olumsuzlukları minimize edecektir.

Aynı malzemelerle yapılacak olan Hertz ve Solidworks'te elde edilen gerilme değerlerinin dişli çarkın yorulma dayanımını nasıl etkileyeceği ayrı bir araştırma konusudur.

## Kaynakça

- Akkurt M. (2005). P. D. AKYURT içinde, *Makine Elemanları Cilt 1-2* (s. 489-491). İstanbul: Birsen Yayın Evi.
- Bibel ve ark., G. D. (1994). Effects of rim thickness on spur gear bending stress. *Journal of Mechanical Design*, 1157-1162.
- Chacón ve ark., R. D. ( 2010). Analysis of stress due to contact between spur gears. *Advances in Computational Intelligence, Man-Machine Systems and Cybernetics*, (s. 216-220). Merida-Venezuela.
- Goss, G. L., & Hoepfner, D. W. (1974). Normal Load Effects in Fretting Fatigue of Titanium and Aluminum Alloys. G. & Goss içinde, *Wear* (s. 153-159). California: Rye Canyon Research Laboratory.
- Hassan, A. R. (2009). Contact Stress Analysis of Spur Gear. *World academy of Science, Engineering and*, 611-616.
- Kapelevich, A. L., & Shekhtman, Y. V. (2003). Direct Gear Design for Asymmetric Involute Gears. *Proceedings of the ASME Design Engineering Technical Conferences (DETC)* (s. 3). Baltimore, MD: Gear Technology.
- Zhao, F., & Maietta, D. (1992,). Stress analysis of gear contact using finite element methods. *Journal of Mechanical Design*, 474-479.



# Digital Transformation in Mechanical Engineering: Internet of Things, Machine Learning, and Autonomous Systems

Mustafa Çakır<sup>1</sup>

## Abstract

The Internet of Things (IoT) represents a transformative paradigm in modern mechanical engineering and industrial automation, enabling physical machinery to evolve into intelligent cyber-physical systems through continuous data exchange. The digitalization of traditional mechanical systems enables a transformation that, according to documented case studies, can reduce equipment downtime by 30-50% and achieve maintenance cost savings of up to 40%. This book chapter comprehensively addresses the conceptual framework and multi-layered architectural principles of the IoT ecosystem within the mechanical engineering domain, spanning device, edge, and cloud computing tiers. The primary focus of this study is the integration of Machine Learning (ML) algorithms with resource-constrained IoT devices and the extraction of actionable features from raw sensor data. In this context, the integration of signal processing techniques, such as Fast Fourier Transform (FFT) and wavelet analysis for vibration and acoustic signals, into ML pipelines is presented through novel architectural frameworks. By analyzing the applications of diverse ML paradigms on multi-modal data, the chapter thoroughly examines Edge AI, TinyML, and hierarchical sensor fusion architectures that overcome the limitations inherent to conventional cloud-centric approaches. Practical engineering solutions are exemplified through autonomous condition monitoring mechanisms deployed in remote scientific facilities with extreme environmental conditions, such as the Eastern Anatolia Observatory (DAG). Ultimately, by also discussing data privacy, federated learning, and 5G/6G infrastructures, this work provides a structured architectural guide demonstrating how IoT and ML integration transforms mechanical systems into autonomous decision-support systems.

<sup>1</sup> Asst. Prof. Dr., Iskenderun Technical University, mustafa.cakir@iste.edu.tr, 0000-0002-1794-9242

## 1. Introduction

The rapid digitalization of industrial infrastructure is fundamentally transforming the nature of mechanical systems. Traditionally, machines such as turbines, pumps, compressors, and manufacturing equipment were designed as isolated physical assets whose performance was assessed through periodic inspection and manual diagnostics (Lee et al., 2015). In modern engineering environments, however, these systems are increasingly embedded with sensing, communication, and computational capabilities that allow them to continuously monitor their operational states and interact with digital infrastructures. As a result, mechanical assets are evolving into intelligent cyber-physical systems capable of data-driven monitoring, predictive analysis, and autonomous decision support (Lin et al., 2017; Kong et al., 2022).

This transformation is largely driven by the convergence of the Internet of Things (IoT) and machine learning (ML) (Mohammadi et al., 2017). IoT technologies enable large-scale deployment of sensors, embedded processors, and networked devices that continuously collect operational data from mechanical components, while ML algorithms provide the analytical capability to extract patterns, detect anomalies, and generate predictive insights from these heterogeneous data streams (Aceto et al., 2021; Dutta & Kant, 2023). Together, these technologies enable the transition from traditional reactive maintenance strategies toward predictive and prescriptive maintenance paradigms, significantly improving system reliability, operational efficiency, and safety (Cakir et al., 2021).

Within the broader context of Industry 4.0, the integration of IoT and ML has become a key enabler of intelligent industrial systems. Applications range from vibration-based fault diagnosis in rotating machinery to structural health monitoring of infrastructure and autonomous control of robotic platforms (Waheed et al., 2020; Abdel-Basset et al., 2020).

Despite the rapid development of IoT technologies and ML methods, these domains are often studied independently. IoT research primarily focuses on networking architectures and connectivity solutions, whereas ML research emphasizes algorithmic performance and data analytics. In mechanical engineering environments, however, intelligent monitoring systems require the integration of sensing infrastructures, communication networks, and data-driven analytics within a unified framework.

This chapter addresses this need by examining the integration of IoT and ML from the perspective of mechanical engineering systems. Rather than treating IoT solely as a networking paradigm, the chapter focuses on

how distributed sensing infrastructures and intelligent data analytics reshape the monitoring, control, and lifecycle management of mechanical assets. Particular emphasis is placed on vibration-based condition monitoring, edge ML for real-time diagnostics, federated learning (FL) for distributed industrial environments, and the deployment of AI-enabled cyber-physical systems in smart manufacturing and energy infrastructures.

Although extensive research has been conducted on IoT architectures and ML algorithms individually, their integrated application within mechanical engineering systems remains comparatively underexplored in the literature. Many studies examine IoT primarily from a networking perspective or focus on ML purely from an algorithmic standpoint. However, modern mechanical infrastructures require a holistic perspective that simultaneously considers sensing technologies, mechanical dynamics, communication architectures, and intelligent data analytics. This chapter addresses this gap by presenting a unified framework that integrates IoT sensing infrastructures with ML pipelines in mechanical engineering environments. By synthesizing concepts from cyber-physical systems, edge computing, TinyML, and predictive maintenance, the chapter provides both a conceptual and application-oriented perspective on how intelligent monitoring architectures can transform traditional mechanical assets into autonomous decision-support systems.

The remainder of this chapter is organized as follows. Section 2 introduces the architectural foundations of IoT-enabled mechanical systems. Section 3 discusses ML techniques and data processing methods for IoT data. Section 4 reviews representative academic applications, while Section 5 presents industrial implementations. Section 6 highlights key challenges and emerging research directions, and Section 7 concludes the chapter.

## **2. Theoretical Framework and Fundamental Concepts**

The integration of IoT technologies into mechanical engineering systems has led to the emergence of intelligent cyber-physical infrastructures capable of continuously sensing, analyzing, and responding to operational conditions. In contrast to traditional mechanical monitoring approaches based on periodic inspection, modern industrial systems increasingly rely on distributed sensing networks, embedded computing platforms, and ML algorithms that operate across device, edge, and cloud layers. This architecture enables mechanical assets to generate high-resolution operational data streams and transform them into actionable intelligence for diagnostics, predictive maintenance, and autonomous decision support.

From a systems perspective, IoT-enabled mechanical infrastructures can be described as layered architectures integrating sensing devices, communication networks, distributed computing resources, and data analytics platforms. Sensors capture physical signals such as vibration, temperature, and strain from mechanical assets, while communication layers transfer these data streams to processing nodes. Edge and cloud computing infrastructures subsequently perform data aggregation, preprocessing, and ML inference to support monitoring and decision-making processes.

This layered architecture forms the technological foundation of modern intelligent mechanical systems and underpins a wide range of industrial applications, including predictive maintenance of rotating machinery, structural health monitoring of infrastructure, and real-time monitoring of energy systems. Understanding the interaction between these layers is therefore essential for designing scalable and reliable AIoT solutions for mechanical engineering environments.

### **2.1. Mechanical Sensing and Data Acquisition**

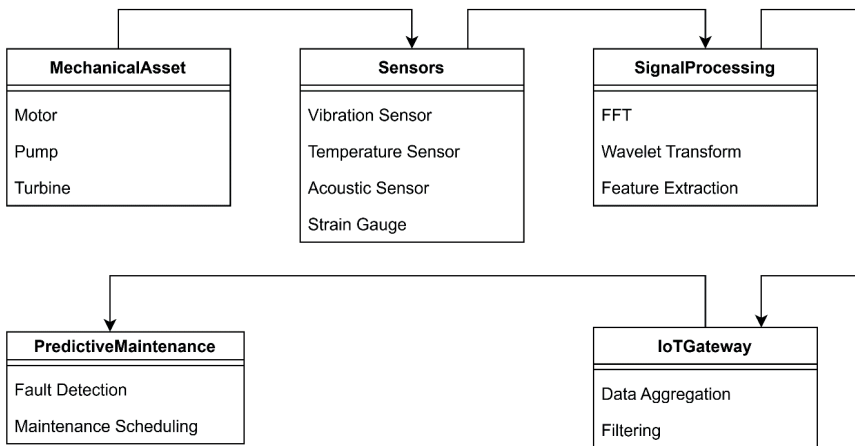
Sensing technologies constitute the physical interface between mechanical systems and digital infrastructures. In industrial environments, a wide range of sensors are deployed to capture the operational behavior of machines and mechanical structures. Among these, vibration sensors are particularly important for monitoring rotating machinery such as motors, pumps, turbines, and gearboxes, where changes in vibration signatures often indicate early-stage mechanical faults. Temperature sensors provide critical information about friction-induced heating, lubrication conditions, and thermal stress in mechanical components, while strain gauges are widely used to measure load distribution and structural deformation in bridges, cranes, and other load-bearing systems.

The effectiveness of data-driven diagnostics depends strongly on sensor placement, sampling frequency, and signal quality. For instance, vibration-based bearing fault detection typically requires sampling frequencies in the kilohertz range to capture high-frequency defect signatures, whereas structural health monitoring of civil infrastructure often operates at significantly lower frequencies. Consequently, sensor configuration must be carefully designed to ensure that the acquired data accurately reflects the dynamic behavior of the monitored mechanical system.

Accelerometers are widely used to capture vibration signatures in rotating machinery, enabling the detection of faults such as bearing wear, imbalance, or shaft misalignment. Strain gauges measure mechanical stress and load

distribution in structural components including bridges and industrial frames, while thermocouples monitor temperature variations related to friction, lubrication conditions, and cooling efficiency. The usefulness of these measurements depends strongly on appropriate sampling configurations and signal quality (Waheed et al., 2020).

Mechanical monitoring systems typically generate high-frequency time-series signals whose statistical and spectral characteristics reflect the physical state of machinery. Common signal modalities include vibration spectra, acoustic emissions, thermal profiles, strain measurements, and electrical current signatures. These signals are often analyzed in both time and frequency domains using techniques such as Fourier transforms, wavelet analysis, and statistical feature extraction. The integration of such signal processing techniques with IoT-based sensing infrastructures enables continuous condition monitoring and early fault detection in mechanical assets. The interaction between mechanical assets, sensing technologies, and signal processing stages in IoT-based monitoring systems is illustrated in Figure 1.



*Figure 1. Multi-modal sensing architecture for IoT-based mechanical condition monitoring systems. Mechanical assets generate operational signals captured by heterogeneous sensors, which are processed through signal analysis techniques and transmitted via IoT gateways for predictive maintenance analytics.*

## 2.2. Layered IoT Architecture

IoT architectures are conventionally modeled in three or five layers. The three-layer model comprises the Perception Layer (physical data acquisition), the Network Layer (data transmission via IPv6, 6LoWPAN, RPL, and application

protocols), and the Application Layer (user-facing services and automation). The five-layer model adds a Processing Layer for data preprocessing, feature extraction, and ML inference, and a Business Layer for decision support, policy enforcement, and operational integration (Lin et al., 2017).

Connectivity technologies provide the communication fabric. Short-range protocols (BLE, Zigbee, Wi-Fi HaLow/802.11ah) serve in-building and personal area network scenarios, while medium- and long-range technologies (LoRaWAN, Sigfox, NB-IoT, LTE-M) address wide-area deployments with stringent energy and coverage requirements. High-bandwidth 5G service categories (URLLC, mMTC, eMBB) are increasingly used for latency-critical and high-density IoT applications. Each technology presents distinct trade-offs among energy consumption, range, data rate, and cost that must be evaluated against application requirements (Jouhari et al., 2023).

The choice of architectural model has direct implications for system design. In resource-constrained deployments where processing must be distributed across the device-edge-cloud continuum, the five-layer model provides a more accurate representation of data flow and processing responsibilities. Modern IoT reference architectures increasingly adopt a device–edge–cloud continuum perspective, where the boundaries between layers are fluid and workload placement is dynamically optimized based on latency, energy, and privacy constraints (Kong et al., 2022).

Architectural decisions also influence security posture. Each layer introduces distinct attack surfaces: the perception layer is vulnerable to physical tampering and sensor spoofing; the network layer faces eavesdropping, routing manipulation, and denial-of-service attacks; and the application layer is exposed to injection, authentication bypass, and data exfiltration risks. Effective security architecture must therefore adopt a defense-in-depth strategy that addresses threats at every layer (Mao et al., 2023).

## **2.3. Communication Protocols and Standards**

### **2.3.1. Network Layer Protocols**

At the network layer, IPv6/6LoWPAN provides header compression and fragmentation for constrained IEEE 802.15.4 environments (RFC 6282), while RPL (RFC 6550) serves as the standard routing backbone for low-power and lossy networks. These protocols collectively enable IPv6 connectivity for resource-constrained IoT devices, bridging the gap between traditional Internet infrastructure and sensor networks. Recent research has focused on

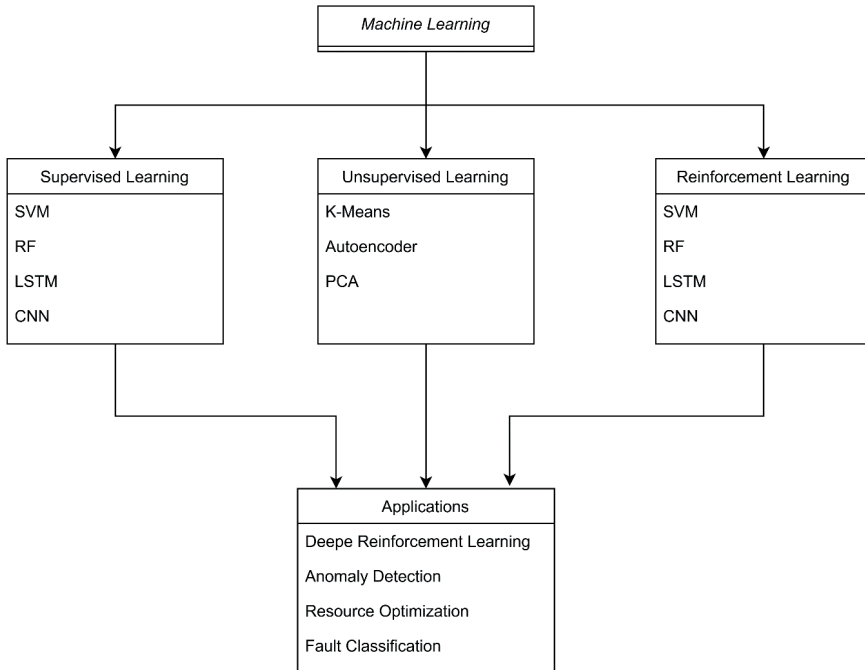
RPL optimizations for dense deployments, including enhanced objective functions, mobility support, and security extensions (Darabkh et al., 2022).

LPWAN technologies complement these standards for wide-area deployments. LoRa/LoRaWAN provides kilometer-scale coverage at the expense of data rate, making it suitable for battery-operated applications such as utility metering, asset tracking, and agricultural monitoring. Comprehensive studies on LoRaWAN scalability have demonstrated that collision management, multi-channel gateways, and data-driven optimization are critical determinants of network performance in dense deployments (Jouhari et al., 2023).

The emergence of 5G NR and its evolution toward 6G introduces new capabilities including network slicing, which enables the creation of virtual network instances tailored to specific IoT use cases. Ultra-reliable low-latency communication (URLLC) slices support mission-critical applications such as industrial automation and remote surgery, while massive machine-type communication (mMTC) slices accommodate the connectivity requirements of millions of low-power devices per square kilometer (Mao et al., 2023).

### **2.3.2. Application Layer Protocols**

CoAP (RFC 7252) and MQTT (OASIS v5.0) are among the most widely used application-layer protocols in IoT systems. CoAP provides a lightweight RESTful communication model optimized for constrained devices, typically operating over UDP, while MQTT implements a publish-subscribe messaging architecture that supports efficient data exchange in bandwidth-limited environments. The selection of an appropriate protocol depends on application-specific requirements including latency sensitivity, data volume, network topology, and energy constraints (Seoane et al., 2021; Silva et al., 2021). ML approaches applied to IoT environments can be broadly categorized into supervised, unsupervised, and reinforcement learning paradigms, as illustrated in Figure 2.



*Figure 2. Major ML paradigms and their application domains in IoT-enabled mechanical systems. Different ML paradigms enable diverse analytical capabilities, including fault classification, anomaly detection, and system optimization.*

## 2.4. Edge, Fog, and Cloud Computing Integration

Modern IoT solutions operate along a device–edge–cloud continuum in which data undergoes progressive refinement: edge nodes perform filtering, summarization, and anomaly flagging; near-real-time inference occurs at fog-layer gateways; deep analytics and model training are executed in the cloud; and updated models are cyclically deployed back to edge devices. This architecture addresses the bandwidth and latency bottlenecks inherent in cloud-centric approaches while enabling the computational depth required for complex ML workloads (Kong et al., 2022).

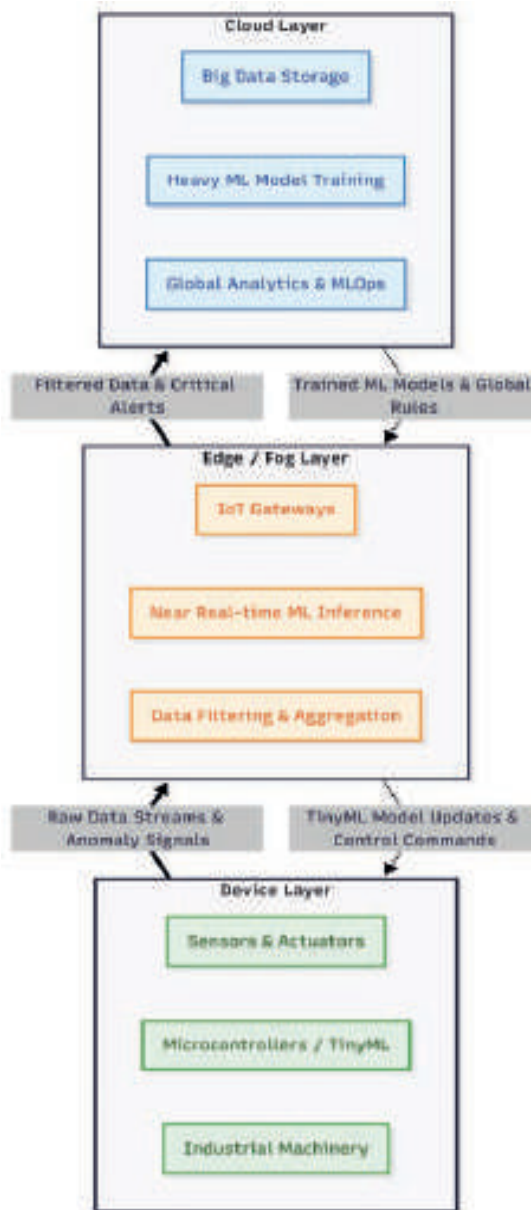
Data processing layers, spanning edge, fog, and cloud tiers, transform raw sensor data into information and knowledge. Edge computing processes data near its source, minimizing latency and network load; fog computing provides intermediate aggregation and analytics at gateways or regional servers; cloud computing offers elastic storage and compute resources for large-scale batch analytics and model training. Application services, industrial monitoring dashboards, industrial automation platforms, predictive maintenance systems,

digital twin platforms, deliver value to end users by converting processed data into actionable insights through RESTful APIs, MQTT, CoAP, or proprietary interfaces (Kong et al., 2022; Shi et al., 2016).

The integration of ML with edge computing has given rise to the concept of Edge AI (Zhou et al., 2019), wherein inference, and increasingly, incremental training, occurs on devices proximate to data sources. This paradigm is particularly relevant for IoT applications where latency, privacy, and connectivity constraints preclude cloud-only processing. Key research challenges include heterogeneous resource management, workload placement optimization, and the co-design of communication and computation to balance the energy-latency-accuracy trade-off (Dutta & Kant, 2023).

Fog computing occupies a strategic intermediate position in this hierarchy, providing localized data aggregation, protocol translation, and preliminary analytics at network edge gateways. In smart manufacturing environments, fog nodes can perform real-time quality inspection using computer vision models, forwarding only summary statistics and anomaly alerts to cloud platforms for trend analysis and model retraining. This hierarchical architecture reduces bandwidth consumption by orders of magnitude while maintaining sub-millisecond response times for critical control loops (Cakir et al., 2021).

The hierarchical interplay between data processing and ML inference across the IoT ecosystem is visually summarized in Figure 3. This multi-tier architecture illustrates the device-edge-cloud continuum, where raw sensor streams and anomaly signals are initially processed at the device layer. Filtered data and critical alerts are subsequently escalated to the edge and fog layers for near real-time inference, while computationally intensive tasks, such as heavy ML model training and global analytics, are reserved for the cloud layer. Conversely, the architecture demonstrates a bidirectional flow, wherein globally trained ML models and control rules are cyclically pushed down to the edge and device layers to continuously update local inference capabilities. This distributed approach effectively balances latency, bandwidth, and computational constraints in modern IoT deployments.



*Figure 3. Device-Edge-Cloud computing continuum and hierarchical ML architecture. (1) Device Layer: Sensors (accelerometers, temperature, acoustic) on physical machinery (motors, pumps, turbines) collect raw data. Microcontrollers running TinyML at this layer can perform instant basic inferences such as anomaly detection. (2) Edge/Fog Layer: Industrial gateways or on-premise servers aggregate, filter, and summarize data from multiple devices, executing more complex ML models (e.g., convolutional neural networks) for real-time quality control or predictive maintenance alerts. (3) Cloud Layer: Centralized servers provide long-term storage for data from all sites, train deep learning models, simulate digital twins, and integrate with enterprise resource planning (ERP) systems. Dashed arrows represent the bidirectional flow of information, where updated models and control policies trained in the cloud are periodically distributed back to the edge and device layers.*

## 2.5. Security and Privacy Foundations

IoT security is a systemic design problem arising from the resource constraints of embedded devices and their physically distributed deployment. Device-level security encompasses secure boot, hardware-rooted trust (TPM, HSM), and secure over-the-air (OTA) firmware updates. Network-level security involves encryption (TLS/DTLS), secure routing, and intrusion detection. Data-level security addresses end-to-end encryption, anonymization, data minimization, and differential privacy techniques (Mao et al., 2023).

The expansion of attack surfaces accompanying the growth of edge AI and open network architectures (e.g., O-RAN) has intensified research into privacy-preserving learning techniques, quantum-resistant cryptographic primitives, and lifecycle security management. Security in the IoT-ML context extends beyond cryptography to encompass model security concerns including adversarial attacks, model poisoning, and model extraction, which require dedicated defensive mechanisms at both training and inference stages (Waheed et al., 2020).

Regulatory frameworks significantly shape IoT security and privacy practices. The EU GDPR and Turkey's KVKK mandate privacy-by-design and minimum-privilege principles that affect every stage of the IoT data lifecycle, from collection and processing to storage and deletion. Compliance requires not only technical controls but also organizational processes for data impact assessments, consent management, breach notification, and cross-border data transfer governance (Tanczer et al., 2018).

## 2.6. Interoperability and Standardization

Interoperability is essential for ensuring that heterogeneous IoT devices, communication technologies, and software platforms can operate together within a unified system. Industrial IoT environments often integrate components from multiple vendors, making standardized communication protocols and data models critical for reliable system integration. International standardization efforts aim to provide common frameworks that facilitate seamless device connectivity, data exchange, and service interoperability across diverse deployment scenarios (Lin et al., 2017).

In industrial contexts, OPC UA provides a platform-independent, service-oriented communication framework with built-in security and information modeling capabilities. The Matter standard (formerly CHIP) addresses smart home interoperability over IP-based networks. Open-source initiatives such as Eclipse IoT and the Linux Foundation's EdgeX Foundry further contribute

to the standardization ecosystem by providing reference implementations that lower barriers to interoperable deployments (Jouhari et al., 2023).

Semantic interoperability, the ability of systems to not only exchange data but to interpret its meaning consistently, remains a significant challenge. Common data models such as SensorML, JSON-LD, and the W3C Web of Things (WoT) Thing Description vocabulary aim to provide machine-readable semantic annotations that facilitate automated discovery, composition, and integration of IoT services. Achieving semantic interoperability at scale requires continued investment in ontology development, metadata standards, and automated mapping tools (Waheed et al., 2020).

### **3. IoT and ML Integration**

#### **3.1. Foundations of IoT-ML Synergy**

The integration of IoT and ML is grounded in a reciprocal value proposition: IoT provides ML algorithms with rich, diverse, and continuously generated data streams, while ML enables IoT systems to extract patterns, predictions, classifications, and anomaly signals that would be unattainable through rule-based approaches alone. This synergy manifests at three architectural levels: cloud-based centralized learning, edge-based local inference, and distributed/federated learning across device populations (Mohammadi et al., 2017).

The exponential growth of IoT-generated data, estimated to exceed 73 zettabytes annually by 2025 across all data sources, with IoT representing a substantial and growing share (Reinsel et al., 2018), has rendered traditional statistical and threshold-based analysis methods inadequate. ML algorithms, by contrast, can adaptively learn complex, non-linear relationships from high-dimensional sensor data without explicit programming. This capability is particularly valuable in IoT contexts where environmental conditions, device populations, and usage patterns are continuously evolving, requiring models that can generalize across variable operating conditions (Aceto et al., 2021).

The practical realization of IoT-ML integration, however, entails significant engineering challenges. IoT data is characteristically noisy, incomplete, temporally misaligned, and heterogeneous in format and sampling rate. The resource constraints of IoT devices, limited memory, processing power, and energy budgets, further constrain the complexity of deployable models. Addressing these challenges requires co-design of data pipelines, model architectures, and deployment infrastructure, as demonstrated in experimental IIoT condition monitoring systems that integrate multi-sensor data acquisition, cloud-based ML training, and edge-based inference for predictive maintenance (Cakir et al., 2021).

## 3.2. ML Techniques for IoT Environments

### 3.2.1. Supervised Learning

Classification and regression tasks constitute the most prevalent ML applications in IoT. Traditional algorithms such as DT, RF, SVM, k-NN, and gradient boosting methods have been extensively applied to sensor data for tasks including device fault prediction, energy consumption classification, and quality control. The work of Cakir et al. (2021) systematically compared the performance of SVM, k-NN, RF, DT, and LDA on IIoT-based condition monitoring data, providing empirical evidence for algorithm selection in industrial predictive maintenance scenarios.

Deep learning (DL) models, including convolutional neural networks (CNNs), recurrent neural networks (RNNs), long short-term memory networks (LSTMs), and Transformer architectures, have demonstrated superior performance on complex IoT tasks such as time-series forecasting, image-based quality inspection, natural language processing of IoT logs, and multi-modal sensor fusion. Recent advances in vision transformers and foundation models have further expanded the applicability of DL to IoT contexts, enabling few-shot learning and domain adaptation with minimal labeled data (Mohammadi et al., 2017).

### 3.2.2. Unsupervised Learning

Clustering algorithms, including k-means, DBSCAN, and hierarchical clustering, are widely applied in IoT networks for device profiling, traffic pattern analysis, and anomaly detection. Autoencoders have assumed a particularly important role in IIoT environments, where they learn normal operational profiles from unlabeled sensor data and flag deviations as potential anomalies. This approach is especially valuable given the scarcity of labeled fault data in many industrial settings (Aceto et al., 2021).

Dimensionality reduction techniques such as PCA, t-SNE, and UMAP facilitate the visualization and analysis of high-dimensional IoT data, enabling domain experts to identify clusters, trends, and outliers that may not be apparent in raw data. Self-organizing maps (SOMs) and variational autoencoders (VAEs) provide additional unsupervised learning capabilities for IoT data analysis, particularly in applications where the underlying data distribution is complex and multimodal (Mohammadi et al., 2017).

Generative models, including generative adversarial networks (GANs) and diffusion models, have recently emerged as tools for IoT data augmentation, synthetic data generation, and privacy-preserving data sharing. This approach

specifically addresses the class imbalance problem frequently encountered in industrial applications. For example, in bearing fault data collection, normal operating data is abundant, while data for rare fault types such as early-stage bearing wear or cage damage may be extremely limited. GANs can learn from the few available fault instances to generate realistic synthetic vibration signals for these rare classes. Training sets augmented with such synthetic data significantly improve classifier performance in detecting infrequent fault types (Dutta & Kant, 2023).

### **3.2.3. Reinforcement Learning**

Reinforcement learning (RL) addresses sequential decision-making problems that arise naturally in IoT contexts, including dynamic resource management, energy optimization, autonomous navigation, and smart grid control. Deep reinforcement learning (DRL) extends RL to high-dimensional state spaces, enabling IoT systems to learn complex control policies through interaction with their environments. Applications include adaptive traffic signal control, autonomous drone path planning, and energy-efficient scheduling of IoT device transmissions (Waheed et al., 2020).

Multi-agent reinforcement learning (MARL) is particularly relevant for IoT ecosystems where multiple autonomous agents must coordinate their actions. In smart manufacturing, MARL-based approaches have been applied to collaborative robot coordination, distributed production scheduling, and cooperative inventory management. The challenge of non-stationarity, arising from the simultaneous learning and adaptation of multiple agents, remains an active research area with significant implications for IoT system stability and convergence (Aceto et al., 2021).

The integration of RL with digital twin technology represents an emerging frontier in IoT-ML research. Digital twins provide high-fidelity simulation environments where RL agents can be trained safely and efficiently before deployment on physical systems. This approach mitigates the risk of destructive exploration in safety-critical IoT applications such as industrial process control, autonomous vehicle navigation, and medical device management (Fuller et al., 2020).

As summarized in Table 1, the selection of an appropriate ML paradigm in IoT environments is fundamentally dictated by data availability, computational constraints, and the specific operational objective. Supervised learning algorithms, ranging from traditional classifiers to advanced DL architectures, excel in predictive forecasting and classification tasks where historical, labeled data is abundant. Conversely, unsupervised learning techniques, particularly

autoencoders and clustering methods, are indispensable in industrial settings where labeled failure data is typically scarce. These methods enable real-time anomaly detection by learning baseline operational profiles and flagging novel deviations. Finally, reinforcement learning provides a robust framework for sequential decision-making, allowing autonomous IoT systems to dynamically optimize resource allocation and control policies through continuous interaction with their environments. Together, these paradigms offer a comprehensive algorithmic toolkit for transforming raw, heterogeneous IoT data streams into actionable intelligence.

*Table 1. Overview of ML Paradigms and Their Applications in IoT Environments*

ML Category	Prominent Algorithms	Key IoT Application Areas	Characteristics & IoT Context
Supervised Learning	SVM, k-NN, RF, DT, DL (CNNs, LSTMs, Transformers)	Predictive maintenance (e.g., bearing fault classification), time-series forecasting, visual quality inspection, automated disease diagnosis.	Highly accurate for predictive tasks; DL models excel at multi-modal sensor fusion but require significant edge computing resources or model compression.
Unsupervised Learning	K-means, DBSCAN, Autoencoders, PCA, t-SNE, Generative Models (GANs, Diffusion)	Real-time anomaly detection, device profiling, network traffic analysis, synthetic sensor data generation, dimensionality reduction.	Crucial for industrial settings where labeled failure data is scarce; autoencoders efficiently learn “normal” operational profiles to flag novel, unseen degradation patterns.
Reinforcement Learning	Deep Reinforcement Learning (DRL), Multi-Agent Reinforcement Learning (MARL)	Dynamic resource management, energy optimization, adaptive traffic signal control, autonomous drone navigation, collaborative robot scheduling.	Excels in sequential decision-making; learns optimal control policies through environment interaction. Increasingly integrated with digital twins for safe, simulated training prior to physical deployment.

### 3.3. Edge ML and TinyML

Conventional cloud-centric ML approaches are not always viable in IoT scenarios due to latency, bandwidth, and privacy constraints. TinyML is an emerging paradigm that targets ML inference on microcontrollers (MCUs) and other resource-constrained embedded devices (Banbury et al., 2020). Model

compression techniques, including pruning, quantization (INT8, binary), and knowledge distillation, enable the deployment of neural network models on devices with as little as tens to hundreds of KB of memory (Sanchez-Iborra & Skarmeta, 2020).

Frameworks such as TensorFlow Lite Micro, Edge Impulse, ONNX Runtime, and Apache TVM have made TinyML development increasingly accessible. Practical applications include keyword spotting, gesture recognition, environmental sound classification, and simple anomaly detection, all operating at millisecond-level latency and microwatt-level energy consumption. The capability to perform on-device inference eliminates the need for continuous network connectivity and cloud processing, making TinyML particularly suitable for remote and intermittently connected IoT deployments (Mohammadi et al., 2017).

Neural architecture search (NAS) techniques have been adapted to automatically discover model architectures that optimize the accuracy-latency-memory trade-off for specific target hardware. Hardware-aware NAS, in particular, takes into account the specific computational characteristics and constraints of target MCUs, FPGAs, or edge AI accelerators, producing custom-tailored models that outperform manually designed architectures. The combination of NAS with model compression techniques represents a promising direction for maximizing ML capability within the severe resource constraints of IoT devices (Abdel-Basset et al., 2020).

### **3.4. FL and Distributed ML**

FL is a distributed learning paradigm in which IoT devices perform local model training and share only model parameter updates, rather than raw data, with a central aggregation server (Kairouz & McMahan, 2021). This approach addresses privacy and data sovereignty requirements while enabling collective learning from distributed data sources. The FedAvg algorithm, proposed by McMahan et al., serves as the foundational FL method, with subsequent extensions including FedProx, FedMA, and personalized FL variants addressing challenges of data heterogeneity and communication efficiency (Waheed et al., 2020).

The application of FL to IoT environments introduces specific challenges arising from the heterogeneity of participating devices, non-IID (non-independently and identically distributed) data distributions, variable communication bandwidth, and the potential for adversarial participants. To concretize the non-IID problem in a mechanical engineering context: consider ten identical pumps in a petrochemical plant. Each pump will produce

different vibration profiles depending on factors such as the pressure of its connected line, the viscosity of the fluid being processed, operating hours, and ambient temperature. One pump may handle clean water at low pressure, while another pumps a viscous chemical at high pressure. Consequently, the local data distributions (vibration frequencies, amplitudes) of each pump differ (non-IID). When the classical FedAvg algorithm simply averages model updates from these diverse distributions, the resulting global model may perform suboptimally for any individual pump. To overcome this, recent personalized FL approaches aim to create models that are close to the global model but adapted to each device's local data (Waheed et al., 2020).

Split learning represents an alternative distributed ML paradigm in which different layers of a neural network are executed on different devices, with only intermediate activations exchanged between them. This approach can reduce the computational burden on IoT devices more effectively than FL for deep network architectures, while providing inherent privacy protection through the separation of raw data from model parameters. Hybrid approaches that combine elements of federated and split learning are actively being explored to address the diverse requirements of IoT deployment scenarios (Dutta & Kant, 2023).

### 3.5. Transfer Learning and Pre-trained Models

Transfer learning enables the application of knowledge acquired in one domain (source) to a different but related domain (target), mitigating the data scarcity that frequently characterizes IoT deployments (Tan et al., 2018). In practice, large models pre-trained on extensive datasets (e.g., ImageNet for vision, large text corpora for NLP) are fine-tuned on task-specific IoT data, often achieving high performance with limited labeled examples. This approach has proven particularly effective for industrial visual quality inspection, where ImageNet-pretrained CNN models adapted to manufacturing defect detection achieve competitive accuracy with as few as tens of labeled images per defect category (Mohammadi et al., 2017).

Domain adaptation techniques extend transfer learning to scenarios where the statistical distributions of source and target domains differ significantly. Unsupervised domain adaptation methods, including domain-adversarial training, maximum mean discrepancy minimization, and optimal transport-based alignment, have been successfully applied to IoT contexts such as cross-machine fault diagnosis, cross-environment activity recognition, and cross-patient health monitoring (Aceto et al., 2021).

The recent advent of foundation models and large language models (LLMs) has introduced new possibilities for transfer learning in IoT. Pre-trained LLMs can serve as general-purpose reasoning engines that interpret natural language queries about IoT system status, generate diagnostic reports from sensor data, and provide conversational interfaces for non-expert users. Multimodal foundation models that process both sensor signals and textual descriptions represent a particularly promising frontier for integrated IoT-AI systems (Zhang & Tao, 2020).

### **3.6. Data Preprocessing and Feature Engineering**

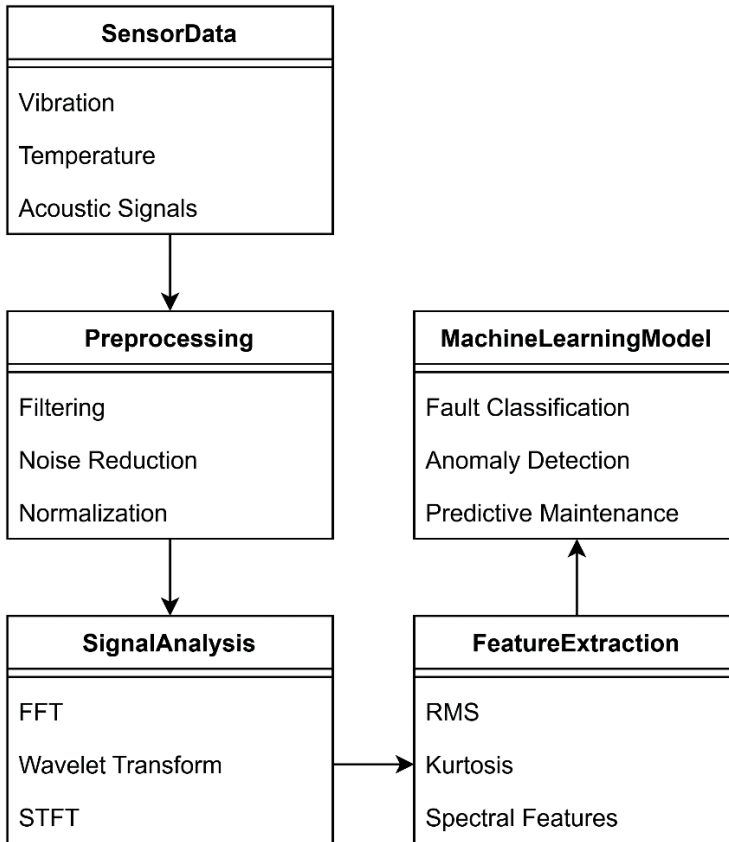
The quality and representativeness of input data fundamentally determine ML model performance in IoT applications. Preprocessing stages, including missing data imputation, noise filtering, normalization, temporal alignment, and outlier removal, are critical for transforming raw sensor streams into model-ready features. Windowing techniques (sliding, tumbling, hopping) are commonly applied to time-series IoT data to create fixed-length feature vectors from continuous data streams (Aceto et al., 2021).

Feature engineering for IoT data encompasses both time-domain features (statistical moments, zero-crossing rates, peak-to-peak values) and frequency-domain features (spectral components, cepstral coefficients, wavelet decompositions). In the IIoT context, Cakir et al. (2021) demonstrated that careful feature extraction from vibration, temperature, acoustic emission, and current sensor data is essential for achieving high classification accuracy in bearing fault diagnosis, highlighting the importance of domain-specific feature engineering in IIoT applications.

Automated feature engineering and AutoML techniques are increasingly being applied to IoT datasets to reduce the need for manual feature design. Tools such as auto-sklearn, H2O, and Google AutoML can automatically search over feature transformations, algorithm selections, and hyperparameter configurations to identify optimal ML pipelines for specific IoT tasks. However, the computational cost of exhaustive AutoML searches may be prohibitive for resource-constrained IoT environments, necessitating efficient search strategies and hardware-aware optimization (Dutta & Kant, 2023).

In mechanical IoT applications, signal processing techniques play a critical role in transforming raw sensor data into informative features. Vibration signals from rotating machinery are commonly analyzed using fast Fourier transform (FFT) to identify characteristic fault frequencies associated with bearing defects, gear mesh irregularities, or shaft misalignment. Time–frequency methods such as short-time Fourier transform (STFT) and wavelet transforms

are frequently employed to capture transient behaviors and non-stationary vibration patterns. These signal-processing techniques provide domain-informed features that significantly enhance the performance of ML models used in predictive maintenance and fault diagnostics. A typical signal processing workflow used in IoT-based monitoring systems is presented in Figure 4.

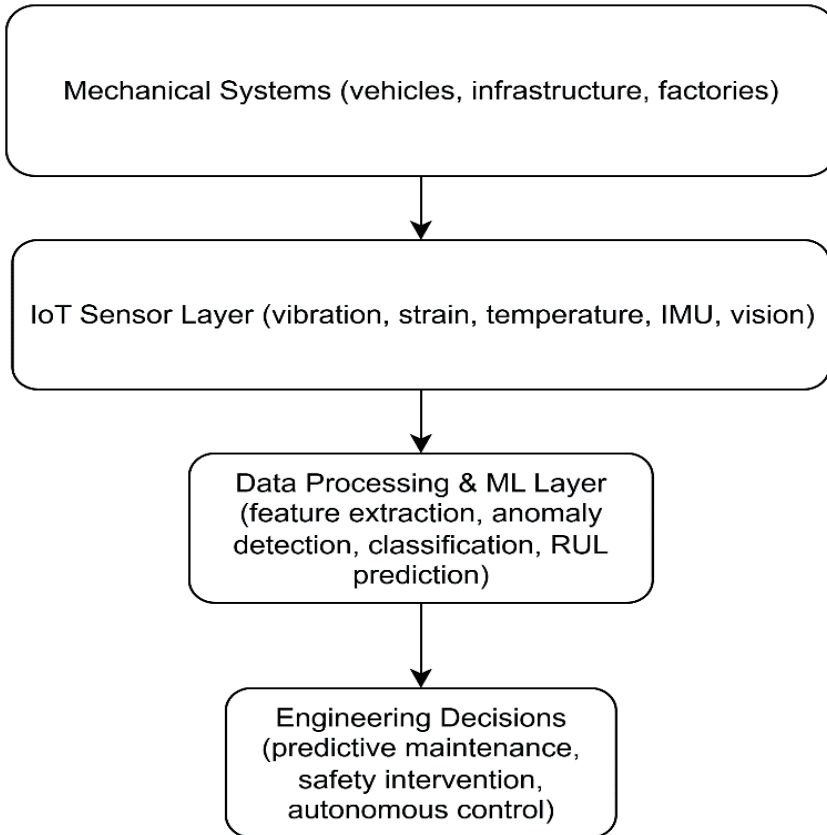


*Figure 4. Signal processing and feature extraction pipeline for ML-based mechanical condition monitoring. Raw sensor signals undergo preprocessing, spectral analysis, and feature extraction before being used by ML models for fault detection and predictive maintenance.*

#### 4. Academic Applications in Mechanical Systems

The application of IoT and ML technologies in mechanical engineering systems typically follows a layered data-to-decision pipeline. Mechanical assets equipped with distributed sensors continuously generate operational data, which are subsequently processed through ML pipelines to extract

actionable insights for engineering decision-making. As illustrated in Figure 5, this architecture connects physical mechanical systems with IoT sensing infrastructures, data-driven analytics, and intelligent operational control mechanisms.



*Figure 5. Conceptual architecture of AIoT applications in mechanical engineering systems. Mechanical assets such as autonomous vehicles, industrial machinery, and infrastructure systems are instrumented with IoT sensors that collect operational data including vibration, strain, temperature, and motion signals. These data streams are processed through ML pipelines that perform feature extraction, anomaly detection, and predictive analytics. The resulting insights support engineering decision-making processes such as predictive maintenance scheduling, safety interventions, and autonomous control adjustments.*

#### 4.1. Autonomous Vehicles and UAV Dynamics

Autonomous ground vehicles and unmanned aerial vehicles (UAVs) represent complex cyber-physical systems in which mechanical dynamics, sensing technologies, and ML algorithms converge. Modern UAV platforms are equipped with dense IoT sensor suites that continuously generate telemetry data, including multi-axis acceleration, gyroscopic orientation, vibration signatures, motor currents, and environmental parameters. These data streams provide real-time insight into the mechanical state of propulsion systems, flight structures, and onboard components. ML techniques are increasingly employed to analyze this high-dimensional telemetry data in order to detect anomalies, optimize flight control policies, and predict component degradation before mechanical failure occurs.

In addition to navigation and control, IoT-enabled UAVs are widely used for industrial inspection tasks involving mechanically complex infrastructure such as wind turbines, bridges, pipelines, and power transmission lines. Vibration patterns, structural responses, and visual inspection data collected by UAV-mounted sensors can be analyzed using deep learning models to identify structural damage, surface defects, or mechanical fatigue. Reinforcement learning methods are also being explored for adaptive flight control and autonomous inspection path planning in dynamic environments. Ensuring the reliability and safety of these autonomous systems requires real-time anomaly detection algorithms capable of operating under strict latency constraints while maintaining robustness against cyber-physical disturbances (Waheed et al., 2020).

#### 4.2. Structural Health Monitoring (SHM) in Smart Infrastructure

SHM represents one of the most important intersections between mechanical engineering principles and IoT-enabled sensing technologies. In modern smart infrastructure systems, wireless IoT sensor networks are deployed on critical mechanical and structural assets such as bridges, cranes, railways, and high-rise buildings to continuously monitor their mechanical integrity. These sensing systems typically collect multi-modal data including strain measurements, load distribution, displacement, acceleration, and low-frequency vibration signals that reflect the dynamic behavior of the structure under operational conditions.

The continuous acquisition of such sensor data enables engineers to analyze structural responses in both time and frequency domains, facilitating early detection of fatigue damage, stiffness degradation, or resonance-related anomalies. ML techniques are increasingly integrated into SHM pipelines

to process large volumes of streaming sensor data and automatically identify abnormal structural patterns. Unsupervised learning methods, such as clustering algorithms and autoencoders, are particularly useful for learning baseline operational signatures of structures and detecting deviations from normal behavior without requiring labeled failure data.

IoT-enabled SHM systems therefore enable a shift from traditional periodic inspection practices toward continuous condition-based monitoring. By detecting early-stage mechanical degradation before it evolves into catastrophic failure, these systems significantly improve infrastructure safety, reduce maintenance costs, and extend the operational lifetime of critical civil and industrial structures (Lin et al., 2017).

### **4.3. Human-Machine Interaction and Operator Safety**

Human–machine interaction in modern industrial environments represents a critical interface between mechanical systems, sensing technologies, and intelligent data analytics. In smart factories and advanced manufacturing facilities, human operators increasingly work alongside automated machinery, collaborative robots (cobots), and autonomous production systems. Ensuring safe and efficient interaction between humans and mechanical equipment requires continuous monitoring of operator movements, machine states, and environmental conditions through IoT-enabled sensing infrastructures.

Wearable sensors, vision-based monitoring systems, inertial measurement units (IMUs), and proximity sensors generate real-time data describing human posture, motion trajectories, and spatial relationships between operators and mechanical equipment. ML algorithms applied to these heterogeneous data streams enable accurate human activity recognition, gesture interpretation, and predictive modeling of operator behavior. These capabilities allow industrial control systems to dynamically adapt machine operations by reducing robot speed, adjusting tool trajectories, or triggering emergency stops when unsafe interactions are detected.

Such IoT-enabled human–machine interaction frameworks significantly enhance workplace safety while enabling more flexible and collaborative production environments. By integrating mechanical system monitoring with intelligent perception of human behavior, these systems support the development of adaptive manufacturing environments in which humans and automated machinery can operate safely within shared workspaces (Abdel-Basset et al., 2020).

#### 4.4. IIoT and ML-Based Predictive Maintenance

Predictive maintenance represents one of the most impactful applications of Industrial Internet of Things (IIoT) technologies in mechanical engineering (Carvalho et al., 2019). Traditional maintenance strategies, including reactive maintenance and time-based preventive maintenance, often lead to unnecessary downtime or unexpected equipment failures. In contrast, predictive maintenance systems leverage IoT-enabled sensing infrastructures and ML algorithms to continuously monitor the operational condition of mechanical assets and anticipate potential failures before they occur (Zonta, 2020).

In modern industrial environments, rotating machinery such as motors, pumps, turbines, compressors, and gearboxes are equipped with distributed sensor networks that collect vibration signals, temperature measurements, acoustic emissions, and electrical current data. These multi-modal sensor streams provide valuable insights into the mechanical health of equipment components, including bearings, shafts, gear trains, and lubrication systems. By analyzing these signals through advanced feature extraction and ML models, predictive maintenance systems can identify subtle degradation patterns associated with bearing wear, gear tooth damage, imbalance, misalignment, and lubrication deficiencies.


ML models, including random forests, support vector machines, deep neural networks, and hybrid anomaly detection frameworks, are widely applied to condition monitoring data in order to classify fault types and estimate remaining useful life (RUL) of critical components. The integration of these predictive models with IoT-based monitoring infrastructures enables maintenance scheduling to be dynamically optimized based on real-time equipment conditions. This data-driven maintenance paradigm reduces operational costs, minimizes unplanned downtime, and significantly improves the reliability and safety of industrial mechanical systems (Cakir et al., 2021).

Recent advances in digital twin technologies further enhance predictive maintenance capabilities by creating virtual replicas of physical machinery that evolve in parallel with their real-world counterparts (Sun et al., 2025). These digital twins integrate real-time sensor data, physics-based models, and ML algorithms to simulate system behavior under varying operational conditions. As a result, engineers can evaluate maintenance strategies, predict failure scenarios, and optimize operational parameters without interrupting physical production processes.

#### **4.5. Defense Robotics and Extreme Environments (DAG Observatory)**

Beyond traditional industrial monitoring, the integration of TinyML and hierarchical sensor fusion represents a critical frontier for mechanical infrastructure in extreme and isolated environments (Somvanshi et al., 2025). In settings exemplified by the Eastern Anatolia Observatory (DAG), harsh weather conditions prevail and continuous broadband connectivity is often unavailable. Instead, a hierarchical sensor fusion architecture powered by TinyML enables microcontrollers at the edge to locally process multi-modal data, including vibration, temperature, and atmospheric seeing conditions (Chaoraingern & Numsomran, 2025).


By performing initial inference and anomaly detection directly on the sensor nodes, only critical alerts are transmitted via scalable, low-bandwidth protocols such as LoRaWAN (Jouhari et al., 2023). This localized intelligence is essential for automated dome control and the predictive maintenance of heavy telescope mechanics, ensuring the autonomous operation of sensitive optical equipment. This hierarchical sensor fusion and TinyML-based local inference architecture (Somvanshi et al., 2025) is visualized in Figure 6.



*Figure 6. Hierarchical sensor fusion and TinyML-based local inference architecture in extreme environments (e.g., DAG Observatory). At the Eastern Anatolia Observatory (DAG, 3200 m altitude), the telescope dome and mechanical components must operate in conditions reaching  $-30^{\circ}\text{C}$ , heavy snowfall, and intermittent internet connectivity. As illustrated: (1) Vibration, temperature, humidity, and atmospheric seeing sensors on the dome generate continuous data streams. (2) These sensors are connected to a local microcontroller (e.g., ARM Cortex-M based) inside the dome. (3) A TinyML model running on this microcontroller (e.g., with TensorFlow Lite Micro) processes sensor data in real-time, distinguishing between “normal operational profiles” and “anomalies” (e.g., unexpected vibration increase in a mechanical component, risk of freezing). (4) Only when an anomaly is detected or critical thresholds are exceeded is a low-bandwidth alert message transmitted via LoRaWAN to the main observation center or cloud. This approach conserves energy and bandwidth by eliminating the need for continuous data transmission.*

## 5. Industry Applications of Cyber-Physical Systems

The overall industrial AIoT architecture integrating sensing infrastructures, edge gateways, and cloud-based analytics platforms is illustrated in Figure 7.



*Figure 7. Industrial AIoT architecture integrating sensor networks, edge computing, and cloud-based analytics in smart manufacturing environments. Industrial machines are monitored through sensor networks whose data are processed at edge gateways and analyzed in cloud platforms to support predictive maintenance and digital twin applications.*

### 5.1. Smart Manufacturing and Quality 4.0

The IIoT constitutes the backbone of the smart factory concept, enabling the comprehensive digitalization of production machinery and assembly lines (Dutta & Kant, 2023). Real-time kinematic monitoring, automated quality control, and digital twins are the primary application areas. The evolution from condition-based maintenance to prescriptive maintenance represents the next frontier in this domain (Cakir et al., 2021). While predictive maintenance forecasts when a mechanical failure is likely to occur, prescriptive maintenance goes further by recommending specific maintenance actions, such as replacing

a specific gear or adjusting spindle speeds, which optimize the trade-off between maintenance costs and production downtime.

## **5.2. Energy Machinery and Turbomachinery**

In the energy sector, mechanical engineering intersects with IoT to optimize the performance of heavy power generation equipment. Wind turbines, gas compressors, and hydroelectric generators are equipped with dense sensor arrays to monitor rotor dynamics, blade fatigue, and gearbox health. ML-based models analyze this operational data to detect aerodynamic imbalances and mechanical stress, thereby improving grid efficiency and preventing catastrophic equipment failures (Dutta & Kant, 2023). Furthermore, edge computing allows for real-time load balancing adjustments directly at the turbine control unit.

## **5.3. Autonomous Intralogistics and Fleet Dynamics**

The digitalization of supply chains heavily relies on the automation of material handling equipment. Automated Guided Vehicles (AGVs), robotic forklifts, and smart conveyor systems form an interconnected mechanical fleet that relies on IoT telemetry for coordination. ML algorithms process real-time positioning and load data to optimize path planning, prevent mechanical collisions, and manage the fleet's battery degradation cycles (Kong et al., 2022).

## **5.4. Biomechatronics and Healthcare 4.0**

The principles of Industry 4.0 are increasingly intersecting with the medical sector to create the Healthcare 4.0 paradigm, particularly in the manufacturing and monitoring of smart medical devices and biomechatronic systems (Aceto et al., 2021). IoT-enabled prosthetics and surgical robots continuously generate kinematic and force-feedback data. Furthermore, ML algorithms applied to clinical data are proving vital for predictive healthcare; for instance, identifying predictive biomarkers from preoperative laboratory data helps foresee complications such as new-onset postoperative atrial fibrillation following complex mechanical interventions like coronary artery bypass grafting. Beyond device-level monitoring, ML pipelines processing clinical sensor and laboratory data similarly exemplify the IoT-ML continuum (Akbulut, Cakir et al., 2025).

## **6. Challenges and Future Directions**

### **6.1. Technical Challenges**

#### **6.1.1. Scalability**

Scalability remains a fundamental challenge for large-scale IoT deployments in industrial environments where thousands of sensors continuously generate operational data. Managing data transmission, processing, and storage across such distributed infrastructures requires efficient communication protocols, scalable data processing pipelines, and adaptive resource allocation strategies. Edge computing and hierarchical system architectures are increasingly adopted to distribute workloads across device, edge, and cloud layers while maintaining reliable system performance.

The scalability challenge extends to ML model management in large IoT deployments. Maintaining, updating, and monitoring thousands or millions of deployed ML models across heterogeneous device populations requires robust MLOps (Machine Learning Operations) infrastructure adapted to IoT-specific constraints. Model versioning, A/B testing at the edge, automated retraining triggers, and model performance monitoring are essential capabilities that must be implemented within the bandwidth and compute constraints of IoT networks (Kreuzberger et al., 2023).

Data management at IoT scale presents additional challenges including storage cost optimization, data quality assurance, and efficient query processing across distributed, heterogeneous data stores. Time-series databases, stream processing frameworks, and data lake architectures have been developed to address these challenges, but their deployment in resource-constrained edge environments requires significant adaptation and optimization (Abdel-Basset et al., 2020).

#### **6.1.2. Energy Efficiency and Latency**

Energy efficiency and communication latency are critical design constraints in IoT-enabled mechanical monitoring systems. Many sensing devices operate in remote environments with limited power availability, requiring low-power hardware platforms, adaptive sensing strategies, and energy-efficient communication protocols. At the same time, real-time monitoring applications demand low latency for anomaly detection and control actions, making edge computing architectures essential for processing time-critical data close to the source.

The energy cost of ML inference on IoT devices represents an increasingly important design consideration. While TinyML techniques have dramatically reduced the computational requirements of inference, the energy consumed by neural network execution can still dominate the overall energy budget of battery-powered IoT devices. Hardware-software co-design approaches that jointly optimize model architecture, inference engine, and processor microarchitecture offer promising paths to further energy reduction (Dutta & Kant, 2023).

Emerging energy harvesting technologies, including solar, piezoelectric, thermoelectric, and RF energy harvesting, promise to enable perpetually powered IoT devices that eliminate battery replacement requirements entirely. However, the intermittent and variable nature of harvested energy introduces new challenges for ML workload scheduling, model update management, and communication protocol design that must be addressed through energy-aware system design (Mao et al., 2023).

### 6.1.3. ML Model Adaptation to IoT Constraints

Running large ML models on memory- and compute-constrained IoT devices requires advanced model compression, quantization, and efficient inference techniques. Distributing model updates over limited bandwidth, handling concept drift (systematic changes in data distribution over time), and managing the full model lifecycle (MLOps for IoT) remain open research challenges. The work of Cakir et al. (2021) on comparing multiple ML algorithms under real IIoT conditions highlights the importance of practical, hardware-aware algorithm selection in industrial deployments.

Concept drift, the phenomenon whereby the statistical relationship between input features and target variables changes over time, is particularly prevalent in IoT environments where operating conditions, environmental factors, and equipment degradation continuously alter data distributions. Adaptive learning techniques, including online learning, incremental learning, and drift detection methods, are essential for maintaining model accuracy over extended deployment periods without requiring costly manual retraining (Gama et al., 2014).

Model interpretability and explainability are increasingly recognized as critical requirements for IoT-ML deployment, particularly in safety-critical and regulated domains. Black-box DL models may achieve superior predictive accuracy but provide limited insight into the reasoning behind their predictions, hindering operator trust and regulatory compliance. A plant engineer or operations manager is not satisfied with merely receiving an alert that “Bearing

23A will fail”; they demand to know “Why?” This is where XAI (Explainable AI) techniques become essential. For instance, SHAP (SHapley Additive exPlanations) values quantify the contribution of each input feature to a specific prediction. In a predictive maintenance scenario, SHAP analysis might reveal that the model’s failure prediction is primarily driven by a 15% increase in the second harmonic component of the vibration spectrum and a 5°C temperature rise. This insight enables the engineer to understand the root cause (e.g., lubrication deficiency in the bearing) and take appropriate corrective action. LIME (Local Interpretable Model-agnostic Explanations) creates a local explanatory model by perturbing the input data to show which factors most influence the prediction. These techniques are becoming indispensable, particularly in safety-critical systems (e.g., unmanned aerial vehicles, nuclear power plants), for building operator trust and ensuring regulatory compliance (Arrieta et al., 2020).

## **6.2. Security, Privacy, and Ethical Concerns**

Security in IoT-ML systems spans device security (secure boot, OTA updates), data security (end-to-end encryption, anonymization), and network security (DDoS protection, intrusion detection). ML models introduce additional attack vectors including adversarial examples that cause misclassification, model poisoning attacks that corrupt training data, and model extraction attacks that steal intellectual property. Developing robust defenses against these threats requires a holistic approach that integrates security considerations into every stage of the ML pipeline, from data collection through model deployment and monitoring (Mao et al., 2023).

Privacy-preserving ML techniques, including differential privacy, secure multi-party computation, homomorphic encryption, and trusted execution environments, provide formal guarantees against information leakage while enabling useful computation on sensitive IoT data. However, these techniques typically impose computational overhead that may be prohibitive for resource-constrained IoT devices, necessitating careful trade-off analysis between privacy protection levels and system performance (Waheed et al., 2020).

Ethical concerns surrounding IoT-ML systems encompass algorithmic bias, surveillance overreach, and the digital divide. ML models trained on biased data may perpetuate or amplify existing inequalities when deployed in IoT systems that affect public services, healthcare delivery, or law enforcement. The pervasive sensing capabilities of IoT infrastructure raise fundamental questions about the appropriate boundaries of data collection and automated monitoring. Addressing these concerns requires interdisciplinary collaboration

between technologists, ethicists, policymakers, and affected communities to develop governance frameworks that balance innovation with human rights protection (Tanczer et al., 2018).

### 6.3. Standardization and Economic Challenges

The IoT-ML ecosystem remains fragmented, with interoperability challenges arising from the diversity of device platforms, communication protocols, data formats, and ML frameworks. Standardization efforts by IETF, OASIS, oneM2M, OPC Foundation, and industry consortia continue to advance, but achieving comprehensive interoperability across the full IoT-ML stack remains a distant goal. The development of standardized ML model exchange formats (e.g., ONNX), benchmark datasets, and evaluation protocols would accelerate progress toward interoperable and reproducible IoT-ML solutions (Lin et al., 2017).

Economic barriers to IoT-ML adoption include high initial investment costs, ROI uncertainty, and the scarcity of skilled professionals who combine domain expertise with ML engineering capabilities. Small and medium enterprises (SMEs) face particular challenges in justifying IoT-ML investments and building the organizational capabilities needed for successful deployment. Addressing these barriers requires industry-academia partnerships, workforce development programs, and government incentive mechanisms that lower adoption barriers and distribute innovation benefits more broadly (Aceto et al., 2021).

Data governance and sovereignty challenges add further complexity to IoT-ML deployment. Data localization requirements, cross-border data transfer restrictions, and sector-specific data handling regulations (GDPR, KVKK, HIPAA) create a complex compliance landscape that varies by jurisdiction and industry. IoT-ML architectures must be designed with regulatory compliance as a first-class architectural concern, incorporating privacy-by-design principles, audit trail capabilities, and flexible data governance policies (Tanczer et al., 2018).

### 6.4. Future Directions

#### 6.4.1. AIoT and Foundation Models

The convergence of AI and IoT (AIoT) is expected to accelerate with the maturation of FL, TinyML, autonomous IoT systems, and foundation models. Large language models (LLMs) and multimodal foundation models are emerging as potential interfaces for IoT system management, enabling

natural language querying of sensor data, automated report generation, and conversational interaction with complex IoT infrastructure. The adaptation of these models for IoT-specific tasks, including sensor data interpretation, fault diagnosis explanation, and maintenance procedure generation, represents a significant research opportunity (Zhang & Tao, 2020).

The concept of self-supervised pre-training for IoT sensor data is gaining traction, with the goal of learning general-purpose sensor data representations that can be fine-tuned for diverse downstream tasks with minimal labeled data. Time-series foundation models, pre-trained on large collections of sensor data from diverse domains, could dramatically reduce the data and engineering effort required to deploy ML in new IoT applications (Mohammadi et al., 2017).

Neuromorphic computing, inspired by the architecture and operating principles of biological neural systems, offers a fundamentally different approach to edge AI that promises orders-of-magnitude improvements in energy efficiency for event-driven IoT processing. Spiking neural networks (SNNs) running on neuromorphic hardware can process sparse, asynchronous sensor events with minimal energy consumption, making them ideally suited for always-on IoT monitoring applications (Dutta & Kant, 2023).

#### **6.4.2. 6G and Advanced Network Infrastructures**

Sixth-generation (6G) communication technologies, featuring terahertz bands, integrated sensing and communication (ISAC), and AI-native network management, will provide the connectivity fabric for next-generation IoT-ML systems. Network-as-a-sensor capabilities will enable IoT applications that extract environmental information directly from communication signals, reducing the need for dedicated sensor hardware. AI-driven network optimization will automatically adapt resource allocation, routing, and security policies to changing IoT traffic patterns and application requirements (Mao et al., 2023).

Reconfigurable intelligent surfaces (RIS), non-terrestrial networks (NTN) including LEO satellite constellations, and ambient backscatter communication represent complementary 6G technologies with significant implications for IoT. RIS can enhance coverage and reduce interference in dense IoT deployments; NTN can provide ubiquitous connectivity for remote and maritime IoT applications; and ambient backscatter enables ultra-low-power communication by harvesting energy from existing RF signals (Mao et al., 2023).

The integration of computation, communication, and sensing in 6G networks will blur the traditional boundaries between infrastructure components, creating a converged cyber-physical fabric that seamlessly supports

IoT-ML workloads. This convergence necessitates new architectural paradigms, standardization frameworks, and engineering methodologies that are currently the focus of intensive international research and pre-standardization activities (Mao et al., 2023).

### 6.4.3. Blockchain, Sustainability, and Autonomous Systems

Blockchain and distributed ledger technologies offer solutions for IoT data integrity, provenance tracking, and decentralized trust management. Smart contracts can automate IoT service-level agreements, data marketplace transactions, and compliance verification without centralized intermediaries. However, the computational and energy overhead of blockchain consensus mechanisms remains a significant challenge for resource-constrained IoT environments, driving research into lightweight consensus protocols and off-chain scaling solutions (Jouhari et al., 2023).

Sustainability-focused IoT-ML research addresses energy harvesting (solar, piezoelectric, thermoelectric), biodegradable materials for sensor packaging, modular and repairable hardware designs, and end-of-life electronics recycling. The concept of circular IoT envisions device lifecycles optimized for environmental sustainability from design through decommissioning, with ML-based optimization of energy consumption, material usage, and waste generation at every stage (Waheed et al., 2020).

Autonomous IoT-ML systems that can collect data, update models, make decisions, and take actions without human intervention represent the long-term vision of IoT evolution. Achieving this vision requires advances in self-supervised learning, continual learning, robust decision-making under uncertainty, and safe exploration, along with governance frameworks that ensure appropriate human oversight of autonomous system behavior in safety-critical and ethically sensitive contexts (Aceto et al., 2021).

## 7. Conclusion and Recommendations

### 7.1. General Assessment

As comprehensively examined in this chapter, the integration of IoT and ML represents a paradigm shift with the potential to fundamentally transform mechanical engineering. Traditional mechanical systems, through the concurrent advancement of sensor hardware, communication infrastructure, and artificial intelligence algorithms, are evolving beyond mere physical assets into cyber-physical systems capable of self-monitoring, prediction, and autonomous decision-making.

The success of this transformation depends on three fundamental pillars: (i) Technical competency: Mastery of the entire technology stack, from sensor selection and protocol design to ML model development and MLOps infrastructure; (ii) Interdisciplinary collaboration: The integrated application of mechanical engineering principles with computer science, data science, and electronics engineering; (iii) Ethical and regulatory awareness: Incorporating societal dimensions such as data privacy, algorithmic transparency, cybersecurity, and the digital divide into system design from the earliest stages.

Looking ahead, as foundation models, neuromorphic computing, 6G networks, and digital twin technologies mature, the capabilities enabled by IoT-ML integration will expand further. In the coming decade, self-optimizing smart factories, self-healing infrastructure equipped with real-time structural health monitoring systems, and biomechatronic devices that redefine human-machine collaboration may become commonplace in engineering practice. Realizing this vision depends not only on technological progress but also on a commitment to responsible innovation, shaped through coordinated efforts among academia, industry, and policymakers. The experimental and applied research reviewed in this chapter, from IIoT-based condition monitoring systems employing multiple ML classifiers (Cakir et al., 2021) to AI-driven clinical biomarker prediction (Akbulut, Cakir et al., 2025), demonstrates the breadth and depth of IoT-ML integration across diverse application domains. These works illustrate that the transition from data collection to actionable intelligence requires not only algorithmic sophistication but also careful attention to data quality, feature engineering, model selection, and deployment architecture.

## **7.2. Recommendations for Academia**

Interdisciplinary research programs that integrate engineering with social sciences are essential for addressing the societal and ethical dimensions of IoT-ML technology. Universities and research institutions should actively participate in standards development organizations (IETF, OASIS, oneM2M) to translate academic outputs into international standards. The establishment of open-access testbeds and benchmark datasets for IoT-ML protocols, security solutions, and energy efficiency techniques would enhance research reproducibility and accelerate innovation (Lin et al., 2017).

Graduate education programs should evolve to produce professionals who combine deep technical competence in IoT systems engineering and ML with awareness of the ethical, legal, and social implications of the technologies they develop. Research funding agencies should prioritize projects that address real-

world IoT-ML deployment challenges through industry-academia partnerships, ensuring that academic research maintains relevance to practical application needs.

The development of standardized evaluation methodologies and benchmark suites for IoT-ML systems would significantly advance the field by enabling rigorous, reproducible comparison of competing approaches. Current evaluations often employ proprietary datasets, inconsistent evaluation metrics, and non-comparable experimental conditions, limiting the ability to draw meaningful conclusions from the published literature.

### **7.3. Recommendations for Industry**

Organizations should begin IoT-ML adoption with well-defined pilot projects that demonstrate measurable value before scaling to enterprise-wide deployments. Edge-cloud hybrid architectures that process latency-critical data locally while performing deep analytics in the cloud offer optimal performance-cost trade-offs for most industrial applications. Device identity management, secure firmware updates, and network traffic monitoring mechanisms are essential for operational continuity in IIoT-ML deployments (Çakır et al., 2021).

The adoption of MLOps practices adapted to IoT environments is critical for managing the model lifecycle from development through deployment, monitoring, and retirement. This includes automated model retraining pipelines triggered by concept drift detection, model performance monitoring dashboards, and rollback mechanisms for safely managing model updates across large device fleets.

Industry collaboration on pre-competitive challenges, including interoperability testing, security vulnerability disclosure, and open-source tooling development, would accelerate IoT-ML ecosystem maturation while reducing individual organizational risk and investment requirements.

### **7.4. Recommendations for Policy and Regulation**

National data protection regulations should be balanced to avoid impeding the global interoperability of IoT-ML systems while providing meaningful privacy protections. Ethical oversight mechanisms should be developed for IoT-based surveillance, biometric data collection, and algorithmic decision-making processes. Infrastructure investments and subsidies in rural and underserved areas would expand IoT-ML technology accessibility and reduce the digital divide (Tanczer et al., 2018).

Regulatory sandboxes that allow controlled experimentation with innovative IoT-ML applications under relaxed regulatory requirements can accelerate responsible innovation while generating evidence to inform future regulatory frameworks. International regulatory harmonization efforts should be supported to reduce compliance complexity and enable cross-border IoT-ML deployment.

Public investment in IoT-ML literacy programs, workforce retraining initiatives, and SME adoption support mechanisms would ensure that the economic and social benefits of IoT-ML integration are broadly distributed across society rather than concentrated in large technology companies and early adopters.

### **7.5. Concluding Remarks**

Looking forward, the convergence of IoT with foundation models, neuromorphic computing, 6G networks, and digital twin technology promises to create intelligent, autonomous, and sustainable cyber-physical systems that fundamentally reshape how humans interact with the physical world. Realizing this potential will require sustained investment in interdisciplinary research, workforce development, standards development, and governance frameworks that ensure the benefits of IoT-ML integration are broadly shared and responsibly managed.

As detailed in this chapter, the integrated design of IoT and ML with mechanical engineering principles enables physical systems to transcend passive monitoring, equipping them with data-driven predictive capabilities and autonomous decision-making mechanisms. This integration provides measurable improvements in industrial efficiency, sustainability, and safety, forming the foundation of a paradigmatic shift in the engineering discipline. Ensuring that this bridge is secure, ethical, and sustainable requires the concurrent advancement of technical innovation, interdisciplinary collaboration, and policy development. Through coordinated efforts by academia, industry, and policymakers, IoT-ML integration can evolve beyond a technological trend to become a fundamental instrument of societal welfare and economic development.

## References

- Abdel-Basset, M., Hawash, H., Chakraborty, R. K., & Ryan, M. J. (2020). Deep learning for heterogeneous human activity recognition in complex IoT environments. *IEEE Internet of Things Journal*, 10(2), 1044–1057. <https://doi.org/10.1109/JIOT.2022.3205310>
- Aceto, G., Persico, V., & Pescapé, A. (2021). Industry 4.0 and health: Internet of Things, big data, and cloud computing for healthcare 4.0. *Journal of Industrial Information Integration*, 18, 100129. <https://doi.org/10.1016/j.jii.2020.100129>
- Akbulut, B., Çakır, M., Sarıkaya, M. G., Oral, O., Yılmaz, M., & Aykal, G. (2025). Artificial intelligence to predict biomarkers for new-onset atrial fibrillation after coronary artery bypass grafting. *Turkish Journal of Thoracic and Cardiovascular Surgery*, 33(2), 144-153. <https://doi.org/10.5606/tgkdc.dergisi.2025.27304>
- Arrieta, A. B., Díaz-Rodríguez, N., Del Ser, J., Benetton, A., Tabik, S., Barbado, A., ... & Herrera, F. (2020). Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information Fusion*, 58, 82-115. <https://doi.org/10.1016/j.inffus.2019.12.012>
- Banbury, C., Zhou, C., Fedorov, I., Matas, K., Thakker, U., Gope, D., ... & Reddi, V. J. (2020). Benchmarking TinyML systems: Challenges and direction. *Proceedings of Machine Learning and Systems*, 3, 409–420. <https://doi.org/10.48550/arXiv.2003.04821>
- Çakır, M., Guvenc, M. A., & Mistikoglu, S. (2021). The experimental application of popular machine learning algorithms on predictive maintenance and the design of IIoT based condition monitoring system. *Computers & Industrial Engineering*, 151, 106948. <https://doi.org/10.1016/j.cie.2020.106948>
- Carvalho, T. P., Soares, F. A. A. M. N., Vita, R., Francisco, R. P., Basto, J. P., & Alcalá, S. G. (2019). A systematic literature review of machine learning methods applied to predictive maintenance. *Computers & Industrial Engineering*, 137, 106024. <https://doi.org/10.1016/j.cie.2019.106024>
- Choraingern, J., & Numsomran, A. (2025). Embedded sensor data fusion and TinyML for real-time remaining useful life estimation of UAV Li polymer batteries. *Sensors*, 25(12), 3810. <https://doi.org/10.3390/s25123810>
- Darabkh, K. A., Al-Akhras, M., Zomot, J. N., & Atiquzzaman, M. (2022). RPL routing protocol over IoT: A comprehensive survey, recent advances, insights, bibliometric analysis, recommendations, and future directions. *Journal of Network and Computer Applications*, 205, 103476. <https://doi.org/10.1016/j.jnca.2022.103476>

- Dutta, S., & Kant, K. (2023). IoT and machine learning: A comprehensive survey. *ACM Computing Surveys*, 55(13s), Article 287. <https://doi.org/10.1145/3589952>
- Fuller, A., Fan, Z., Day, C., & Barlow, C. (2020). Digital twin: Enabling technologies, challenges and open research. *IEEE Access*, 8, 108952-108971. <https://doi.org/10.1109/ACCESS.2020.2998358>
- Gama, J., Žliobaitė, I., Bifet, A., Pechenizkiy, M., & Bouchachia, A. (2014). A survey on concept drift adaptation. *ACM Computing Surveys (CSUR)*, 46(4), 1-37. <https://doi.org/10.1145/2523813>
- Jouhari, M., Amhoud, E. M., Saeed, N., & Alouini, M.-S. (2023). A survey on scalable LoRaWAN for massive IoT: Recent advances, potentials, and challenges. *IEEE Communications Surveys & Tutorials*, 25(3), 1841–1876. <https://doi.org/10.1109/COMST.2023.3274934>
- Kairouz, P., & McMahan, H. B. (2021). Advances and open problems in federated learning. *Foundations and trends in machine learning*, 14(1-2), 1-210. <https://doi.org/10.1561/22000000083>
- Kong, L., Tan, J., Huang, J., Chen, G., Wang, S., Jin, X., Zeng, P., Khan, M., & Das, S. K. (2022). Edge-computing-driven Internet of Things: A survey. *ACM Computing Surveys*, 55(8), Article 174. <https://doi.org/10.1145/3555308>
- Kreuzberger, D., Kühnl, N., & Hirschl, S. (2023). Machine learning operations (MLOps): Overview, definition, and architecture. *IEEE Access*, 11, 31866-31879. <https://doi.org/10.1109/ACCESS.2023.3262138>
- Lee, J., Bagheri, B., & Kao, H. A. (2015). A cyber-physical systems architecture for Industry 4.0-based manufacturing systems. *Manufacturing Letters*.
- Lin, J., Yu, W., Zhang, N., Yang, X., Zhang, H., & Zhao, W. (2017). A survey on Internet of Things: Architecture, enabling technologies, security and privacy, and applications. *IEEE Internet of Things Journal*, 4(5), 1125-1142. <https://doi.org/10.1109/JIOT.2017.2683200>
- Mao, B., Liu, J., Wu, Y., & Kato, N. (2023). Security and privacy on 6G network edge: A survey. *IEEE Communications Surveys & Tutorials*, 25(2), 1095–1127. <https://doi.org/10.1109/COMST.2023.3244674>
- Mohammadi, M., Al-Fuqaha, A., Guizani, M., & Oh, J.-S. (2017). Deep learning for IoT big data and streaming analytics. *IEEE Internet of Things Journal*, 8(3), 1909–1922. <https://doi.org/10.1109/JIOT.2017.2784380>
- Reinsel, D., Gantz, J., & Rydning, J. (2018). The digitization of the world from edge to core. IDC White Paper, 16.
- Sanchez-Iborra, R., & Skarmeta, A. (2020). TinyML-enabled frugal smart objects: Challenges and opportunities. *IEEE Circuits and Systems Magazine*, 20(3), 4-18. <https://doi.org/10.1109/MCAS.2020.3005467>
- Seoane, V., García-Rubio, C., Almenares, F., & Campo, C. (2021). Performance evaluation of CoAP and MQTT with security support for IoT environ-

- ments. *Computer Networks*, 197, 108338. <https://doi.org/10.1016/j.comnet.2021.108338>
- Shi, W., Cao, J., Zhang, Q., Li, Y., & Xu, L. (2016). Edge computing: Vision and challenges. *IEEE Internet of Things Journal*, 3(5), 637–646. <https://doi.org/10.1109/JIOT.2016.2579198>
- Silva, D., Carvalho, L. I., Soares, J., & Sofia, R. C. (2021). A performance analysis of Internet of Things networking protocols: Evaluating MQTT, CoAP, OPC UA. *Applied Sciences*, 11(11), 4879. <https://doi.org/10.3390/app11114879>
- Somvanshi, S., Islam, M. M., Chhetri, G., Chakraborty, R., Mimi, M. S., Shuvo, S. A., Islam, K. S., Javed, S. A., Rafat, S. A., Dutta, A., & Das, S. (2025). From tiny machine learning to tiny deep learning: A survey. arXiv preprint arXiv:2506.18927.
- Sun, X., Zhang, F., Wang, J., Yang, Z., Huang, Z., & Xue, R. (2025). Digital twin for smart manufacturing equipment: modeling and applications. *The International Journal of Advanced Manufacturing Technology*, 137(9), 4929-4946.
- Tan, C., Sun, F., Kong, T., Zhang, W., Yang, C., & Liu, C. (2018). A survey on deep transfer learning. *Artificial Intelligence Review*, 52(2), 1–40. <https://doi.org/10.1007/s10462-018-9639-0>
- Tanczer, L. M., Steenmans, I., Elsdén, M., Craggs, B., & Carr, M. (2018). Emerging risks in the IoT ecosystem: Who's afraid of the big bad smart fridge? In *The Cambridge Handbook of Smart Contracts, Blockchain Technology and Digital Platforms* (pp. 291–312). Cambridge University Press.
- Waheed, N., He, X., Ikram, M., Usman, M., Hashmi, S. S., & Usman, M. (2020). Security and privacy in IoT using machine learning and blockchain: Threats and countermeasures. *ACM Computing Surveys*, 53(6), Article 132. <https://doi.org/10.1145/3417987>
- Zhang, J., & Tao, D. (2020). Empowering things with intelligence: A survey of the progress, challenges, and opportunities in artificial intelligence of things. *IEEE Internet of Things Journal*, 8(10), 7789-7817. <https://doi.org/10.1109/JIOT.2020.3039359>
- Zhou, Z., Chen, X., Li, E., Zeng, L., Luo, K., & Zhang, J. (2019). Edge intelligence: Paving the last mile of artificial intelligence with edge computing. *Proceedings of the IEEE*, 107(8), 1738–1762. <https://doi.org/10.1109/JPROC.2019.2918951>
- Zonta, T., da Costa, C. A., da Rosa Righi, R., de Lima, M. J., da Trindade, E. S., & Li, G. P. (2020). Predictive maintenance in the Industry 4.0: A systematic literature review. *Computers & Industrial Engineering*, 150, 106889. <https://doi.org/10.1016/j.cie.2020.106889>



# **Makina Mühendisliğinde Güncel Yaklaşımlar: Teori, Tasarım, Analiz ve Üretim Perspektifleri**

**Editör:**

**Yusuf FEDAI**