



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



EKLEMELİ İMALATTA PROSES
PARAMETRELERİNİN YAPAY ZEKA
YÖNTEMLERİ İLE TAHMİNİ

Nevzat BOL

YÜKSEK LİSANS TEZİ

Elektrik Elektronik Mühendisliği Anabilim Dalı

Ocak-2023
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Nevzat BOL tarafından hazırlanan “EKLEMELİ İMALATTA PROSES PARAMETRELERİNİN YAPAY ZEKA YÖNTEMLERİ İLE TAHMİNİ” adlı tez çalışması 12/ 01/2023 tarihinde aşağıdaki jüri tarafından oy birliği ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Dr. Öğr. Üyesi Burak YILMAZ

.....

Danışman

Doç. Dr. Akif DURDU

.....

Üye

Dr. Öğr. Üyesi Halil ÇİMEN

.....

Üye

Dr. Öğr. Üyesi Burak YILMAZ

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Saadettin Erhan KESEN
Enstitü Müdürü

Bu tez çalışması TÜBİTAK tarafından 3200280 nolu proje ile desteklenmiştir.

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Nevzat BOL

Tarih:

ÖZET

YÜKSEK LİSANS TEZİ

EKLEMELİ İMALATTA PROSES PARAMETRELERİNİN YAPAY ZEKA YÖNTEMLERİ İLE TAHMİNİ

Nevzat BOL

Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Elektrik Elektronik Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Akif DURDU

2023, 76 Sayfa

Jüri

Doç. Dr. Akif DURDU
Dr. Öğr. Üyesi Halil ÇİMEN
Dr. Öğr. Üyesi Burak YILMAZ

Eklemeli İmalat (Eİ) yöntemlerinden birisi olan Tel Beslemeli Eklemeli İmalat (TBEİ), malzemelerin katmanlar halinde biriktirilerek, parça üretilmesine imkan sağlayan bir imalat yöntemidir. TBEİ’de ısı kaynağı olarak kaynak arkı ve besleme malzemesi olarak kaynak teli kullanılmaktadır. Yüksek yığılma oranına sahip olan bu imalat yöntemi ile büyük yapısal parçalar üretilmektedir. Sağladığı avantajlar ile uzay, havacılık, gemcilik gibi sektörlerin ilgisini geçmektedir.

TBEİ’de seçilen proses parametreleri, üretilen parçanın kalitesini, mekanik ve mikro yapı özelliklerini etkilemektedir. Seçilen parametrelere bağlı olarak kaynak havuzunun alanının, genişliğinin ve uzunluğunun tahmin edilmesi prosesin kalitesi noktasında önemli bilgiler vermektedir. Bu tez çalışmasında proses parametrelerine karşılık kaynak havuzunun alanı, genişliği ve uzunluğu yapay sinir ağları (YSA) ile tahmin edilmiştir. YSA’nın giriş parametreleri olarak tel besleme hızı (Wire Feed Speed - WFS), kaynak akımı, kaynak voltajı ve torç hareket hızı (Torch Travel Speed - TTS) kullanılmıştır.

Anahtar Kelimeler: Eklemeli İmalat, Eİ, Tel Beslemeli Eklemeli İmalat, TBEİ, Yapay Sinir Ağları, YSA

ABSTRACT

MS THESIS

**ESTIMATE OF PROCESS PARAMETERS IN ADDITIVE MANUFACTURING
WITH ARTIFICIAL INTELLIGENCE METHODS**

Nevzat BOL

**Konya Technical University
Institute of Graduate Studies
Department of Electrical Electronics Engineering**

Advisor: Assoc. Prof. Akif DURDU

2023, 76 Pages

**Jury
Assoc. Prof. Akif DURDU
Asst. Prof. Halil ÇİMEN
Asst. Prof. Burak YILMAZ**

Wire Arc Additive Manufacturing (WAAM), one of the Additive Manufacturing (AM) methods, is a manufacturing method that allows materials to be part produced by deposited them in layers. In WAAM, welding arc is used as heat source and welding wire is used as feeding material. Large structural parts can be produced with this manufacturing method, which has a high deposition rate. With the advantages it provides, it attracts the attention of sectors such as space, aviation and shipping.

The process parameters selected in WAAM affect the quality, mechanical and microstructure properties of the produced part. Estimating the area, width and length of the weld pool depending on the selected parameters gives important information about the quality of the process. In this thesis, the area, width and length of the melting pool against the process parameters were estimated by artificial neural networks (ANN). Wire feed speed (WFS), welding current, welding voltage and torch travel speed (TTS) were used as input parameters of ANN.

Keywords: Additive Manufacturing, AM, Artificial Neural Network, ANN, Wire Arc Additive Manufacturing, WAAM,

ÖNSÖZ

Tez çalışmam sırasında ve hayatımın her anında benim yanımda olan ve destek veren aileme ve tüm arkadaşlarıma teşekkürlerimi sunarım. Onların yardımları ve anlayışları sayesinde bu günlere ulaşabilmiş olmaktan dolayı onlara minnettarım.

Bu tez çalışmama katkıda bulunan danışmanın Sayın Doç. Dr. Akif DURDU'ya, Tez çalışmamı destekleyen Intecro Robotik yöneticilerine, Ar-Ge bölümüne ve şirket danışmanımız sayın Prof. Dr. Oğuzhan YILMAZ'a teşekkürlerimi sunuyorum.

Nevzat BOL
KONYA-2023

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
SİMGELER VE KISALTMALAR	ix
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	3
2.1. Tel Beslemeli Eklemeli İmalatta Yapay Zeka Çalışmaları.....	3
2.2. Metal Eklemeli İmalatta Yapay Zeka Çalışmaları.....	7
3. MATERYAL VE YÖNTEM.....	12
3.1. Eklemeli İmalat.....	12
3.1.1. Eklemeli İmalat Nedir?	12
3.1.2. Metal Eklemeli İmalat Türleri	12
3.1.2. Tel Beslemeli Eklemeli İmalat	13
3.2. Proses Aşamaları.....	17
3.3. Proses Parametreleri	18
3.4. Tez Çalışmasında Kullan Sistem	18
3.5. Deneysel Proses Çalışmaları.....	19
3.6. Yapay Zeka Nedir?	21
3.6.1. Makine Öğrenmesi.....	22
3.7. Yapay Sinir Ağları Nedir?	23
3.7.1. Yapay Sinir Ağları Nasıl Çalışır?	24
3.7.2. Çok Katmanlı Algılayıcı (MLP).....	25
3.7.3. Veri Ayırma	26
3.7.4. Aktivasyon Fonksiyonları.....	27
3.7.5. Optimizasyon Algoritmaları	32
3.7.6. Hata Fonksiyonları.....	36
3.7.7. Geriye Yayılım	40
3.7.8. Regresyon Problemi.....	41
3.7.9. Doğruluk Fonksiyonu	42
3.7.10. Hiperparametre Optimizasyonu	43
3.7.11. Toplu Normalleştirme.....	44
4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....	45
5. SONUÇLAR VE ÖNERİLER	70
5.1 Sonuçlar	70
5.2 Öneriler	71

KAYNAKLAR	72
EKLER	76



SİMGELER VE KISALTMALAR

Kısaltmalar

BoW	: Kelime Çantası (Bag of Words)
CAD	: Bilgisayar Destekli Tasarım (Computer Aided Design)
CCD	: Yük Bağlantılı Cihaz (Charge-Coupled Device)
CC-KNN	: Karşı Eğri Özelliği KNN (Counter Curve Feature KNN)
CFG	: Hesaplamalı Akışkanlar Dinamiği (Computational Fluid Dynamics)
CMT	: Soğuk Metal Transferi (Cold Metal Transfer)
CNN	: Evrişimli Sinir Ağları (Convolution Neural Networks)
DED	: Doğrudan Enerji Biriktirme (Direct Energy Deposition)
DPE	: Dinamik Parametreler Deneyi (Dynamic Parameters Experiment)
GA	: Genetik Algoritma (Genetic Algorithm)
GMAW	: Gaz Metal Ark Kaynağı (Gas Metal Arc Welding)
GRU	: Geçitli Tekrarlayan Birim (Gated Recurrent Unit)
GTAW	: Gaz Tungsten Ark Kaynağı (Gas Tungsten Arc Welding)
KNN	: K-En Yakın Komşu (K-Nearest Neighbors)
LPP-KNN	: Yerelliği Koruma Projeksiyonu KNN (Locality Preserving Projection)
LRW	: Uzun Menzil Penceresi (Long Range Window)
LSTM	: Uzun Kısa Süreli Bellek (Long Short-Term Memory)
MAE	: Ortalama Mutlak Hata (Mean Absolute Error)
MAG	: Metal Aktif Gaz (Metal Active Gas)
MAPE	: Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error)
MAT	: Orta Eksen Dönüştürme (Median Axis Transformation)
MIG	: Metal Asal Gaz (Metal Inert Gas)
MLP	: Çok Katmanlı Algılayıcı (Multi-Layer Perceptron)
MsCNN	: Çok Ölçekli CNN (Multi Scale CNN)
MSE	: Ortalama Kare Hatası (Mean Squared Error)
MSLE	: Ortalama Kare Logaritmik Hata (Mean Squared Logarithmic Error)
PAW	: Plazma Ark Kaynağı (Plasma Arc Welding)
PBF	: Toz Yatağı Füzyonu (Powder-Bed Fusion)
RMSE	: Kök Ortalama Kare Hatası (Root Mean Squared Error)
RNN	: Özyinelemeli Sinir Ağları (Recurrent Neural Network)
SCNN	: Spektral Evrişimli Sinir Ağları (Spectral CNN)
SLM	: Seçici Lazer Eritme (Selective Laser Melting)
SRW	: Kısa Menzil Penceresi (Short Range Window)
TBEİ	: Tel Beslemeli Eklemeli İmalat (Wire Arc Additive Manufacturing)
TIG	: Tungsten Asal Gaz (Tungsten Inert Gas)
TTS	: Torç Hareket Hızı (Torch Travel Speed)
WFS	: Tel Sürme Hızı (Wire Feed Speed)
YSA	: Yapay Sinir Ağları (Artificial Neural Network)

1. GİRİŞ

Son zamanlarda imalat sektörüne giren ve hızla gelişen, Tel Beslemeli Eklemeli İmalat (TBEİ); geleneksel imalat yöntemlerindeki (CAM tabanlı) üretim metodolojisinden farklı olarak, malzeme eksiltme yaklaşımının aksine malzemelerin katmanlar halinde biriktirilerek, parça üretilmesine imkan sağlayan modern bir imalat yöntemidir. Bu yöntemin başlıca avantajları; parça imalatında geometrik tasarım özgürlüğü sağlaması, geleneksel imalat yöntemlerinde oldukça yer kaplayan tedarik ve operasyon süreçlerinin azaltılarak maliyet optimizasyonu yapılması ve bütüncül parça üretimi ile montaj aşamaların azaltılmasıdır.

TBEİ ısı kaynağı olarak kaynak arkı, besleme malzemesi olarak ise metal kaynak teli kullanan bir Metal Eklemeli İmalat yöntemidir. Bu yöntem, tipik ark kaynak ekipmanlarının kullanılması ile büyük ölçekli yapısal parçaları üretmek için çok kaynak pasolu kaynak işleminden oluşur.

TBEİ ile üretilen malzemeler, çoğunlukla geleneksel yöntemlerle üretilen benzerlerinden daha iyi mekanik özellikler gösterir. Mevcut bir yüzeye kolayca malzeme ekleyebildiğinden, mevcut metal parçaları onarmak veya değiştirmek için de çok uygundur. TBEİ, orta-büyük ölçekli parçaların üretiminde/tamirinde avantajlı ve düşük maliyetli bir imalat yöntemidir.

TBEİ prosesinin kontrolüne yönelik, yüksek ısı girdisinin kontrolü gibi bazı zorluklar bulunmaktadır. TBEİ prosesinde kullanılan malzeme, kaynak teknolojisi vb. birçok parametreye göre proses parametreleri değişmektedir. Bu değişen proses parametrelerinin belirlenmesi ve üretilen parçanın minimum hata ile hızlı üretilebilmesi için birçok deneysel çalışma yapılması gerekmektedir.

Literatürde ayarlanan proses parametrelerine göre üretilecek parçanın katman genişliği ve yüksekliğini tahmin etmeye yönelik çeşitli yapay sinir ağları (YSA) modelleri önermiştir. Bu YSA modelleri genellikle gerçek zamanlı toplanan veriler ile eğitilmemiş proses öncesi ayarlanan parametreler ve bu parametreler ile yapılan üretim sonrası yapılan ölçümler ile eğitilmiştir. Ayarlanan parametreler kaynak prosesi esnasında kaynak makinesi tarafından otomatik olarak değiştirilir ve çoğu zaman ayarlanan değerlerden farklıdır. Bu tez çalışmasında önerilen YSA modelinin eğitilmesinde gerçek zamanlı toplanan proses verileri ve termal kaynak havuz görüntüsü toplanarak eğitimi gerçekleştirilmiştir.

Bu tez çalışmasında, literatürdeki diğer çalışmalardan farklı olarak; Robotik TBEİ prosesinde, MIG-MAG kaynağı ve CMT teknolojisi kullanılarak proses esnasında toplanan veriler (TTS, WFS, Akım, Voltaj, Termal kaynak havuz görüntüsü) ile üretilen parçanın geometrik özelliklerinin (Kaynak havuz genişliği, uzunluğu ve alanını) yapay zeka yöntemlerinden biri olan YSA ile tahmini gerçekleştirilmiştir.

İkinci bölümde literatürde öncelikle TBEİ üzerine gerçekleştirilen yapay zeka çalışmaları sonrasında ise metal eklemeli imalatta gerçekleştirilen yapay zeka çalışmaları özetlenerek kaynak araştırması sunulmaktadır. Üçüncü bölümde bu tez çalışmasında kullanılan materyal ve yöntem açıklanmaktadır. Bu bölümde ilk olarak eklemeli imalat açıklanmıştır. Sonrasında proses aşamaları, proses parametreleri, bu tez çalışmasında kullanılan sistem, deneysel proses çalışmaları, yapay zeka ve YSA anlatılmaktadır. Dördüncü bölümde önerilen YSA modeli ve elde edilen sonuçlar aktarılmaktadır. Son bölümde ise bu tez çalışmasında gerçekleştirilen çalışmalar özetlenmiş, elde edilen sonuçlar ve gelecek çalışma önerileri sunulmuştur.

2. KAYNAK ARAŞTIRMASI

Literatürde, metal eklemeli imalat yöntemlerinde kalite kontrol, mekanik, geometrik özellik tahmini, proses parametrelerinin tahmini üzerine yapılmış çeşitli çalışmalar bulunmaktadır. Literatür araştırmasında ilk olarak robotik TBEİ uygulamalarında, proses parametreleri ile geometrik özellik tahmini, sonrasında kalite kontrol süreçlerinde çeşitli sensörler kullanılarak geliştirilen yapay zeka algoritmaları, son olarak ise çeşitli metal eklemeli imalat sistemlerinde gerçekleştirilen çalışmalar özetlenmiştir.

2.1. Tel Beslemeli Eklemeli İmalatta Yapay Zeka Çalışmaları

Nagesh ve arkadaşı yapmış olduğu çalışmada Tungsten Asal Gaz (Tungsten Inert Gas - TIG) kaynak prosesinde kaynak parametrelerinin YSA ve genetik algoritma (GA) ile optimizasyonu üzerine çalışmıştır. TIG kaynak sürecinin modellenmesi amacıyla deneysel veriler üzerinde iki seviyeli bir faktöriyel tasarım tekniği kullanılmıştır. TIG kaynak değişkenleri olan torç hareket hızı, tel sürme hızı, temizleme yüzdesi (cleaning percentage), kaynak akımı ve ark boşluğu (arc gap)'nun ön ve arka yükseklik, ön ve arka genişlik içeren kaynak havuz geometrisi parametreleri üzerine etkisi incelenmiştir (Nagesh & Datta, 2010).

Kaynak havuz geometrisi üzerine yapılan bir diğer çalışmayı, Xiong ve arkadaşları, bir YSA ve ikinci dereceden bir regresyon analizi aracılığıyla gerçekleştirmiştir. YSA'nın regresyona göre daha iyi sonuç verdiği bulunmuştur. Kaynak havuz geometrisi, katmanlı biriktirme işleminde metal parçaların katman kalınlığı, yüzey kalitesi ve boyutsal doğruluğu üzerinde kritik etkilere sahiptir. YSA modelinin girişine tel sürme hızı, torç hareket hızı, ark voltajı ve torç yüksekliği değerleri verilmiştir. Ağın çıkışında ise kaynak genişliği ve yüksekliği tahmin edilmeye çalışılmıştır. Giriş verilerine lineer normalizasyon uygulanarak ağı eğitmişlerdir. Çalışmada robotik sistem kullanılmıştır (Xiong, Zhang, Hu, & Wu, 2014).

Ding ve arkadaşları yaptıklarının kaynak havuz geometrisinin tahmini üzerine yaptığı çalışmada ilk olarak tek kat kaynak havuz geometrisi ile kaynak işlemi parametreleri arasındaki ilişki YSA ile kurmuşlardır. YSA modelinin giriş katmanına tel besleme hızı ve torç hareket hızı değerlerini verilmiştir. Çıkışında ise kaynak havuzunun genişliği ve yüksekliğini tahmin etmişlerdir. Ardından, yüksek geometrik doğrulukta

boşluksuz biriktirme için uyarlanabilir Orta Eksen Dönüştürme (Medial Axis Transformation - MAT) algoritması tanıtmışlardır. Sonuçlar, geliştirilen modelinin ve uyarlanabilir MAT tabanlı yolun, TBEİ işlemi için proses değişkenlerinin otomatik seçimi yoluyla yüksek kalitede ve geometrik doğrulukta birikimler üretebildiğini göstermektedir. Çalışmaları robotik sistem üzerinde deneysel olarak doğrulamışlardır (Ding et al., 2016).

Hu ve arkadaşları yapmış oldukları çalışmada YSA kullanarak kaynak havuzu genişliği (Bead Width), yüksekliği (Bead Height) ve alanını (Bead Cross Section Area) tahmin etmek üzerine bir model geliştirmişlerdir. Proses verileri ileri YSA ve geriye yayımlı YSA modelleri ile eğiterek sonuçları karşılaştırmışlardır. TBEİ'daki ana malzemeye nüfuzu ve ana malzeme üzerindeki kaynak takviyesini etkileyen işlem parametreleri kaynak akımı, tel besleme hızı, ark voltajı, kaynak torcu çalışma açısı, temas ucu ile çalışma mesafesi ve torç hareket hızıdır. Bu proses verileri giriş katmanı olarak ve üç geometrik profil değişkeni (kaynak genişliği, yüksekliği ve alanı) çıkış katmanı olarak ayarlanmıştır. Gizli katmandaki nöronların sayısı, tahmin modelinin performansını önemli ölçüde etkilemiştir. Gizli katmandaki yetersiz nöronlar, daha fazla eğitime ve zayıf tahmin doğruluğuna yol açarken, aşırı nöronlar modelin aşırı öğrenmesine neden olur. Datanın %85'i model eğitimi için, %5'i doğrulama için ve %10'u model testi için kullanılmıştır. Deneme yanılma yöntemi ile gizli katmandaki 10 nöron ile minimum ortalama karesel hata (Mean Squared Error - MSE) elde edilmiştir (Hu, Qin, Li, & Ni, 2020).

Tang ve arkadaşlarının yapmış olduğu çalışmada kaynak havuz geometrisinin modellenmesinde derin öğrenme kullanmışlardır. Çalışmaları kartezyen sistemde gerçekleştirmişlerdir. Kızılötesi kamera sensörü, lazer tabanlı alan topografi ölçüm sensörü, akımı ve voltaj sensörleri ile veri toplamışlardır. TBEİ proses parametrelerini (sıcaklık, kaynak havuzu geometrisi, kaynak akımı, kaynak gerilimi, torç hareket hızı ve tel besleme hızı) gerçek zamanlı olarak toplamışlardır. Bu parametreler, derin öğrenme modelinin eğitiminde kullanılmaktadır. Proses verilerinin toplanmasında, deneysel verileri artırırken deneysel adımları ve zorluğu azaltmak için bir dinamik parametreler deneyi (Dynamic Parameters Experiment - DPE) yöntemini önermişlerdir. Torç hareket hızı, tel besleme hızı ve kaynak akımı birleştirilmiş, dinamik ve senkron olarak değiştirilmiştir. Üç parametre, artan veya azalan her 10 mm'de bir değiştirilmiştir. 100 mm uzunluğunda tek bir kaynak havuzunda on kez değişim yapılmıştır. DPE olarak adlandırılan bu yöntemle veri toplama işlemini yapmışlardır. Proses parametreleri ile

kaynak havuzu geometrisi arasındaki ilişkiyi temsil etmek için bir derin öğrenme modeli kullanılmıştır. Derin öğrenme modeli bir girdi katmanı, üç gizli katman ve bir çıktı katmanından oluşmaktadır (Tang, Wang, Song, Li, & Zhang, 2021).

Wang ve arkadaşlarının yapmış olduğu çalışmada kaynak havuz genişliğinin tahmini için EPNet Segmentasyon ağı tasarlamışlardır. Çalışma robotik sistem üzerinde yapılmıştır. Kaynak havuzunun genişliğini tespit etmek için monochrome CCD kamera kullanmışlardır. Kamera görüntüsünü EPNet ağına vererek segmentasyon gerçekleştirmişler ve kaynak havuzunun genişliğini hesaplamışlardır. Son olarak, kaynak sırasında eriyik kaynak havuzu genişliğinin gerçek zamanlı kontrolünü sağlamak için aktif bir bozulma engelleme kontrolü (Active Disturbance Rejection Control) algoritması tasarlanmıştır. Gerçekleştirdikleri çalışmayı deneysel olarak doğrulamışlardır (Y. Wang et al., 2021).

Bose ve arkadaşlarının yapmış oldukları çalışmada kaynak havuzu ebatlarının (genişlik ve yükseklik) tahmini için hibritleştirilmiş YSA modeli önermişlerdir. Bu model ileri ve geri haritalama için kullanılmıştır. Modelin eğitiminde momentumlu gradyan iniş metodu ve gri kurt optimizasyonu kullanmışlardır. Modelin giriş parametreleri tel sürme hızı ve torç hareket hızıdır. Yapmış oldukları çalışmayı deneysel olarak doğrulamışlardır. Yaklaşık, ileri haritalamada %5 MAPE değeri ve geri haritalamada %6 MAPE değeri ile geliştirdikleri YSA model tahmin üretmektedir (Bose, Biswas, Tiwari, Mukherjee, & Roy, 2022).

Yapay Zeka Yöntemleri ile Proses Hatalarının Tespiti

Literatürde proses kalitesini etkileyen faktörler ve prosesin izlenmesine yönelik yapılan çalışmalar araştırılmıştır.

Mirapeix ve ark. yapmış oldukları çalışmada TIG kaynak prosesinde Temel bileşen analizi (Principal Component Analysis) ve yapay sinir ağının birlikte kullanımına dayalı olarak otomatik kaynak hatası tespitine ve sınıflandırmasına yönelik bir yöntem önermişlerdir. Kaynak testleri sırasında yakalanan plazma spektrumları, temel bileşen analizi vasıtasıyla işlenir ve YSA'nın girdisi olarak kullanılmaktadır. YSA'nın çıkışında doğru kaynak, penetrasyon eksikliği, düşük kaynak yoğunluğu, gaz akış azalması, hafif penetrasyon eksikliğini tahmin edilmeye çalışmıştır (Mirapeix, García-Allende, Cobo, Conde, & López-Higuera, 2007).

Bhattacharya ve arkadaşları yapmış oldukları çalışmada, MIG kaynağında ark voltaj sinyalleri ve kaynak akımı ile kaynak ses sinyallerini kullanarak kaynak biriktirme verimliliğini tahmin etmek için YSA modelleri geliştirmiştir. Üç farklı model kullanılmış ve model başarıları karşılaştırılmışlardır. Bu modeller; gradient iniş hatası geriye yayılım (gradient descent error back-propagation), nöro genetik algoritma (neuro-genetic algorithm) ve nöro diferansiyel evrim (neuro differential evolution)'dir. Nöro diferansiyel evrim diğer modellere göre daha düşük MSE değerine ulaşmıştır (Bhattacharya, Pal, & Pal, 2012).

Sumesh ve arkadaşları yapmış oldukları çalışmada akım ve gerilim imzaları ile kaynağın kalitesi arasında bir ilişki kurmak için karar ağacı algoritması kullanmıştır. Normal kaynak sırasında ark stabildir ve bir kusur başladığında arkta bozulmalar olur ve ark istikrarsız hale gelir. Bu dengesizlikler kaynak ark akımına ve gerilimine yansımaya sebep olacaktır. Çatlak, yırtılma vb. kusurlar kaynak arkına yansımaya sebep olacaktır ancak yanma, gözeneklilik vb. nedenlerle oluşan dengesizlik kaynak akımı ve gerilim imzalarına yansımaya sebep olacaktır. 52 numune kullanarak veri toplanmıştır. Toplanan veriden 12 önemli istatistiksel özellik çıkarılmıştır. Mevcut sinyallerden çıkarılan istatistiksel özellikler, iyi kaynak, yanma (Burn-through) ve gözeneklilik (Porosity) olarak ayarlanarak karar ağacı algoritmasını oluşturmuşlardır (Sumesh et al., 2018).

Zhao ve arkadaşlarının yapmış olduğu çalışmada spektrometre ve kamera kullanılarak kaynak havuzunun kalite kontrolünü gerçekleştirilmiştir. Çalışmalarını CMT kullanarak paslanmaz çelik, yüksek mukavemetli çelik ve yüksek nitrojenli çelik kaynağında deneysel olarak doğrulamışlardır. Kamera görüntüleri için CC-KNN (Counter Curve Feature) algoritması ve spektrum analizi için LPP-KNN (Locality Preserving Projection) algoritması kullanmışlardır (Zhao, Guo, Bai, Wang, & Han, 2019).

Wang ve arkadaşları yapmış oldukları çalışmada, kaynak takviyesi ve erimiş havuz görüntüsünün biriken katman üzerindeki konumu, erimiş havuz görsel toplama sistemi tarafından belirleyecek bir model önermişlerdir. Aynı yönde eklemeli üretim deneyinin verilerine göre, gelecekteki erimiş havuz görüntüsü, geliştirilmiş tahmin ağı (PredNet) tarafından tahmin edilmektedir. Deneysel sonuçlar, bu makalede tasarlanan izleme sisteminin erimiş havuz şeklindeki değişikliği 140 ms önceden tahmin edebildiğini ve kaynak takviye gerilemesinin ortalama hassasiyetinin 0,3 mm'den daha iyi olduğunu göstermektedir (Y. Wang et al., 2020).

Bir incelemede metal eklemeli imalatta başlıca problemler deformasyon, füzyon eksikliği, yüzey kusurları, geometrik doğruluk, boşluklar, penetrasyon, laminasyon olarak

sıralanmaktadır. Prosesin izlenmesinde kamera, spektrometre ve akustik algılayıcılar kullanılmaktadır. Kamera ile elde edilen veriler, kaynak havuzunun gelecek görüntülerin tahmini, yüzey kusurlarının incelenmesi ve sınıflandırılmasında kullanılmaktadır. Spektrometre ve akustik sensörler ile içyapıda oluşan çatlak, gözenek vb. kusurların tespit edilmesinde kullanılmaktadır (Xia, Pan, Polden, et al., 2020).

Cho ve arkadaşları, TBEİ'ta bir CNN kullanan gerçek zamanlı bir anormallik algılama yöntemi sundu. Önerilen yöntem, öğrenme performansını artırmak için önceden işlenmiş eriyik havuzu görüntü verilerinden öğrenerek anormallikleri tespit eden CNN tabanlı modellerin oluşturulmasını sağlar. Eriyik kaynak havuzu görüntülerini "normal" ve "anormal" durumlar olarak sınıflandırmak için bir prototip sistem uygulandılar. Deneyler, maliyetli ve işlenmesi zor bir malzeme olan molibden kullanılarak gerçekleştirildi. MobileNetV2, DenseNet169, Resnet50V2 ve InceptionResNetV2 kullanılarak dört CNN tabanlı model oluşturular. Daha sonra performansları, sınıflandırma doğruluğu ve işlem süresi açısından doğruladılar. MobileNetV2 modeli, %98 sınıflandırma doğruluğu ve 0,033 s/kare işleme süresi ile en iyi performansı vermiştir. Bu model aynı zamanda, sınıflandırma doğruluğunun %73,5'ini ve 0,067 s/kare işlem süresini veren "YOLO" adlı bir nesne algılama algoritması ile de karşılaştırıldılar (Cho, Shin, Seo, Kim, & Lee, 2022).

2.2. Metal Eklemeli İmalatta Yapay Zeka Çalışmaları

Literatürde, metal eklemeli imalatta kullanılan farklı sistemler üzerine gerçekleştirilmiş proses parametrelerinin tahmini ve kalite kontrolü üzerine gerçekleştirilen çalışmalar aşağıda özetlenmektedir.

Duman ve arkadaşının yapmış olduğu çalışmada, Seçmeli Lazer Sinterleme/Ergitme (SLS/E) sisteminde bulanık mantık modeli kullanarak imal edilecek parçanın mekanik özelliklerinin tahminini gerçekleştirmişlerdir. Literatürde gerçekleştirilen kalite parametreleri ile proses parametreleri arasındaki ilişki özetlenmiştir. Literatürde yer alan parametreler kullanılarak oluşturulan bulanık mantık modeli ile tahminler gerçekleştirilmiş ve sonuçlar literatürdeki sonuçlar ile karşılaştırılmıştır. Giriş parametreleri lazer gücü, tarama hızı, mesafesi ve deseni (stratejisi), katman kalınlığı, imalat atmosferi ve toz karakteristiği olarak belirtilmiştir. Çıkış parametreleri ise bağıl yoğunluk, sertlik, dayanım, metalürjik, yapı yüzey kalitesi, şekil ve boyut doğruluğudur (Duman & Kayacan, 2017).

Wasmer ve arkadaşları yapmış oldukları çalışmada eklemeli imalatta eş zamanlı kalite kontrol uygulamaları için yapay zeka ile akustik analizi gerçekleştirmişlerdir. 316L çelik ve lazer ile yaptıkları uygulamada, katmanlı üretim sürecinin kalite açısından tespit edilebilen, çıkarılabilen ve yorumlanabilen bir dizi benzersiz akustik imzaya sahip olduğunu tespit etmişlerdir. Sonuçlar, sınıflandırmada elde edilen güven seviyesinin %79-84 olup, bu yaklaşımın katmanlı imalatta yerinde ve gerçek zamanlı kalite izleme için uygulanabilirliğini göstermektedir. İlk yaptıkları çalışmada SCNN (Spectral Convolutional Neural Networks) ve evrimsel sinir ağlarını (Convolution Neural Network – CNN) değerlendirmişlerdir. SCNN için sınıflandırma doğruluğu CNN'den daha yüksektir ve üç kalite seviyesi için %83 ile 89 arasında değiştiğini tespit etmişlerdir. Bu çalışmada, CNN yapısı hem uzun menzil penceresi (LRW) hem de kısa menzil penceresi (SRW)'den spektrogramların akışlarını aynı anda işleyecek şekilde ayarlanmıştır. İki spektrogram, iki ayrı evrişim katmanından geçer. Bunlardan elde edilen bilgiler, havuz katmanlarında (Pooling Layer) toplanır ve ortak evrişim katmanına iletilir. Nihai sınıflandırma tam bağlantılı katman (Fully Connected Layer) ile gerçekleştirilir (Wasmer, Kenel, Leinenbach, & Shevchik, 2017).

Scime ve arkadaşının yapmış olduğu çalışmada lazer toz yatağı beslemeli eklemeli imalat sistemlerinde hata tespitinde MsCNN kullanmışlardır. AlexNet modelini transfer öğrenme kullanarak kendi veri setleri ile eğitmişlerdir. Elde edilen sınıflandırma sonuçları ile parça kalitesi ve genel yapı kararlılığı ile ilgili bilgi elde edilmektedir. Çalışmalarında MATLAB kullanmışlardır. Üretilecek parçanın dilimleme (slicing) görüntülerinin bilgisayar üzerinden ekran görüntülerini alarak kamera görüntüsü ile aynı boyuta getirmişlerdir. Ardından segmentasyon için bu görüntüler kamera görüntüleri ile birleştirilerek kullanılmıştır. Giriş görüntüsü her bir derinlik matrisinde farklı ebatlarda görüntü içerecek (Multi-scale CNN - MsCNN) şekilde ağ eğitilmiştir. Bu yöntem kelime çantası (Bag of Words - BoW) metodolojisinde kullanılan bağlamsal sezgisel yöntemlerden esinlenilmiştir. Elde edilen sonuçlar Bow ve CNN'e göre çok daha yüksek başarı elde ettiğini göstermektedir (Scime & Beuth, 2018).

Mozaffar ve arkadaşları yapmış oldukları çalışmada, geometri, yapı boyutları, takım yolu stratejisi, lazer gücü ve tarama hızındaki varyasyonlarla Yönlendirilmiş Enerji Biriktirme (Directed Energy Deposition -DED) işlemlerinde yüksek boyutlu termal geçmişi tahmin etmek için Geçitli Tekrarlayan Birim (GRU) formülasyonlu Yinelenen Sinir Ağı (Recurrent Neural Network - RNN) yapısı önermişlerdir. Uzun kısa süreli bellek (LSTM) ve Geçitli Tekrarlayan Birim (GRU) uzun veri dizilerini eğitmek için

RNN yapılarının iki başarılı formülasyonudur. Her bir GRU hücresi, o zaman adımı için girdi özelliklerini ve önceki zaman adımından gizli bir durumu alır ve yeni bir çıktı verir. Her eğitim noktası için takım yolu, biriktirme süresi, yapının sınırına en yakın mesafe, katman yüksekliği, lazer yoğunluğu ve lazer durumu bulunur. Eğitim verileri termal analiz yazılımı ile oluşturulmuştur. RNN modeli 1-5 katman, GRU birimi 100-500 birim ve 1-3 birim tam bağlı katman bulunan farklı yapılar ile 100 dönem eğitilmiştir. MSE $1e-4$ olarak bulunmuştur (Mozaffar et al., 2018).

Zhang ve arkadaşları yapmış oldukları çalışmada toz yatağı fizyonu sistemlerinde kalite düzeyinin belirlenmesi için destek vektör makineleri (Support Vector Machine) ve CNN önermişlerdir. CNN için AlexNet modeli kullanarak gerçekleştirmişlerdir. CNN ile ham görüntüleri kullanarak, üç kalite seviyesi için sınıflandırma doğruluğunu %92,7 olarak elde etmişlerdir. Sonuçlar, farklı nesnelere gelen bilgilerin farklı kalite anormalliklerine duyarlı olduğunu göstermiştir (Y. Zhang, Hong, Ye, Zhu, & Fuh, 2018)

Caggiano ve arkadaşları yapmış oldukları çalışmada, lazer toz yataklı sistemlerde kaynak kusurlarının tespiti için Bi-stream Deep CNN modeli önermişlerdir. Geliştirilen makine öğrenimi yöntemi, kusurlu koşulları tanımada %99,4'e varan bir doğruluk elde etmiştir. Her evrişimli katmanda, özellik çıkarımına bilgi kaybı eşlik eder. Standart CNN'de, daha yüksek katman, orijinal girdi görüntüsüne veya daha düşük düzeydeki özelliklere erişim olmaksızın, yalnızca önceki katmandan çıkarılan özellikleri görebilir. Bu nedenle, özellik çıkarma işlemi daha derin katmanlara doğru ilerlerken, kayıp birikir ve standart CNN'de daha yüksek düzeyde özellik çıkarımı için bilgi zenginliğini azaltır. Bi-stream Deep CNN'de atlama bağlantıları, giriş görüntüsü ve evrişimli katmanlar arasına dahil edilir. Atlama bağlantısı, daha yüksek katmanların giriş görüntüsüne ve önceki çok düzeyli görüntü özelliklerine tam erişim sağlamasına ve bu nedenle, görüntü tanıma için doğru üst düzey özellik çıkarımı elde etmek için bilgi zenginliğini geliştirmesine izin verir (Caggiano et al., 2019).

Bir incelemede eklemeli imalatta kullanılan YSA uygulamaları derlenmiştir. YSA, parametrelerinin belirlenmesi, literatürde kullanılan katman ve nöron sayıları derlenmiş ve eklemeli imalatta YSA eğitimi sırasında karşılan sorunlar özetlenmiştir. Eklemeli imalat ile geleneksel döküm veya dövme ile üretilmesi zor olan, topolojik olarak optimize edilmiş yapılar gibi karmaşık şekillere sahip ürünler oluşturulabilir. Bu malzeme israfını azaltır. Böylece endüstri için maliyetten tasarruf sağlar. Eklemeli imalat parçaları aynı zamanda, dökümlerinde ve işlenmiş emsallerinde görülenlerden farklı düzinelere benzersiz kusur sunar; bunlar, füzyon eksikliğinden ve gaz sıkışmasından kaynaklanan

gözeneklilik, baskı yönüne göre hem dikey hem de paralel yönlerde ağır anizotropik mikro yapı ve yüksek soğutma hızı ve dik sıcaklık gradyanı ile ortaya çıkan büyük artık gerilmeye bağlı distorsiyonu içerir. Örneğin, seçici lazer eritmede (SLM), lazer gücü, tarama aralığı, tarama hızı ve katman kalınlığını içeren işleme parametrelerinin tümü, üretilen parçaların kalitesini önemli ölçüde etkiler. Parametrelerin mikro yapı üzerindeki ilişkisini çıkarmak için fizik tabanlı hesaplamalı akışkanlar dinamiği (Computational Fluid Dynamics - CFD) ve lazer toz yatağı füzyonu (Laser Powder-Bed Fusion - PBF) gibi simülasyon yöntemleri geliştirilmiştir. Ama şu anda tüm eklemeli imalat sürecini bu fizik güdümlü yöntemlerle kısa sürede hızlı ve doğru bir şekilde tahmin etmek pratik değildir. Veriye dayalı modeller eklemeli imalat alanında yaygın olarak kullanılmaktadır; bu modeller birleşik makine öğrenimi adını taşır. Bu tür bir modelin en büyük avantajı, uzun bir fizik tabanlı denklemler listesi oluşturmalarına gerek olmamasıdır. Bunun yerine, önceki verilere dayalı olarak giriş özellikleri ile çıktı hedefleri arasındaki ilişkiyi otomatik olarak öğrenirler (Qi, Chen, Li, Cheng, & Li, 2019).

Literatürdeki Çalışmaların Genel Değerlendirmesi

Literatürde yapılan çalışmalar incelendiğinde robotik TBEİ uygulamalarında proses parametreleri (torç hareket hızı, tel sürme hızı, kaynak akımı, vb.) ile kaynak havuzunun geometrik özellikleri (genişlik, yükseklik vb.), YSA, GA ve Regresyon modelleri ile tahmin edilmeye çalışılmıştır. Kalite kontrol üzerine yapılan çalışmalar incelendiğinde kaynak kamerası, termal kamera, spektrometre, akustik sensör kullanılarak elde edilen veriler çeşitli makine öğrenmesi metotları ile analiz edilmiştir. Son olarak incelenen metal eklemeli imalat sistemlerinde proses parametreleri ve kalitenin incelenmesine yönelik çeşitli makine öğrenmesi modelleri kullanıldığı görülmektedir.

Eklemeli imalat prosesleri dikkate alındığında kullanılan sistem (robotik, kartezyen vb.), kullanılan proses ekipmanı (MIG/MAG, TIG, Lazer, Plazma, Elektron vb.) ve kullanılan malzeme (alüminyum, çelik, titanyum, vb.) parça üretimine etki etmektedir. Parça üretimine etki eden proses parametrelerine yönelik kullanılan sensör ve parça üretiminde kullanılan sistemlerin değişiklik göstermesi ile sistemden elde edilen veriler değişiklik göstermektedir. Bu durum, çalışmalarda kullanılan makine öğrenmesi modellerinin yapısını ve başarısını doğrudan etkilemektedir.

Bu tez çalışmasında literatürde yapılan çalışmalardan farklı olarak proses esnasında toplanan gerçek zamanlı proses verileri ve kaynak havuzu özelliklerinin toplanması için termal kaynak kamerası kullanılmıştır. Gerçek zamanlı toplanan proses verileri (WFS, Akım, Voltaj, TTS) verileri ile kaynak havuz özellikleri (genişlik, uzunluk ve alan) eşleştirilmiştir. Bu toplanan veriler kullanılarak YSA modeli eğitilmiş ve proses parametrelerine bağlı olarak kaynak havuzu özellikleri tahmin edilmiştir.



3. MATERYAL VE YÖNTEM

Bu bölümde ilk olarak eklemeli imalat türleri, TBEİ, kullanılan malzemeler, avantajları, dezavantajları ve zorluklar açıklanmıştır. Ardından proses aşamaları, proses parametreleri, tez çalışmasında kullanılan sistem ve özellikleri, gerçekleştirilen proses çalışmaları, veri toplama ve hazırlık işlemleri, yapay zeka metotları ve YSA açıklanmaktadır.

3.1. Eklemeli İmalat

Bu başlıkta eklemeli imalatın tanımı, eklemeli imalat türleri, tez çalışmasının gerçekleştirildiği TBEİ'nin tanımı, proses metotlarından olan soğuk metal transferin çalışma prensibi, kullanılan malzemeler, TBEİ'nin avantaj, dezavantaj ve zorlukları aktarılmaktadır.

3.1.1. Eklemeli İmalat Nedir?

ASTM F2792-10 standardına göre, Eklemeli İmalat, geleneksel malzeme eksiltmeli üretim metodolojilerinin aksine, kademeli olarak ince malzeme katmanlarını birbirinin üzerine ve/veya yan yana ekleyerek üç boyutlu parçalar oluşturan nispeten yeni bir teknolojidir (Standard, 2012). Eklemeli imalat, malzeme israfını önleyerek parça üretim maliyetlerini düşürmeyi ve pazara sunma süresini kısaltmayı vaat etmektedir. Eklemeli imalat sağladığı avantaj ile üretimde ve tasarımda özgürlük sağlarken parça montajını kolaylaştırmakta ve parça ağırlığından tasarruf sağlamaktadır (Stewart et al., 2016).

3.1.2. Metal Eklemeli İmalat Türleri

Metal bileşenlerin üretiminde malzemenin bir yatağa önceden yerleştirildiği toz yatağı füzyonu (Powder Bed Fusion – PBF) veya malzemenin doğrudan işlem bölgesine yönlendirildiği doğrudan enerji biriktirme (Direct Energy Deposition - DED) yöntemleri kullanılmaktadır. PBF prosesinde hammadde metal tozu iken, DED prosesinde hammadde metal tozu veya kaynak teli olabilir. DED prosesinde kullanılan hammaddeye göre toz beslemeli sistemler (Powder-Feed Systems) ve tel beslemeli sistemler (Wire-


Feed Systems) olarak adlandırılmaktadır. Bu sistemler, hammaddeyi ısıtan enerji kaynağına göre de kategorize edilebilir, örneğin elektron demeti (electron beam), lazer, plazma, ark tabanlı işlemler (Frazier, 2014; S. Liu & Shin, 2019; Silva, 2018).

Bu tez çalışmasında DED'nin alt metotlarından birisi olan TBEİ (Wire Arc Additive Manufacturing – WAAM) prosesine odaklanılmıştır.

3.1.2. Tel Beslemeli Eklemeli İmalat

3.1.2.1. Tel Beslemeli Eklemeli İmalat Nedir?


TBEİ, malzemenin katman-katman biriktirilmesi için geleneksel ark kaynağı teknolojisi kullanan (Şekil 1) bir eklemeli imalat yöntemidir (Hofer, Haelsig, & Mayr, 2018). Bu yöntemde ısı kaynağı olarak kaynak arkı, besleme malzemesi olarak ise kaynak teli kullanılmaktadır (Stewart et al., 2016). Isı kaynağının türüne göre, TBEİ'nin genel olarak üç türü vardır: gaz metal ark kaynağı (Gas Metal Arc Welding - GMAW), gaz tungsten ark kaynağı (Gas Tungsten Arc Welding - GTAW) ve plazma ark kaynağı (Plasma Arc Welding - PAW) tabanlı yöntemlerdir (Xia, Pan, Polden, et al., 2020). GMAW yönteminde ısı azaltılmış ve proses kontrollü işlemi olan soğuk metal transferi (Cold Metal Transfer - CMT), TBEİ uygulamalarında yaygın olarak kullanılan bir yöntemdir (Hofer et al., 2018).



Şekil 1. Tel Beslemeli Eklemeli İmalat (Xia, Pan, Zhang, et al., 2020)

3.1.2.2. Soğuk Metal Transferi (CMT)

CMT, gaz metal ark kaynağı prosesinde kullanılan ısı girdisini azaltmaya yönelik bir prostedir. Bu yöntem kısa arka veya daha çok bu arkın sistematik devamsızlığına dayanmaktadır. Ortaya çıkan sonuç “sıcak-soğuk-sıcak-soğuk” olarak değişen bir kaynak düzenidir. CMT, akım voltaj ve kaynak teli hareketi Şekil 2’de gösterilmektedir. Bu “sıcak-soğuk” prosesi, ark basıncını büyük oranda azaltır. Bu proses, düşük ısı girdisi, düşük distorsiyon, diğer kaynak metotlarına göre yüksek hassasiyet ve yüzey kalitesi gibi avantajlara sahiptir (Imoudu, Ayele, & Barabadi, 2017).



Şekil 2. CMT'nin akım, voltaj grafiği ve tel hareketi (Galeazzi, Viviani, Jaeger, & Schwedersky, 2022)

3.1.2.3. Tel Beslemeli Eklemeli İmalatta Kullanılan Malzemeler

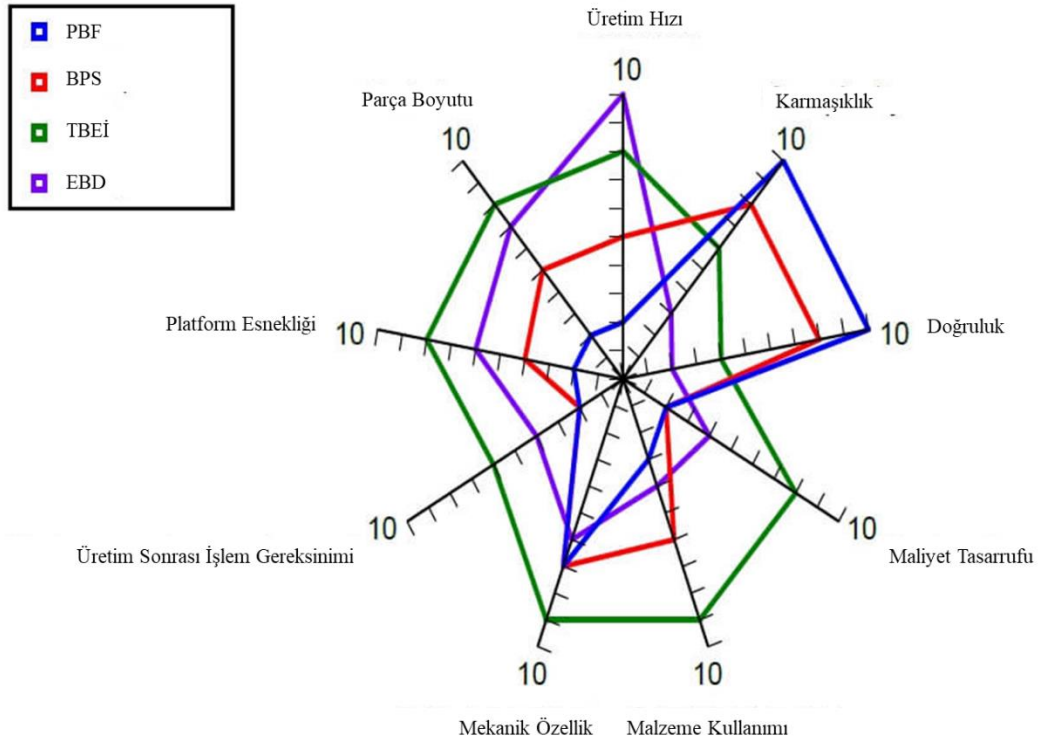
TBEİ proseslerinde, yaygın olarak Çelik bazlı (Hackenhaar, Mazzaferro, Montevecchi, & Campatelli, 2020; Lehmann et al., 2020; L. Wang, Xue, & Wang, 2019), Alüminiyum bazlı (Hauser et al., 2020; Oyama, Diplas, M'hamdi, Gunnæs, & Azar, 2019; C. Zhang, Gao, Chen, & Zeng, 2019), Nikel bazlı (Dharmendra, Hadadzadeh, Amirkhiz,

Ram, & Mohammadi, 2019; Dhinakaran et al., 2020; Shen et al., 2018) ve Titanyum bazlı (Bambach, Sizova, Sydow, Hemes, & Meiners, 2020; Lu et al., 2020; Wu et al., 2017) alaşımları kullanılmaktadır.

3.1.2.4. Tel Beslemeli Eklemeli İmalatın Avantajları

TBEİ yüksek yığıma oranına sahiptir böylece büyük ve yapısal parçalar üretilebilir. Bununla birlikte TBEİ ile hasarlı veya aşınmış parçaların onarımı da gerçekleştirilebilmektedir (Treutler & Wesling, 2021). TBEİ metodunda parça üretimi için kullanılan hammaddenin final ürünün ağırlığına oranını ifade eden satın al uç oranı düşüktür (McFadden, Ward, & Quinn, 2018). Bu yöntem, karmaşık geometrili parçaların imalatına olarak tanımakla birlikte, hızlı tedarik ve operasyon kabiliyeti, düşük maliyet, malzeme kullanım verimliliğinin artırılması, talaşlı imalat maliyetlerinin azaltılması, üretimde kalite ve esnekliğin artırılması, montaj basamaklarının sadeleştirilebilmesi, iç kanal ve boşluklara sahip parça üretimi gibi birçok avantaja sahiptir (Fu et al., 2021). TBEİ'nin metal eklemeli imalat yöntemleri ile karşılaştırması Şekil 3'te gösterilmektedir. Diğer metal eklemeli imalat yöntemleri ile kıyaslandığında daha düşük ekipman maliyetine sahiptir. Daha iyi malzeme kullanım oranı ve daha çevre dostu bir üretim süreci sunar (Xia, Pan, Polden, et al., 2020).

TBEİ geleneksel talaşlı imalat (subtractive manufacturing) yöntemleri ile kıyaslandığında, parça boyutuna ve geometrisine bağlı olarak imalat süresini %40-60 ve işleme sonrası süreyi %15-20 azaltabilmektedir (Wu et al., 2018). Tüm bu avantajları ile başta savunma sanayi olmak üzere, havacılık, denizcilik, otomotiv vb. birçok sektörde geniş kullanım alanına sahiptir.



Şekil 3. Metal Eİ Süreç Karşılaştırma Şeması (McFadden et al., 2018)

3.1.2.5. Tel Beslemeli Eklemeli İmalatın Dezavantajları ve Zorluklar

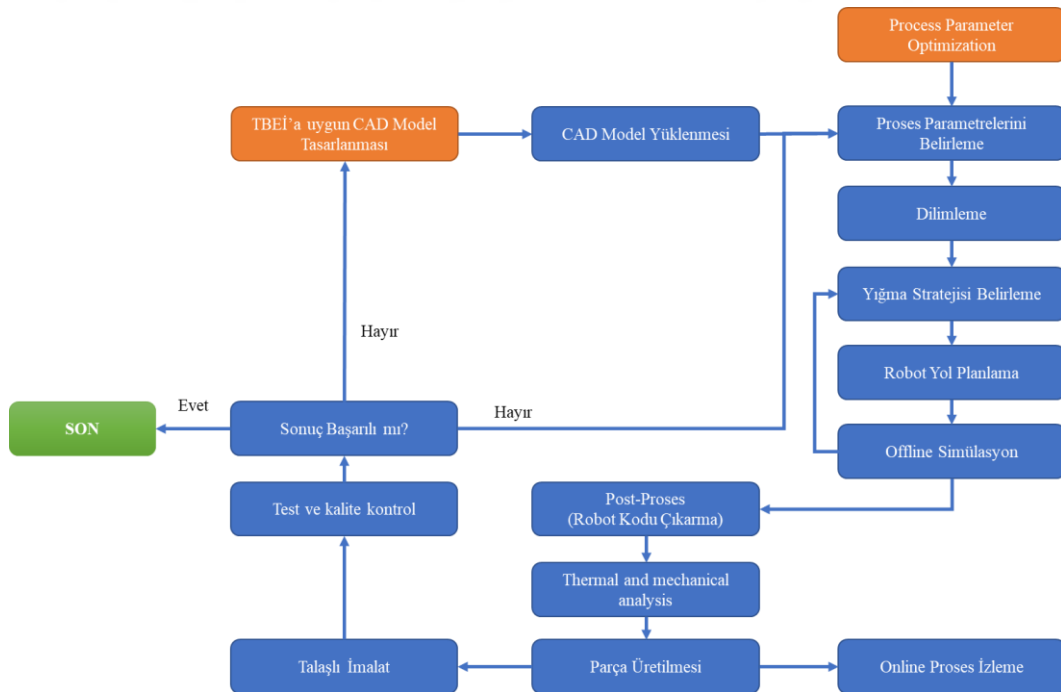
TBEİ'nin dezavantajı diğer metal eklemeli imalat yöntemleri ile karşılaştırıldığında daha yüksek yüzey pürüzlülüğüne sahip olmasıdır. Mühendislik toleranslarını elde etmek ve mekanik özellikleri iyileştirmek için genellikle üretim sonrası talaşlı imalat ve ısıtma işlemi uygulanması gerekir (Knezović & Topić, 2018). TBEİ prosesini, kullanılan malzeme, kaynak teknolojisi, ortam koşulları ve birçok proses parametresine bağlı olarak elde edilen ürünün kalitesi değişiklik göstermektedir. Bu değişen proses parametrelerinin belirlenmesi için birçok deneysel çalışma yapılması gerekmektedir (Li et al., 2019; Rodrigues, Duarte, Miranda, Santos, & Oliveira, 2019).

TBEİ prosesinin kontrolüne yönelik en büyük zorluk yüksek ısı girdisinin kontrolüdür. Döngüsel ısı girdisi, üretilen parça içerisinde artık gerilmelere yol açarak, parçanın fikstürden ayrılması ile deformasyona neden olabilir (McFadden et al., 2018).

TBEİ'nin çeşitli imalat endüstrisinde yaygın şekilde entegrasyonunu engelleyen temel sorun, proses sağlamlığı (robustness), kararlılığı (stability) ve tekrarlanabilirliğidir (repeatability). Bu, büyük ölçüde, TBEİ sürecinin henüz süreç izleme ve kapalı döngü kontrol (Cloos Loop Control) sistemlerinin yeterli düzeyde gelişmemesine bağlanabilir (Xia, Pan, Polden, et al., 2020).

3.2. Proses Aşamaları

TBEİ Prosesi, 5 temel adımdan oluşmaktadır. Öncelikle TBEİ prosesine uygun CAD model tasarlanması gerekmektedir. Oluşturulan CAD model çevrimdışı robot simülasyon programı içerisine aktarılmakta ve dilimleme işlemi gerçekleştirilmektedir. Parça üretimi öncesi proses parametre optimizasyonu gerçekleştirilmekte ve üretilecek parça için uygun proses parametresi belirlenmektedir. Belirlenen bu proses parametresine bağlı olarak dilimleme işlemi gerçekleştirilerek ve parçayı üretmek için uygun yığma stratejisinin belirlenmesi ve bu stratejiye uygun robot yol planlamasının yapılması gerekmektedir. Yapılan yol planlama simülasyon ortamı içerisinde test edilmektedir. Yapılan yol planlaması parçayı üretmek için uygun bulunması durumunda robot kodu (Post-Proses) çıkartılmaktadır. Böylece parça üretimi gerçekleştirilebilir. Parça üretimi sırasında proses gerçek zamanlı olarak izlenebilir ve proses verileri toplanabilir. Bu toplanan veriler süreci iyileştirmek için kullanılması amaçlanmaktadır. Üretilen parça talaşlı imalat işlemi uygulanmaktadır. Son olarak üretilen parçanın kalite kontrol testleri gerçekleştirilerek, belirlenen üretme metodu ve proses parametrelerinin üretim için uygun olup olmadığına karar verilmektedir. TBEİ proses aşamaları Şekil 4’de gösterilmektedir.



Şekil 4. TBEİ Proses Aşamaları


3.3. Proses Parametreleri

TBEİ prosesini etkileyen temelde iki parametre bulunmaktadır. Bu parametreler, tel sürme hızı (Wire Feed Speed - WFS) ve torç hareket hızıdır (Torch Travel Speed - TTS). WFS, kaynak akımı ve voltajına bağlı olarak değişmektedir. Bu parametreler ile birlikte TTS, parça üzerindeki ısı girdisi ve yığılma miktarını belirlemektedir. WFS ve TTS aynı zamanda kaynak havuzunun genişliği ve yüksekliğini belirlemektedir. Bu parametreler, parça üzerindeki deformasyon, gözeneklilik, geometrik doğruluk, mikro yapı ve mekanik yapı gibi kalite özelliklerini etkilemektedir. TTS ve WFS değiştirilerek proses kontrolü gerçekleştirilebilmektedir.


3.4. Tez Çalışmasında Kullanılan Sistem

Sistem Kuka KR6 R1820 ARC HW 6 Eksen endüstriyel robot, Fronius TPS500i CMT kaynak makinesi, Xiris Xir-1800 termal kaynak kamerası ve pirometreden oluşmaktadır.

Termal kaynak kamerası ile proses esnasında kaynak havuzu ve kaynak havuzunun sıcaklık dağılımı izlenmiştir. Pirometre katmanlar arası sıcaklık kontrolü için kullanılmıştır. Kullanılan robotik sistem Şekil 5'te ve robotik ekipmanlar Şekil 6'da gösterilmektedir.



Şekil 5. Robotik Sistem



Şekil 6. Robotik Ekipmanlar

3.5. Deneysel Proses Çalışmaları

Proses çalışmaları, 1.2mm ER70S-6 SG2 çelik kaynak teli kullanılarak gerçekleştirilmiştir. Alt plaka 300x200x30mm ebatlarında ST52 Çeliktir. Koruyucu gaz %82 Ar + %18 CO₂'tir ve gaz akış hızı 18 L/dk'dır (Tablo 1). Kaynak metodu olarak CMT Universal metodu kullanılmıştır. YSA modelinin eğitimi, doğrulanması ve testleri için farklı parametrelerde 14 düz duvar üretimi gerçekleştirilmiştir. Düz duvarların üretiminde her katmanın orta noktasından pirometre ile sıcaklık ölçümü yapılarak sıcaklık 150°C'ye düştüğünde prosesin devam etmesi sağlanmıştır. Pirometre ölçümünden sonra proses devam ederken termal kaynak kamerası ile görüntü toplanmıştır. Böylece katmanlar arası farklı sıcaklık değerlerinden kaynaklı kaynak havuzunun değişiminin önüne geçilmiştir.

Tablo 1. Deney Parametreleri


Tel	ER70S-6 SG2 Çelik
Tel çapı	1.2 mm
Alt Plaka	ST52 Çelik
Alt Plaka Ebatları	300x200x30 mm
Koruyucu Gaz	%82 Ar + %18 CO ₂
Gaz debisi	18 L/dk
Katmanlar arası yükselme miktarı	1.78 mm
Torç Mesafesi	18 mm
Duvar uzunluğu	150 mm
Katmanlar arası sıcaklık	150 °C

Üretilen 14 duvardan 12 tanesi, taguchi metodu kullanılarak, WFS veya TTS'e göre belirlenmiştir. Bu 12 duvardan toplanan veriler YSA modelinin eğitim ve doğrulanması için kullanılmıştır. Üretilen 13.cü duvarda TTS değeri sabit tutulmuş ve WFS değeri belirli aralıklarla değiştirilmiştir. 14.cü duvarda ise WFS değeri sabit tutulmuş ve TTS değeri belirli aralıklarla değiştirilmiştir. 13.cü ve 14.cü duvardan toplanan veriler YSA modelinin testinde kullanılmıştır. Proses parametreleri Tablo 2'de verilmektedir.

Tablo 2. Proses Parametreleri

No	WFS (m/dk)	TTS (m/dk)
1	4	0.4
2	5	0.4
3	6	0.4
4	7	0.4
5	4	0.5
6	5	0.5
7	6	0.5
8	7	0.5
9	4	0.6
10	5	0.6
11	6	0.6
12	7	0.6
13	4 ile 7	0.45
14	5.5	0.4 ile 0.6

Proses çalışmaları sırasında MetalWorm yazılımı ile TTS, WFS, Kaynak Voltajı ve Kaynak Akımı değerleri toplanmıştır. Yazılımla toplanan veriler termal kaynak kamerasından elde edilen veriler ile eşleştirilerek modelin eğitiminde kullanılmıştır. Termal kaynak kamerası görüntülerinden 800°C altındaki alanlar filtrelenerek kaynak havuz alanı, kaynak havuzunun genişliği ve uzunluğu hesaplanmıştır. Kaynak başlangıç ve bitişlerinde kaynak havuzu daha küçük bir alana sahip olduğundan bu alanlar ihmal edilmiş ve kaynak havuzunun daha stabil olduğu duvarın ortasına yakın alanlarda gerçekleştirilen ölçümler eğitim setinde kullanılmıştır. Kaynak havuzunun sıcaklık dağılımı, kaynak havuzunun farklı noktalarındaki sıcaklık değerleri ve kaynak havuzunda işaretlenen alan Şekil 7'de gösterilmektedir.



Şekil 7. Kaynak Havuzu

Belirlenen deney parametrelerine ve proses parametrelerine bağlı olarak üretilen düz duvarlar Şekil 8’de gösterilmektedir.



Şekil 8. Düz Duvar Çalışması

3.6. Yapay Zeka Nedir?

Yapay zeka, bir makinenin veya bilgisayar sisteminin, öğrenme, problem çözme, karar verme ve örüntü tanıma gibi normalde insan zekası gerektiren görevleri gerçekleştirme yeteneğini ifade eder. Aşağıdakiler de dahil olmak üzere yapay zekaya birkaç farklı yaklaşım vardır:

- Kural tabanlı sistemler: Karar vermek veya sorunları çözmek için önceden tanımlanmış bir dizi kuralı izleyen sistemlerdir.
- Uzman sistemler: Belirli bir alandaki bir uzmanın karar verme yeteneklerini taklit eden sistemlerdir.
- Makine öğrenimi: Bir bilgisayar sistemini bir veri kümesi üzerinde eğitmeyi, verilerden öğrenmesini ve zaman içinde performansını iyileştirmesini sağlayan bir yapay zeka türüdür.

Yapay zeka, doğal dil işleme, görüntü ve konuşma tanıma, otonom araçlar ve karar destek sistemleri dahil olmak üzere çok çeşitli uygulamalara sahiptir. Birçok sektörde devrim yaratma potansiyeline sahiptir ve yaşama ve çalışma şeklimiz üzerinde şimdiden önemli bir etkisi olmuştur.

3.6.1. Makine Öğrenmesi

Makine öğrenimi, bir bilgisayar sistemini bir veri kümesi üzerinde eğitmeyi, verilerden öğrenmesini ve zaman içinde performansını iyileştirmesini sağlayan bir tür yapay zekadır. Açıkça programlanmadan bilgisayarların öğrenmesini ve uyum sağlamasını sağlamanın bir yoludur (Jordan & Mitchell, 2015). Aşağıdakiler de dahil olmak üzere makine öğrenimine yönelik birkaç farklı yaklaşım vardır:

- Denetimli öğrenme: Modelin hem giriş verilerini hem de karşılık gelen doğru çıktı etiketlerini içeren etiketli veriler üzerinde eğitildiği bir makine öğrenimi türüdür. Amaç, modelin girdi verilerini doğru çıktı etiketleriyle eşleyen bir fonksiyonu öğrenmesidir. Bu tez çalışmasında önerilen YSA modeli bir denetimli öğrenme örneğidir.
- Denetimsiz öğrenme: Modele herhangi bir etiketli eğitim verisi verilmeyen bir makine öğrenimi türüdür. Amaç, verilerdeki kalıpları ve ilişkileri keşfetmek veya verileri kümeler halinde gruplandırmaktır.
- Yarı denetimli öğrenme: Modeli kısmen etiketlenmiş ve kısmen etiketlenmemiş bir veri kümesi üzerinde eğitmeyi içeren bir makine öğrenimi türüdür. Tamamen etiketlenmiş eğitim verilerini elde etmenin pahalı veya zor olduğu durumlarda kullanışlıdır.
- Takviyeli öğrenme: Modelin çevresiyle etkileşime girerek ve ödül veya ceza şeklinde geri bildirim alarak öğrendiği bir makine öğrenimi türüdür.

3.6.1.1. Denetimli Öğrenme

Denetimli öğrenme, modelin hem giriş verilerini hem de karşılık gelen doğru çıkış etiketlerini içeren etiketli veriler üzerinde eğitildiği bir makine öğrenimi türüdür. Denetimli öğrenmenin amacı, girdi verilerini doğru çıktı etiketleriyle eşleyen bir fonksiyonu öğrenmektir.

Denetimli öğrenme algoritmaları, doğrusal regresyon, lojistik regresyon ve destek vektör makinelerini ve YSA modellerini içerir. Bu algoritmalar, bir dizi girdi-çıkış çiftinden oluşan eğitim verilerine bir model uydurarak öğrenir. Model daha sonra, öğrenilen fonksiyonu girdi verilerine uygulayarak görünmeyen veriler üzerinde tahminler yapmak için kullanılır.

Denetimli öğrenmenin ana avantajlarından biri, uygulayıcının belirli bir girdi için doğru çıktıyı belirlemesine izin vermesidir, bu da öğrenmeyi ve veriler hakkında tahminlerde bulunmayı mümkün kılar. Eğitim verileri için doğru çıktı bilindiğinden, uygulanması ve değerlendirilmesi de nispeten kolaydır.

Bununla birlikte, denetimli öğrenme algoritmaları, etkili bir şekilde öğrenmek için büyük miktarda etiketlenmiş veri gerektirir ve eğitim verileri genel dağılımı temsil etmiyorsa, görünmeyen verilere genelleme yapamayabilirler. Ek olarak, girdi ve çıktı verileri arasındaki temel ilişki zaman içinde değişirse modelin performansı düşebilir (B. Liu, 2011).

3.7. Yapay Sinir Ağları Nedir?

YSA, insan beyninin yapısından ve fonksiyonundan esinlenen bir hesaplama modelidir. Katmanlar halinde organize edilmiş nöronlar olarak bilinen çok sayıda birbirine bağlı işlem düğümlerinden oluşur. YSA'lar verilerden öğrenme ve bu öğrenmeye dayalı akıllı kararlar verme yeteneğine sahiptir.

Bir YSA'nın temel yapı taşı, diğer nöronlardan veya dış kaynaklardan girdi alan, girdiyi bir dizi ağırlık ve önyargı (bias) kullanarak işleyen ve bir çıktı üreten nörondur. Nöronun çıktısı daha sonra diğer nöronlara veya ağın son çıktı katmanına iletilir.

YSA'lar, tahmin edilen çıktı ile gerçek çıktı arasındaki hatayı en aza indirmek için ağın ağırlıklarını ve yanlılıklarını ayarlayan bir veri kümesi ve bir optimizasyon algoritması kullanılarak eğitilir. Bu süreç, ağı eğitme olarak bilinir ve ağın verilerden öğrenmesine ve performansını zaman içinde iyileştirmesine olanak tanır.

İleri beslemeli ağlar, CNN ve RNN dahil olmak üzere birkaç farklı YSA türü vardır. Her tür, farklı görev türleri için uygundur ve kendine özgü özelliklere sahiptir.

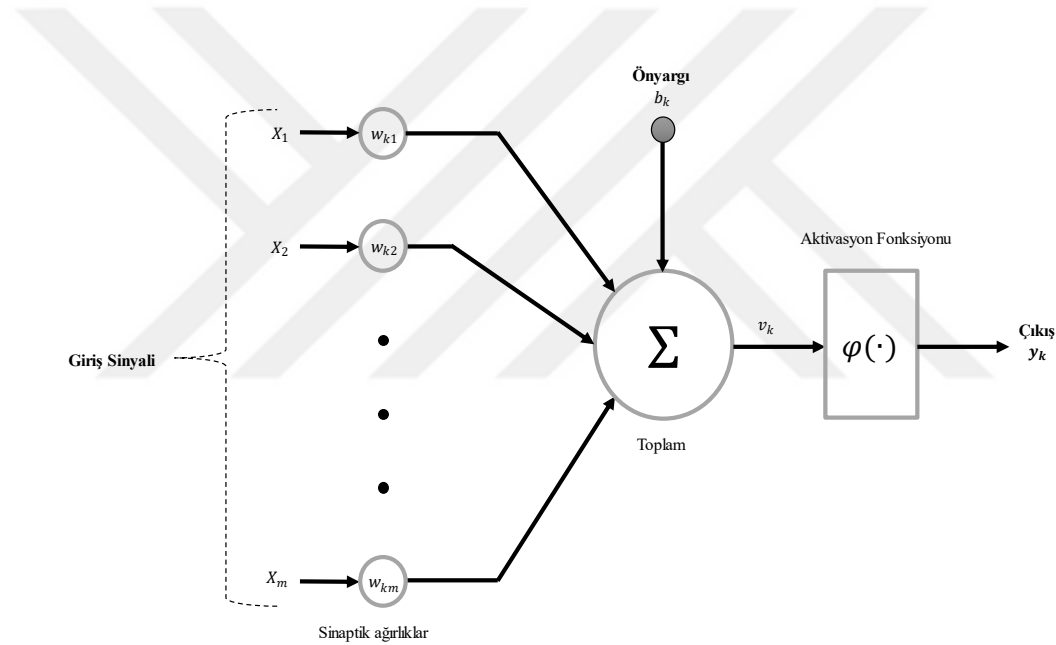
YSA'lar, görüntü ve konuşma tanıma, doğal dil işleme ve karar destek sistemleri dahil olmak üzere çok çeşitli uygulama yelpazesine sahiptir. Eğitildikleri verilere dayalı olarak öğrenme ve uyum sağlama yetenekleri vardır, bu da onları karmaşık sorunları çözmek için güçlü bir araç haline getirir. Bununla birlikte, büyük miktarda veriye ihtiyaç duyma ve aşırı öğrenme (overfitting) gibi bazı sınırlamaları da vardır (Abiodun et al., 2018).

3.7.1. Yapay Sinir Ağları Nasıl Çalışır?

YSA, giriş katmanı, gizli katman ve çıkış katmanı olmak üzere üç katmandan oluşur. Giriş katmanı, bir sinir ağının ilk katmanıdır ve giriş verilerini kabul ederek ağdaki bir sonraki katmana iletmekten sorumludur. Giriş katmanında, verilere uygulanan herhangi bir hesaplama veya dönüşüm yoktur. Verileri basitçe bir sonraki katmana iletir. Giriş katmanı tipik olarak, her biri giriş verilerindeki bir özelliğe karşılık gelen bir dizi nörondan oluşur. Örneğin, girdi verileri üç özellikten (boy, ağırlık ve yaş gibi) oluşuyorsa, girdi katmanında üç nöron olabilir. Gizli katman, bir sinir ağında dış dünya tarafından görülemeyen bir nöron katmanıdır. Girdi katmanı ile çıktı katmanı arasında yer alan bir katmandır ve tahminlerde kullanılacak yararlı özellikleri çıkarmak için girdi verilerini dönüştürmek için kullanılır. Bir sinir ağında birden fazla gizli katman olabilir ve her bir gizli katman farklı sayıda nörona sahip olabilir. Gizli katmandaki nöron sayısı, modelin performansını iyileştirmek için ayarlanabilen bir hiperparametredir. Gizli katmanlar, verilerdeki karmaşık kalıpları ve ilişkileri öğrenmekten sorumlu oldukları için sinir ağının önemli bir parçasıdır. Bunu, ağdan geçerken verilere dönüşümler ve hesaplamalar uygulayarak yapabilirler. Çıkış katmanı, bir sinir ağının son katmanıdır ve ağın son çıktısını üretmekten sorumludur. Çıkış katmanı tipik olarak, her biri çıkış verilerinde bir sınıfa veya etikete karşılık gelen bir dizi nörondan oluşur. Örneğin, bir sınıflandırma görevinde, çıktı katmanında her biri farklı bir sınıf etiketine karşılık gelen bir dizi nöron olabilir. Bir regresyon görevinde, çıktı katmanı sürekli bir çıktı değeri üreten tek bir nörona sahip olabilir.

Giriş değerleri başlangıçta rastgele olarak belirlenen ağırlık değerleri ile çarpılarak toplanır. Bu değerlere önyargı (bias) değeri eklendikten sonra aktivasyon fonksiyonu uygulanır. Şekil 9'da YSA hücre yapısı gösterilmektedir. Aktivasyon

fonksiyonu uygulanarak elde edilen çıktı bir sonraki gizli katman nöronuna veya çıkışa aktarılabilir. Ağın çıkışındaki değerin hedef değere yakın olması için ağın ağırlık parametrelerinin ve önyargı değerlerinin güncellenmesi gerekmektedir. Ağın ağırlık parametrelerinin güncellenmesinde geriye yayılım algoritması (backpropagation) gradyan iniş tekniğini kullanır. Bu algoritma denklemin lokal minimum değerine yakınsamak için birinci derece türev kullanır (Rumelhart, Hinton, & Williams, 1986). Ağın çıkışında tahmin edilen değer ile gerçek değer arasındaki hata kayıp fonksiyonları ile hesaplanır. Bu hata değerini kullanılarak ağın ağırlık parametrelerinin güncellenmesinde farklı optimizasyon fonksiyonları kullanılmaktadır. Ağın performansını artırmak için, normalizasyon, veri çoğaltma, seyreltme (dropout) gibi çeşitli metotlar kullanılabilir.



Şekil 9. YSA Hücresi

3.7.2. Çok Katmanlı Algılayıcı (MLP)

Bu tez çalışmasında kullanılan YSA modeli Çok Katmanlı Algılayıcıdır (Multilayer Perceptron - MLP). MLP, tam bağlı katmanlara sahip bir tür ileri beslemeli sinir ağıdır. En temel ve yaygın olarak kullanılan sinir ağı modellerinden biridir ve genellikle sınıflandırma ve regresyon gibi görevler için kullanılır.

Bir MLP, bir girdi katmanı, bir veya daha fazla gizli katman ve bir çıktı katmanından oluşur. Bir MLP'nin gizli katmanları, bitişik katmanlardaki nöronlara

ağırlıklar ve önyargılarla bağlanan nöronlardan oluşur. Ağırlıklar ve önyargılar, kayıp fonksiyonunu en aza indirmek ve modelin performansını iyileştirmek için eğitim sırasında güncellenir.

MLP'ler genellikle resimler veya tablo verileri gibi yapılandırılmış verileri içeren görevler için kullanılır. Ağdan geçerken giriş verilerine dönüşümler ve hesaplamalar uygulayarak verilerdeki karmaşık kalıpları ve ilişkileri öğrenebilirler (Heidari, Faris, Mirjalili, Aljarah, & Mafarja, 2020).

3.7.3. Veri Ayırma

Makine öğreniminde, bir veri setini üç kümeye bölmek yaygındır: Eğitim seti, doğrulama seti ve test seti. Bu setler, makine öğrenimi sürecinde farklı amaçlar için kullanılır.

- Eğitim seti: Modeli eğitmek için kullanılır. Kayıp fonksiyonunu en aza indirmek için modelin ağırlıklarını ve sapmalarını ayarlamak için kullanılır. Model, stokastik gradyan iniş (SGD) veya Adam gibi bir optimizasyon algoritması kullanılarak eğitilir.
- Doğrulama seti: Eğitim sürecinde modelin performansını değerlendirmek için kullanılır. Öğrenme oranı ve düzenleme gücü gibi modelin hiperparametrelerini ayarlamak için kullanılır. Doğrulama seti, modelin ağırlıklarını ve önyargıyı güncellemek için kullanılmaz.
- Test seti: Modelin nihai performansını değerlendirmek için kullanılır. Modelin genelleme yeteneğini veya modelin daha önce görmediği yeni veriler üzerinde ne kadar iyi performans gösterdiğini değerlendirmek için kullanılır.

Modelin performansını doğru bir şekilde değerlendirmek ve aşırı öğrenme önlemek için veri setini eğitim, doğrulama ve test setlerine bölmek önemlidir. Aşırı öğrenme, makine öğreniminde yaygın bir sorundur ve model çok karmaşık olduğunda ve eğitim verilerini mükemmel bir şekilde sığırdığında ortaya çıkar, ancak yeni, görünmeyen veriler üzerinde düşük performans gösterir. Veri kümesini eğitim, doğrulama ve test kümelerine bölmek, fazla öğrenme riskini azaltmaya yardımcı olur.

3.7.4. Aktivasyon Fonksiyonları

Aktivasyon fonksiyonu, YSA'daki bir nöronun çıkışına uygulanan matematiksel bir fonksiyondur. Aktivasyon fonksiyonu, aldığı girdiye göre nöronun "ateşleme" yapıp yapmayacağını belirler. Yani nöron çıktısının bir sonraki katmana geçip geçmeyeceğini belirler.

Sigmoid fonksiyonu, hiperbolik tanjant (Tanh) fonksiyonu, düzeltilmiş doğrusal birim (ReLU) fonksiyonu ve Leaky ReLU fonksiyonu dahil olmak üzere bir sinir ağında kullanılacak birkaç farklı aktivasyon fonksiyonu vardır. Her etkinleştirme fonksiyonunun kendine has özellikleri vardır ve farklı görev türleri için uygundur. Etkinleştirme işlevleri, bir sinir ağının işleyişinde çok önemli bir rol oynar ve bir model tasarlarırken ve eğitirken dikkate alınması gereken önemli bir faktördür.

3.7.4.1. Lineer Fonksiyon

Lineer bir fonksiyon, bir grafik üzerinde çizildiğinde düz bir çizgiyi tanımlayan matematiksel bir fonksiyondur. Formülü denklem 3.1'deki gibidir.

$$f(x) = ax + b \quad (3.1)$$

burada "a" ve "b" sabittir ve "x" giriş değişkenidir. "a" değeri doğrunun eğimini, "b" değeri ise y-kesen noktasını veya doğrunun y-eksenini kestiği noktayı belirler.

Lineer fonksiyonlar basit ve anlaşılması kolaydır ve matematik, istatistik ve makine öğreniminde yaygın olarak kullanılırlar. Makine öğreniminde, doğrusal işlevler genellikle doğrusal regresyon ve destek vektör makineleri gibi daha karmaşık modellerin temeli olarak kullanılır.

Lineer fonksiyonlar, onları makine öğrenimi görevleri için yararlı kılan çeşitli özelliklere sahiptir. Parametreler, gradyan iniş gibi basit optimizasyon algoritmaları kullanılarak öğrenilebildiğinden, optimize edilmesi kolaydır. Girdi değişkenlerinin katsayıları, modeldeki her bir değişkenin görece önemini anlamak için kullanılacağından, bunların yorumlanması da kolaydır.

Bununla birlikte, lineer fonksiyonların bazı sınırlamaları vardır. Yalnızca düz bir çizgiyle modellenen görevler için uygundur ve verilerdeki karmaşık kalıpları veya

ilişkileri yakalayamayabilirler. Bu durumlarda doğrusal olmayan fonksiyonlar veya YSA gibi daha karmaşık modeller gerekebilir.

3.7.4.2. Tanh

Tanh fonksiyonu, herhangi bir giriş değerini -1 ile 1 arasında bir çıkış değerine eşleyen matematiksel bir işlevdir. Formülü denklem 3.2'deki gibidir.

$$f(x) = \tanh(x) = \frac{\exp(x) - \exp(-x)}{\exp(x) + \exp(-x)} \quad (3.2)$$

Tanh fonksiyonu, orijine göre simetrik olan düzgün, S-şekilli bir eğridir. Herhangi bir girdi değerini 0 ile 1 arasında bir çıktı değerine eşleyen sigmoid fonksiyonuna benzer, ancak daha geniş bir çıktı değerleri aralığına sahiptir.

Tanh fonksiyonu, YSA'da ve makine öğrenimi modellerinde sıklıkla aktivasyon fonksiyonu olarak kullanılır. Onu bu görevler için yararlı kılan birtakım özelliklere sahiptir. Türevlenebilir, yani bir türevi vardır ve gradyan tabanlı optimizasyon algoritmalarında kullanılabilir. Tanh fonksiyonu, -1 veya 1'e yakın değerler verebildiğinden, sınıflandırma içeren görevler için de çok uygundur. Ancak Tanh fonksiyonunun diğer aktivasyon fonksiyonlarına göre bazı sınırlamaları vardır. Kaybolan gradyanlardan muzdarip olabilir. Bu, giriş değerleri büyüdükçe fonksiyonun gradyanlarının çok küçük hale geldiği anlamına gelir. Bu durum gizli katmanlarda Tanh fonksiyonunu kullanırken modelin öğrenmesini zorlaştırabilir. Ayrıca, üstel fonksiyonun hesaplanmasını içerdiğinden, hesaplama maliyeti açısından pahalı olabilir. Bu sınırlamalara rağmen Tanh fonksiyonu, bir dizi görevdeki iyi performansı nedeniyle makine öğreniminde ve YSA'nda hala yaygın olarak kullanılmaktadır.

3.7.4.3. Sigmoid

Sigmoid fonksiyonu, herhangi bir girdi değerini 0 ile 1 arasında bir çıktı değerine eşleyen matematiksel bir fonksiyondur. Formülü denklem 3.3'deki gibidir.

$$f(x) = \frac{1}{1 + \exp(-x)} \quad (3.3)$$

Sigmoid fonksiyonu, makine öğrenimi ve YSA'nda yaygın olarak kullanılan pürüzsüz, S şeklinde bir eğridir. Onu bu görevler için yararlı kılan birtakım özelliklere sahiptir. Türevlenebilir, yani bir türevi vardır ve gradyan tabanlı optimizasyon algoritmalarında kullanılabilir. Sigmoid fonksiyonu 0 veya 1'e yakın değerler verebildiğinden, sınıflandırma içeren görevler için de çok uygundur.

Sigmoid fonksiyonu genellikle, belirli bir sınıfın olasılığını tahmin etmek için kullanılabilir. Bir ikili sınıflandırma modelinin çıktı katmanında bir aktivasyon fonksiyonu olarak kullanılır. Örneğin, sigmoid fonksiyonunun çıktısı 0'a yakınsa, model pozitif sınıfın düşük olasılığını tahmin edecek ve çıktı 1'e yakınsa, model pozitif sınıfın yüksek olasılığını tahmin edecektir. Ancak sigmoid fonksiyonunun diğer aktivasyon fonksiyonlarına göre bazı sınırlamaları vardır. Kaybolan gradyanlardan muzdarip olabilir. Bu, giriş değerleri büyüdükçe fonksiyonun gradyanlarının çok küçük hale geldiği anlamına gelir. Bu durum gizli katmanlarda sigmoid fonksiyonunu kullanırken modelin öğrenmesini zorlaştırabilir. Ayrıca, üstel fonksiyonun hesaplanmasını içerdiğinden, hesaplama maliyeti açısından pahalı olabilir. Bu sınırlamalara rağmen, sigmoid fonksiyonu, bir dizi görevdeki iyi performansı nedeniyle makine öğreniminde ve YSA'nda hala yaygın olarak kullanılmaktadır.

3.7.4.4. Softmax

Softmax fonksiyonu, makine öğreniminde ve YSA'nda sınıflandırma görevleri için sıklıkla kullanılan matematiksel bir işlemdir. Bir dizi keyfi gerçek değerli puanları, olasılıkların toplamının 1'e eşit olduğu bir olasılık dağılımına dönüştürmek için kullanılır. Softmax fonksiyonu denklem 3.4'deki gibi tanımlanmaktadır.

$$f(x_i) = \exp(x_i) / \sum \exp(x_j) \quad (3.4)$$

burada x_i , i'nci sınıf için girdi değeridir ve x_j , j'inci sınıf için girdi değeridir. Üs alma, tüm çıkış değerlerinin pozitif olmasını sağlar ve toplama göre normalleştirme, çıkış değerlerinin toplamının 1 olmasını sağlar.

Softmax fonksiyonu, onu sınıflandırma görevleri için yararlı kılan bir dizi özelliğe sahiptir. Pürüzsüz, türevlenebilir bir fonksiyondur, yani bir türevi vardır ve gradyan tabanlı optimizasyon algoritmalarında kullanılabilir. Ayrıca, çıktı değerlerinin 0 ile 1

arasında sınırlandırılması, çıktının olasılıklar olarak yorumlanmasını kolaylaştıran arzu edilen bir özelliğe sahiptir.

Softmax fonksiyonu genellikle, her bir sınıfın olasılığını tahmin etmek için kullanılabilen çok sınıflı sınıflandırma görevleri için bir sinir ağının çıktı katmanında kullanılır. Örneğin, belirli bir girdi için softmax fonksiyonunun çıktısı $[0.1, 0.2, 0.7]$ ise, model birinci sınıf için %10, ikinci sınıf için %20 ve üçüncü sınıf için %70 olasılıkla olduğunu tahmin edecektir.

Birçok avantajına rağmen, softmax fonksiyonunun bazı sınırlamaları vardır. Her bir girdi değeri için üstel fonksiyonun hesaplanmasını içerdiğinden, hesaplama maliyeti açısından pahalı olabilir. Ayrıca girdi değerlerinin ölçeğine duyarlı olabilir ve bu da bazı durumlarda optimize etmeyi zorlaştırabilir.

3.7.4.5. ReLU

ReLU fonksiyonu, makine öğrenimi ve YSA'nda sıklıkla aktivasyon fonksiyonu olarak kullanılan matematiksel bir işlemdir. ReLU fonksiyonu denklemin 3.5'deki gibi tanımlanmaktadır.

$$f(x) = \max(0, x) \quad (3.5)$$

ReLU fonksiyonu, sıfırdan küçük herhangi bir giriş değerini sıfıra ve sıfırdan büyük veya sıfıra eşit herhangi bir giriş değerini giriş değerinin kendisine eşleyen basit bir işlemdir. Sıfırdan büyük veya sıfıra eşit giriş değerleri için 1 eğim ve sıfırdan küçük giriş değerleri için 0 eğim ile grafiksel olarak yarı düzeltilmiş bir çizgi olarak gösterilir.

ReLU fonksiyonu, onu makine öğrenimi görevleri için yararlı kılan bir dizi özelliğe sahiptir. Basit, türevlenebilir bir fonksiyondur, yani bir türevi vardır ve gradyan tabanlı optimizasyon algoritmalarında kullanılabilir. Üs alma veya normalleştirme gibi pahalı işlemleri içermediği için hesaplama açısından da verimlidir.

ReLU fonksiyonu genellikle, modelin verilerdeki daha karmaşık kalıpları öğrenmesine izin vererek öğrenme sürecini iyileştirmeye yardımcı olabileceği bir sinir ağının gizli katmanlarında kullanılır. Modeli eğitmenin hesaplama maliyetini azaltmaya yardımcı olabileceğinden, özellikle büyük, seyrek veri kümelerini içeren görevler için çok uygundur. Ancak, ReLU fonksiyonunun diğer etkinleştirme işlevlerine kıyasla bazı sınırlamaları vardır. Ağdaki bazı nöronların etkisiz hale geldiği ve öğrenmeyi durdurduğu

"ölmekte olan ReLU" probleminden muzdarip olabilir. Bu, sıfırdan küçük giriş değerleri için küçük bir negatif eğime izin veren Leaky ReLU fonksiyonu gibi ReLU fonksiyonunun varyantları kullanılarak ele alınabilir.

3.7.4.6. Leaky ReLU

Sızdıran doğrultulmuş doğrusal birim (Leaky ReLU) fonksiyonu, makine öğrenimi ve YSA'nda bir aktivasyon fonksiyonu olarak kullanılan düzeltilmiş doğrusal birim (ReLU) fonksiyonunun bir çeşididir. Leaky ReLU fonksiyonu denklem 3.6'deki gibi tanımlanmaktadır.

$$f(x) = \max(\alpha * x, x) \quad (3.6)$$

burada alfa küçük bir sabittir ve tipik olarak 0,01'e ayarlanır. Leaky ReLU fonksiyonu, sıfırdan küçük herhangi bir giriş değerini sıfıra ve sıfırdan büyük veya sıfıra eşit herhangi bir giriş değerini giriş değerinin kendisine eşleyen ReLU fonksiyonun benzer. Ancak Leaky ReLU fonksiyonu, sıfırdan küçük giriş değerleri için sıfıra ayarlamak yerine küçük bir negatif eğime izin verir.

Leaky ReLU fonksiyonu, ağdaki bazı nöronlar devre dışı kaldığında ve öğrenmeyi durdurduğunda ortaya çıkan "ölmekte olan ReLU" sorununu ele almak için tanıtılmıştır. Bu, ReLU fonksiyonun giriş değerleri sürekli olarak negatif olduğunda ortaya çıkabilir ve çıkışın sıfır olmasına neden olur. Leaky ReLU fonksiyonu, ölmekte olan ReLU sorununu hafifletmeye ve öğrenme sürecini iyileştirmeye yardımcı olabilecek bu girdi değerleri için küçük bir gradyanın geçmesine izin verir.

Leaky ReLU fonksiyonu, onu makine öğrenimi görevleri için yararlı kılan bir dizi özelliğe sahiptir. Basit, türevlenebilir bir fonksiyondur, yani bir türevi vardır ve gradyan tabanlı optimizasyon algoritmalarında kullanılabilir. Üs alma veya normalleştirme gibi pahalı işlemleri içermediği için hesaplama açısından da verimlidir. Ancak Leaky ReLU fonksiyonu, diğer etkinleştirme işlevlerine kıyasla bazı sınırlamalara sahiptir. Bazı görevlerde ReLU fonksiyonu kadar iyi performans göstermeyebilir ve hiperparametre alfanın daha dikkatli ayarlanmasını gerektirebilir. Ayrıca girdi değerlerinin ölçeğine karşı da hassastır ve bu da bazı durumlarda optimize etmeyi zorlaştırabilir.

3.7.5. Optimizasyon Algoritmaları

Optimizasyon algoritması, bir probleme en uygun çözümleri bulmak için kullanılan bir yöntem veya prosedürdür. Sinir ağları bağlamında, ağın kayıp fonksiyonunu en aza indiren optimum ağırlık ve önyargı setini bulmak için optimizasyon algoritmaları kullanılır. Sinir ağlarını eğitmek için kullanılacak birçok farklı optimizasyon algoritması vardır. Optimizasyon algoritmasının seçimi, bir sinir ağının performansı üzerinde önemli bir etkiye sahip olabilir ve belirli bir problem için en iyi olanı bulmak için farklı algoritmalarla denemeler yapmak genellikle önemlidir.

3.7.5.1. Adam

Adam (Adaptive Moment Estimation), makine öğrenimi ve YSA'nda yaygın olarak kullanılan bir optimizasyon algoritmasıdır. Modeldeki her parametre için öğrenme oranını uyarlamalı olarak ayarlamak üzere tasarlanmış gradyan iniş algoritmasının bir uzantısıdır.

Adam algoritması, geçmiş gradyanların ve geçmiş kare gradyanların üstel olarak azalan bir ortalamasını hesaplar ve bu ortalamaları her parametre için öğrenme oranını uyarlamalı olarak ayarlamak için kullanır. Bu, Adam algoritmasının optimizasyon sürecinin başında hızlı ilerlemesini ve parametreler için optimal değerlere yaklaştıkça yavaşlamasını sağlar.

Adam algoritmasının uygulanması basittir ve çeşitli farklı optimizasyon işlevleriyle birlikte kullanılabilir. İyi performansı ve hesaplama verimliliği nedeniyle derin öğrenme modellerini eğitmek için popüler bir seçimdir. Ancak Adam algoritmasının diğer optimizasyon algoritmalarına göre bazı sınırlamaları vardır. Model parametrelerinin başlatılmasına duyarlı olabilir ve hiperparametrelerin dikkatli bir şekilde ayarlanmasını gerektirebilir. Ayrıca bazı problem türleri için diğer algoritmalarından daha az verimli olabilir. Bu sınırlamalara rağmen Adam algoritması, iyi performansı ve uygulama kolaylığı nedeniyle makine öğrenimi ve YSA'nda hala yaygın olarak kullanılmaktadır.

3.7.5.2. SGD

Stokastik gradyan iniş (SGD), makine öğrenimi ve YSA'nda yaygın olarak kullanılan bir optimizasyon algoritmasıdır. Her yinelemede küçük bir veri grubu kullanarak model parametrelerine göre kayıp fonksiyonunun gradyanını tahmin ederek büyük veri kümelerini işlemek için tasarlanmış gradyan iniş algoritmasının bir uzantısıdır.

SGD algoritması, küçük bir veri grubu üzerinde hesaplanan gradyanı kullanarak, model parametrelerini kayıp fonksiyonunun negatif gradyanı yönünde yinelemeli olarak güncelleyerek çalışır. Bu, verileri küçük gruplar halinde işleyebildiğinden, veri kümesi belleğe sığmayacak kadar büyük olduğunda bile SGD algoritmasının ilerleme kaydetmesine olanak tanır.

SGD algoritmasının uygulanması basittir ve çeşitli farklı optimizasyon fonksiyonlarıyla birlikte kullanılabilir. Hesaplama verimliliği ve büyük veri kümelerini işleme yeteneği nedeniyle büyük ölçekli makine öğrenimi modellerini eğitmek için popüler bir seçimdir. Ancak, SGD algoritmasının diğer optimizasyon algoritmalarına kıyasla bazı sınırlamaları vardır. Model parametrelerinin başlatılmasına duyarlı olabilir ve öğrenme hızı ile diğer hiperparametrelerin dikkatli bir şekilde ayarlanmasını gerektirebilir. Ayrıca bazı problem türleri için diğer algoritmalarından daha az verimli olabilir. Bu sınırlamalara rağmen, SGD algoritması, iyi performansı ve uygulama kolaylığı nedeniyle makine öğrenmesi ve YSA'nda hala yaygın olarak kullanılmaktadır.

3.7.5.3. AdaGrad

AdaGrad (Adaptive Gradient Algorithm), makine öğrenimi ve YSA'nda yaygın olarak kullanılan bir optimizasyon algoritmasıdır. Geçmiş gradyan bilgisine dayalı olarak modeldeki her parametre için öğrenme oranını uyarlamalı olarak ayarlamak üzere tasarlanmış gradyan iniş algoritmasının bir uzantısıdır.

AdaGrad algoritması, zaman içinde her parametrenin kare gradyanını toplayarak ve bu bilgiyi her parametre için öğrenme oranını ölçeklendirerek. Bu sayede, AdaGrad algoritmasının seyrek parametrelerde daha büyük güncellemeler yapmasına ve sık parametreler için daha küçük güncellemeler yapmasına izin vermekte ve modelin yakınsamasını hızlandırmaya yardımcı olmaktadır.

AdaGrad algoritmasının uygulanması basittir ve çeşitli farklı optimizasyon işlevleriyle birlikte kullanılabilir. İyi performansı ve her parametre için öğrenme oranını uyarlamalı olarak ayarlama yeteneği nedeniyle makine öğrenimi modellerini eğitmek için popüler bir seçimdir. Ancak AdaGrad algoritmasının diğer optimizasyon algoritmalarına göre bazı sınırlamaları vardır. Model parametrelerinin başlatılmasına duyarlı olabilir ve hiperparametrelerin dikkatli bir şekilde ayarlanmasını gerektirebilir. Hesaplama açısından pahalı olabilecek kareli gradyanların birikmesini gerektirdiğinden, bazı problem türleri için diğer algoritmalarından daha az verimli olabilir.

Bu sınırlamalara rağmen AdaGrad algoritması, iyi performansı ve uygulama kolaylığı nedeniyle makine öğrenimi ve YSA'da hala yaygın olarak kullanılmaktadır.

3.7.5.4. AdaDelta

Adadelta, sinir ağlarını ve diğer makine öğrenme modellerini eğitmek için kullanılan bir optimizasyon algoritmasıdır. Adagrad algoritmasının bir çeşididir ve Adagrad'ın bazı sınırlamalarını ele almak için geliştirilmiştir.

Adadelta, geçmiş gradyan bilgisine dayalı olarak modelin öğrenme oranını ayarlayan uyarlanabilir bir öğrenme oranı optimizasyon algoritmasıdır. Geleneksel optimizasyon algoritmalarında olduğu gibi sabit bir öğrenme oranı kullanmak yerine, öğrenme oranını ölçeklendirmek için geçmiş kareli gradyanların üstel olarak azalan bir ortalamasını kullanır. Bu, öğrenme oranının eğitim verilerinin belirli özelliklerine uyum sağlamasına izin verir ve modelin daha hızlı ve doğru bir şekilde yakınsamasına yardımcı olabilir.

Adadelta'nın temel özellikleri; Öğrenme oranını geçmiş gradyan bilgilerine göre otomatik olarak ayarladığından, kullanıcının öğrenme oranını manuel olarak ayarlamasını gerektirmez. Yalnızca mevcut mini toplu veri kümesiyle ilgili parametreleri güncellediğinden, seyrek verileri ve büyük veri kümelerini verimli bir şekilde işleyebilir. Geçmiş gradyan bilgilerine dayalı olarak öğrenme oranını ölçeklendirdiği için modelin salınımlardan kaçınmasına ve daha hızlı ve doğru bir şekilde yakınsamasına yardımcı olabilir.

Adadelta popüler bir optimizasyon algoritmasıdır ve genellikle sinir ağlarında ve diğer makine öğrenimi modellerinde kullanılır. Eğitim verilerinin büyük ve/veya seyrek olduğu durumlarda özellikle yararlıdır ve çok çeşitli görevlerde iyi performans gösterdiği gösterilmiştir.

3.7.5.5. NAG

Nesterov hızlandırılmış gradyan (NAG), modelin yakınsamasını hızlandırmak ve optimizasyon sürecini iyileştirmek için genellikle stokastik gradyan iniş (SGD) ve diğer optimizasyon algoritmalarıyla birlikte kullanılan bir tekniktir. Gradyanın "ileri" tahminini kullanarak momentum terimini düzeltmek için tasarlanmış momentum tekniğinin bir uzantısıdır.

NAG tekniği, momentum tekniğinde olduğu gibi gradyan güncellemesine bir momentum terimi ekleyerek, ancak mevcut konumdaki gradyan yerine gradyanın "ileriye dönük" bir tahminini kullanarak çalışır. Bu, optimizasyon algoritmasının negatif gradyan yönünde daha büyük adımlar atmasına ve modelin yakınsamasını iyileştirmeye yardımcı olabilecek momentum terimini düzeltmesine olanak tanır.

NAG tekniği, optimizasyon sürecini iyileştirmek ve modelin yakınsamasını hızlandırmak için yararlı bir araç olabilir. Yerel minimumlara takılmayı önlemeye ve modelin genelleme performansını iyileştirmeye yardımcı olabileceğinden, özellikle yüksek boyutlu parametre uzayları veya karmaşık kayıp manzaraları ile ilgili problemler için kullanışlıdır. Bununla birlikte, NAG tekniğinin bazı sınırlamaları vardır. En iyi performansı elde etmek için momentum hiperparametresinin dikkatli bir şekilde ayarlanmasını gerektirebilir ve her tür problem için uygun olmayabilir. Ayrıca, model parametrelerinin başlatılmasına karşı hassastır ve en iyi performansı elde etmek için dikkatli bir başlatma gerektirebilir.

3.7.5.6. RMSProp

RMSProp (Root Mean Square Propagation), makine öğrenimi ve YSA'nda yaygın olarak kullanılan bir optimizasyon algoritmasıdır. Geçmiş gradyan bilgisine dayalı olarak modeldeki her parametre için öğrenme oranını uyarlamalı olarak ayarlamak üzere tasarlanmış gradyan iniş algoritmasının bir uzantısıdır.

RMSProp algoritması, zaman içinde her parametre için kare gradyanını toplayarak ve bu bilgiyi her parametre için öğrenme oranını ölçeklendirmek için çalışır. Bu, RMSProp algoritmasının sık olmayan parametrelerde daha büyük güncellemeler ve sık parametrelerde daha küçük güncellemeler yapmasına izin vererek modelin yakınsamasını hızlandırmaya yardımcı olabilir.

RMSProp algoritmasının uygulanması basittir ve çeşitli farklı optimizasyon işlevleriyle birlikte kullanılabilir. İyi performansı ve her parametre için öğrenme oranını uyarlamalı olarak ayarlama yeteneği nedeniyle makine öğrenimi modellerini eğitmek için popüler bir seçimdir. Ancak, RMSProp algoritmasının diğer optimizasyon algoritmalarına kıyasla bazı sınırlamaları vardır. Model parametrelerinin başlatılmasına duyarlı olabilir ve hiperparametrelerin dikkatli bir şekilde ayarlanmasını gerektirebilir. Hesaplama açısından pahalı olabilecek kareli gradyanların birikmesini gerektirdiğinden, bazı problem türleri için diğer algoritmalarından daha az verimli olabilir. Bu sınırlamalara rağmen, RMSProp algoritması, iyi performansı ve uygulama kolaylığı nedeniyle makine öğrenimi ve YSA’nda hala yaygın olarak kullanılmaktadır.

3.7.6. Hata Fonksiyonları

Hata fonksiyonu olarak da bilinen bir kayıp fonksiyonu, bir modelin tahmin edilen çıktısı ile gerçek çıktı arasındaki farkı ölçen bir işlevdir. Makine öğreniminde, modelin performansını değerlendirmek ve eğitim sürecini yönlendirmek için kayıp fonksiyonu kullanılır.

Kayıp fonksiyonu, tek bir eğitim örneği veya bir grup örnek için kaybı veya hatayı hesaplamak için kullanılır. Kayıp daha sonra, toplam kaybı en aza indirmek için modelin ağırlıklarını güncellemek için kullanılır. Eldeki göreve bağlı olarak makine öğreniminde kullanılacak birçok farklı türde kayıp fonksiyonu vardır. Modelin performansı üzerinde önemli bir etkiye sahip olabileceğinden, eldeki görev için uygun bir kayıp fonksiyonu seçmek önemlidir. Kayıp fonksiyonu, verilerin özelliklerine ve modelin amaçlarına göre seçilmelidir.

3.7.6.1. Ortalama Kare Hatası (MSE)

MSE, gerileme görevleri için makine öğreniminde kullanılan yaygın bir hata fonksiyonudur. Modelin tahmin edilen çıktısıyla gerçek çıktı arasındaki ortalama kare farkını ölçer. MSE formülü denklem 3.7’de gösterilmektedir.

$$MSE = (1/n) * \sum (y_{pred} - y)^2 \quad (3.7)$$

burada y_{pred} tahmin edilen çıktıdır, y gerçek çıktıdır ve n örnek sayısıdır.

MSE, ortalama karesel hatanın bir ölçüsüdür ve büyük hatalara karşı hassastır. Büyük hataları küçük hatalardan daha fazla cezalandırır, bu da bazı durumlarda faydalı olabilir. MSE'nin aşağıdakiler de dahil olmak üzere çeşitli avantajları vardır:

- Yorumlaması kolaydır: MSE skaler bir değerdir ve anlaşılması ve diğer modellerle karşılaştırılması kolaydır.
- Türevlenebilir: MSE türevlenebilir bir işlemdir, yani gradyan iniş ve diğer optimizasyon algoritmalarıyla birlikte kullanılabilir.
- Usludur: MSE, optimize etmeyi kolaylaştırabilen dışbükey ve benzersiz bir minimuma sahip olmak gibi güzel matematiksel özelliklere sahiptir.

Bununla birlikte, MSE'nin aşağıdakiler de dahil olmak üzere bazı sınırlamaları vardır:

- Aykırı değerlere karşı hassastır: MSE, veriler aykırı değerler içeriyorsa sorunlu olabilen büyük hatalara karşı hassastır.
- Sağlam değildir: MSE, aşırı değerlerin veya aykırı değerlerin varlığına karşı dayanıklı değildir ve verilerin dağılımından etkilenebilir.

Sınırlamalarına rağmen MSE, makine öğrenimindeki hata işlevleri için popüler bir seçimdir ve çeşitli regresyon görevlerinde yaygın olarak kullanılır.

3.7.6.2. Kök Ortalama Kare Hatası (RMSE)

Kök ortalama kare hatası (RMSE), bir modelin tahmin edilen çıktısı ile gerçek çıktı arasındaki farkın bir ölçüsüdür. Makine öğreniminde regresyon görevleri için kullanılan yaygın bir ölçümdür ve tahmin edilen ile gerçek çıktı arasındaki ortalama farkın bir ölçüsüdür. RMSE formülü denklem 3.8'de gösterilmektedir.

$$RMSE = \sqrt{(1/n) * \sum (y_{pred} - y)^2} \quad (3.8)$$

burada y_{pred} tahmin edilen çıktıdır, y gerçek çıktıdır ve n örnek sayısıdır.

RMSE, ortalama kare hatanın bir ölçüsüdür ve büyük hatalara karşı hassastır. Büyük hataları küçük hatalardan daha fazla cezalandırır, bu da bazı durumlarda faydalı olabilir. RMSE, yorumlanması ve diğer modellerle karşılaştırılması kolay olduğu için genellikle makine öğreniminde bir değerlendirme ölçütü olarak kullanılır. MSE gibi, RMSE'nin de aşağıdakiler dahil çeşitli faydaları vardır:

- Yorumlaması kolaydır: RMSE skaler bir değerdir ve anlaşılması ve diğer modellerle karşılaştırılması kolaydır.
- Türevlenebilir: RMSE, türevlenebilir bir işlevdir, yani gradyan iniş ve diğer optimizasyon algoritmalarıyla birlikte kullanılabilir.
- Usludur: RMSE, optimize etmeyi kolaylaştırabilen dışbükey ve benzersiz bir minimuma sahip olmak gibi güzel matematiksel özelliklere sahiptir.

Bununla birlikte, RMSE'nin aşağıdakiler de dahil olmak üzere bazı sınırlamaları vardır:

- Aykırı değerlere karşı hassastır: RMSE, veriler aykırı değerler içeriyorsa sorunlu olabilen büyük hatalara karşı hassastır.
- Sağlam değildir: RMSE, aşırı değerlerin veya aykırı değerlerin varlığına karşı dayanıklı değildir ve verilerin dağılımından etkilenebilir.

Sınırlamalarına rağmen RMSE, makine öğrenimindeki değerlendirme ölçütleri için popüler bir seçimdir ve çeşitli regresyon görevlerinde yaygın olarak kullanılır.

3.7.6.3. Ortalama Mutlak Hata (MAE)

Ortalama mutlak hata (MAE), bir modelin tahmin edilen çıktısı ile gerçek çıktı arasındaki farkın bir ölçüsüdür. Makine öğreniminde regresyon görevleri için kullanılan yaygın bir ölçümdür ve tahmin edilen ile gerçek çıktı arasındaki ortalama mutlak farkın bir ölçüsüdür. MAE formülü denklem 3.9'de gösterilmektedir.

$$MAE = (1/n) * \sum |y_{pred} - y| \quad (3.9)$$

burada y_{pred} tahmin edilen çıktıdır, y gerçek çıktıdır ve n örnek sayısıdır.

MAE, ortalama mutlak hatanın bir ölçüsüdür ve büyük hatalara MSE'den daha az duyarlıdır. Bazı durumlarda yararlı olabilecek MSE kadar büyük hataları cezalandırmaz. MAE, yorumlanması ve diğer modellerle karşılaştırılması kolay olduğu için genellikle makine öğreniminde bir değerlendirme ölçütü olarak kullanılır. MSE ve RMSE gibi, MAE'nin aşağıdakiler de dahil olmak üzere çeşitli faydaları vardır:

- Yorumlaması kolaydır: MAE skaler bir değerdir ve anlaşılması ve diğer modellerle karşılaştırılması kolaydır.

- Türevlenebilir: MAE türevlenebilir bir işlevdir, yani gradyan iniş ve diğer optimizasyon algoritmalarıyla birlikte kullanılabilir.
- Usludur: MAE, optimize etmeyi kolaylaştırabilecek dışbükey ve benzersiz bir minimuma sahip olmak gibi güzel matematiksel özelliklere sahiptir.

Bununla birlikte, MAE'nin aşağıdakiler de dahil olmak üzere bazı sınırlamaları vardır:

- Büyük hatalara karşı o kadar duyarlı değildir: MAE, büyük hatalara MSE'den daha az duyarlıdır; bu, büyük hataların tanımlanması önemliyse sorunlu olabilir.
- Sağlam değildir: MAE, aşırı değerlerin veya aykırı değerlerin varlığına karşı dayanıklı değildir ve verilerin dağılımından etkilenebilir.

MAE, sınırlamalarına rağmen, makine öğrenimindeki değerlendirme ölçütleri için popüler bir seçimdir ve çeşitli regresyon görevlerinde yaygın olarak kullanılır.

3.7.6.4. Ortalama Mutlak Yüzde Hata (MAPE)

Ortalama mutlak yüzde hata (MAPE), bir modelin tahmin edilen çıktısı ile gerçek çıktı arasındaki farkın bir ölçüsüdür. Makine öğreniminde regresyon görevleri için kullanılan yaygın bir ölçümdür ve tahmin edilen değer ile gerçek çıktı arasındaki ortalama mutlak yüzde farkının bir ölçüsüdür. MAPE formülü denklem 3.10'da gösterilmektedir.

$$MAPE = (1/n) * \sum |(y_{pred} - y)/y| \quad (3.10)$$

burada y_{pred} tahmin edilen çıktıdır, y gerçek çıktıdır ve n örnek sayısıdır.

MAPE, ortalama mutlak yüzde hatasının bir ölçüsüdür ve büyük hatalara MSE'den daha az duyarlıdır. Bazı durumlarda yararlı olabilecek MSE kadar büyük hataları cezalandırmaz. MAPE, yorumlanması ve diğer modellerle karşılaştırılması kolay olduğu için genellikle makine öğreniminde bir değerlendirme ölçütü olarak kullanılır. MSE, RMSE ve MAE gibi, MAPE'nin de aşağıdakiler dahil birçok faydası vardır:

- Yorumlanması kolaydır: MAPE skaler bir değerdir ve anlaşılması ve diğer modellerle karşılaştırılması kolaydır.
- Usludur: MAPE, dışbükey olma ve benzersiz bir minimuma sahip olma gibi optimize etmeyi kolaylaştırabilecek güzel matematiksel özelliklere sahiptir.

MAPE'nin aşağıdakiler de dahil olmak üzere bazı sınırlamaları vardır:

- Türevlenemez: MAPE türevlenebilir bir işlev değildir, yani gradyan iniş ve diğer optimizasyon algoritmalarıyla kullanılamaz.
- $y = 0$ için tanımlanmamıştır: MAPE, $y = 0$ olduğunda tanımlanmamıştır; bu, veriler sıfır içeriyorsa veya gerçek çıktı sıfıra yakınsa sorun olabilir.
- Sağlam değildir: MAPE, aşırı değerlerin veya aykırı değerlerin varlığına karşı dayanıklı değildir ve verilerin dağılımından etkilenebilir.

Sınırlamalarına rağmen MAPE, makine öğrenimindeki değerlendirme ölçütleri için popüler bir seçimdir ve çeşitli regresyon görevlerinde yaygın olarak kullanılır.

3.7.6.5. Ortalama Kare Logaritmik Hata (MSLE)

Ortalama Karesel Logaritmik Hata (MSLE), bir regresyon modelindeki kayıp veya hatanın bir ölçüsüdür. Öngörülen değerler ile gerçek değerler arasındaki logaritmik hataların karesinin ortalaması olarak tanımlanır. MSLE formülü denklem 3.11'de gösterilmektedir.

$$L = (1/n) * \sum ((\log(1+y) - \log(1+y_{pred}))^2) \quad (3.11)$$

burada y gerçek değerdir, y_{pred} tahmin edilen değerdir, n örnek sayısıdır ve L MSLE kaybıdır.

MSLE kayıp fonksiyonu, tahmin edilen değerler gerçek değerlere yakın olduğunda minimize olma özelliğine sahiptir. Genellikle hedef değişkenin pozitif bir sayı olduğu ve hataların nispeten küçük olduğu regresyon problemlerinde kullanılır, çünkü aykırı değerlere ortalama karesel hata (MSE) kayıp fonksiyonundan daha az duyarlıdır.

MSLE, hisse senedi fiyatlarını veya enerji tüketimini tahmin etmek gibi regresyon görevleri için eğitilmiş sinir ağlarında ve diğer makine öğrenimi modellerinde genellikle bir kayıp işlevi olarak kullanılır. Makine öğrenmesi alanında yaygın olarak kullanılan ve köklü bir kayıp fonksiyonudur.

3.7.7. Geriye Yayılım

Geri yayılım, YSA ve diğer makine öğrenimi modellerini eğitmek için kullanılan bir algoritmadır. Modelin tahmin edilen çıktısı ile gerçek çıktısı arasındaki hatayı en aza

indirmek için modelin ağırlıklarını ve sapmalarını ayarlamak için kullanılan denetimli bir öğrenme algoritmasıdır.

Geri yayılım, gradyan inişini gerçekleştirmek için model parametrelerine göre kayıp fonksiyonunun gradyanını kullanarak çalışır. Öngörülen çıktıyı üretmek için girdi verilerini model boyunca ileri doğru yayarak başlar ve ardından tahmin edilen çıktı ile gerçek çıktı arasındaki hatayı hesaplar. Ardından, hatayı en aza indirmek için modelin ağırlıklarını ve eğilimlerini ayarlayarak bu hatayı model boyunca geriye doğru yayar (Rumelhart et al., 1986).

Geri yayılım, derin öğrenme modellerini eğitmek için gerekli olan güçlü ve yaygın olarak kullanılan bir algoritmadır. CNN, RNN ve YSA dahil olmak üzere birçok makine öğrenimi modeli türü için eğitim sürecinin önemli bir bileşenidir. Bununla birlikte, geriye yayılımın bazı sınırlamaları vardır. Büyük modeller ve veri kümeleri için hesaplama açısından pahalı olabilir ve derin ağları eğitmeyi zorlaştırabilen kaybolan gradyan probleminden muzdarip olabilir. Bu sınırlamalara rağmen, geri yayılım hala yaygın olarak kullanılmaktadır ve makine öğrenimi modellerini eğitmek için önemli bir araçtır.

3.7.8. Regresyon Problemi

YSA kullanarak bir regresyon problemini çözmek için izleyebileceğiniz birkaç adım vardır:

- Verileri ön işleme: Verileri önceden işlemek, herhangi bir makine öğrenimi görevinde önemli bir adımdır ve özellikle regresyon problemleri için önemlidir. Ön işleme adımları, verilerin temizlenmesini, eksik değerlerin işlenmesini, verilerin normalleştirilmesini veya standardize edilmesini ve verilerin eğitim, doğrulama ve test kümelerine bölünmesini içerebilir.
- Model mimarisini tanımlama: Model mimarisi, katman sayısı, her katmandaki nöron sayısı ve kullanılan aktivasyon fonksiyon türleri dahil olmak üzere sinir ağının yapısıdır. Eldeki göreve uygun bir model mimarisi seçmek önemlidir.
- Modeli eğitimi: Model mimarisi tanımlandıktan sonra, model bir eğitim veri kümesi kullanılarak eğitilebilir. Model, kayıp fonksiyonunu en aza indirmek için nöronların ağırlıklarını ve yanlılıklarını ayarlayarak eğitilir. Bu genellikle SGD veya Adam gibi bir optimizasyon algoritması kullanılarak yapılır.

- Modeli deęerlendirmesi: Model eęitildikten sonra, performansını bir doęrulama veya test veri kümesi üzerinde deęerlendirmek önemlidir. Deęerlendirme MSE veya RMSE gibi çeşitli deęerlendirme ölçütleri kullanılarak yapılabilir.
- Modelde ince ayar: Model istedięiniz kadar iyi performans göstermiyorsa, modelde ince ayar yapmak için atabileceęiniz birkaç adım vardır. Bu, model mimarisini ayarlamayı, optimizasyon algoritmasını deęiştirmeyi veya bırakma veya aęırlık azaltma gibi düzenleme tekniklerini eklemeyi içerebilir.
- Tahminlerin yapılması: Model eęitilip ince ayar yapıldıktan sonra, yeni, görünmeyen veriler üzerinde tahminler yapmak için kullanılabilir.

3.7.9. Doğruluk Fonksiyonu

Doęruluk, bir makine öğrenimi modelinin performansını deęerlendirmek için kullanılan yaygın bir ölçüdür. Modelin, belirli bir girdi verisi kümesi için çıktıyı doęru bir şekilde sınıflandırabildięinin veya tahmin edebildięinin bir ölçüsüdür.

Sınıflandırma görevleri için doęruluk, model tarafından yapılan doęru tahmin sayısının toplam tahmin sayısına bölümü olarak tanımlanır. Örneęin, model 100 tahmin yapıyorsa ve bunların 80'i doęruysa, doęruluk %80'dir.

Regresyon görevleri için doęruluk genellikle ortalama hatanın karesi (MSE), ortalama hatanın karesi (RMSE), ortalama mutlak hata (MAE) veya ortalama mutlak hata yüzdesi (MAPE) gibi metrikler kullanılarak ölçülür. Bu metrikler, modelin tahmin edilen çıktısı ile gerçek çıktı arasındaki farkı ölçer.

Verilerin özelliklerine ve modelin amaçlarına baęlı olarak, modelin doęruluęunu ölçmek için uygun bir metrik seçmek önemlidir. Örneęin MSE, uslu ve yorumlanması kolay olduęu için regresyon görevleri için popüler bir seçimdir, ancak büyük hatalara karşı hassastır ve aykırı deęerlerin varlığına karşı dayanıklı olmayabilir.

Genel olarak doęruluk, bir makine öğrenimi modelinin performansını deęerlendirirken dikkate alınması gereken önemli bir ölçüdür, ancak tek ölçü deęildir. Modeli deęerlendirirken, modelin görünmeyen verilere genelleme yeteneęi gibi dięer faktörler de dikkate alınmalıdır.

3.7.10. Hiperparametre Optimizasyonu

Hiperparametre optimizasyonu, bir makine öğrenimi modelinin hiperparametreleri için en iyi değerleri seçme işlemidir. Hiperparametreler, eğitim sürecinde verilerden öğrenilmeyen, uygulayıcı tarafından belirlenen parametrelerdir. Modelin davranışını kontrol ederler ve modelin görünmeyen veriler üzerindeki performansını önemli ölçüde etkileyebilirler.

Hiperparametre optimizasyonu, eldeki görevde en iyi performansı elde etmek için hiperparametreler için doğru değerlerin seçilmesini gerektirdiğinden, zaman alıcı ve zorlu bir görev olabilir. Manuel arama, ızgara arama, rastgele arama ve gradyan tabanlı optimizasyon dahil olmak üzere hiperparametre optimizasyonuna yönelik birkaç farklı yaklaşım vardır.

- Manuel arama, hiperparametreler için farklı değerleri manuel olarak denemeyi ve bir doğrulama setinde modelin performansını değerlendirmeyi içerir. Bu yaklaşım zaman alıcı olabilir, ancak modelin davranışını ve farklı hiperparametrelerin etkisini anlamak için yararlı olabilir.
- Izgara araması, bir hiperparametre değerleri ızgarası tanımlamayı ve her bir değer kombinasyonu için model performansını değerlendirmeyi içerir. Bu yaklaşım hesaplama açısından pahalı olabilir, ancak basit ve uygulanması kolaydır.
- Rastgele arama, hiperparametre değerlerinin rastgele kombinasyonlarını örneklemeyi ve her kombinasyon için model performansını değerlendirmeyi içerir. Bu yaklaşım hesaplama açısından ızgara aramadan daha ucuzdur, ancak optimum değerleri bulmada daha az verimli olabilir.
- Gradyan tabanlı optimizasyon, hiperparametrelerin optimal değerlerini aramak için gradyan iniş gibi bir optimizasyon algoritmasının kullanılmasını içerir. Bu yaklaşım, manuel arama veya kılavuz aramadan daha verimli olabilir, ancak türevlenebilir bir model gerektirir ve hiperparametrelerin başlatılmasına duyarlı olabilir.

Hiperparametre optimizasyonu, modelin görünmeyen veriler üzerindeki performansını önemli ölçüde etkileyebileceğinden, makine öğrenimi sürecinde önemli bir adımdır. Mümkün olan en yüksek performansı elde etmek için doğru yaklaşımı dikkatli bir şekilde seçmek ve hiperparametreleri uygun şekilde ayarlamak için zaman ayırmak önemlidir.

3.7.11. Toplu Normalleştirme

Toplu normalleştirme, derin sinir ağlarının performansını ve kararlılığını iyileştirmek için kullanılan bir tekniktir. Giriş verisinden ziyade ağız gizli katmanlarının aktivasyonlarına uygulanan bir normalleştirme yöntemidir.

Toplu normalleştirmenin amacı, ağız ağırlıklarındaki değişiklik nedeniyle gizli katmanların aktivasyonlarının dağılımındaki değişiklik olan dahili ortak değişken kaymasını azaltmaktır. Bu bir problem olabilir çünkü eğitim sürecini yavaşlatabilir ve ağız öğrenmesini zorlaştırabilir.

Toplu normalleştirme, ortalamayı çıkararak ve standart sapmaya bölerek her bir gizli katmanın aktivasyonlarını normalleştirerek çalışır. Normalleştirme, eğitim verilerinin küçük bir örneği olan mini bir veri yığını üzerinde gerçekleştirilir. Ortalama ve standart sapma, mini kümeden tahmin edilir ve bu tahminler kullanılarak normalleştirme yapılır. Toplu normalleştirmenin birçok avantajı vardır:

- Geliştirilmiş ağız performansı: Toplu normalleştirme, özellikle ağızlıkların başlatılmasına duyarlı görevlerde derin sinir ağlarının performansını önemli ölçüde artırabilir.
- Azaltılmış eğitim süresi: Toplu normalleştirme, ağız daha büyük öğrenme hızları kullanmasına izin vererek ve dikkatli ağızlık başlatma ihtiyacını azaltarak eğitim süresini azaltabilir.
- İyileştirilmiş genelleştirme: Toplu normalleştirme, dahili ortak değişken kaymasını azaltarak ve bir miktar düzenleme sağlayarak ağız görünmeyen verilere daha iyi genelleme yapmasına yardımcı olabilir.

Toplu normalleştirme, modern derin öğrenme modellerinde yaygın olarak kullanılır ve görüntü sınıflandırma ve doğal dil işleme dahil olmak üzere çeşitli görevlerde etkili olduğu gösterilmiştir. Bununla birlikte, en başarılı sonuçları elde etmek için, öğrenme oranı ve toplu iş boyutu gibi toplu normalleştirmenin hiperparametrelerini dikkatli bir şekilde ayarlamak önemlidir (Ioffe & Szegedy, 2015).

4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Bu bölümde, öncelikle TBEİ prosesi ile gerçekleştirilen proses çalışmaları özetlenmektedir. Sonrasında TBEİ prosesinde, proses parametreleri (WFS, Akım, Voltaj, TTS) ile kaynak havuz genişliği, uzunluğu ve alanının tahmini üzerine geliştirilen YSA modelleri açıklanmaktadır. YSA modelinin optimize edilmesi ve regresyon tahmininin düşük hata oranına ulaşması için hiperparametre optimizasyonu gerçekleştirilmiş ve 29 YSA modeli eğitilerek, elde edilen sonuçlar karşılaştırılmıştır.

DeneySEL çalışmalar ve veri toplama işlemi 6 eksen endüstriyel robot kol, Fronius TPS 500i CMT kaynak makinesi, Xiris Xir-1800 termal kaynak kamerası ve pirometre kullanılarak gerçekleştirilmiştir. Robot ve kaynak makinesinden gelen veriler özel geliştirilen MetalWorm yazılımı ile zaman etiketli olarak gerçek zamanlı toplanmaktadır. Bu veriler robottan alınan TTS değeri, kaynak makinesinden alınan WFS, Akım ve Voltaj değerleridir. Toplanan bu veriler YSA modelinin giriş katmanını oluşturmaktadır. Modelin çıkış katmanında ise termal kaynak kamerası kullanılarak proses esnasında ölçülen kaynak havuz genişliği, uzunluğu ve alanı verileri bulunmaktadır.


YSA modelinin eğitilmesi için 14 deneysel, düz duvar üretme çalışması gerçekleştirilmiştir. Bu gerçekleştirilen deneysel çalışmalar ile üretilen 12 düz duvar verisinin %20'si YSA modelinin doğrulanması ve %80'i YSA modelinin eğitiminde kullanılmıştır. Diğer iki deneysel çalışmada elde edilen veriler ise YSA modelinin testinde kullanılmıştır. Eğitim datası 341 adet, doğrulama datası 86 adet ve test datası 108 adet veriden oluşmaktadır. Gerçekleştirilen 14 deneysel düz duvar çalışma parametreleri Tablo 2'de verilmektedir.

Verilerin kalitesini artırmak, üst üste yığılan malzemenin belirli bir sıcaklığın üzerinde olması, katmanların üretimi sırasında daha stabil bir kaynak havuzu oluşmasına yol açmaktadır. Bundan dolayı, belirlenen proses parametreleri ile gerçekleştirilen düz duvar üretiminde bir katman yığıldıktan sonra bir sonraki katmana geçmeden robot üzerindeki pirometre ile katmanın orta noktasından sıcaklık ölçümü gerçekleştirilmiş ve katma sıcaklığının 150°C'ye ulaşması ile prosese devam edilmiştir. İlk katmanlar belirlenen bu eşim değerinin altında kaldığından oluşan kaynak banyosunun ebatı ve kaynak havuzunun sıcaklık dağılımı stabil olmadığından bu veriler modele dahil edilmemiştir. Pirometre ile sıcaklık ölçümü Şekil 10'da gösterilmektedir.



Şekil 10. Pirometre Katmanlar Arası Sıcaklık Ölçümü

Düz duvarların üretimi proses deney tablosunda belirtilen parametre ve sıra ile yan yana gerçekleştirilmiştir. Düz duvarların üretiminde robotun yığıma yönü, kamera açısına bağlı olarak tek yön olacak şekilde sabit tutulmuştur. Proses çalışmaları sırasında çekilen görüntü Şekil 11’de gösterilmektedir.



Şekil 11. Düz Duvar Üretimi

Deney setinde tanımlanan parametreler ile üretilen 14 düz duvarların yandan görünüşü

Şekil 12’de gösterilmektedir.



Şekil 12. Düz Duvarların Yandan Görünümü

Veri toplama işleminin ardından, zaman damgası ile birlikte toplanan proses parametreleri ile kaynak havuz özellikleri eşleştirilerek YSA modelinin eğitiminde ve testinde kullanılacak veri seti tabloları oluşturulmuştur. Bu toplanan giriş ve çıkış verilerine toplu normalizasyon işlemi uygulanarak değerler 0-1 aralığına getirilmiştir. Toplu normalizasyon, YSA modelinin öğrenme başarısını artıran bir metottür.

İlk olarak YSA modelinin eğitiminde toplanan giriş verilerinin etkisini incelemek için 3 farklı model yapısı belirlenmiştir. Model-1’de giriş parametresi olarak WFS ve TTS değerleri kullanılmıştır. Model-2’de giriş parametresi olarak Akım, Voltaj ve TTS değerleri kullanılmıştır. Model-3’te giriş parametresi olarak WFS, Akım, Voltaj ve TTS değerleri kullanılmıştır. WFS değeri kaynak prosesi esnasında kaynak makinesi tarafından akım ve voltaja bağlı olarak otomatik değiştirilen bir parametredir. TTS değerinin tüm model yapılarında kullanılmasının sebebi, bu değere bağlı olarak yığma oranının ve ısı girdisinin değişmesidir. Bu üç modelin karşılaştırılması için 3 gizli katmandan oluşan, her katmanda 50 nöronun bulunan, sigmoid aktivasyon fonksiyonu ve

Adam optimizasyon algoritmasının kullanıldığı bir model yapısı belirlenmiştir. YSA modelinin eğitimi için parti boyutu 8 seçilmiş ve modeller 600 dönem eğitilmiştir.

Modellerin performans kıyaslaması MSE, MSLE, MAE, MAPE ve RMSE'a göre gerçekleştirilmiştir. Bu modeller arasında en iyi performansı Model-3 göstermiştir. Bu modelin başarısı referans alınarak giriş katmanında WFS, Akım, Voltaj ve TTS değerlerinin kullanılmasına karar verilmiştir. Modellerin elde edilen karşılaştırma tablosu Tablo 3'te gösterilmektedir.

Tablo 3. YSA Modelleri Değerlendirme Tablosu-1

YSA Modeli		MSE	MSLE	MAE	MAPE	RMSE
Model-1	Eğitim	0.00227	0.00075	0.03606	5.03052	0.04762
	Doğrulama	0.00240	0.00084	0.03640	5.45264	0.04898
	Test	0.00270	0.00086	0.04051	5.32631	0.05197
Model-2	Eğitim	0.00251	0.00084	0.03863	5.43832	0.05012
	Doğrulama	0.00314	0.00111	0.04342	6.55253	0.05604
	Test	0.00268	0.00087	0.04122	5.52806	0.05181
Model-3	Eğitim	0.00217	0.00072	0.03423	4.74110	0.04654
	Doğrulama	0.00234	0.00079	0.03763	5.22209	0.04840
	Test	0.00247	0.00079	0.03988	5.24211	0.04972

Diğer modellere göre daha iyi performans gösteren Model-3 referans alınarak gizli katman sayısının model performansı üzerine etkisi incelenmiştir. Model-4'te 2 gizli katman ve Model-5'te 5 gizli katman kullanılmıştır. Model-3, Model-4 ve Model-5'in diğer tüm parametreleri aynıdır. Bu modellerin performansı kıyaslandığında Model-3 daha düşük hata oranına sahip olduğu görülmektedir. Etkisi incelenen gizli katman sayısının Model-3'ün sahip olduğu 3 gizli katmanlı yapının daha uygun olduğuna karar verilmiştir. Modellerin karşılaştırması Tablo 4'te gösterilmektedir.

Tablo 4. YSA Modelleri Değerlendirme Tablosu-2

YSA Modeli		MSE	MSLE	MAE	MAPE	RMSE
Model-3	Eğitim	0.00217	0.00072	0.03423	4.74110	0.04654
	Doğrulama	0.00234	0.00079	0.03763	5.22209	0.04840
	Test	0.00247	0.00079	0.03988	5.24211	0.04972
Model-4	Eğitim	0.00275	0.00093	0.04033	5.72532	0.05245
	Doğrulama	0.00250	0.00087	0.03678	5.42402	0.04996
	Test	0.00249	0.00080	0.03866	5.13275	0.04990
Model-5	Eğitim	0.00236	0.00078	0.03845	5.39095	0.04857

	Doğrulama	0.00221	0.00075	0.03710	5.25169	0.04701
	Test	0.00269	0.00085	0.03989	5.30683	0.05187

Üç gizli katmanlı YSA model yapısında katmanlardaki nöron sayısının etkisinin incelenmesi için 5 farklı model yapısı kullanılmıştır. Bu modelin gizli katmanlarındaki nöron sayıları Tablo 5’te gösterilmektedir.

Tablo 5. YSA Modelleri Gizli Katmanlardaki Nöron Sayıları

YSA Modeli	1. Gizli Katman	2. Gizli Katman	3. Gizli Katman
Model-3	50	50	50
Model-6	20	50	20
Model-7	50	50	20
Model-8	20	50	50
Model-9	20	20	20

Bu modellerin performansı kıyaslandığında birinci ve ikinci gizli katmanda 50, üçüncü gizli katmanda 20 nörona sahip YSA modelin daha düşük hata oranı ile tahmin gerçekleştirdiği görülmektedir. Modellerin karşılaştırması Tablo 6’da gösterilmektedir.

Tablo 6. YSA Modelleri Değerlendirme Tablosu-3

YSA Modeli		MSE	MSLE	MAE	MAPE	RMSE
Model-3	Eğitim	0.00217	0.00072	0.03423	4.74110	0.04654
	Doğrulama	0.00234	0.00079	0.03763	5.22209	0.04840
	Test	0.00247	0.00079	0.03988	5.24211	0.04972
Model-6	Eğitim	0.00258	0.00086	0.03984	5.54144	0.05075
	Doğrulama	0.00299	0.00103	0.04372	6.30515	0.05467
	Test	0.00254	0.00082	0.03846	5.04768	0.05039
Model-7	Eğitim	0.00210	0.00071	0.03399	4.72710	0.04585
	Doğrulama	0.00200	0.00065	0.03298	4.46415	0.04475
	Test	0.00244	0.00079	0.04059	5.33111	0.04940
Model-8	Eğitim	0.00276	0.00094	0.03999	5.77890	0.05253
	Doğrulama	0.00249	0.00083	0.03835	5.40820	0.04986
	Test	0.00282	0.00090	0.04103	5.44041	0.05315
Model-9	Eğitim	0.00271	0.00091	0.04088	5.73483	0.05208
	Doğrulama	0.00255	0.00087	0.03908	5.68238	0.05050
	Test	0.00254	0.00081	0.03865	5.07178	0.05043

Model-7 Referans alınarak farklı aktivasyon fonksiyonlarının model performansı üzerindeki etkisi incelenmiştir. Model-10 Lineer aktivasyon fonksiyonu, Model-11 Tanh aktivasyon fonksiyonu, Model-12 Softmax aktivasyon fonksiyonu, Model-13 ReLU

aktivasyon fonksiyonu ve son olarak Model-14'te Leaky ReLU aktivasyon fonksiyonu kullanılarak modeller karşılaştırılmıştır.

Modellerin performansları karşılaştırıldığında Sofmax ve ReLU aktivasyon fonksiyonu kullanılan modellerin yüksek hata oranına sahip olduğu gözlemlenmiştir. Diğer aktivasyon fonksiyonu kullanılan modeller incelendiğinde Model-11'in daha düşük hata oranına sahip olduğu fakat MAPE değeri incelendiğinde Model-14'ün daha iyi performans gösterdiği ve eğitim, doğrulama ve test setlerinde elde edilen MAPE değerinin birbirine daha yakın olduğu gözlemlenmiştir. Bu çıkarımlar doğrultusunda, modellerin başarı sırası, Model-14, Model-11, Model-7 ve Model-10 şeklindedir. Modellerin karşılaştırması Tablo 7'de gösterilmektedir.

Tablo 7. YSA Modelleri Değerlendirme Tablosu-4

YSA Modeli		MSE	MSLE	MAE	MAPE	RMSE
Model-7	Eğitim	0.00210	0.00071	0.03399	4.72710	0.04585
	Doğrulama	0.00200	0.00065	0.03298	4.46415	0.04475
	Test	0.00244	0.00079	0.04059	5.33111	0.04940
Model-10	Eğitim	0.00247	0.00085	0.03869	5.58632	0.04971
	Doğrulama	0.00241	0.00086	0.03735	5.47970	0.04910
	Test	0.00211	0.00068	0.03583	4.79408	0.04589
Model-11	Eğitim	0.00110	0.00036	0.02471	3.40097	0.03323
	Doğrulama	0.00162	0.00055	0.03080	4.43220	0.04027
	Test	0.00239	0.00078	0.03908	5.34855	0.04889
Model-12	Eğitim	0.16599	0.06974	0.39231	53.2012	0.40741
	Doğrulama	0.16578	0.06973	0.39255	53.1999	0.40716
	Test	0.18448	0.07759	0.42515	55.8948	0.42951
Model-13	Eğitim	0.19222	0.10551	0.26770	35.7346	0.43843
	Doğrulama	0.19904	0.10854	0.27426	35.8292	0.44614
	Test	0.19558	0.10741	0.27584	36.2899	0.44225
Model-14	Eğitim	0.00125	0.00041	0.02625	3.63169	0.03534
	Doğrulama	0.00140	0.00047	0.02817	3.86188	0.03738
	Test	0.00176	0.00058	0.03326	4.46849	0.04195

Farklı gizli katmanlarda kullanılan farklı aktivasyon fonksiyonlarının YSA modelinin performansına etkisini incelemek için Tablo 8'de verilen Model yapısına göre testler gerçekleştirilmiştir. Bu modeller, Linear, Tanh, Sigmoid ve Leaky ReLU aktivasyon fonksiyonlarının kullanıldığı kombinasyonlardan oluşmaktadır.

Tablo 8. YSA Modelleri Gizli Katmanlarda Kullanılan Aktivasyon Fonksiyonları

YSA Modeli	1. Gizli Katman	2. Gizli Katman	3. Gizli Katman	Çıkış Katmanı
Model-15	Lineer	Tanh	Sigmoid	Sigmoid
Model-16	Tanh	Lineer	Sigmoid	Sigmoid
Model-17	Lineer	Tanh	Leaky ReLU	Leaky ReLU
Model-18	Tanh	Lineer	Leaky ReLU	Leaky ReLU
Model-19	Sigmoid	Sigmoid	Leaky ReLU	Leaky ReLU
Model-20	Leaky ReLU	Leaky ReLU	Sigmoid	Sigmoid
Model-21	Tanh	Tanh	Leaky ReLU	Leaky ReLU
Model-22	Leaky ReLU	Leaky ReLU	Tanh	Tanh

Model-15 ile Model-18 arasındaki modellerin karşılaştırması Tablo 9'da gösterilmektedir. Bu modeller kıyaslandığında, Model-15'in daha düşük hata oranına sahip olduğu fakat Test veri setinde daha düşük başarı elde ettiği görülmektedir. Dolayısı ile eğitim, doğrulama ve test veri seti sonuçları birbirine daha yakın olan Model-18'in daha iyi bir genelle yapısına sahip bir YSA modeli olduğu söylenebilir.

Tablo 9. YSA Modelleri Değerlendirme Tablosu-5

YSA Modeli	Veri Seti	MSE	MSLE	MAE	MAPE	RMSE
Model-15	Eğitim	0.00109	0.00036	0.02399	3.31471	0.03297
	Doğrulama	0.00140	0.00047	0.02835	3.99609	0.03742
	Test	0.00229	0.00075	0.03808	5.14248	0.04788
Model-16	Eğitim	0.00113	0.00038	0.02466	3.45277	0.03367
	Doğrulama	0.00110	0.00037	0.02528	3.58369	0.03321
	Test	0.00260	0.00085	0.04166	5.66989	0.05099
Model-17	Eğitim	0.00156	0.00051	0.03098	4.34572	0.03945
	Doğrulama	0.00188	0.00064	0.03396	4.97158	0.04337
	Test	0.00305	0.00099	0.04459	6.14773	0.05520
Model-18	Eğitim	0.00136	0.00045	0.02760	3.86396	0.03685
	Doğrulama	0.00135	0.00045	0.02750	3.79617	0.03679
	Test	0.00151	0.00050	0.03055	4.14997	0.03887

Model-19 ile Model-22 arasındaki modellerin karşılaştırması Tablo 10'da gösterilmektedir. Hata oranlarının yüksek kaldığı ve iyi bir genelleme yapamadığı görülmektedir.

Tablo 10. YSA Modelleri Değerlendirme Tablosu-6

YSA Modeli	Veri Seti	MSE	MSLE	MAE	MAPE	RMSE
Model-19	Eğitim	0.00211	0.00072	0.03445	4.9796	0.04591
	Doğrulama	0.00235	0.00078	0.03704	5.16174	0.04852
	Test	0.00255	0.00082	0.04	5.39717	0.05051
Model-20	Eğitim	0.00115	0.00038	0.02514	3.49335	0.03396
	Doğrulama	0.00121	0.0004	0.02717	3.77602	0.03482
	Test	0.00249	0.00081	0.04069	5.56066	0.04987
Model-21	Eğitim	0.00115	0.00038	0.02562	3.56969	0.03387
	Doğrulama	0.00183	0.00059	0.02998	4.05675	0.04275
	Test	0.00176	0.00058	0.03279	4.43895	0.04199
Model-22	Eğitim	0.00124	0.00041	0.02602	3.6199	0.03528
	Doğrulama	0.00103	0.00036	0.02321	3.39275	0.03209
	Test	0.00304	0.00099	0.04505	6.14785	0.05515

Aktivasyon fonksiyonun etkisinin incelenmesi üzerine yapılan deneylerde Model-18'in daha iyi bir performans gösterdiği görülmüştür. Model-18 referans alınarak sırası ile SGD, AdaGrad, AdaDelta, RMSProp ve NAG optimizasyon algoritmalarının YSA modelinin performansı üzerine etkisi incelenmiştir. Modellerin performansı Tablo 11'de gösterilmektedir. Elde edilen sonuçlar kıyaslandığında Adam optimizasyon algoritmasının kullanıldığı Model-18'in daha düşük hata oranına sahip olduğu görülmektedir. En kötü performansı AdaDelta optimizasyon algoritmasının kullanıldığı Model-25 göstermiştir. Model-18'den sonraki en iyi performansı NAG optimizasyon algoritmasının kullanıldığı Model-27 göstermiştir.

Tablo 11. YSA Modelleri Değerlendirme Tablosu-7

YSA Modeli	Veri Seti	MSE	MSLE	MAE	MAPE	RMSE
Model-18	Eğitim	0.00136	0.00045	0.02760	3.86396	0.03685
	Doğrulama	0.00135	0.00045	0.02750	3.79617	0.03679
	Test	0.00151	0.00050	0.03055	4.14997	0.03887
Model-23	Eğitim	0.00238	0.00081	0.03698	5.29013	0.04882
	Doğrulama	0.00281	0.00098	0.04126	6.16924	0.05305
	Test	0.00215	0.00069	0.03608	4.81989	0.04637
Model-24	Eğitim	0.00335	0.00112	0.04538	6.39164	0.05792
	Doğrulama	0.00277	0.00096	0.04119	6.11785	0.05262
	Test	0.00285	0.0009	0.04052	5.31967	0.05334
Model-25	Eğitim	0.00463	0.00157	0.05465	7.9047	0.06802
	Doğrulama	0.00574	0.00191	0.05986	8.54706	0.07577
	Test	0.0033	0.00105	0.04355	5.6582	0.05747

Model-26	Eđitim	0.00188	0.00062	0.03371	4.69928	0.04339
	Dođrulama	0.00215	0.00073	0.03719	5.42921	0.04638
	Test	0.0036	0.00117	0.05011	6.81138	0.06002
Model-27	Eđitim	0.00153	0.00051	0.02979	4.16037	0.03909
	Dođrulama	0.00167	0.00055	0.03102	4.28935	0.0409
	Test	0.00269	0.00087	0.0423	5.61144	0.05186

Son olarak parti boyutunun modelin performansı üzerine etkisi incelenmiştir. Model-28’de parti boyutu dört ve Model-29’da parti boyutu 16 seçilerek, en iyi performans gösteren Model-18’in eğitim performansı Tablo 12’de karşılaştırılmıştır. Model-28’in sonuçları incelendiğinde eğitim, doğrulama ve test datasında birbirine çok yakın sonuçlar elde edildiđi görülmektedir. Parti boyutu deđerinin düşük seçilmesi modelin eğitim süresini uzatmıştır. Model-29’un sonuçları incelendiğinde ise hata oranının yükseldiđi gözlemlenmiştir. Bu modeller kıyaslandığında en iyi performansı Model-18 göstermektedir.

Tablo 12. YSA Modelleri Deđerlendirme Tablosu-8

YSA Modeli	Veri Seti	MSE	MSLE	MAE	MAPE	RMSE
Model-18	Eđitim	0.00136	0.00045	0.02760	3.86396	0.03685
	Dođrulama	0.00135	0.00045	0.02750	3.79617	0.03679
	Test	0.00151	0.00050	0.03055	4.14997	0.03887
Model-28	Eđitim	0.00155	0.00052	0.03102	4.31438	0.03935
	Dođrulama	0.00153	0.00050	0.03186	4.31837	0.03913
	Test	0.00163	0.00054	0.03057	4.14076	0.04034
Model-29	Eđitim	0.00215	0.00071	0.0356	4.85742	0.04636
	Dođrulama	0.00216	0.00071	0.03505	4.76693	0.04650
	Test	0.00241	0.00078	0.0402	5.26829	0.04913

YSA Model performansının gelişimin görülebilmesi için yapılan deneylerin sonuçları, Model-3, Model-7, Model-11, Model-14, Model-15 ve Model-18 üzerinde Tablo 13’te karşılaştırılmaktadır.


Tablo 13. İyi Performans Gösteren YSA Modelleri Deđerlendirme Tablosu

YSA Modeli	Veri Seti	MSE	MSLE	MAE	MAPE	RMSE
Model-3	Eđitim	0.00217	0.00072	0.03423	4.74110	0.04654
	Dođrulama	0.00234	0.00079	0.03763	5.22209	0.04840
	Test	0.00247	0.00079	0.03988	5.24211	0.04972
Model-7	Eđitim	0.00210	0.00071	0.03399	4.72710	0.04585

	Doğrulama	0.00200	0.00065	0.03298	4.46415	0.04475
	Test	0.00244	0.00079	0.04059	5.33111	0.04940
Model-11	Eğitim	0.00110	0.00036	0.02471	3.40097	0.03323
	Doğrulama	0.00162	0.00055	0.03080	4.43220	0.04027
	Test	0.00239	0.00078	0.03908	5.34855	0.04889
Model-14	Eğitim	0.00125	0.00041	0.02625	3.63169	0.03534
	Doğrulama	0.00140	0.00047	0.02817	3.86188	0.03738
	Test	0.00176	0.00058	0.03326	4.46849	0.04195
Model-15	Eğitim	0.00109	0.00036	0.02399	3.31471	0.03297
	Doğrulama	0.00140	0.00047	0.02835	3.99609	0.03742
	Test	0.00229	0.00075	0.03808	5.14248	0.04788
Model-18	Eğitim	0.00136	0.00045	0.02760	3.86396	0.03685
	Doğrulama	0.00135	0.00045	0.02750	3.79617	0.03679
	Test	0.00151	0.00050	0.03055	4.14997	0.03887

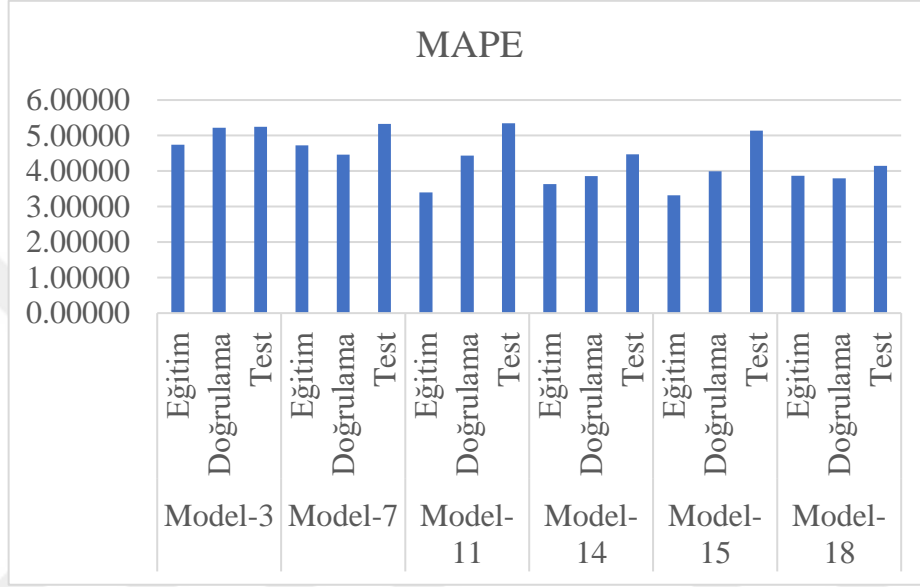
Modellerin karşılaştırması, MSE hata fonksiyonuna göre grafiksel olarak Grafik 1’de gösterilmektedir. Grafikten görüleceği üzere Eğitim hataları kıyaslandığında en düşük hata oranına sahip modelin, Model-11 ve sonraki en düşük hata oranına sahip modelin Model-15 olduğu görülmektedir. Fakat doğrulama ve test datası ile elde edilen hata oranları incelendiğinde bu modellerin iyi bir genelleme yapamadığı gözlemlenmektedir. Dolayısı ile Model-18’in eğitim, doğrulama ve test datalarındaki sonuçlarının birbirine yakın olması diğer YSA modellerinden daha iyi genelleme yaparak tahmin ürettiğini göstermektedir.

Grafik 1. İyi Performans Gösteren YSA Modellerinin MSE Grafiği




Modellerin karşılaştırması, MAPE hata fonksiyonuna göre grafiksel olarak Grafik 2’de gösterilmektedir. Grafik-1 için yapılan çıkarımların bir benzeri MAPE hata fonksiyonu kullanılarak elde edilen hata değer grafiğinde de gözlemlenmektedir. Model-18’in eğitim, doğrulama ve test datalarında %3,79 ile %4,15 arasında değiştiği görülmektedir.

Grafik 2. İyi Performans Gösteren YSA Modellerinin MAPE Grafiği




Modellerin hata değerleri radar grafiği olarak MSE ve MAPE hata fonksiyonlarına göre Grafik 3 ile Grafik 8 arasındaki grafiklerde gösterilmektedir.


Grafik 3. Eğitim Datasına Göre Modellerin MSE Grafiği




Grafik 4. Eğitim Datasına Göre Modellerin MAPE Grafiği




Grafik 5. Doğrulama Datasına Göre Modellerin MSE Grafiği




Grafik 6. Doğrulama Datasına Göre Modellerin MAPE Grafiği



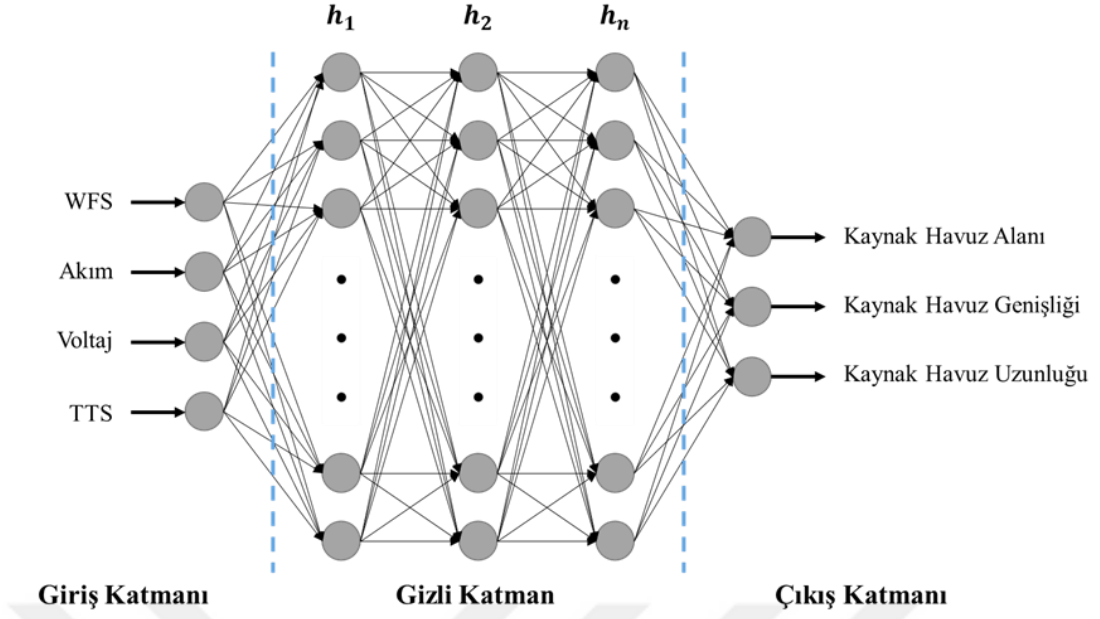
Grafik 7. Test Datasına Göre Modellerin MSE Grafiği



Grafik 8. Test Datasına Göre Modellerin MAPE Grafiği



YSA modelinin performansını artırmak ve ideal YSA modelini bulmak için yapılan iterasyonlar sonucunda Model-18 seçilmiştir. Bu YSA modeli üç gizli katmandan oluşmaktadır. İlk iki gizli katmanda 50 nöron, üçüncü gizli katmanda 20 nöron kullanılmıştır. Modelin ilk gizli katmanında Tanh aktivasyon fonksiyonu, ikinci gizli katmanında lineer aktivasyon fonksiyonu, modelin üçüncü gizli katmanında ve çıkış katmanında Leaky ReLU aktivasyon fonksiyonu kullanılmıştır. Optimizasyon algoritması olarak Adam seçilmiştir. Adam optimizasyon algoritmasının varsayılan öğrenme oranı olan 0.001 değeri sabit tutulmuştur. Model 8 parti boyutunda 600 dönem eğitilmiştir. Modelin girişine WFS, Akım, Voltaj ve TTS verileri çıkışında ise Kaynak havuz genişliği, uzunluğu ve alanı bulunmaktadır. YSA model yapısı Şekil 13'te gösterilmektedir.



Şekil 13. YSA Modeli


YSA modelinin değerlendirmesinde, üzerinde çalışılan problem regresyon problemi olmasından dolayı MSE, MSLE, MAE, MAPE ve RMSE fonksiyonları kullanılmıştır. Modelin bu değerlendirme metrikleri ile elde edilen sonuçlar Tablo 14'te gösterilmektedir. Elde edilen sonuçların birbirine oldukça yakın olduğu ve kabul edilebilir hata oranlarında, modelin kaynak havuz alanını, genişliğini ve uzunluğunun tahmin edebildiğini göstermektedir.

Tablo 14. YSA Model Değerlendirme Tablosu

	MSE	MSLE	MAE	MAPE	RMSE
Eğitim	0.00136	0.00045	0.02760	3.86396	0.03685
Doğrulama	0.00135	0.00045	0.02750	3.79617	0.03679
Test	0.00151	0.00050	0.03055	4.14997	0.03887


Modelin eğitimi sırasında kaydedilen hata (MSE) değeri Grafik 9'da gösterilmektedir. Hata değeri 0.0926'den başlayarak 100 dönem sonrasında yaklaşık 0.0019 seviyesine düştüğü, 600 dönemlik eğitim sonrasında 0.00136 seviyesine düştüğü görülmektedir.

Grafik 9. YSA Modeli MSE Grafiđi




Modelin deđerlendirilmesinde kullanılan metrik fonksiyonların modelin eđitimi sırasında kaydedilen veriler, Grafik 10 ile Grafik 15 arasındaki grafiklerde gösterilmektedir. MSLE deđeri 0.05'ten başlayarak 100 dönem sonrasında $6.4675E-04$ seviyesine düřtüđü görülmektedir. MAE deđeri 0.21'den başlayarak 100 dönem sonrasında 0.0334 deđerine düřmüřtür. MAPE deđerleri %29,49'dan başlayarak 100 dönem sonrasında %4,7154 seviyesine düřmüřtür. RMSE deđerleri 0.3043'ten başlayarak 100 dönem sonrasında 0.0440 seviyesine düřmüřtür.


Grafik 10. YSA Modeli MSLE Grafiđi




Grafik 11. YSA Modeli MAE Grafiđi



Grafik 12. YSA Modeli MAPE Grafiđi



Grafik 13. YSA Modeli RMSE Grafiđi



Modelin eğitimi sonrasında test veri seti ile modelde gerçekleştirilen tahmin sonuçlarından rast gele seçilen 40 veri Tablo 15'te gösterilmektedir. Bu tablo içerisinde ilk dört sütunda giriş verileri, sonraki 3 sütunda normalize edilmiş gerçekte olması gereken kaynak havuz alanı, genişliği ve uzunluğu verileri ve son üç sütunda giriş verilerine karşılık YSA modeli tarafından tahmin edilen kaynak havuz alanı, genişliği ve uzunluğu değerleri gösterilmektedir.

Tablo 15. Test Datası Giriş, Çıkış ve Tahmin Değerleri

No	Giriş Verileri				Gerçek Çıkış Verileri			Tahmin Edilen		
	WFS	Akım	Voltaj	TTS	Alan	Genişlik	Uzunluk	Alan	Genişlik	Uzunluk
1	5.97	190.1	18.00	0.48	0.696	0.7913	0.7292	0.6982	0.8196	0.7407
2	6.60	202.6	18.23	0.48	0.785	0.8231	0.8131	0.7574	0.8121	0.7984
3	7.13	219.4	18.32	0.48	0.778	0.8324	0.8504	0.7853	0.8016	0.8357
4	6.88	217.8	18.18	0.48	0.763	0.8237	0.8120	0.7785	0.8155	0.8193
5	7.04	218.2	18.31	0.48	0.755	0.8303	0.8281	0.7823	0.8064	0.8267
6	5.51	181.2	17.49	0.48	0.643	0.7746	0.6705	0.6372	0.7981	0.7009
7	5.47	179.4	17.43	0.48	0.655	0.7786	0.6826	0.6264	0.7881	0.6961
8	6.04	190.6	17.70	0.48	0.696	0.7951	0.7135	0.7124	0.8216	0.7546
9	6.02	191.9	17.97	0.48	0.709	0.7951	0.7257	0.7114	0.8303	0.7474
10	6.06	192.0	18.01	0.48	0.71	0.8030	0.7350	0.7137	0.8270	0.7510
11	6.34	194.0	17.96	0.48	0.728	0.8065	0.7486	0.7364	0.8056	0.7874
12	6.66	205.0	18.42	0.48	0.744	0.8056	0.7630	0.7661	0.8195	0.8013
13	6.49	199.5	17.93	0.48	0.748	0.8108	0.7553	0.7437	0.8009	0.7958

14	6.53	202.0	18.40	0.48	0.763	0.8127	0.7761	0.7597	0.8258	0.7934
15	6.50	201.2	18.17	0.48	0.77	0.8183	0.7807	0.7517	0.8195	0.7887
16	6.51	200.1	18.02	0.48	0.782	0.8205	0.7845	0.7472	0.8055	0.7950
17	6.35	202.4	18.30	0.48	0.785	0.8099	0.7901	0.7541	0.8533	0.7712
18	7.12	218.9	18.28	0.48	0.792	0.8160	0.8583	0.7834	0.7993	0.8366
19	7.09	218.9	18.35	0.48	0.782	0.8246	0.8642	0.7852	0.8061	0.8302
20	6.98	217.6	18.31	0.48	0.775	0.8313	0.8391	0.7804	0.8088	0.8214
21	7.02	217.7	18.20	0.48	0.773	0.8284	0.8758	0.7782	0.8027	0.8275
22	6.93	215.9	18.33	0.48	0.766	0.8341	0.8176	0.7786	0.8104	0.8175
23	7.15	218.3	18.33	0.48	0.758	0.8341	0.8257	0.7852	0.7994	0.8385
24	6.97	217.3	18.24	0.48	0.745	0.8491	0.8394	0.7779	0.8064	0.8221
25	5.59	191.3	17.49	0.42	0.734	0.9207	0.7732	0.7569	0.9272	0.7352
26	5.63	190.4	17.57	0.42	0.744	0.9317	0.7808	0.7520	0.9147	0.7357
27	5.60	190.3	17.77	0.42	0.713	0.9337	0.7498	0.7455	0.9128	0.7307
28	5.79	190.6	17.69	0.48	0.709	0.8362	0.7786	0.6994	0.8432	0.7364
29	5.77	190.3	17.78	0.48	0.683	0.8541	0.7434	0.6947	0.8437	0.7295
30	5.88	190.3	17.78	0.48	0.668	0.8446	0.7512	0.6999	0.8336	0.7374
31	6.04	189.0	18.14	0.48	0.68	0.8003	0.7494	0.6988	0.8035	0.7525
32	6.18	188.8	17.66	0.48	0.701	0.8032	0.7646	0.7196	0.7973	0.7786
33	6.17	190.0	17.98	0.48	0.703	0.7951	0.7635	0.7194	0.8044	0.7735
34	6.26	188.3	17.60	0.60	0.67	0.6754	0.8113	0.6699	0.6915	0.8127
35	6.22	187.6	17.56	0.60	0.658	0.6789	0.8047	0.6685	0.6951	0.8084
36	6.08	187.5	17.71	0.60	0.651	0.6580	0.8163	0.6534	0.7139	0.7771
37	5.58	192.3	17.62	0.42	0.734	0.9389	0.7615	0.7592	0.9338	0.7343
38	5.94	192.4	17.81	0.48	0.709	0.8119	0.7631	0.7140	0.8439	0.7457
39	5.83	187.3	17.53	0.48	0.714	0.8090	0.7681	0.6864	0.8150	0.7372
40	5.98	192.5	17.90	0.48	0.726	0.8090	0.7810	0.7144	0.8402	0.7463

Tüm test veri seti ile gerçekleştirilen tahminlere göre her çıkış için ayrı ayrı ve çıkışların ortalaması olacak şekilde MSE, MAPE değerleri kutu grafiği olarak Grafik 14 ve Grafik 15'te gösterilmektedir. Bu grafiklerden görüleceği üzere aykırı değerler göz ardı edildiğinde MSE değerinin 0.0024'ün altında olduğu, MAPE değerinin %7'nin altında ve hata ortalamasının %4'ün altında olduğu görülmektedir.

1	6.81E-06	8.01E-04	1.33E-04	3.14E-04	2.36E-06	2.46E-04	4.40E-05	9.74E-05
2	7.71E-04	1.22E-04	2.17E-04	3.70E-04	2.46E-04	3.68E-05	6.66E-05	1.16E-04
3	6.13E-05	9.50E-04	2.15E-04	4.09E-04	1.93E-05	2.88E-04	6.32E-05	1.23E-04
4	2.41E-04	6.61E-05	5.44E-05	1.21E-04	7.70E-05	2.00E-05	1.65E-05	3.78E-05
5	7.42E-04	5.75E-04	1.82E-06	4.40E-04	2.37E-04	1.74E-04	5.46E-07	1.37E-04
6	3.00E-05	5.53E-04	9.24E-04	5.02E-04	1.11E-05	1.73E-04	3.25E-04	1.70E-04
7	8.38E-04	9.09E-05	1.81E-04	3.70E-04	3.11E-04	2.86E-05	6.36E-05	1.35E-04
8	2.65E-04	7.05E-04	1.68E-03	8.85E-04	9.13E-05	2.16E-04	5.60E-04	2.89E-04
9	5.96E-06	1.24E-03	4.67E-04	5.72E-04	2.04E-06	3.78E-04	1.55E-04	1.78E-04
10	1.79E-05	5.72E-04	2.54E-04	2.81E-04	6.13E-06	1.74E-04	8.37E-05	8.78E-05
11	7.17E-05	9.21E-07	1.51E-03	5.27E-04	2.39E-05	2.82E-07	4.83E-04	1.69E-04
12	5.04E-04	1.95E-04	1.47E-03	7.23E-04	1.64E-04	5.92E-05	4.63E-04	2.28E-04
13	1.50E-05	9.83E-05	1.64E-03	5.85E-04	4.91E-06	3.01E-05	5.21E-04	1.85E-04
14	8.06E-06	1.72E-04	2.98E-04	1.59E-04	2.60E-06	5.20E-05	9.36E-05	4.94E-05
15	3.41E-04	1.48E-06	6.35E-05	1.35E-04	1.10E-04	4.49E-07	1.99E-05	4.35E-05
16	1.20E-03	2.25E-04	1.11E-04	5.12E-04	3.86E-04	6.85E-05	3.45E-05	1.63E-04
17	9.44E-04	1.88E-03	3.57E-04	1.06E-03	3.01E-04	5.62E-04	1.13E-04	3.25E-04
18	7.70E-05	2.81E-04	4.73E-04	2.77E-04	2.41E-05	8.61E-05	1.39E-04	8.30E-05
19	1.07E-05	3.44E-04	1.16E-03	5.04E-04	3.38E-06	1.05E-04	3.39E-04	1.49E-04
20	3.25E-05	5.05E-04	3.14E-04	2.84E-04	1.03E-05	1.52E-04	9.37E-05	8.55E-05
21	3.02E-05	6.63E-04	2.34E-03	1.01E-03	9.59E-06	2.01E-04	6.82E-04	2.98E-04
22	1.72E-04	5.64E-04	2.27E-08	2.45E-04	5.49E-05	1.70E-04	6.85E-09	7.49E-05
23	7.56E-04	1.21E-03	1.65E-04	7.10E-04	2.41E-04	3.67E-04	4.91E-05	2.19E-04
24	1.12E-03	1.82E-03	3.01E-04	1.08E-03	3.59E-04	5.46E-04	8.98E-05	3.32E-04
25	5.51E-04	4.20E-05	1.44E-03	6.79E-04	1.81E-04	1.14E-05	4.69E-04	2.21E-04
26	6.96E-05	2.92E-04	2.03E-03	7.98E-04	2.28E-05	7.89E-05	6.58E-04	2.53E-04
27	1.06E-03	4.38E-04	3.64E-04	6.22E-04	3.56E-04	1.18E-04	1.20E-04	1.98E-04
28	9.40E-05	4.88E-05	1.78E-03	6.40E-04	3.23E-05	1.44E-05	5.76E-04	2.07E-04
29	1.45E-04	1.10E-04	1.93E-04	1.49E-04	5.08E-05	3.22E-05	6.41E-05	4.90E-05
30	1.04E-03	1.21E-04	1.88E-04	4.48E-04	3.66E-04	3.57E-05	6.19E-05	1.54E-04
31	3.45E-04	9.97E-06	1.01E-05	1.22E-04	1.21E-04	3.07E-06	3.29E-06	4.25E-05
32	3.44E-04	3.42E-05	1.97E-04	1.92E-04	1.18E-04	1.06E-05	6.28E-05	6.37E-05
33	2.58E-04	8.61E-05	9.92E-05	1.48E-04	8.82E-05	2.66E-05	3.17E-05	4.88E-05
34	2.65E-10	2.60E-04	2.12E-06	8.72E-05	9.32E-11	9.16E-05	6.44E-07	3.07E-05
35	1.00E-04	2.61E-04	1.37E-05	1.25E-04	3.62E-05	9.16E-05	4.21E-06	4.40E-05
36	4.70E-06	3.13E-03	1.54E-03	1.56E-03	1.72E-06	1.10E-03	4.78E-04	5.27E-04
37	6.61E-04	2.56E-05	7.39E-04	4.75E-04	2.17E-04	6.84E-06	2.42E-04	1.55E-04
38	2.83E-05	1.02E-03	3.00E-04	4.50E-04	9.67E-06	3.06E-04	9.75E-05	1.38E-04
39	7.70E-04	3.56E-05	9.51E-04	5.86E-04	2.67E-04	1.08E-05	3.10E-04	1.96E-04
40	1.39E-04	9.76E-04	1.21E-03	7.73E-04	4.68E-05	2.93E-04	3.88E-04	2.43E-04

Tablo 17. Test Datası MAE ve RMSE Sonuçları Tablosu

No	MAE				RMSE			
	Alan	Genişlik	Uzunluk	Ortalama	Alan	Genişlik	Uzunluk	Ortalama
1	2.61E-03	2.83E-02	1.15E-02	1.41E-02	3.72E-02	3.72E-02	3.72E-02	3.72E-02
2	2.78E-02	1.10E-02	1.47E-02	1.78E-02	3.73E-02	3.73E-02	3.73E-02	3.73E-02
3	7.83E-03	3.08E-02	1.47E-02	1.78E-02	3.73E-02	3.73E-02	3.72E-02	3.72E-02
4	1.55E-02	8.13E-03	7.38E-03	1.03E-02	3.72E-02	3.72E-02	3.72E-02	3.72E-02
5	2.72E-02	2.40E-02	1.35E-03	1.75E-02	3.72E-02	3.72E-02	3.72E-02	3.72E-02
6	5.47E-03	2.35E-02	3.04E-02	1.98E-02	3.76E-02	3.76E-02	3.76E-02	3.76E-02
7	2.90E-02	9.54E-03	1.35E-02	1.73E-02	3.76E-02	3.76E-02	3.76E-02	3.75E-02
8	1.63E-02	2.65E-02	4.10E-02	2.80E-02	3.75E-02	3.75E-02	3.75E-02	3.75E-02
9	2.44E-03	3.52E-02	2.16E-02	1.98E-02	3.75E-02	3.75E-02	3.75E-02	3.75E-02
10	4.24E-03	2.39E-02	1.59E-02	1.47E-02	3.75E-02	3.75E-02	3.75E-02	3.75E-02
11	8.47E-03	9.60E-04	3.88E-02	1.61E-02	3.75E-02	3.75E-02	3.75E-02	3.75E-02
12	2.24E-02	1.39E-02	3.83E-02	2.49E-02	3.74E-02	3.74E-02	3.74E-02	3.74E-02
13	3.87E-03	9.92E-03	4.05E-02	1.81E-02	3.74E-02	3.74E-02	3.74E-02	3.74E-02
14	2.84E-03	1.31E-02	1.73E-02	1.11E-02	3.74E-02	3.74E-02	3.74E-02	3.74E-02
15	1.85E-02	1.22E-03	7.97E-03	9.22E-03	3.73E-02	3.73E-02	3.73E-02	3.73E-02
16	3.47E-02	1.50E-02	1.05E-02	2.01E-02	3.73E-02	3.73E-02	3.73E-02	3.73E-02
17	3.07E-02	4.34E-02	1.89E-02	3.10E-02	3.73E-02	3.73E-02	3.73E-02	3.73E-02
18	8.78E-03	1.68E-02	2.18E-02	1.58E-02	3.73E-02	3.73E-02	3.73E-02	3.73E-02
19	3.28E-03	1.86E-02	3.40E-02	1.86E-02	3.72E-02	3.72E-02	3.72E-02	3.72E-02
20	5.70E-03	2.25E-02	1.77E-02	1.53E-02	3.72E-02	3.72E-02	3.72E-02	3.72E-02
21	5.50E-03	2.57E-02	4.84E-02	2.65E-02	3.72E-02	3.72E-02	3.72E-02	3.72E-02
22	1.31E-02	2.37E-02	1.51E-04	1.23E-02	3.72E-02	3.72E-02	3.72E-02	3.72E-02
23	2.75E-02	3.48E-02	1.28E-02	2.50E-02	3.72E-02	3.72E-02	3.71E-02	3.71E-02
24	3.34E-02	4.27E-02	1.73E-02	3.11E-02	3.71E-02	3.71E-02	3.71E-02	3.71E-02
25	2.35E-02	6.48E-03	3.80E-02	2.27E-02	3.72E-02	3.72E-02	3.72E-02	3.72E-02
26	8.34E-03	1.71E-02	4.51E-02	2.35E-02	3.72E-02	3.72E-02	3.72E-02	3.72E-02
27	3.26E-02	2.09E-02	1.91E-02	2.42E-02	3.72E-02	3.72E-02	3.72E-02	3.72E-02
28	9.69E-03	6.98E-03	4.22E-02	1.96E-02	3.73E-02	3.73E-02	3.73E-02	3.73E-02
29	1.20E-02	1.05E-02	1.39E-02	1.21E-02	3.73E-02	3.73E-02	3.73E-02	3.73E-02
30	3.22E-02	1.10E-02	1.37E-02	1.90E-02	3.73E-02	3.73E-02	3.73E-02	3.73E-02
31	1.86E-02	3.16E-03	3.18E-03	8.31E-03	3.73E-02	3.73E-02	3.73E-02	3.73E-02
32	1.86E-02	5.85E-03	1.40E-02	1.28E-02	3.72E-02	3.72E-02	3.72E-02	3.72E-02
33	1.61E-02	9.28E-03	9.96E-03	1.18E-02	3.72E-02	3.72E-02	3.72E-02	3.72E-02
34	1.63E-05	1.61E-02	1.45E-03	5.86E-03	3.73E-02	3.73E-02	3.73E-02	3.72E-02
35	1.00E-02	1.61E-02	3.70E-03	9.95E-03	3.72E-02	3.72E-02	3.72E-02	3.72E-02
36	2.17E-03	5.60E-02	3.93E-02	3.25E-02	3.72E-02	3.72E-02	3.72E-02	3.72E-02
37	2.57E-02	5.06E-03	2.72E-02	1.93E-02	3.72E-02	3.72E-02	3.72E-02	3.72E-02
38	5.32E-03	3.20E-02	1.73E-02	1.82E-02	3.73E-02	3.73E-02	3.73E-02	3.73E-02
39	2.78E-02	5.97E-03	3.08E-02	2.15E-02	3.73E-02	3.73E-02	3.73E-02	3.72E-02

40	1.18E-02	3.12E-02	3.47E-02	2.59E-02	3.72E-02	3.72E-02	3.72E-02	3.72E-02
----	----------	----------	----------	----------	----------	----------	----------	----------


Tablo 18. Test Datası MAPE Sonuçları Tablosu

No	MAPE			
	Alan	Genişlik	Uzunluk	Ortalama
1	0.375	3.577	1.579	1.844
2	3.535	1.340	1.812	2.229
3	1.007	3.703	1.723	2.144
4	2.037	0.987	0.909	1.311
5	3.607	2.888	0.163	2.219
6	0.852	3.036	4.534	2.807
7	4.418	1.225	1.974	2.539
8	2.339	3.339	5.752	3.810
9	0.344	4.432	2.979	2.585
10	0.597	2.979	2.169	1.915
11	1.163	0.119	5.190	2.157
12	3.018	1.731	5.024	3.258
13	0.518	1.223	5.366	2.369
14	0.372	1.615	2.224	1.404
15	2.399	0.149	1.021	1.189
16	4.433	1.829	1.341	2.534
17	3.914	5.359	2.393	3.889
18	1.108	2.056	2.534	1.899
19	0.419	2.251	3.937	2.202
20	0.735	2.703	2.111	1.850
21	0.711	3.107	5.523	3.114
22	1.716	2.847	0.018	1.527
23	3.629	4.171	1.554	3.118
24	4.485	5.030	2.067	3.860
25	3.202	0.704	4.915	2.940
26	1.121	1.834	5.775	2.910
27	4.573	2.242	2.545	3.120
28	1.367	0.835	5.416	2.539
29	1.763	1.228	1.869	1.620
30	4.821	1.301	1.826	2.650
31	2.732	0.395	0.424	1.183
32	2.648	0.729	1.836	1.738
33	2.285	1.167	1.305	1.586
34	0.002	2.385	0.179	0.856
35	1.519	2.378	0.460	1.453
36	0.333	8.505	4.810	4.549
37	3.504	0.539	3.570	2.538

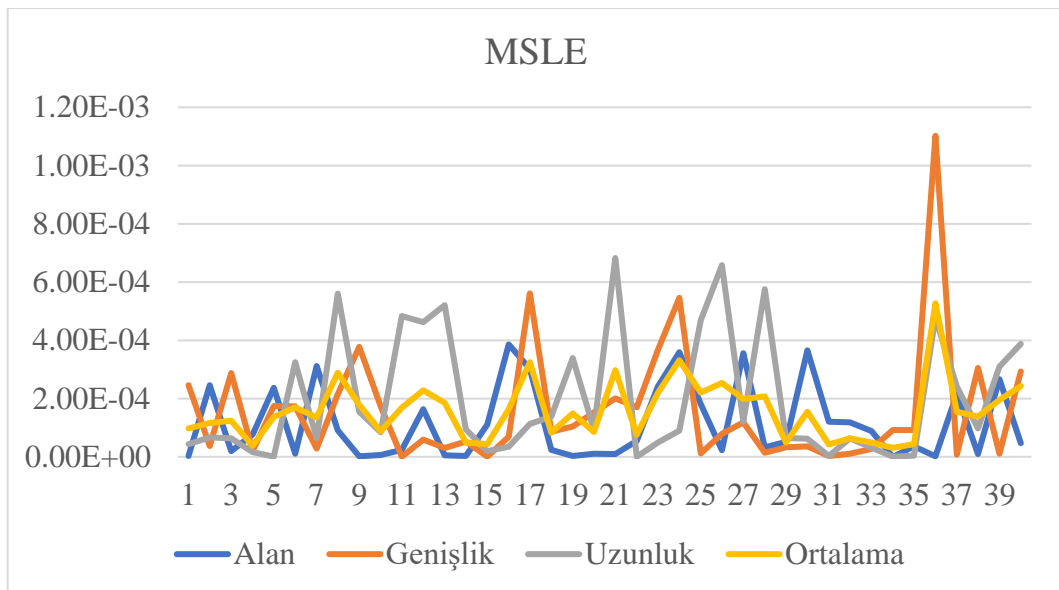
38	0.751	3.936	2.270	2.319
39	3.887	0.738	4.016	2.880
40	1.621	3.861	4.446	3.309

Rastgele seçilmiş olan bu 40 veri için hesaplanan MSE grafiği Grafik 16'da, MSLE grafiği Grafik 17'de, MAE grafiği Grafik 18'de ve MAPE grafiği Grafik 19'da gösterilmektedir. Grafiklerden de görüleceği üzere YSA modelinin kabul edilebilir hata toleransları içerisinde kaynak havuzu özelliklerini tahmin etmektedir.


Grafik 16. Test Datası MSE Grafiği




Grafik 17. Test Datası MSLE Grafiği



Grafik 18. Test Datası MAE Grafiği



Grafik 19. Test Datası MAPE Grafiği



5. SONUÇLAR VE ÖNERİLER

5.1 Sonuçlar

Bu çalışmada, literatürde TBEİ ve YSA kullanılarak gerçekleştirilen katman genişliği, katman yüksekliği gibi değerlerin tahmininden farklı olarak, gerçek zamanlı toplanmış WFS, kaynak akımı, kaynak voltajı ve TTS değerlerine bağlı olarak kaynak havuzunun alanı, kaynak havuz genişliği ve uzunluğu tahmin etmek için bir YSA modeli önermektedir.

14 deneysel düz duvar üretimi ile gerçek zamanlı olarak proses parametreleri toplanmış ve proses esnasında kaydedilen termal kaynak kamera görüntüsü ile elde edilen kaynak havuz özellikleri eşleştirilmiştir. YSA modelinin performansının artırılmasına yönelik olarak hiperparametre optimizasyonu yapılmış ve yapılan optimizasyon adımları boyunca 29 farklı YSA modelinin performansı ve parametrelerinin etkisi karşılaştırılmıştır.

Önerilen YSA modeli üç gizli katmandan oluşmaktadır. İlk iki gizli katmanda 50 nöron ve son gizli katmanda 20 nöron bulunmaktadır. İlk gizli katmanda Tanh aktivasyon fonksiyonu, ikinci gizli katmanda lineer aktivasyon fonksiyonu, üçüncü gizli katman ve çıkış katmanında Leaky ReLU aktivasyon fonksiyonu kullanılmıştır. Leaky ReLU'nun sızdırma değeri olarak 0.3 seçilmiştir. Modelin eğitiminde geriye yayılım ve Adam optimizasyon algoritması kullanılmaktadır. Adam optimizasyon algoritmasının öğrenme oranı olarak varsayılan değeri olan 0.001 sabit tutulmuştur. Model, 8 parti boyutunda 600 dönem boyunca eğitilmiştir.

Modeli eğitmek için toplanan 427 adet verinin %80'i eğitim datası, %20'si doğrulama datası olarak kullanılmıştır. Eğitilen YSA modelini test etmek için bağımsız olarak toplanan 108 adet test verisi kullanılarak modelin performansı test edilmiştir.

Elde edilen sonuçlar, MSE değerine göre 0.00151'in altında hata oranı ile YSA modelin tahmin gerçekleştirdiğini göstermektedir. Sonuçlar, MAPE değerine göre incelendiğinde yaklaşık ortalama %4 hata oranı ile kaynak havuzu özelliklerini tahmin edilebildiğini göstermiştir. Kaynak havuzu ile ilgili bu bilgileri elde etmek için kullanılması gereken yüksek maliyetli termal kaynak kamerası çözümleri yerine kabul edilebilir toleranslar içerisinde bir tahmin modelinin oluşturulmasının mümkün olduğu görülmektedir.

5.2 Öneriler

Gelecekte yapılacak çalışmalar ile, proses esnasında toplanan gerçek zamanlı verilerin artırılması, farklı malzemeler ile yapılan çalışmaların veri setine dahil edilmesiyle daha yüksek başarımlarına sahip ve daha genel bir YSA modelleri geliştirilebilir. Gelecekteki çalışmalarda, bu tez çalışmasında tahmin edilen kaynak havuzu özelliklerine ek olarak kaynak havuzu yüksekliğinin de tahmin edilmesi mümkündür. Proses parametreleri ile kaynak havuz özellikleri arasındaki ilişkinin çıkarılmasına yönelik olarak geliştirilecek YSA'na ilave olarak proses esnasında oluşan kaynak kusurlarının tahmin edilmesi ve kaynak parametreleri arasındaki ilişkisinin çıkartılması YSA modellerinin TBEİ uygulamalarındaki kullanılabilirliği artıracaktır. Olası bu gelişmeler ile TBEİ proses parametrelerinin, proses esnasında gerçekleştirilen bu tahminlere bağlı olarak gerçek zamanlı kapalı çevrim kontrol metodlarının geliştirilmesinin önünü açacaktır.

KAYNAKLAR

- Abiodun, O. I., Jantan, A., Omolara, A. E., Dada, K. V., Mohamed, N. A., & Arshad, H. (2018). State-of-the-art in artificial neural network applications: A survey. *Heliyon*, 4(11), e00938.
- Bambach, M., Sizova, I., Sydow, B., Hemes, S., & Meiners, F. (2020). Hybrid manufacturing of components from Ti-6Al-4V by metal forming and wire-arc additive manufacturing. *Journal of Materials Processing Technology*, 282, 116689.
- Bhattacharya, S., Pal, K., & Pal, S. K. (2012). Multi-sensor based prediction of metal deposition in pulsed gas metal arc welding using various soft computing models. *Applied soft computing*, 12(1), 498-505.
- Bose, S., Biswas, A., Tiwari, Y., Mukherjee, M., & Roy, S. S. (2022). Artificial neural Network-Based approaches for Bi-directional modelling of robotic wire arc additive manufacturing. *Materials Today: Proceedings*.
- Caggiano, A., Zhang, J., Alfieri, V., Caiazzo, F., Gao, R., & Teti, R. (2019). Machine learning-based image processing for on-line defect recognition in additive manufacturing. *CIRP Annals*, 68(1), 451-454.
- Cho, H.-W., Shin, S.-J., Seo, G.-J., Kim, D. B., & Lee, D.-H. (2022). Real-time anomaly detection using convolutional neural network in wire arc additive manufacturing: Molybdenum material. *Journal of Materials Processing Technology*, 302, 117495.
- Dharmendra, C., Hadadzadeh, A., Amirkhiz, B., Ram, G. J., & Mohammadi, M. (2019). Microstructural evolution and mechanical behavior of nickel aluminum bronze Cu-9Al-4Fe-4Ni-1Mn fabricated through wire-arc additive manufacturing. *Additive Manufacturing*, 30, 100872.
- Dhinakaran, V., Ajith, J., Fahmidha, A. F. Y., Jagadeesha, T., Sathish, T., & Stalin, B. (2020). Wire Arc Additive Manufacturing (WAAM) process of nickel based superalloys—A review. *Materials Today: Proceedings*, 21, 920-925.
- Ding, D., Pan, Z., Cuiuri, D., Li, H., van Duin, S., & Larkin, N. (2016). Bead modelling and implementation of adaptive MAT path in wire and arc additive manufacturing. *Robotics and Computer-Integrated Manufacturing*, 39, 32-42.
- Duman, B., & Kayacan, M. C. (2017). Doğrudan metal lazer sinterleme/ergitme yöntemi ile imal edilecek parçanın mekanik özelliklerinin tahmini. *Teknik Bilimler Dergisi*, 7(1), 12-28.
- Frazier, W. E. (2014). Metal additive manufacturing: a review. *Journal of Materials Engineering and performance*, 23(6), 1917-1928.
- Fu, R., Tang, S., Lu, J., Cui, Y., Li, Z., Zhang, H., . . . Liu, C. (2021). Hot-wire arc additive manufacturing of aluminum alloy with reduced porosity and high deposition rate. *Materials & Design*, 199, 109370.
- Galeazzi, D., Viviani, A. B., Jaeger, P. R., & Schwedersky, M. B. (2022). Evaluation of thermal and geometric properties of martensitic stainless steel thin walls built by additive manufacturing cold metal transfer (CMT) processes. *The International Journal of Advanced Manufacturing Technology*, 120(3), 2151-2165.
- Hackenhaar, W., Mazzaferro, J. A., Montevecchi, F., & Campatelli, G. (2020). An experimental-numerical study of active cooling in wire arc additive manufacturing. *Journal of Manufacturing Processes*, 52, 58-65.
- Hauser, T., Da Silva, A., Reisch, R. T., Volpp, J., Kamps, T., & Kaplan, A. F. (2020). Fluctuation effects in Wire Arc Additive Manufacturing of aluminium analysed by high-speed imaging. *Journal of Manufacturing Processes*, 56, 1088-1098.

- Heidari, A. A., Faris, H., Mirjalili, S., Aljarah, I., & Mafarja, M. (2020). Ant lion optimizer: theory, literature review, and application in multi-layer perceptron neural networks. *Nature-inspired optimizers*, 23-46.
- Hoefer, K., Haelsig, A., & Mayr, P. (2018). Arc-based additive manufacturing of steel components—Comparison of wire-and powder-based variants. *Welding in the World*, 62(2), 243-247.
- Hu, Z., Qin, X., Li, Y., & Ni, M. (2020). Welding parameters prediction for arbitrary layer height in robotic wire and arc additive manufacturing. *Journal of Mechanical Science & Technology*, 34(4).
- Imoudu, N. E., Ayele, Y., & Barabadi, A. (2017). *The characteristic of cold metal transfer (CMT) and its application for cladding*. Paper presented at the 2017 IEEE International Conference on Industrial Engineering and Engineering Management (IEEM).
- Ioffe, S., & Szegedy, C. (2015). *Batch normalization: Accelerating deep network training by reducing internal covariate shift*. Paper presented at the International conference on machine learning.
- Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255-260.
- Knezović, N., & Topić, A. (2018). *Wire and Arc Additive Manufacturing (WAAM)—a new advance in manufacturing*. Paper presented at the International Conference “New Technologies, Development and Applications”.
- Lehmann, T., Jain, A., Jain, Y., Stainer, H., Wolfe, T., Henein, H., & Qureshi, A. J. (2020). Concurrent geometry-and material-based process identification and optimization for robotic CMT-based wire arc additive manufacturing. *Materials & Design*, 194, 108841.
- Li, C., Gu, H., Wang, W., Wang, S., Ren, L., Wang, Z., . . . Zhai, Y. (2019). Effect of heat input on formability, microstructure, and properties of Al–7Si–0.6 Mg alloys deposited by CMT-WAAM process. *Applied Sciences*, 10(1), 70.
- Liu, B. (2011). Supervised learning. In *Web data mining* (pp. 63-132): Springer.
- Liu, S., & Shin, Y. C. (2019). Additive manufacturing of Ti6Al4V alloy: A review. *Materials & Design*, 164, 107552.
- Lu, T., Liu, C., Li, Z., Wu, Q., Wang, J., Xu, T., . . . Ma, S. (2020). Hot-wire arc additive manufacturing Ti–6.5 Al–2Zr–1Mo–1V titanium alloy: Pore characterization, microstructural evolution, and mechanical properties. *Journal of Alloys and Compounds*, 817, 153334.
- McFadden, S., Ward, R., & Quinn, J. (2018). *DEVELOPMENTS IN LARGE SCALE ADDITIVE MANUFACTURE—THE POTENTIAL AND LIMITATIONS OF WIRE ARC ADDITIVE MANUFACTURE AND ASSOCIATED TECHNOLOGIES*. Paper presented at the The 35th International Manufacturing Conference.
- Mirapeix, J., García-Allende, P., Cobo, A., Conde, O., & López-Higuera, J. (2007). Real-time arc-welding defect detection and classification with principal component analysis and artificial neural networks. *NDT & e International*, 40(4), 315-323.
- Mozaffar, M., Paul, A., Al-Bahrani, R., Wolff, S., Choudhary, A., Agrawal, A., . . . Cao, J. (2018). Data-driven prediction of the high-dimensional thermal history in directed energy deposition processes via recurrent neural networks. *Manufacturing letters*, 18, 35-39.
- Nagesh, D., & Datta, G. (2010). Genetic algorithm for optimization of welding variables for height to width ratio and application of ANN for prediction of bead geometry for TIG welding process. *Applied soft computing*, 10(3), 897-907.

- Oyama, K., Diplas, S., M'hamdi, M., Gunnæs, A. E., & Azar, A. S. (2019). Heat source management in wire-arc additive manufacturing process for Al-Mg and Al-Si alloys. *Additive Manufacturing*, 26, 180-192.
- Qi, X., Chen, G., Li, Y., Cheng, X., & Li, C. (2019). Applying neural-network-based machine learning to additive manufacturing: current applications, challenges, and future perspectives. *Engineering*, 5(4), 721-729.
- Rodrigues, T. A., Duarte, V., Miranda, R., Santos, T. G., & Oliveira, J. (2019). Current status and perspectives on wire and arc additive manufacturing (WAAM). *Materials*, 12(7), 1121.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *nature*, 323(6088), 533-536.
- Scime, L., & Beuth, J. (2018). A multi-scale convolutional neural network for autonomous anomaly detection and classification in a laser powder bed fusion additive manufacturing process. *Additive Manufacturing*, 24, 273-286.
- Shen, C., Pan, Z., Ding, D., Yuan, L., Nie, N., Wang, Y., . . . Li, H. (2018). The influence of post-production heat treatment on the multi-directional properties of nickel-aluminum bronze alloy fabricated using wire-arc additive manufacturing process. *Additive Manufacturing*, 23, 411-421.
- Silva, M. I. C. e. (2018). *Study of Deposition Strategies of a Wire + Arc Additive Manufactured Component*. (Master's Degree), Técnico Lisboa,
- Standard, A. (2012). Standard terminology for additive manufacturing technologies. *ASTM International F2792-12a*.
- Stewart, S., Martina, F., Addison, A., Ding, J., Pardal, G., & Colegrove, P. (2016). Wire+ arc additive manufacturing. *Mater Sci TECH-LOND*, 32(7), 641.
- Sumesh, A., Nair, B. B., Rameshkumar, K., Santhakumari, A., Raja, A., & Mohandas, K. (2018). Decision tree based weld defect classification using current and voltage signatures in GMAW process. *Materials Today: Proceedings*, 5(2), 8354-8363.
- Tang, S., Wang, G., Song, H., Li, R., & Zhang, H. (2021). A novel method of bead modeling and control for wire and arc additive manufacturing. *Rapid Prototyping Journal*.
- Treutler, K., & Wesling, V. (2021). The current state of research of wire arc additive manufacturing (WAAM): a review. *Applied Sciences*, 11(18), 8619.
- Wang, L., Xue, J., & Wang, Q. (2019). Correlation between arc mode, microstructure, and mechanical properties during wire arc additive manufacturing of 316L stainless steel. *Materials Science and Engineering: A*, 751, 183-190.
- Wang, Y., Lu, J., Zhao, Z., Deng, W., Han, J., Bai, L., . . . Yao, J. (2021). Active disturbance rejection control of layer width in wire arc additive manufacturing based on deep learning. *Journal of Manufacturing Processes*, 67, 364-375.
- Wang, Y., Zhang, C., Lu, J., Bai, L., Zhao, Z., & Han, J. (2020). Weld reinforcement analysis based on long-term prediction of molten pool image in additive manufacturing. *IEEE Access*, 8, 69908-69918.
- Wasmer, K., Kenel, C., Leinenbach, C., & Shevchik, S. (2017). *In situ and real-time monitoring of powder-bed AM by combining acoustic emission and artificial intelligence*. Paper presented at the International Conference on Additive Manufacturing in Products and Applications.
- Wu, B., Ding, D., Pan, Z., Cuiuri, D., Li, H., Han, J., & Fei, Z. (2017). Effects of heat accumulation on the arc characteristics and metal transfer behavior in Wire Arc Additive Manufacturing of Ti6Al4V. *Journal of Materials Processing Technology*, 250, 304-312.

- Wu, B., Pan, Z., Ding, D., Cuiuri, D., Li, H., Xu, J., & Norrish, J. (2018). A review of the wire arc additive manufacturing of metals: properties, defects and quality improvement. *Journal of Manufacturing Processes*, 35, 127-139.
- Xia, C., Pan, Z., Polden, J., Li, H., Xu, Y., Chen, S., & Zhang, Y. (2020). A review on wire arc additive manufacturing: Monitoring, control and a framework of automated system. *Journal of Manufacturing Systems*, 57, 31-45.
- Xia, C., Pan, Z., Zhang, S., Li, H., Xu, Y., & Chen, S. (2020). Model-free adaptive iterative learning control of melt pool width in wire arc additive manufacturing. *The International Journal of Advanced Manufacturing Technology*, 110(7), 2131-2142.
- Xiong, J., Zhang, G., Hu, J., & Wu, L. (2014). Bead geometry prediction for robotic GMAW-based rapid manufacturing through a neural network and a second-order regression analysis. *Journal of Intelligent Manufacturing*, 25(1), 157-163.
- Zhang, C., Gao, M., Chen, C., & Zeng, X. (2019). Spectral diagnosis of wire arc additive manufacturing of Al alloys. *Additive Manufacturing*, 30, 100869.
- Zhang, Y., Hong, G. S., Ye, D., Zhu, K., & Fuh, J. Y. (2018). Extraction and evaluation of melt pool, plume and spatter information for powder-bed fusion AM process monitoring. *Materials & Design*, 156, 458-469.
- Zhao, Z., Guo, Y., Bai, L., Wang, K., & Han, J. (2019). Quality monitoring in wire-arc additive manufacturing based on cooperative awareness of spectrum and vision. *Optik*, 181, 351-360.

EKLER**EK-1** Proje Desteđi ve Verilerin Kullanımı İzni

Bu alıřma, Trkiye Bilimsel ve Teknolojik Arařtırma Kurumu (TBİTAK) tarafından 1501 Sanayi Ar-Ge Projelerini Destekleme Programı kapsamında, Intecro Robotik A.ř. tarafından yrtlen 3200280 kodlu ‘‘Robotik Metal Eklemeli İmalat Tezghının Geliřtirilmesi ve Prototip İmalatı’’ isimli proje kapsamında desteklenmiřtir.

Bu alıřma kapsamında Intecro Robotik A.ř.’nin laboratuvar altyapısının kullanılması, deneysel alıřmaların gerekleřtirilmesi ve yapılan alıřmalar sırasında toplanan verilerin kullanımına ve elde edilen sonuların paylařılmasına izin verilmiřtir.



Ar-Ge Direktr
zge Ece Kara