

**YÖNLENDİRİLMİŞ ENERJİ GİRDİLİ METAL
KATMANLI İMALAT YÖNTEMİ İÇİN TOPOLOJİ
OPTİMİZASYONU**

Metin ÇALLI



T.C.
BURSA ULUDAĞ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**YÖNLENDİRİLMİŞ ENERJİ GİRDİLİ METAL KATMANLI İMALAT
YÖNTEMİ İÇİN TOPOLOJİ OPTİMİZASYONU**

Metin ÇALLI
0000-0002-4148-3163

Prof. Dr. Ferruh ÖZTÜRK
(Danışman)

DOKTORA TEZİ
OTOMOTİV MÜHENDİSLİĞİ ANABİLİM DALI

BURSA – 2022
Her Hakkı Saklıdır

TEZ ONAYI

Metin ÇALLI tarafından hazırlanan “YÖNLENDİRİLMİŞ ENERJİ GİRDİLİ METAL KATMANLI İMALAT YÖNTEMİ İÇİN TOPOLOJİ OPTİMİZASYONU” adlı tez çalışması aşağıdaki jüri tarafından oy birliği ile Bursa Uludağ Üniversitesi Fen Bilimleri Enstitüsü Otomotiv Mühendisliği Anabilim Dalı’nda **DOKTORA TEZİ** olarak kabul edilmiştir.

Danışman: Prof. Dr. Ferruh ÖZTÜRK

Başkan	:	Prof. Dr. Ferruh ÖZTÜRK 0000-0001-5767-8312 Bursa Uludağ Üniversitesi, Mühendislik Fakültesi, Otomotiv Mühendisliği Anabilim Dalı	İmza
Üye	:	Prof. Dr. Necmettin KAYA 0000-0002-8297-0777 Bursa Uludağ Üniversitesi, Mühendislik Fakültesi, Makina Mühendisliği Anabilim Dalı	İmza
Üye	:	Prof. Dr. Abdil KUŞ 0000-0002-4626-0719 Bursa Uludağ Üniversitesi, Mühendislik Fakültesi, Otomotiv Mühendisliği Anabilim Dalı	İmza
Üye	:	Doç. Dr. Hüseyin LEKESİZ 0000-0003-3350-1509 Bursa Teknik Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Makina Mühendisliği Anabilim Dalı	İmza
Üye	:	Dr.Öğr. Üyesi İsmail ÖZTÜRK 0000-0003-2641-5880 Pamukkale Üniversitesi, Teknoloji Fakültesi, Otomotiv Mühendisliği Anabilim Dalı	İmza

Yukarıdaki sonucu onaylarım

Prof. Dr. Hüseyin Aksel EREN
Enstitü Müdürü

.././.....

B.U.Ü. Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

.../.../.....

Metin ÇALLI

TEZ YAYINLANMA FİKRİ MÜLKİYET HAKLARI BEYANI

Enstitü tarafından onaylanan lisansüstü tezin/raporun tamamını veya herhangi bir kısmını, basılı (kâğıt) ve elektronik formatta arşivleme ve aşağıda verilen koşullarla kullanıma açma izni Bursa Uludağ Üniversitesi'ne aittir. Bu izinle Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet hakları ile tezin tamamının ya da bir bölümünün gelecekteki çalışmalarda (makale, kitap, lisans ve patent vb.) kullanım hakları tarafımıza ait olacaktır. Tezde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanılması zorunlu metinlerin yazılı izin alınarak kullandığını ve istenildiğinde suretlerini Üniversiteye teslim etmeyi taahhüt ederiz.

Yükseköğretim Kurulu tarafından yayımlanan “**Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge**” kapsamında, yönerge tarafından belirtilen kısıtlamalar olmadığı takdirde tezin YÖK Ulusal Tez Merkezi / B.U.Ü. Kütüphanesi Açık Erişim Sistemi ve üye olunan diğer veri tabanlarının (Proquest veri tabanı gibi) erişimine açılması uygundur.

Danışman Adı-Soyadı
Tarih

Öğrencinin Adı-Soyadı
Tarih

İmza

Bu bölüme kişinin kendi el yazısı ile okudum
anladım yazmalı ve imzalanmalıdır.

İmza

Bu bölüme kişinin kendi el yazısı ile okudum
anladım yazmalı ve imzalanmalıdır.

ÖZET

Doktora Tezi

YÖNLENDİRİLMİŞ ENERJİ GİRDİLİ METAL KATMANLI İMALAT YÖNTEMİ İÇİN TOPOLOJİ OPTİMİZASYONU

Metin ÇALLI

Bursa Uludağ Üniversitesi
Fen Bilimleri Enstitüsü
Otomotiv Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Ferruh ÖZTÜRK

Yönlendirilmiş enerji girdili metal yığma yöntemi (DED), serbest biçimli geometrilerin üretiminde, onarım uygulamalarında, kaplama ve yüzey modifikasyonunda ve fonksiyonel olarak derecelendirilmiş malzemelerin imalatında kullanılan bir katmanlı üretim sürecidir. Malzemeleri eriterek kaynaştırmak için odaklanmış termal enerjinin kullanıldığı bir süreçtir. Termal etkiler, DED işlemi sırasında parçalarda bozulmalara ve kusurlara neden olabilir, bu nedenle ürünlerin imalatı sırasında değerlendirilmeli ve dikkate alınmalıdır. Eritme havuzu kontrolü ve DED dolgu geometrileri de doğru tanımlanmalıdır. Bu çalışmada, geometrik desenleri tahmin etmek ve hibrit bir üretim teknolojisi olarak lokal takviyeli bir ürün oluşturmak için DED süreç parametreleri dikkate alınarak bir Yapay Sinir Ağı modeli uygulanmıştır.

Döküm, ekstrüzyon ve toz yatak füzyonu gibi üretim yöntemleri için topoloji optimizasyonu üzerine birçok çalışma mevcut olmasına rağmen; DED süreci için tasarım geometrik modellerini tahmin etmede topoloji optimizasyonu yaygın olarak dikkate alınmamaktadır. Bu çalışmada, hibrit parçanın enerji, toplam kütle ve maksimum kuvvet sonuçlarını optimize eden lokal güçlendirmelerin uygun boyutları, topoloji tabanlı geometrik desenleri ve ısı kaynağı gücünü tahmin etmek için yanıt yüzey metodu (YYM) ve genetik algoritma destekli yapay sinir ağları (YSA-GA) yaklaşımları uygulanmıştır. Tek bir DED dolgu biriktirmesi, sayısal ısı kaynağı modelinin doğrulanması açısından simüle edilmiş ve DED dolgularından alınan kesitler analiz edilmiştir.

DED cihazı kullanılarak bir atkı elemanını oluşturacak bir yapı üretilmiş ve bu atkı yapısı, test cihazında üç nokta bükme fiziksel koşulları altında doğrulanmıştır. Lokal olarak güçlendirilmiş atkı kirişin düz modele göre çok daha fazla enerji emilimine ve maksimum kuvvet değerlerine sahip olduğu gözlenmiştir. Sonuçlar, önerilen YSA-GA modelinin, hibrit üretim teknolojileri kullanılarak lokal güçlendirilmiş bir ürün oluşturmak adına topoloji tabanlı geometrik desenler ve süreç parametreleri oluşturmada kullanılabilecek umut verici bir yaklaşım olduğunu göstermiştir.

Anahtar Kelimeler: Katmanlı üretim, yönlendirilmiş enerji girdili metal yığma, DED prosesi için topoloji optimizasyonu, yapay sinir ağları

2022, viii + 95 sayfa.

ABSTRACT

PhD Thesis

TOPOLOGY OPTIMIZATION FOR DIRECTED ENERGY DEPOSITION METAL ADDITIVE MANUFACTURING

Metin ÇALLI

Bursa Uludağ University
Graduate School of Natural and Applied Sciences
Department of Automotive Engineering

Supervisor: Prof. Dr. Ferruh ÖZTÜRK

Directed energy deposition (DED) is an additive manufacturing process used in manufacturing free form geometries, repair applications, coating and surface modification, and fabrication of functionally graded materials. It is a process in which focused thermal energy is used to fuse materials by melting. Thermal effects can cause distortions and defects on the parts during the DED process, therefore they should be evaluated and taken into account during the manufacturing of products. Melting pool control and DED bead geometries should be defined properly as well. In this work, an Artificial Neural Network model has been applied considering the DED process parameters in order to predict the geometrical patterns and create a local reinforced product as a hybrid manufacturing technology.

Although lots of studies are available on topology optimization for manufacturing methods such as casting, extrusion, and powder bed fusion, topology optimization for the DED process is not widely taken into consideration to predict the design geometrical patterns. DOE RSM and ANN approaches were applied in this study to predict convenient dimensions, topology based geometrical patterns of local stiffeners and heat source power optimizing the energy, total mass, and peak force results of the hybrid part. A single bead track deposition is simulated in terms of validation of the numerical heat source model, and cross-sections of the beads are analysed.

A cross-member structure is manufactured using the DED device and the structure is correlated under the three point bending physical conditions on test bench. It has been observed that locally reinforced cross beam has much more energy absorption and peak force values than plain model. The results showed that the proposed NN-GA is a promising approach to generate the topology based geometrical patterns and process parameters which can be used to create a local reinforced product as hybrid manufacturing technologies..

Key words: Additive manufacturing, directed energy deposition, topology for DED process; artificial neural networks

2022, viii + 95 pages.

TEŞEKKÜR

Doktora tez çalışmalarım sürecinde hep yanımda olan danışmanım ve değerli hocam Prof. Dr. Ferruh ÖZTÜRK'e; çalışmalarım süresince birçok konuda bilgi ve yardımlarını esirgemeyen, teknik bilgi ve tecrübesiyle bana yardımcı olan Dr. Emre İsa ALBAK'a teşekkürlerimi sunarım.

Çalışmaların gerçekleşmesi için bütün altyapı ve imkanları sağlayan, 2244 programıyla da desteklerini esirgemeyen Coşkunöz Holding'e, Coşkunöz Kalıp Makina A.Ş' ye, Tübitak'a, Eureka Smart Cluster' a ve Uludağ Üniversitesi'ne teşekkür ederim.

Çalışmalarımda beni cesaretlendiren değerli yöneticilerim Volkan AKINCI ve Mesut KAYA beylere, emeği geçen ismini saymadığım tüm ekip arkadaşlarıma ve Coşkunöz Holding Arge ve İnovasyon Direktörlüğü çalışanlarına destekleri için teşekkür ederim.

Ayrıca bu zorlu süreçte beni her zaman destekleyen ve hep yanımda olan eşim Hilal ÇALLI' ya ve kızım Zeynep Duru' ya, bugünlere gelmemde büyük emeği olan annem Sevdije ÇALLI ve babam Ahmet ÇALLI'ya ve aileme sonsuz teşekkürlerimi sunarım.

Metin ÇALLI

.../.../.....

İÇİNDEKİLER

	Sayfa
ÖZET.....	i
ABSTRACT.....	ii
TEŞEKKÜR.....	iii
SİMGELER ve KISALTMALAR DİZİNİ.....	v
ŞEKİLLER DİZİNİ.....	vi
ÇİZELGELER DİZİNİ.....	viii
1. GİRİŞ.....	1
2. KURAMSAL TEMELLER ve KAYNAK ARAŞTIRMASI.....	4
2.1. Yönlendirilmiş Enerji Girdili Katmanlı Üretim.....	5
2.1.1.Yönlendirilmiş enerji girdili katmanlı üretim kullanım alanları, avantajları ve dezavantajları.....	6
2.2. Katmanlı Üretimde Hibrit Teknolojiler.....	8
2.3. Katmanlı Üretimde Karşılaşılan Hata Türleri.....	11
2.4. Katmanlı Üretimde Optimizasyon.....	13
2.5. Katmanlı Üretimde Malzeme.....	17
3. MATERYAL ve YÖNTEM.....	20
3.1. Parça Belirleme.....	20
3.1.1. Otomotiv kapı barı.....	21
3.2. Sayısal Modelleme ve Doğrulama.....	26
3.2.1. DED prosesi tasarım kısıtları.....	26
3.2.3. Hibrit DED ürünün sanal modelleme ve topoloji optimizasyonu çalışmaları	33
3.2.4. Hibrit DED örnek ürün üretimi ve fiziksel testler.....	39
3.2.5. Hibrit DED örnek ürün iç yapı incelemesi.....	42
3.3. En İyileme Çalışmaları.....	43
3.3.1. Deney tasarım metodları.....	43
3.3.2. Optimizasyon yöntemleri.....	45
3.3.3. Metamodelleme yöntemleri.....	50
4. BULGULAR.....	69
4.1. Hibrit DED Ürün Parça Seçimi Bulguları.....	69
4.2. Dilüsyon Simülasyonu Bulguları.....	70
4.3. Hibrit DED Ürün Fiziksel Test Bulguları.....	72
4.4. Hibrit DED Ürün İç Yapı İnceleme Bulguları.....	73
4.5. Hibrit DED Ürün İçin Metamodelleme Bulguları.....	75
5. SONUÇLAR.....	78
KAYNAKLAR.....	80
EKLER.....	87
ÖZGEÇMİŞ.....	93

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler	Açıklama
α	Alfa Fazı
β	Beta Fazı
Q_r	Yüzey Akısı
Q_0	Maksimum Akı
C	Dağılım Genişliği Katsayısı
η_e	Proses Verimi
P_l	Isı Kaynağı Gücü
r_f	Odak Yarıçapı
D_r	Dilüsyon Yüzdesi
D	Taban Malzemesi Altında Kalan Ergiyik Havuzu Penetrasyon Derinliği
R	Pearson Korelasyon Katsayısı

Kısaltmalar	Açıklama
AM	Additive Manufacturing / Katmanlı Üretim
DED	Yönlendirilmiş Enerji Girdili Katmanlı Üretim
PBF	Powder Bed Fusion/Toz Yatak Ergitme
YSA	Yapay Sinir Ağları
GA	Genetik Algoritma
LMD	Laser Metal Deposition/Lazerli Metal Yığıma Katmanlı Üretimi
EBAM	Elektron Işınli Ergitme Katmanlı Üretimi
WAAM	Tel Ark Yöntemi ile Katmanlı Üretimi
SLA	Stereo-Lithography Apparatus/Foto Kürlenebilir Katmanlı Üretimi
PCM	Phase Change Materials/Faz Değişim Malzemeleri
LHÖ	Latin Hiperküp Örnekleme
YYM	Yanıt Yüzey Metodu
DOE	Design of Experiments/Deney Tasarımı
SLM	Selective Laser Melting/Seçici Lazer Ergitmeli Katmanlı Üretimi
SEBM	Seçici Elektron Işını Ergitme Katmanlı Üretimi
TY	Topoloji Yaklaşımı
KY	Kafes Yaklaşımı
CAE	Computer Aided Engineering/Bilgisayar Destekli Mühendislik
CAD	Computer Aided Design/Bilgisayar Destekli Tasarım
DBW	DED Dolgu Genişliği
DBH	DED Dolgu Yüksekliği
DBD	DED Dolguları Arası Mesafe
BMT	Ana Malzeme Kalınlığı
PP	Dolgu Modeli
LP/HS	Isı Kaynağı Gücü
SEA	Spesifik Enerji Emilimi

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 2.1.	Parça geometrisi çözünürlüğü ve boyutlarına göre farklı katmanlı üretim teknikleri..... 3
Şekil 2.2.	DED uygulama türleri..... 4
Şekil 2.3.	DED uygulama şematiği (LMD) 5
Şekil 2.4.	DED uygulama örneği (Gemi pervanesi) 6
Şekil 2.5.	DED ve PBF karşılaştırması..... 6
Şekil 2.6.	DED prosesi ve termal frezeleme işleminin hibrit uygulaması.... 8
Şekil 2.7.	SLA yöntemiyle oluşturulmuş küçük boyutlu hibrit kafes , PCM uygulaması..... 9
Şekil 2.8.	Değişken sertleşmiş iç yapı örnekleri..... 11
Şekil 2.9.	Toz yatak teknolojisi için kafes yapı örneği 12
Şekil 2.10.	Toz yatak teknolojisi için kafes ve topoloji yaklaşımı..... 13
Şekil 2.11.	SLM yöntemi için bir YSA uygulaması..... 14
Şekil 2.12.	DED yöntemi için proses parametresi tayininde Taguchi uygulaması..... 15
Şekil 2.13.	Farklı teknolojiler için malzeme yığılma oranları..... 17
Şekil 2.14.	Farklı teknolojiler için malzeme birim maliyetleri..... 18
Şekil 3.1.	DED uygulama önerisi-B-Pillar..... 19
Şekil 3.2.	DED uygulama önerisi-Torpedo traversi..... 19
Şekil 3.3.	DED uygulama önerisi-Kapı barı..... 20
Şekil 3.4.	Otomotivde pasif güvenlik uygulaması. A) Çarpışma türleri dağılımı B) Yan kapı barı uygulaması..... 20
Şekil 3.5.	Araç Yan Çarpışma Durumu..... 21
Şekil 3.6.	Topoloji Optimizasyonu Sınır Koşulları..... 21
Şekil 3.7.	Optimizasyon sonuçlarına göre yeniden tasarlanmış kapı barı.... 22
Şekil 3.8.	Kapı barı ağ modeli..... 22
Şekil 3.9.	Kapı barı ısı kaynağı robot yolu..... 23
Şekil 3.10.	DED yazılımındaki analiz sonuçları-Sıcaklık dağılımı..... 23
Şekil 3.11.	DED cihazı ile kapı barı üretimi. A) DED cihazı B) Kapı barı.... 24
Şekil 3.12.	Tasarım değişkenleri..... 25
Şekil 3.13.	DED malzemesinin farklı sıcaklıklardaki gerilim-gerinim eğrileri [316L]..... 26
Şekil 3.14.	Isı kaynağı modeli..... 27
Şekil 3.15.	Isı kaynağı parametreleri..... 28
Şekil 3.16.	Dilüsyon ölçümü..... 28
Şekil 3.17.	Dilüsyon simülasyonu..... 29
Şekil 3.18.	Akışkan hacim oranı yöntemiyle dilüsyon hesaplama örneği. A) Analiz çözümünde toz partiküllerin yayılımı B) Fiziksel iç yapı incelemesi C) Analiz ile elde edilmiş iç yapı..... 31
Şekil 3.19.	Kavramsal tasarım ve optimizasyon süreci..... 33
Şekil 3.20.	Gradyent tabanlı optimizasyon çözücüsü yaklaşımı..... 33
Şekil 3.21.	Topoloji optimizasyonu yazılımı örneği- Aşırı mühendislik tasarımı..... 34
Şekil 3.22.	Topoloji optimizasyonu yazılımı örneği-Kısıtlar..... 35
Şekil 3.23.	Topoloji optimizasyonu yazılımı örneği-Çekme yönü örnekleme..... 35

Şekil 3.24.	Atkı elemanı optimizasyon modeli için sınır koşulları.....	36
Şekil 3.25.	Topoloji optimizasyonu ve parçanın yeniden tasarlanması.....	37
Şekil 3.26.	DED hibrit ürün geliştirme akışı.....	38
Şekil 3.27.	Prototip üretimi. A) DED cihazı B) Hibrit DED atkı parçası.....	39
Şekil 3.28.	DED proses simülasyonu-Yığıma sonrası kalıntı gerilmeler.....	40
Şekil 3.29.	Prototip doğrulama çalışması. A) Fiziksel üç nokta eğme düzenegi B) Sanal üç nokta eğme görseli.....	40
Şekil 3.30.	Prototip parça iç yapı incelemesi.....	41
Şekil 3.31.	Latin hiperküp örnekleme karşılaştırması.....	43
Şekil 3.32.	Arı sürülerinin yiyecek arayışı davranışı.....	45
Şekil 3.33.	Parçacık sürü algoritmasının çalışma adımları.....	46
Şekil 3.34.	Genetik algoritma akışı.....	47
Şekil 3.35.	Doğrusal trende sahip bir Kriging metamodeli tahmini.....	49
Şekil 3.36.	Radyal tabanlı fonksiyon.....	50
Şekil 3.37.	Yanıt yüzey metodu temel işlem adımları.....	51
Şekil 3.38.	Basit YSA yapısı.....	52
Şekil 3.39.	Örnek bir yapay nöron.....	53
Şekil 3.40.	İleri beslemeli sinir ağı.....	54
Şekil 3.41.	Metamodelleme çalışmaları için girdi parametreleri aralıkları.....	59
Şekil 3.42.	DOE YYM öneri modeli simülasyon görseli.....	59
Şekil 3.43.	DOE YYM İle elde edilmiş girdi parametreleri ile çıktılar arasındaki ilişki sonuçları.....	60
Şekil 3.44.	DED prosesi için yapay sinir ağı mimarisi.....	61
Şekil 3.45.	Maksimum kuvvet çıktısında en iyi yapay sinir ağı yapıları için R-değer eğrileri.....	64
Şekil 3.46.	Spesifik enerji emilimi çıktısında en iyi yapay sinir ağı yapıları için R-değer eğrileri.....	65
Şekil 3.47.	Toplam kütle çıktısında en iyi yapay sinir ağı yapıları için R-değer eğrileri.....	66
Şekil 4.1.	Çarpışma analizi sonuçları. A) Mevcut model gerilim sonuçları B) Önerilen modele ait gerilim sonuçları C) İki modelin kuvvet-deplasman eğrisi kıyaslaması.....	68
Şekil 4.2.	Kapı barı proses simülasyonu.....	68
Şekil 4.3.	Farklı tarama hızlarında ısı kaynağı gücünün dilüsyon oranına etkisi.....	69
Şekil 4.4.	DED dolgu simülasyonu.....	70
Şekil 4.5.	Test bulguları. A) Test edilen prototip ürünler B) Üç nokta eğme fiziksel test sonuçları.....	71
Şekil 4.6.	Fiziksel ve sanal sonuçların kıyaslanması. A) Fiziksel test sonrası numune B) Sanal analiz sonrası numune C) Fiziksel ve sanal analiz sonuçlarına ait kuvvet-deplasman grafiği karşılaştırması.....	71
Şekil 4.7.	Fiziksel duvar kesitlerinin makro muayene ve penetrant test görselleri. A) Ön prototipte görülen gözenek hatası B) Bakalitte alınmış duvar kesitlerinin penetrant testi C) ve D) PT testi yapılmış duvarların makro Görüntüleri.....	73
Şekil 4.8.	YYM toplam kütle yanıtı için pareto analizi.....	74

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 2.1.	DED yönteminin avantaj ve dezavantajları..... 7
Çizelge 2.2.	Katmanlı üretimde karşılaşılan hata türleri..... 10
Çizelge 2.3.	Metal katmanlı üretim için malzeme kullanımını ve uygulama alanları..... 16
Çizelge 3.1.	DED cihazı özellikleri..... 24
Çizelge 3.2.	DED dolgu malzemesi kimyasal kompozisyonu [316 L] 25
Çizelge 3.3.	DED Dolgusu Dilüsyon Sonuçları..... 29
Çizelge 3.4.	Hibrit atkı parçasının yeniden tasarlanması için geometrik desenler 37
Çizelge 3.5.	Hibrit giriş ürününün ana malzemesinin kimyasal özellikleri..... 39
Çizelge 3.6.	Girdiler ve çıktılar..... 56
Çizelge 3.7.	Taguchi DOE tablosu..... 57
Çizelge 3.8.	YSA için Taguchi ile oluşturulmuş deney seti..... 57
Çizelge 3.9.	YSA için LHS ile oluşturulmuş deney seti..... 58
Çizelge 3.10.	Tasarım ve proses parametreleri için DOE YYM optimizasyon sonuçları 59
Çizelge 3.11.	Yapay sinir ağı parametreleri..... 61
Çizelge 3.12.	DED simülasyon sonuçları..... 62
Çizelge 3.13.	DED prosesi tasarım ve proses parametreleri için YSA + GA optimizasyon sonuçları 67
Çizelge 4.1.	Kuvvet, enerji emilimi ve toplam kütle değerleri için DOE RSM yaklaşımı sonuçları 75
Çizelge 4.2.	Kuvvet, enerji emilimi ve toplam kütle değerleri için YSA yaklaşımı sonuçları 75
Çizelge 4.3.	DOE RSM ve YSA+GA yaklaşımlarının karşılaştırılması..... 76

1. GİRİŞ

Katmanlı Üretim (Additive Manufacturing)(AM), özellikle havacılık ve biyomedikal sektörleri başta olmak üzere tasarım özgürlüğü, karmaşık geometrilerin oluşturulması, ürün optimizasyonu, hafiflik, modülerlik ve malzemenin verimli kullanılması gibi birçok benzersiz avantaj sunmaktadır. Katmanlı üretim, kattığı değer ve faydalar doğrultusunda “Endüstri 4.0 Sanayi Devrimi” konsepti içerisinde önemli bir yere sahip olmakla birlikte farklı yöntemler sunmaktadır. Katmanlı üretim teknolojilerinde, toz malzemesinin bir yatak içerisinde serildiği (toz yataklı ergitme teknolojisi)(PBF) ve tozun püskürtüldüğü veya telin sürüldüğü (yönlendirilmiş enerji girdili malzeme yığıma)(DED) iki ana yapı bu üretim teknolojisinin temel yapısını oluşturmaktadır.

Toz yataklı katmanlı imalat teknolojileri, orijinal ekipman üreticileri ve dünya çapındaki birinci sınıf tedarikçiler tarafından yoğun bir şekilde kullanılmakta ve araştırılmaktadır. Bununla birlikte, toz yataklı katmanlı üretim metotlarındaki bazı temel kısıtlar mevcuttur. Bunların en kritik olanı; toz yatak tezgahının boyutuyla (standart ticari ekipman üzerinde genellikle herhangi bir boyutunda tipik olarak 300 mm'den az) sınırlandırılmak zorunda olan bileşenlerin boyutudur.

Bunların yanısıra; toz yatak katmanlı imalat prosesi kullanılarak onarım, çoklu malzeme kullanılarak hibrit yapılar oluşturmak mümkün olamamaktadır (Shah. 2011). Bahsi geçen bu sebepler doğrultusunda literatürde DED (Directed Energy Deposition) olarak adlandırılan yönlendirilmiş enerji girdili katmanlı imalat yöntemi, büyük boyutlu parçaların üretilmesi, onarım & tamirat ve daha geniş malzeme kullanımı olanakları ile avantaj sağlayarak ön plana çıkmaktadır.

DED yöntemi özellikle hibrit yapıların kullanımına imkan sağladığı için otomotiv ve havacılık sanayisi başta olmak üzere endüstriyel yapısal parçalarında ağırlık azaltma imkanı da sunmaktadır.

DED yöntemi ile üretilen ürünlerin yapısal mekanik özellikleri birçok parametreden etkilenmektedir. Bu parametreler; yapının dayanım özelliklerini de çok farklılaştırdığından yapılacak yapısal optimizasyon çalışmalarında göz önünde

bulundurulmalıdır. Lazer gücü, tarama hızı, toz besleme oranı and tozun püskürtülme mesafesi de mikro yapıda etkili olan ve kontrol edilebilecek üretim prosesi parameterlerinden bazılarıdır (Segerstark. 2017). Bununla birlikte soğuma süreleri ve ısı girdisinin [lazer gücü veya ısı kaynağı gücü] proseste etkili olduğu gözlemlenmiştir (Neikter. 2017).

Tez çalışmasının temel amacı; otomotiv, havacılık, enerji, makine -teçhizat vb. sektörler için yüksek katma değer yaratan büyük boyutlara sahip hibrit ürünlerin veya bileşenlerin bir DED teknolojisi ile en optimum seviyede üretimi için ilgili engellerin üstesinden gelmektir. Bu tez çalışması, "Havacılık ve Otomotiv Komponentlerinin Katmanlı İmalat Teknolojisi ile Üretilmesi" adlı Tübitak 2244 Sanayi Üniversite İş Birliği Projesinin bir adımını oluşturmaktadır. Bir DED platformu kullanılarak temsili bir otomotiv veya havacılık parçası, çevre komponentlerle ilişkisini belirleyen tasarım hacmine uygun bir şekilde belirlenmiş kritik DED proses parametreleri göz önünde bulundurularak yapay zeka tabanlı topoloji optimizasyonu yöntemi ile tasarlanmıştır.

Tez çalışmasında, DED dolguları ile desteklenmiş bir sac metal yapının spesifik enerji emilimi gibi nihai parça özelliğini geliştirmek için DED imalat prosesinden gelen etkilerin parça üzerine yansıtılarak ve nihai parçanın optimum tepe kuvveti ile toplam kütle kısıtlamaları da dikkate alınarak iki yapının (düz metal ve DED yapıları) entegrasyonunun sunduğu potansiyelin incelenmesi hedeflenmiştir.


Bu tez çalışmasında ayrıca ısı kaynağı modellenmiş olup, mevcut bilinen yanıt yüzey metodu gibi deney tasarım metodları ile de yapıdan elde edilen sonuçlar kıyaslanmıştır. Üretilen örnek fiziksel prototipler aracılığıyla, fiziksel testlerle sanal analiz sonuçları kıyaslanmıştır. Yapısal topoloji optimizasyonunun bir yapay sinir ağı ve uygulanabilir DED dolgu geometrilerinin tasarımına dayalı genetik algoritmalar kullanılarak uygulandığı bir üç nokta eğme test senaryosu geometrisinin (yarı çapraz büyük metal bileşen) ürün ve süreç optimizasyonu çalışması gerçekleştirilmiştir.

Küçük eğitim veri seti kullanılarak hem girdilerin hem de çıktılarının yüksek boyutlu ve doğrusal olmadığı problemler için vekil bir model oluşturmak için hesaplamalı verimli

bir yaklaşıml geliştirilmiştir. Bu kıyaslama çalışmaları neticesinde, tez çalışmasında sunulan yapay zeka algoritmaları ile desteklenmiş topoloji optimizasyon çalışması, basitleştirilmiş bir hibrit otomotiv/havacılık giriş parçasının konsept tasarımını bilindik optimizasyon tekniklerine göre daha hızlı ve etkin bir şekilde ortaya koyabilecektir.

2. KURAMSAL TEMELLER ve KAYNAK ARAŞTIRMASI

Literatürde birçok katmanlı üretim yöntemi yer almaktadır. Bunlarla birlikte, tasarlanacak ya da geliştirilecek parçanın müşteri beklentileri, maliyet, parça boyutları ve parça geometrisinin basit veya karmaşık olmasına bağlı olarak bu yöntemlerden hangisinin daha uygun olacağına karar verilebilir. Şekil 2.1’ de parça boyutu ve parça geometrisinin kompleksitesine ve istenen şekil çözünürlüğüne göre karşılaştırmalı olarak yöntemlerin uygunluğu belirtilmiştir.

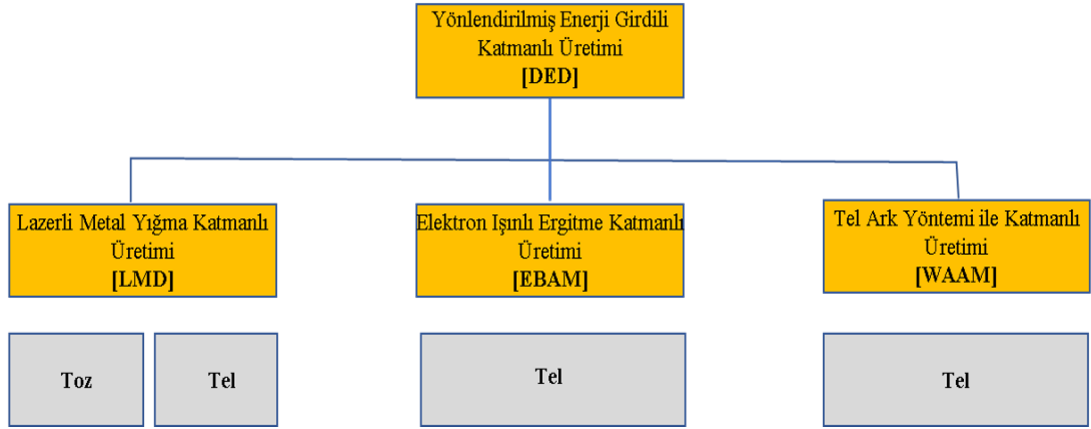


Şekil 2.1. Parça geometrisi çözünürlüğü ve boyutlarına göre farklı katmanlı üretim teknikleri (Ramlab. 2021)

Geliştirilen parça geometrisi özellikle 1000 mm civarına yaklaştığında yönlendirilmiş enerji girdili katmanlı imalat çözümlerinin daha etkili olabileceği görülmektedir. Buna karşılık parça boyutları arttığında elde edilecek ürünün çözünürlüğünün düştüğü aşıkardır.

2.1. Yönlendirilmiş Enerji Girdili Katmanlı Üretim

Son yıllarda, eklemeli imalat; tasarım özgürlüğü, konsolidasyon, ürünlerin özelleştirilmesi, talep üzerine imalat, ağırlık azaltma ve azaltılmış insan etkileri sağladığı için giderek daha fazla büyümüştür (Diegel ve ark. 2020)(Zhang.ve ark. 2018). Katmanlı üretim (AM), havacılık, enerji, petrol ve gaz, otomotiv, tıp, alet, kalıp ve tüketim malları gibi çeşitli sektörlerde önemli bir rol oynamaktadır (Milewski. 2017).




Şekil 2.2. DED uygulama türleri (Ahn. 2021)

AM teknolojilerinden biri olan DED süreci, “malzemeleri eriterek kaynaştırmak için odaklanmış termal enerjinin kullanıldığı katmanlı üretim süreci” olarak tanımlanmaktadır (ISO/ASTM 52900. 2018). DED teknolojileri; lazer ışını, elektron ışını ve ark kaynağı gibi kullandıkları termal enerji kaynaklarına göre sınıflandırılmaktadırlar. Ayrıca bu teknolojiler, Şekil 2.2' de gösterilen toz veya tel gibi farklı biriktirilmiş malzeme tiplerini kullanma kabiliyetine sahip olabilir (Ahn. 2021). DED, metal tozunu/teli eritmek ve uygun bir malzemenin yüzeyinde biriktirmek için bir lazer ışını veya bir ısı kaynağı kullanan "toz üfleme" veya "tel besleme" bir katmanlı üretim işlemi olabilir.

Lazer/ısı kaynağı bir eriyik havuzu oluşturur ve toz/tel üflenir veya inert gaz yardımıyla eriyik havuzuna beslenir. Toz veya tel, eriyik havuzuna girerken erir, böylece eriyik havuzunun hacmi artar. Lazer veya ısı kaynağı sıvı içinde hareket ettikçe katılır ve bir malzeme dolgusu oluşturur. Parçalar, bir katman oluşturmak için örtüşen dolguları paralel bir yöne yerleştirerek ve ardından istenen geometriyi oluşturmak için birden çok katman

yaratılarak oluşturulabilir. DED işlemlerinin bir türü olan Lazer Metal Biriktirme (LMD) Şekil 2.3' de şematik olarak gösterilmiştir.




Şekil 2.3. DED uygulama şematiği (LMD)

2.1.1. Yönlendirilmiş enerji girdili katmanlı üretim kullanım alanları, avantajları ve dezavantajları

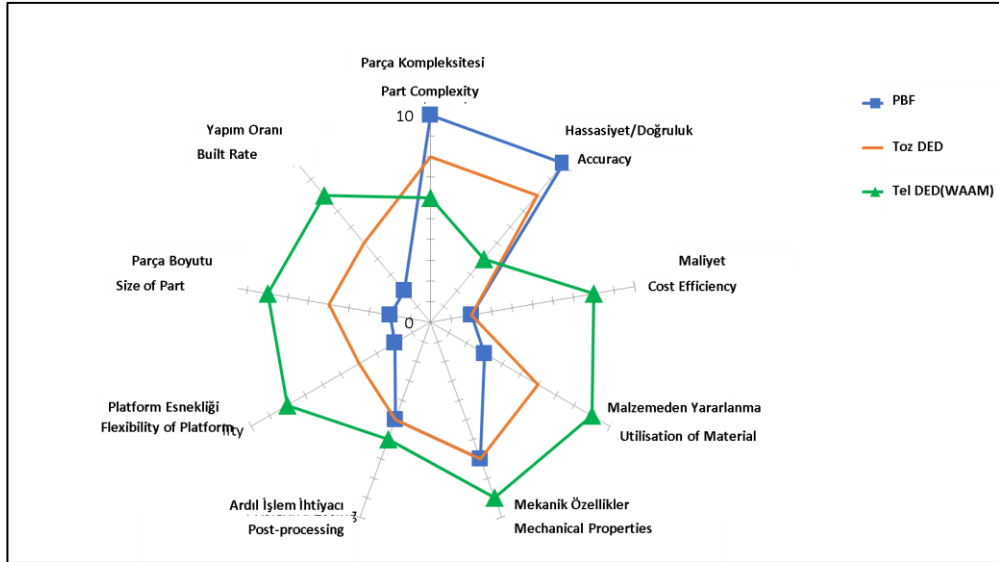
Havacılık, savunma, otomotiv, takım geliştirme gibi sektörlerde, işleme ve geleneksel üretim süreçleri çok fazla hurda malzeme oluşturdukları için yaşanabilir bir çevre için sürdürülebilir çözümler sunamamaktadırlar. DED yöntemi; malzeme israfını, enerji tüketimini, üretim maliyetini ve çalışma saatlerini azaltabilir. Hem robotik hem de kızaklı portal sistemler kullanılarak toz veya tel besleme imkanı ile büyük parçaların üretiminde kullanılabilir.

DED prosesi, hibrit ürünler yaratma imkanı da sunmaktadır. Şekil 2.4' de de gösterildiği üzere bir gemi pervanesinde olduğu gibi serbest biçimli geometrilerin imalatında, onarım uygulamalarında, kaplama ve yüzey modifikasyonunda ve fonksiyonel olarak derecelendirilmiş malzemelerin imalatında geniş bir uygulama alanına sahiptir ve özellikle toz yatak ergitme teknolojisine sahip cihazlarda üretimi mümkün olmayan roket gövdeleri ve yapısal kiriş braketleri gibi havacılık endüstrisindeki büyük parçaların imalatında önemli bir işlemdir (Piscopo ve ark. 2022).



Şekil 2.4. DED uygulama örneği (Gemi pervanesi)

DED yöntemi, bileşenlerin nihai şekline yakın üretim yapmak için kullanılmaktadır. Öte yandan, değeri yüksek bileşenlerin onarılmasını ve yeniden üretilmesini, mevcut parçalara hibrit ürün olarak yeni özellikler eklemeyi, işlevsel olarak derecelendirilmiş malzemeler ve yüzey özelliklerini geliştirmek için kaplama uygulamalarını da kolaylaştırmaktadır.



Şekil 2.5. DED ve PBF karşılaştırması (Panchenko ve ark. 2018)

Katmanlı üretim teknolojileri için geliştirilecek ürün yapısında özellikle DED metotlarından biri olan tel ark kaynağı ergitmeli katmanlı üretim prensibi, Şekil 2.5' de tanımladığı üzere nispeten düşük ekipman maliyeti, malzemeden yüksek oranda fayda sağlama, yüksek güç verimliliği gibi özellikleri ile büyük boyutlu yapıların üretimi için katkı sağlamaktadır.

Çizelge 2.1. DED yönteminin avantaj ve dezavantajları

Avantajları	Dezavantajları
Yüksek kaliteli fonksiyonel parçaların onarımı için kullanılmasına izin veren tane yapısını kontrol etme yeteneği bulunmaktadır .	Bu, doğruluk ve hız arasında bir denge gerektirir, çünkü daha yüksek hızlar, daha düşük bir doğruluk seviyesine ve daha az tutarlı bir mikro yapıya eşittir.
DED, minimum aletle nispeten büyük parçaların üretimine izin verir .	Oluşturulan yüzey, kullanılan malzemeye bağlı olarak değişir ve bazı durumlarda arzu edilen etkiyi elde etmek için düzenlemeler gerektirebilir.
DED aynı zamanda, farklı bileşimlere sahip birden çok malzeme kullanılarak bileşim gradyanlarına veya hibrit yapılara sahip bileşenlerin oluşturulmasına da izin verir.	Malzeme kullanımı hala nispeten sınırlıdır.

Özellikle PBF teknolojilerinin sınırlı tabla ölçülerine sahip olması nedeniyle en az bir boyutu 400 mm ve daha fazla olan endüstriyel bileşenler veya parçalar için DED daha uygun ve esnektir. Ayrıca DED yönteminin sunduğu avantajlar ve karşılaşılabilecek sorunlar ve dezavantajlar Çizelge 2.1' de gösterilmiştir.

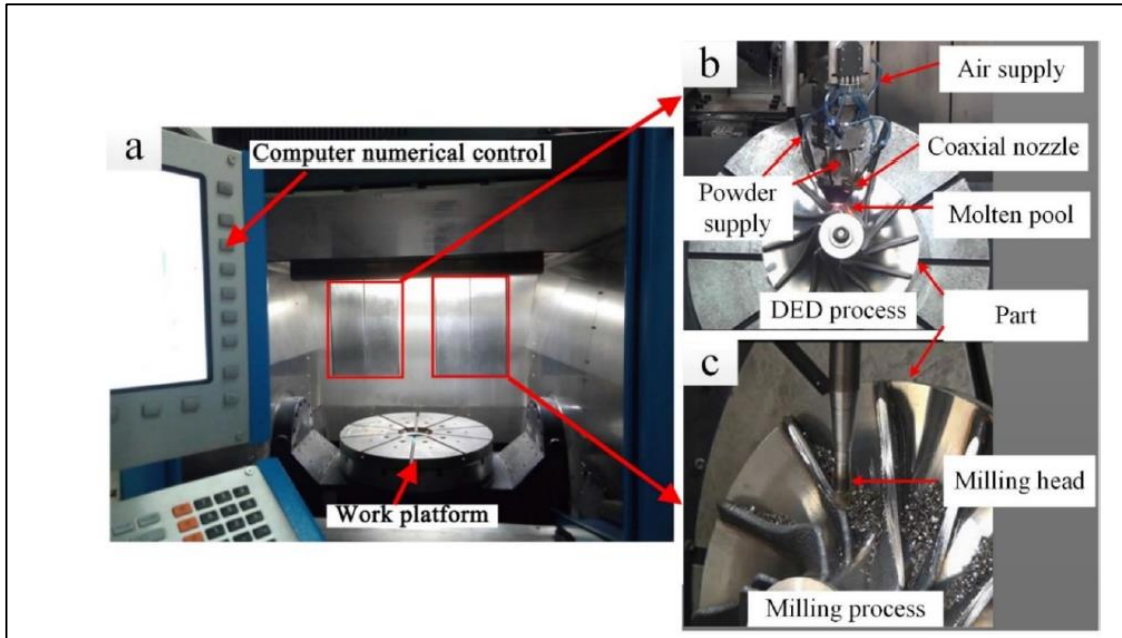
2.2. Katmanlı Üretimde Hibrit Teknolojiler

Son dönemde araştırmacılar; özellikle havacılık ve uzay bileşenlerinin farklı bölümleri için lokal olarak büyük ölçekli çoklu malzemeler ve/veya farklı hammaddeler için farklı katmanlı üretim süreçlerinin birarada uygulanabileceği hibrit çözümler üzerine çalışmaktadır. Hibrit proseslerin, katmanlı üretimde meydana gelen kusurları en aza indirmede veya ortadan kaldırmada, nihai parçaların daha iyi mekanik özelliklerini ve

işlevselliğini sağlamada ve ayrıca proses performansını iyileştirmede etkili olduğu gözlemlenmiştir (Altıparmak ve ark. 2021).


Sistem bileşenlerinin veya ürünlerin gelecekteki bir çalışma olarak mühendislik gereksinimlerine daha iyi uyarlanmaları amacıyla hibrit yapılar ve parçalar oluşturmak için katmanlı üretim teknolojilerinin mevcut olup olmadığı yaygın olarak araştırılmaktadır. Literatürde özellikle hibrit ürün oluşturma denildiğinde, katmanlı üretim teknolojisi ile üretildikten sonra konvansiyonel talaşlı imalat teknolojilerinin bir arada kullanıldığı çözümler ile karşılaşılmaktadır.

Bir yekpare uçak motoru pervanesi gibi karmaşık geometriye sahip yapısal parçalar elde etmek amacıyla 316L malzemesini katman katman biriktirme ve termal talaş kaldırma işlemlerini içeren geniş bir hibrit DED uygulaması için Şekil 2.6' da gösterildiği gibi bir çalışma gerçekleştirilmiştir. Her yığmadan sonra termal frezeleme işlemi uygulanarak, sadece parçanın yüksek sıcaklığını korumakla kalmayarak aynı zamanda bir sonraki yığma adımı için önceden ayarlanmış bir yükseklikle yüzey kalitesi de geliştirilmiştir (Yang ve ark. 2021).



Şekil 2.6. DED prosesi ve termal frezeleme işleminin hibrit uygulaması (Yang ve ark. 2021)

Toz yatağı teknolojileri için daha küçük ve daha uygun boyutlara sahip bir uzay havacılık parçası üzerinde farklı eklemeli üretim teknolojilerinin kombinasyonunu gözlemlemek mümkün olmaktadır. Hibrit bir SLM/DED katmanlı üretim kombinasyonu ile işlenmiş Inconel 718 örnekleri araştırılmış olup bu çalışmada iki farklı AM sürecini birleştiren karmaşık ve farklı bir mikro yapı yaratılmıştır. Küçük boyutlu hibrit parça üretmek için SLA yönteminin, düşük yoğunluklu ısı girdisi sayesinde alternatif bir çözüm oluşturabileceği görülmüştür (Godec ve ark.2021). SLA yöntemi, foto-kürlenabilir reçinelerin kullanıldığı yüksek yapım hızı ve çözünürlüğü olan küçük ölçekli bileşenler için uygun maliyetli bir katmanlı üretim çözümüdür (Suryatal ve ark. 2021).



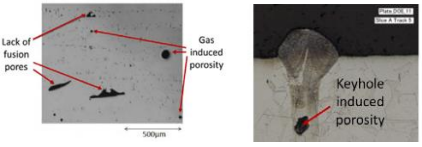
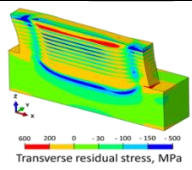
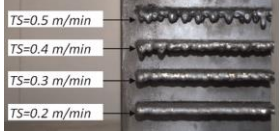
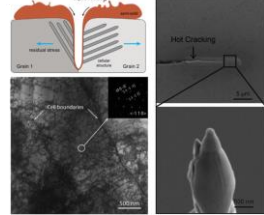
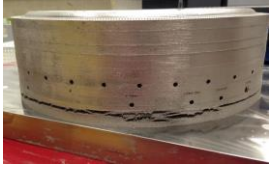
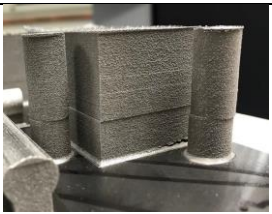
Şekil 2.7. SLA yöntemiyle oluşturulmuş küçük boyutlu hibrit kafes PCM uygulaması (Almonti ve ark. 2022)

Bunların yanısıra, Şekil 2.7’ de belirtildiği üzere SLA yöntemiyle, özellikle güneş panelleri sistemlerinde ısı toplayıcı olarak yer alabilen PCM gibi metalik olmayan biyobazlı malzemeleri kullanan küçük boyutlu hibrit bileşenlerin geliştirildiği görülmektedir. Farklı PCM tipolojileri ile doldurulmuş bileşik yapılar üretilmiş ve termal depolama için kullanılacak modüler bir prototip tasarlamak için ANOVA analizi kullanılarak yapının termal olarak karakterize edildiği çözümler sunulmuştur (Almonti ve ark. 2022).


2.3. Katmanlı Üretimde Karşılaşılan Hata Türleri

Katmanlı üretim teknolojileri özellikle termal prosesler içerdiklerinden ilgili cihazlarda üretilmiş ürün ve bileşenlerde belli başlı sorunlar ortaya çıkmaktadır. Bunun yanısıra katmanlı üretim sırasında kullanılan koruyucu gazlar ve süpürme işlemi gibi mekanik operasyonlar da parça içerisinde hata oluşumlarına sebep olmaktadır.

Çizelge 2.2. Katmanlı üretimde karşılaşılan hata türleri

Görsel	Açıklama	
	Uniform olmayan iç yapı karakteristiği	Koruyucu gaz ve yetersiz ergime kaynaklı porozif yapı oluşumları Isıl güç türü kaynaklı porozif yapı oluşumları (Debroy ve ark. 2018)
	Deformasyonlar ve Çarpılmalar	Atıl Gerilmelerden Kaynaklı İç Yapı Kusuru (Wei ve ark. 2021)
	Geometrik ve Boyutsal hassasiyet	Isı kaynağının ilerleme hızına bağlı olarak oluşan hata türü (Debroy ve ark. 2018)
	Sıcak yırtılma	Atıl Gerilmelerden Kaynaklı İç Yapı Kusuru (Zhongji ve ark. 2019)
	Delaminasyon	İç gerilme kaynaklı hata türü. Katmanlar arası uygun bekleme soğuma süresinin yetersiz olmasından kaynaklı hata türü (Gradl ve ark. 2018)
	Yüzey pürüzlülüğü	Kullanılan yığılma malzemesi, koruyucu gaz ve ortam koşullarından kaynaklı hata türü (Gradl ve ark. 2018)

Parçada oluşacak hataların önüne geçebilmek için ısı kaynağı gücü, tarama hızı, yığma miktarı vb. katmanlı üretim prosesi parametreleri mutlaka süreç içerisinde göz önünde bulundurulmalıdır. Katmanlı üretimde yaygın olarak karşılaşılan sorunlar Çizelge 2.2’de belirtilmiştir.




Şekil 2.8. Değişken sertleşmiş iç yapı örnekleri (Childerhouse ve ark. 2019)

Bu hata türlerinin yanısıra, katmanlı üretim süreçlerinde değişken sertleşmiş iç yapılar ile karşılaşılmaktadır. Katmanlı üretimde yaygın olarak kullanılan titanyum malzemesi, α dan β ya yaklaşık $980\text{ }^{\circ}\text{C}$ civarında transformasyonunun olduğu Ti-6Al-4V kompozisyonuna sahipken allotropik özellikler göstermektedir. Katmanlı üretim tarama yollarının farklı soğutma hızları farklı iç morfolojileri üretir. Bir toz yatak ergitme teknolojisi olan seçici lazer ergitme (SLM)' den elde edilen malzemede iç içe geçmiş trombositlerden oluşan bir sepet örgüsü morfolojisi gelişirken, seçici elektron ışını (SEBM) sürecinde daha hızlı soğutma hızları ince bir ölçek geliştirerek iğnemi martensit yapısını oluşturur. Şekil 2.8, oda sıcaklığında ağırlıklı olarak oluşabilecek bu faz mikroyapılarını göstermektedir (Childerhouse ve ark. 2019).

2.4. Katmanlı Üretimde Optimizasyon


Teknolojinin bilinen durumunda topoloji optimizasyonu teknikleri; ağırlık azaltma ve parçanın geometrik optimizasyonu için kullanışlı bir araç olup, tüm katmanlı üretim yöntemlerinin kendi özel tasarım kurallarına ve gereksinimlerine sahip olmaları sebebiyle, herbir katmanlı üretim süreci için düzgün çalışmamaktadır. Ayrıca bu doğrultuda, literatürde DED prosesi ile hibrit parça üretimi oluşturmak için topoloji optimizasyonu konusunda yaygın ve kapsamlı bir bilgi bulunmamaktadır. Konvansiyonel üretim metodolojileri ile topoloji optimizasyonu tabanlı tasarımları gerçeğe dönüştürmenin zorlukları göz önüne alındığında ise, bunların gerçekleştirilmesi için katmanlı üretim yöntemlerinin kullanılması fikri doğal olarak kabul edilmektedir (Meng ve ark. 2020).



Şekil 2.9. Toz yatak teknolojisi için kafes yapı örneği (Gümüş ve ark. 2018)

Toz yatak teknolojileri için topoloji optimizasyonu yaygın olarak kullanılmaktadır. Özellikle parçanın ağırlığının optimum hale getirilmesi adına poroz veya boşluklu yapılar olan kafes yapıları Şekil 2.9' da gösterildiği üzere çokça tercih edilmektedir (Gümüş ve ark. 2018).

Literatürde; bir C-klip parçası için katmanlı üretimdeki proses kısıtı olarak yazdırma süresini dikkate alan ve klasik topoloji yaklaşımı (TY), kafes yaklaşımı (KY) nın yanısıra bu her iki TY ve KY' nin akıllı bir karışımı olan hibrit bir çözüm yaklaşımı ile süreç oluşturulduğu görülmüştür. Ayrıca son derece karmaşık bir kafes yapısı oluşturmak ve bunların entegrasyonunun hangi avantajları sunduğunu değerlendirmek için de incelemelerde bulunulmuştur (Primo ve ark. 2017). Şekil 2.10' da topoloji ve kafes yaklaşımı görselleştirilmiştir.



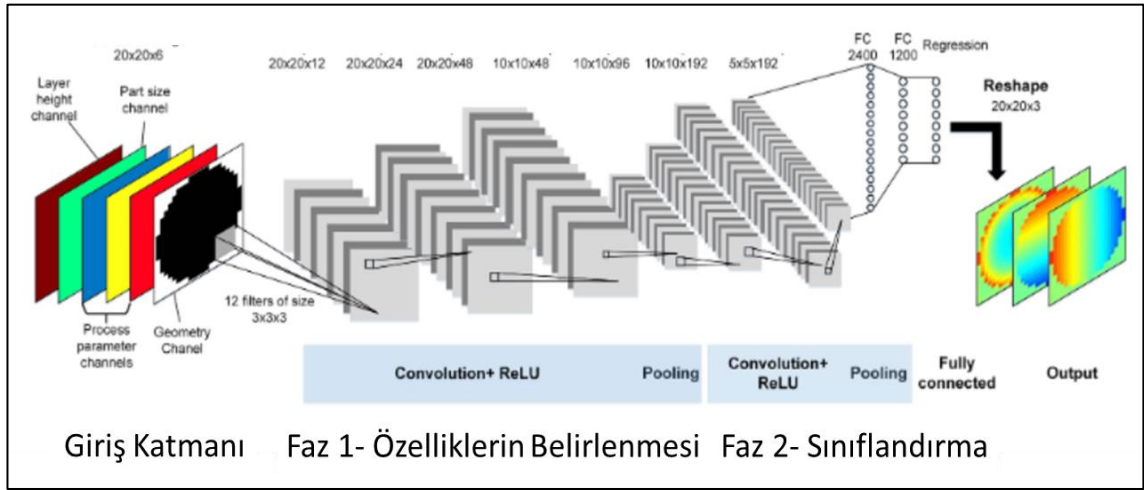
Şekil 2.10. Toz yatak teknolojisi için kafes ve topoloji yaklaşımı

Öte yandan, katmanlı üretimin yeniden imalatta uygulanabilirliği konusunda araştırmacılar arasında ilgi artmıştır. Ancak optimizasyon amacıyla yapay zekaya dayalı sistematik yaklaşımlar konusunda veri eksikliği vardır (Aziz ve ark. 2021). Yapay sinir ağları ve optimizasyon algoritmaları; özellikle optimizasyon modelinin hesaplama karmaşıklıkları ve belirsizliklerine dayalı olarak kurulduğu süreçlerde optimizasyon yöntemi olarak ürünlerin, sistemlerin ve bileşenlerin en iyilemesinde önemli bir rol oynamaktadır ve sistemin temsil noktalarını tahmin etmek için vekil modeller olarak uygulanmaktadırlar (Bulut ve ark. 2022).

Katmanlı üretimin tüm aşamalarında uygulanabilmesi hedefiyle yapay sinir ağları (YSA) yaklaşımları gözden geçirilmektedir. Özellikle optimizasyon açısından gerekli kısıt ve parametrelerin belirlenmesi önemlidir. Katmanlı üretimde, LMD ve WAAM gibi DED yöntemleri için işlem parametrelerinin lazer gücü, tarama hızı, toz besleme hızı, dolgu

geniřlięi, dolgu ykseklęi ve dolgu biriktirme yollarının merkez mesafesi olduęuna dikkat çekilmektedir (Xinbo ve ark. 2019).

PBF teknolojilerinden biri olan seęici lazer ergitme iin farklı ısı kaynaęı gcne sahip eriyik havuzu grntlerinin sınıflandırmasını tanımlamak iin YSA yaklařımları uygulanabilmektedir. Yapay sinir aęları kullanılarak oluřturulan sınıflandırma modelinin, mikro yapıların beklenmedik řekilde deęiřmesine neden olacak konumun tespit edilmesi iin veya kusurlu rnleri tahribatsız bir řekilde ayırabilmek iin kullanılabileceęi grlmřtr (Kwon ve ark.2020).



řekil 2.11. SLM yntemi iin bir YSA uygulaması (Zhu ve ark.2020)

Yapay sinir aęları, iřlem grntlerini sınıflandırarak fzyon yıęma modellemesi iin geometrik sapmaların ve arpılmaların tahmin edilebilmesi adına tercih edilebilmektedir. Burada para retimi esnasında proses grntleri ile iřlem gerekleřtirilmektedir. zellikle proses parametrelerinin deęiřimine gre elde edilen grseller YSA yaklařımı ile řekil 2.11' de belirtildięi zere ilgili adımlarda grsellerin piksellerine gre deęerlendirilerek SLM yntemi iin uygun geometride para elde edilmesini hedeflemiřtir (Zhu ve ark.2020) .

Toz yatak ergitme prosesi ile retilmiř bir paranın nihai kalitesini arttırmak hedefiyle PBF proses parametrelerinin en iyilemesi iin sre parametreleri ve malzeme zellikleriyle eřleřtiren bir optimizasyon yaklařımının sunulduęu zmler de

bulunmaktadır. İlk faz çalışmalarında, lazer gücünün ve tarama hızının, SS 316L paslanmaz çelik malzemesi ile üretilen parçaların mikroyapısı ve gözenekliliği üzerindeki etkileri araştırılmıştır. PBF yöntemi ile üretilen bir parçanın istenen nihai kalitesine göre optimize edilmiş proses parametrelerini önermek için bir YSA uygulaması gerçekleştirmişlerdir (Marrey ve ark.2019).



Şekil 2.12. DED yöntemi için proses parametresi tayininde Taguchi uygulaması

Yönlendirmeli enerji girdili katmanlı üretim metodolojisi için tek bir dolgu yapısına ait optimizasyon çalışması daha fazla gözlemlenmektedir. Altlık ile dolgu malzemesi arasında gözeneksiz bir mikro yapı ve iyi bir arayüzey bağı elde etmek amacıyla proses parametrelerinin optimize edildiği görülmektedir. Taguchi'nin L9 yöntemi, deney tasarımı için tercih edilmekte olup; toz besleme hızı, lazer gücü ve lazer tarama hızı optimizasyon parametreleri için kullanılmaktadır. Taguchi yöntemiyle, oluşturulan numunelerin mikroyapısı ve mikrosertliği incelenerek en iyilenmiş proses parametrelerine erişim sağlanmıştır (Manjunath ve ark.2020). Şekil 2.12' de DED dolgularının incelenmesi adına benzer bir Taguchi çalışması gösterilmiştir.

Bunlarla birlikte, yapılan literatür araştırmalarında DED ile tam bir hibrit parça üretimi ve üretilecek bu parçanın optimizasyonu için mevcut araç ve gereçlerin sınırlı olduğu görülmüştür. Ayrıca, toz yatak teknolojisinde olduğu gibi DED prosesi için yaygın ve

geniş bir bilgi birikiminin olmadığı gözlemlenmiştir. Bu sebeple bu tez çalışması kapsamında DED proses parametrelerini de gözönünde bulunduran yapay zeka destekli bir topoloji optimizasyon çalışması metodolojisi irdelenmektedir.

2.5. Katmanlı Üretimde Malzeme

Katmanlı üretim süreçleri, ASTM Standardı F2792 içerisinde Yönlendirilmiş Enerji Biriktirme (DED) ve Toz Yatak Ergitme (PBF) olarak tanımlanan temel iki kategoriye ayrılmaktadır. Katmanlı üretim süreçleri; toz, tel veya levha gibi hammadde malzemelerini ergiterek bir metalik parça oluşturmak amacıyla lazer, elektron ışını veya elektrik arkı gibi bir enerji kaynağının yardımıyla birleştirmektedir.


Çizelge 2.3. Metal katmanlı üretim için malzeme kullanımı ve uygulama alanları

Uygulama alanı	Alüminyum	Paslanmaz Çelik	Titanyum	Kobalt Krom	Nikel Süper Alaşımları	Maraging Çeliği
Uzay ve havacılık	☆	☆	☆	☆	☆	
Medikal		☆	☆	☆	☆	
Enerji		☆				
Otomotiv	☆	☆	☆			
Marina		☆	☆			
Takım & Kalıp		☆				☆
Tüketici Ürünleri	☆	☆				

Yapısal olarak sağlam, hatasız ve güvenilir bir parçanın imalatı için mevcut parçanın gereksinimlerinin çok iyi anlaşılması gerekir. Özellikle parçanın gereksinimleri karşılayabilmesi adına malzeme seçimi kritik bir öneme sahiptir. Metal katmanlı üretim süreçlerinde yaygın olarak kullanılan malzemeler ve alaşımlar ile bunların çeşitli uygulama alanları Çizelge 2.3’ de gösterilmektedir (Debroy ve ark. 2018).

Uygulama alanına göre doğru malzeme seçeneklerinde, metal katmanlı üretim süreçleri için paslanmaz çelik uygulamalarının birçok uygulama alanında yaygın bir şekilde kendisine yer bulduğu gözlemlenmektedir. Kolay bulunabilmesi, otomotiv ve havacılık


sektörlerinde yaygın olması ve özellikle de parça üretimi sırasında diğer malzemelere göre iş güvenliği riskinin daha az olması sebebiyle bu tez çalışmasında paslanmaz çelik malzemeye odaklanılmıştır.



Şekil 2.13. Farklı teknolojiler için malzeme yığma oranları

Katmanlı üretimde kullanılan malzemeler farklı üretim teknolojileri için tel veya toz halinde bulunabilmektedirler. Bununla birlikte özellikle toz püskürtmeli veya tel beslemeli yönlendirilmiş enerji girdili katmanlı üretim çözümlerinde saatte 4 kg' a kadar malzeme yığılabilmektedir. Toz yatak teknolojisinde ise malzeme yığma oranları DED yöntemine göre çok daha düşük seviyelerde gerçekleşmektedir. Ayrıca toz DED sistemlerinde malzeme yığma miktarları tel ark ergitme DED yöntemine kıyasla 2.5 kg/h olarak görülmektedir. Farklı teknolojiler için malzeme yığma oranları Şekil 2.13' de ifade edilmiştir (3Dmpwire).

Katmanlı üretimde malzeme seçiminde önemli kriterlerden birisi de malzeme maliyetidir. Tel beslemesine sahip katmanlı üretim teknolojileri genellikle daha düşük toplam malzeme maliyetlerine sahiptir. Toz yataklı ergitme teknolojisi bazlı katmanlı üretim prosesleri ise daha yüksek maliyetli malzeme kullanmaktadırlar ve toz malzemenin yeniden kullanımında bazı limitleri mevcuttur. Tipik olarak 1 kg nihai ağırlığa sahip bir titanyum parçası oluşturmak için yaklaşık toplam malzeme maliyetleri Şekil 2.14' de orantısal birim para değeri olarak belirtilmiştir (DigitalAlloys).




Şekil 2.14. Farklı teknolojiler için malzeme birim maliyetleri (DigitalAlloys)

3. MATERYAL ve YÖNTEM

3.1. Parça Belirleme

Endüstriyel uygulamalarda, toz yatak füzyon teknolojileri genellikle 400mm x 400mm' den daha küçük çalışma masası boyutlarına sahiptir veya hibrit üretim sunamaz. Daha büyük uzunluk veya genişlik boyutlarına sahip hibrit ürünlerin oluşturulmasının ihtiyaç duyulduğu durumlarda DED teknolojisi, üretim süreçleri için maliyetleri kolaylaştırabilmekte ve optimize edebilmektedir.


Günümüzde özellikle elektrikli araçlara olan ilginin artmasıyla birlikte, araç ağırlığının hafifletilmesi odak konu haline gelmiştir. Özellikle araç ağırlığının düşürülmesi elektrikli araçlarda menzil artırılması için önem kazanmaktadır. Araç ağırlığı azaltılırken otomotiv parçasının mevcut güvenlik gereksinimlerinden ödün vermemesi gerekmektedir. Bu hedefler doğrultusunda, güvenlik gereksinimlerine ulaşmada bir yöntem de yönlendirilmiş enerji girdili katmanlı imalat yöntemi bir çözüm oluşturabilir.




Şekil 3.1. DED uygulama önerisi-B-Pillar

DED Hibrit imalatına uygun olabilecek bileşenlere ilişkin bazı örnekler Şekil 3.1, 3.2 ve 3.3' de gösterilmiştir. Bu örneklerin yanı sıra savunma, havacılık, otomotiv, denizcilik, makine gibi hemen hemen tüm endüstriyel sektörlerde çok sayıda dikey veya yatay

travers parçası bulunmaktadır. Bu yapılar DED yöntemiyle hibrit teknoloji kullanılarak üretilebilir potansiyele sahiptir.



Şekil 3.2. DED uygulama önerisi-Torpedo traversi




Şekil 3.3. DED uygulama önerisi-Kapı barı

3.1.1. Otomotiv kapı barı


Otomotiv endüstrisinde araç tasarımı sürecinde aracın çarpışma performanslarının iyileştirilmesi adına çalışmalar gerçekleştirilmektedir. Özellikle araç kazalarının % 19.4' ü yandan çarpışma şeklinde gerçekleşmektedir (Çallı ve ark. 2020). Araç kazalarında

çarpışma türleri ve yan kapı barı uygulaması Şekil 3.4’ de gösterilmiştir. Bununla birlikte, yan kapı barları araç içerisindeki yolcu güvenliğini sağlamak amacıyla kullanılan pasif güvenlik sistemleridir. Yan kapı barları kaza esnasında oluşan enerjiyi sönmölemektedir.



Şekil 3.4. Otomotivde pasif güvenlik uygulaması. A) Çarpışma türleri dağılımı B) Yan kapı barı uygulaması (Çallı ve ark. 2020)


Yan kapı barının boyutlarından en az biri 400 mm den fazla olmaktadır. Endüstriyel uygulamalarda DED yönteminin büyük boyutlu parça üretimi avantajı göz önünde bulundurulduğunda otomotiv endüstrisi için hibrit bir yan kapı barı oluşturulması için çalışmalar gerçekleştirilmiştir.



Şekil 3.5. Araç yan çarpışma durumu


Yan kapı barı, aracın yandan çarpışması esnasında temel olarak Şekil 3.5’ de tasvir edildiği gibi bir yükleme koşuluna maruz kalmaktadır. Bu çarpışma durumunu temsil

edebilmek adına, kapı barları rijit bir darbe direği ile orta bölgesinden eğilme kuvvetine zorlanmaktadır denilebilmektedir. Bu doğrultuda, çalışma kapsamında ilk olarak topoloji optimizasyonu için Şekil 3.6’da belirtildiği gibi tasarım ve tasarım dışı alanlar belirlendikten sonra üç nokta eğme sınır koşulu uygulanarak parça optimizasyonu sağlanmıştır.




Şekil 3.6. Topoloji optimizasyonu sınır koşulları

Kapı barı parçası topoloji optimizasyonu sonucuna göre yeniden tasarlanmıştır. Bunun yanısıra feder yapıları DED prosesine uygun hale getirilmiştir. Optimizasyon sonucu ve yeniden tasarlanmış kapı barı parçası Şekil 3.7’ de gösterilmiştir.




Şekil 3.7. Optimizasyon sonuçlarına göre yeniden tasarlanmış kapı barı

Kapı barı yapısı topoloji optimizasyonu sonuçlarına uygun olarak yeniden tasarlanmasının ardından, yapının sanal analizleri üç nokta eğme metoduna uygun olarak gerçekleştirilmiş olup parçanın enerji emilimi kıyaslanmıştır.




Şekil 3.8. Kapı barı ağ modeli

Yan kapı barı parçasının yapısal ve termomekanik analizleri için sonlu elemanlar ağ yapısı, Altair Hypermesh yazılımı kullanılarak Şekil 3.8’ de gösterildiği gibi oluşturulmuştur. Sonucun doğruluğu için ağ tipi olarak prizmatik elemanlar tercih edilmiş olup, hexahedral elemanlarla örülmüştür.




Şekil 3.9. Kapı barı ısı kaynağı robot yolu

DED simülasyon yazılımı olarak kullanılan Simufact yazılımında, üretilen parçanın termomekanik analiz çalışmaları gerçekleştirilmiştir. Termomekanik modelleme çalışmalarında proses simülasyonunun gerçekleştirilebilmesi adına Şekil 3.9’ da gösterilen ısı kaynağının ilerleyeceği yolun tanımlanması gerekmektedir. Diğer taraftan, termomekanik analizlerde DED dolgu işlemi sırasında oluşan sıcaklık durumuna ait analiz görselleri Şekil 3.10’ da gösterilmiştir.



Şekil 3.10. DED yazılımındaki analiz sonuçları-Sıcaklık dağılımı

Bir otomotiv yan kapı barı parçasının DED yöntemiyle hibrit olarak Lazer Metal Yığma (LMD) (DED) Cihazında üretimi gerçekleştirilmiştir. Lazer Metal Yığma cihazına ait özellikler Çizelge 3.1’de belirtilmiştir. Ayrıca DED cihazına ait görsel ve DED dolguları ile lokal olarak güçlendirilmiş kapı barı parçasına ait üretim görseli Şekil 3.11’ de gösterilmiştir.



Şekil 3.11. DED cihazı ile kapı barı üretimi. A) DED cihazı B) Kapı barı


Çizelge 3.1. DED cihazı özellikleri

Işın Türü	Lazer
Lazer Türü	Fiber
Isı Kaynağı Gücü	3 kW
Malzeme Türü	Toz
Malzeme Besleme Türü	Püskürtme (Powder Blown)
Hareket Kabiliyeti	4 metre
Serbestlik Derecesi	6 eksen

3.2. Sayısal Modelleme ve Doğrulama

3.2.1. DED prosesi tasarım kısıtları

DED prosesinde, metal tozunu veya teli ergitmek ve uygun bir malzemenin yüzeyinde yığmak için bir lazer ışını veya bir ısı kaynağı kullanılmaktadır. Isı kaynağı gücü, özellikle püskürtülen veya beslenen toz/tel malzemenin uygun bir şekilde eriyik havuzunu oluşturması adına kritik olmaktadır. Bununla birlikte her bir DED dolgusuna ait genişlik, yükseklik ve aralarındaki mesafe gibi özellikleri hibrit yapının ne kadar dayanıma sahip olacağını belirleyici tasarım değişkenlerinden biri olacaktır. Ayrıca bu dolguların geometrik desenleri/modelleri ve ana malzemenin kalınlığı diğer tasarım değişkenleridir. Tez çalışmada kullanılan DED prosesine ait tasarım değişkenleri Şekil 3.12’ de ifade edilmektedir.



Şekil 3.12. Tasarım değişkenleri

3.2.2. Isı kaynağının modellenmesi

Yönlendirilmiş enerji girdili katmanlı üretim prosesi, malzemeleri eriterek kaynaştırmak için kullanılan termal enerjiye odaklandığından, termal etkiler, katmanlar veya ana malzeme/alt tabaka arasında mukavemet ve temas kaybı gibi bozulmalara ve kusurlara neden olabilir (Wahab ve ark. 2019). Bu nedenle termal etkiler, DED tarafından üretilen bileşenlerin tasarımı sırasında, işlemten sonra bileşen üzerinde kalan gerinim ve gerilmelerin neden olduğu herhangi bir dayanım kaybını önlemek için değerlendirilmeli ve dikkate alınmalıdır. Eritme havuzu kontrolü ve DED dolgu geometrileri de uygun şekilde tanımlanmalıdır.

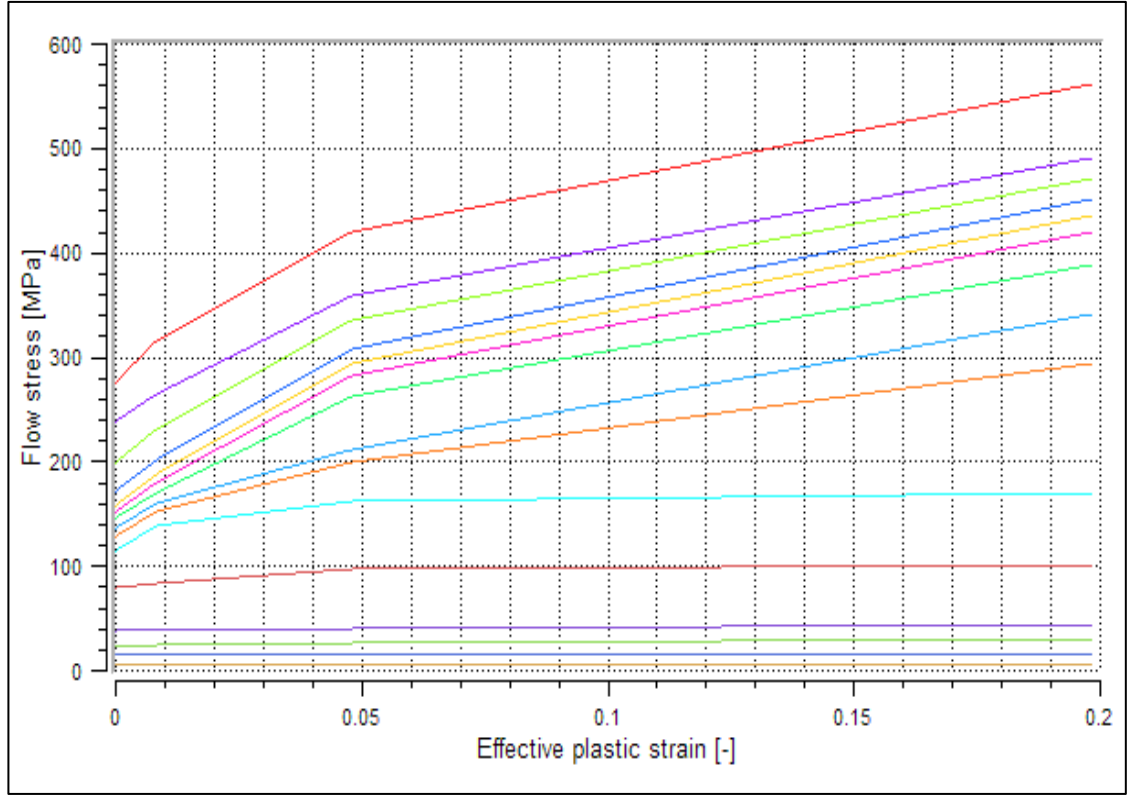
Çizelge 3.2. DED dolgu malzemesi kimyasal kompozisyonu [316 L]

Element	C	Co	Cr	Mn	Mo	N	Ni	P	S	Si
% Kütle Oranı	0,018	0,19	16,63	1,57	2,05	0,0153	11,18	0,04	0,002	0,48

Termo-mekanik davranışın modellenmesi, DED sürecinin sayısal analizinin önemli bir parçasıdır. Kaynak yaklaşımı varsayılarak DED proses simülasyonu yapılmıştır. Isıl işlem proseslerini, soğutma ve kenet açma kurulumlarının varyasyonlarını ve ayrıca kaynaklı yapıların mekanik yüklemesini modelleme olanakları sağladığı için proses simülasyonları Simufact Welding yazılımı üzerinde gerçekleştirilmiştir.

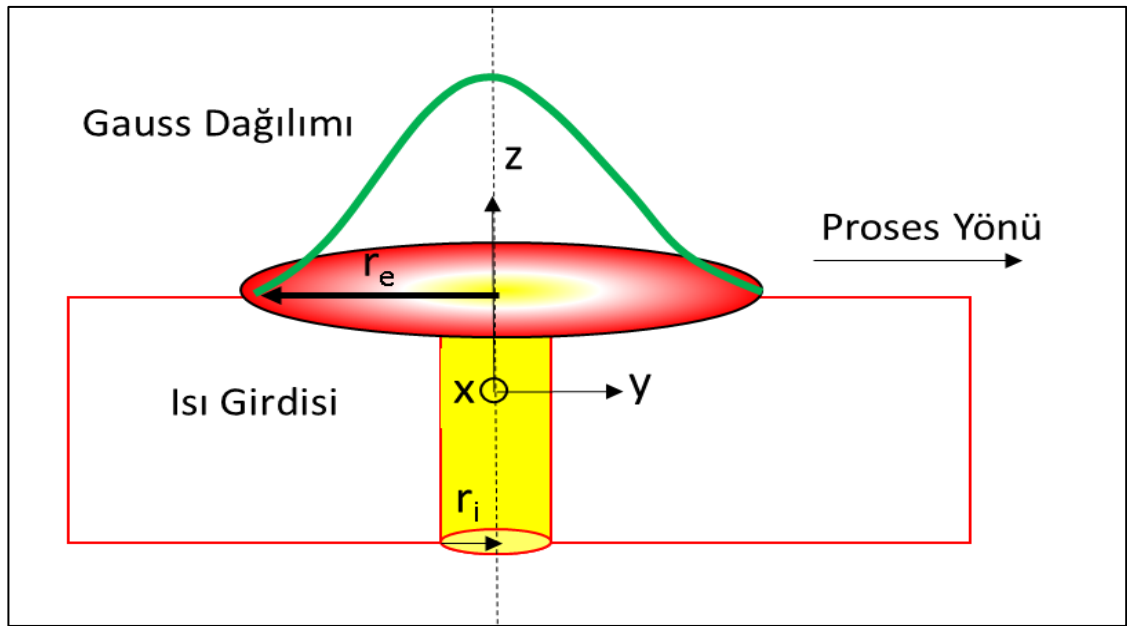
Bununla birlikte, Simufact Welding yazılımı malzemelerin akış eğrilerini kullanarak artık gerilmeleri tanımlama ve parça üzerindeki termal işlem etkilerini haritalama yeteneğine sahiptir. Dolgu malzemesi olarak 316L malzemesi seçilmiştir. Çizelge 3.2'deki kimyasal bileşimi ve yazılım malzeme veri tabanından akış eğrileri (bkz. Şekil 3.13) ile DED dolgu malzemesinin tanımlanması gerçekleştirilmiştir.

Isı girdisi sayısal modelde; bir hacim ve yüzey dağılımına sahip ısı kaynağı olarak tanımlanmıştır. Isı kaynağı, Gauss yüzey dağılımına sahip bir ısı girdisine sahip olmakla birlikte, sabit bir ısı dağıtım silindirinden oluşmaktadır.



Şekil 3.13. DED malzemesinin farklı sıcaklıklardaki gerilim-gerinim eğrileri [316L]

Tez çalışmasında kullanılan ve Gaussian dağılımına sahip, proses yönü ve ısı girdisi tarif edilen ısı kaynağı modelinin bir gösterimi Şekil 3.14' te görülebilmektedir.



Şekil 3.14. Isı kaynağı modeli

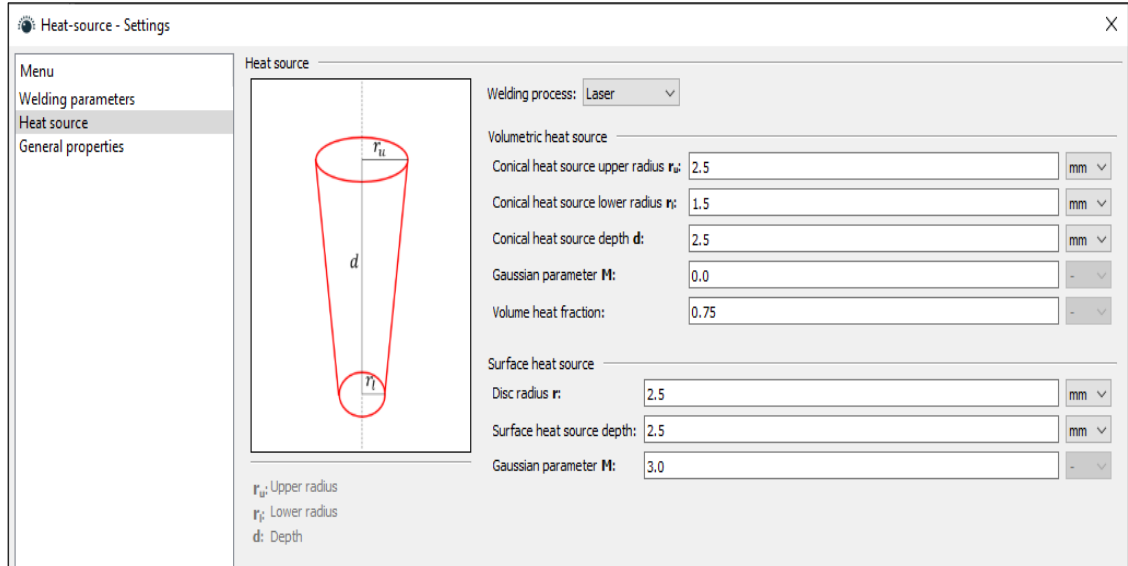
Genel bir Gaussian dağılımı için, yüzey akısı Q_r ($W \cdot mm^{-2}$) 3.1 ile ifade edilen denklemdeki haliyle elde edilir (Goldak ve ark. 2005);

$$Q_r = Q_0 e^{-Cr^2} \quad (3.1)$$

Q_0 ($W \cdot mm^{-2}$) maksimum akı, r (mm) ısı kaynağının merkezinden olan radyal mesafe, ve C (mm^{-2}) ise dağılım genişliği katsayısı olarak ifade edilmektedir. Lazer ışını kaynağının özel durumu için ısı akısı 3.2 denkleminde gösterildiği gibi tanımlanır:

$$Q_r = \frac{2\eta_e P_l}{\pi r_f^2} e^{-\frac{2r^2}{r_f^2}} \quad (3.2)$$

η_e proses verimi, P_l güç (W), ve r_f ise odak yarıçapı olarak tanımlanmaktadır (Goldak ve ark. 2005). Deneysel lazer parametrelerine dayalı olarak bir DED simülasyon modeli gerçekleştirilmiştir. Analizde kullanılan ısı kaynağı parametreleri temsili olarak Şekil 3.15' de gösterilmektedir.



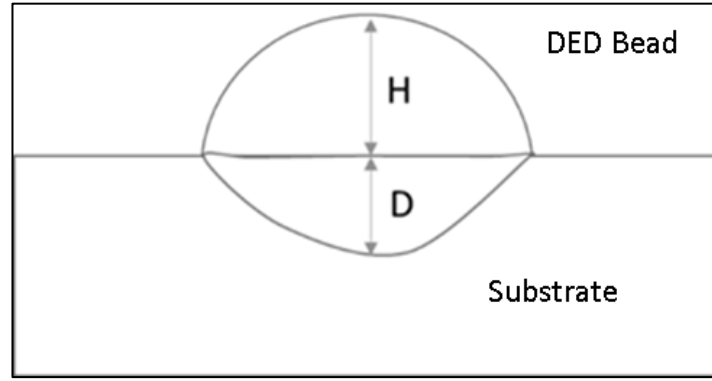
Şekil 3.15. Isı kaynağı parametreleri

Dilüsyon (dilution), DED süreç performansı için en kritik parametrelerden biridir. Bu boyutsal bir parametredir. Dilüsyon; alt tabakanın altındaki eriyik havuzu penetrasyon derinliği ile tek bir dolgu katmanı için eriyik havuzu penetrasyon derinliği ve yığılan

yükseklığın toplamı arasındaki oran ile tanımlanır. Denklem 3.3' de gösterildiği gibi hesaplanmaktadır.


$$D_r (\%) = (D / (D + H)) \times 100 \quad (3.3)$$

D_r (%) dilüsyon yüzdesi veya dilüsyon oranı, D taban malzemesi altında kalan ergiyik havuzu penetrasyon derinliği, ve H (mm) ise yığılmış tek bir katmanın yüksekliğini ifade etmektedir. Bu kavramlar, Şekil 3.16 de görselleştirilmiştir.



Şekil 3.16. Dilüsyon ölçümü (Çallı ve ark. 2022)

Dilüsyon simülasyonu 1100, 1300 ve 1500 Watt olmak üzere üç farklı Isı Kaynağı Gücü ile gerçekleştirilmiştir. Öte yandan, DED katman yüksekliği 5 mm sabit bir değerde tutularak 8 ve 12 mm/sn olarak 2 farklı tarama hızı tercih edilerek gerçekleştirilmiştir.



Şekil 3.17. Dilüsyon simülasyonu

DED süreci için ısı kaynağı yaklaşımını doğrulamak amacıyla CAE modeli için blok elemanlar kullanılmıştır. Bu tür bir elemanı kullanmanın avantajı, ayrıklaştırmanın

doğruluğundaki artıştır. Dilüsyon için ısı kaynağı gücünün 1500 Watt ve tarama hızının 12 mm/sn olduğu koşulda elde edilen sonuçlar Şekil 3.17' de gösterilmektedir.

Dilüsyon oranı için ısı kaynağı simülasyon modeli kurulmuş ve bu yaklaşımlardan elde edilen sonuçlar Çizelge 3.3' de toplanmıştır. Modelin rasyonelliği akademik çalışmalarla da karşılaştırılmıştır (Xi ve ark. 2019).

Çizelge 3.3. DED Dolgusu Dilüsyon Sonuçları

Isı Kaynağı Gücü(W)	Lazer Tarama Hızı (mm/sn)	D (mm)	H (mm)	D + H (mm)	Dilüsyon Oranı
1500	12	3,368	5	8,368	0,402486
1500	8	3,723	5	8,723	0,426803
1300	12	3,178	5	8,178	0,388604
1300	8	3,589	5	8,589	0,41786
1100	12	3,006	5	8,006	0,375468
1100	8	3,496	5	8,496	0,411488

3.2.2.1. Alternatif ısı kaynağı modelleme tekniği

DED yöntemi için alternatif bir ısı kaynağı ve ergiyik havuzunun modellenme şekli de akışkan hacim metodudur. Bu modelleme yöntemini kullanan birçok akış modelleme ticari yazılımı mevcuttur. Bu yöntemde kütle, momentum ve enerjinin korunumu için 3.4 – 3.6 denklemleri kullanılmaktadır.

$$\nabla \cdot \vec{v} = 0 \quad (3.4)$$

$$\partial \vec{v} / \partial t + (\vec{v} \cdot \nabla) \vec{v} = -(1/\rho) \nabla \vec{P} + \mu \nabla^2 \vec{v} + \vec{g} [1 - \alpha(T - T_m)] g [1 - \alpha(T - T_m)] \quad (3.5)$$

$$\partial h / \partial t + (\vec{v} \cdot \nabla) h = (1/\rho) (\nabla \cdot k \nabla T) \quad (3.6)$$

Burada k ısı iletimi katsayısı, h özgül entalpi, ρ yoğunluk, α termal genişleme katsayısı, \vec{g} yerçekimi fonksiyonu, μ viskozite, \vec{P} basınç ve \vec{v} hız profili olarak ifade edilmektedir. Akışkan hacmi modeli serbest yüzey olarak tasvir edilmektedir (Lee ve ark. 2016).

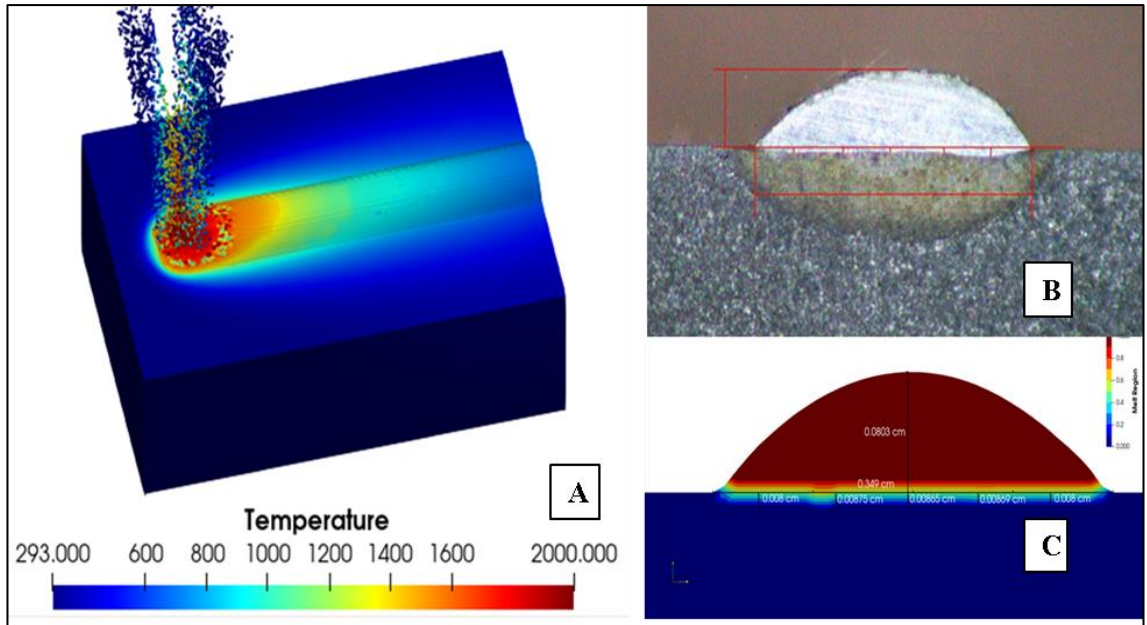
Ergiyik havuzunun şeklini ve boyutunu tayin etmek için uygulanabilmektedir. Akışkan hacmi metodu 3.7 ile ifade edilen denklemi kullanmaktadır.

$$\partial V_F / \partial t + \nabla(\vec{v} \cdot V_F) = 0 \quad (3.7)$$

V_F , control hacmindeki metal hacmini temsil etmektedir. $V_F=0$ olduğunda hücre içerisinde herhangi bir akışkan olmadığı belirtilmektedir. $V_F=1$ olduğunda ise hücrenin tamamen akışkan ile dolu olduğu anlaşılır. V_F değeri eğer 0 ile 1 arasında bir değer alıyorsa control hücresi tamamen boş ve akışkan bölgelerinin arasında bir yüzeyde konumlandırılmış olur. Lazer ışını ise bir enerji yoğunluğu tanımlayabilmek adına Gaussian dağılımı şeklinde 3.8’ deki gibi gösterilmektedir.

$$q = 2Ap/\pi R_b^2 \exp[-2((x - vt - x_0)^2 + (y - y_0)^2/R_b^2)] \quad (3.8)$$

Bu denklemde; q enerji yoğunluğu, A toz partiküllerinin lazer ışını sönmleme katsayısı, p lazer gücü, R_b lazer ışınının yarıçapı, v tarama hızı oranı olmakla birlikte x_0, y_0 ifadeleri de lazer ışınının merkez konumunu belirtmektedir. DED prosesi bu yöntem ile üç boyutlu kartezyen sisteminde çözümlenebilmektedir.



Şekil 3.18. Akışkan hacim oranı yöntemiyle dilüsyon hesaplama örneği. **A)** Analiz çözümünde toz partiküllerin yayılımı **B)** Fiziksel iç yapı incelemesi **C)** Analiz ile elde edilmiş iç yapı

Akışkan hacmi oranı yöntemi, özellikle toz partikül yapısının hesaba dahil edilebilmesi, koruyucu gaz miktarının ergiyik havuzuna olan etkilerinin görülebilmesi, katmanlar arasında oluşabilecek gözenekli yapıların veya kusurların tespit edilebilmesi gibi avantajlarıyla toz püskürtülen yönlendirilmiş enerji girdili katmanlı üretim yöntemlerinde tercih edilmektedir. Bununla birlikte çözüme ulaşma süresi uzun olduğundan tüm bir yapının bu yöntemle analiz edilebilmesi için bu yöntem uygun olmamaktadır. Akışkan hacim oranı yöntemiyle dilüsyon hesaplama örneğine ait bir görsel Şekil 3.18’ de belirtilmiştir.

3.2.3. Hibrit DED ürünün sanal modelleme ve topoloji optimizasyonu çalışmaları

3.2.3.1. Topoloji optimizasyonu

Optimizasyon probleminde kullanılan veya kullanılacak tasarım değişkenlerinin dışyapısına göre eniyileme problemini farklı gruplara ayırmak mümkün olmaktadır. Buna göre parametre, şekil, topoloji ve sıralama optimizasyon sorunundan bahsedilebilir (Pehlivanoglu. 2017).

Tasarım değişkenleri, tasarımı belirleyen parametreleri ve sınırları ifade etmektedir. Tasarım değişkenleri 3.9 şeklinde ifade edilebilmektedir.

$$x = (x_1, x_2, x_3, \dots, x_n) \quad (x_i)_{min} \leq x_i \leq (x_i)_{maks} \quad (3.9)$$

Bununla birlikte x_i tasarım değişkenlerini de kullanarak minimize veya maksimize edilmek istenen fonksiyonlar amaç fonksiyonu olarak adlandırılmakla birlikte 3.10 şeklinde ifade edilmektedirler.

$$\text{maks veya min: } f(x) \quad (3.10)$$

Ayrıca, amaç fonksiyonunun maksimize veya minimize edilmesinde uyulması gereken sınırlamalar ise kısıt fonksiyonları olarak 3.11’ deki gibi tanımlanabilmektedir.

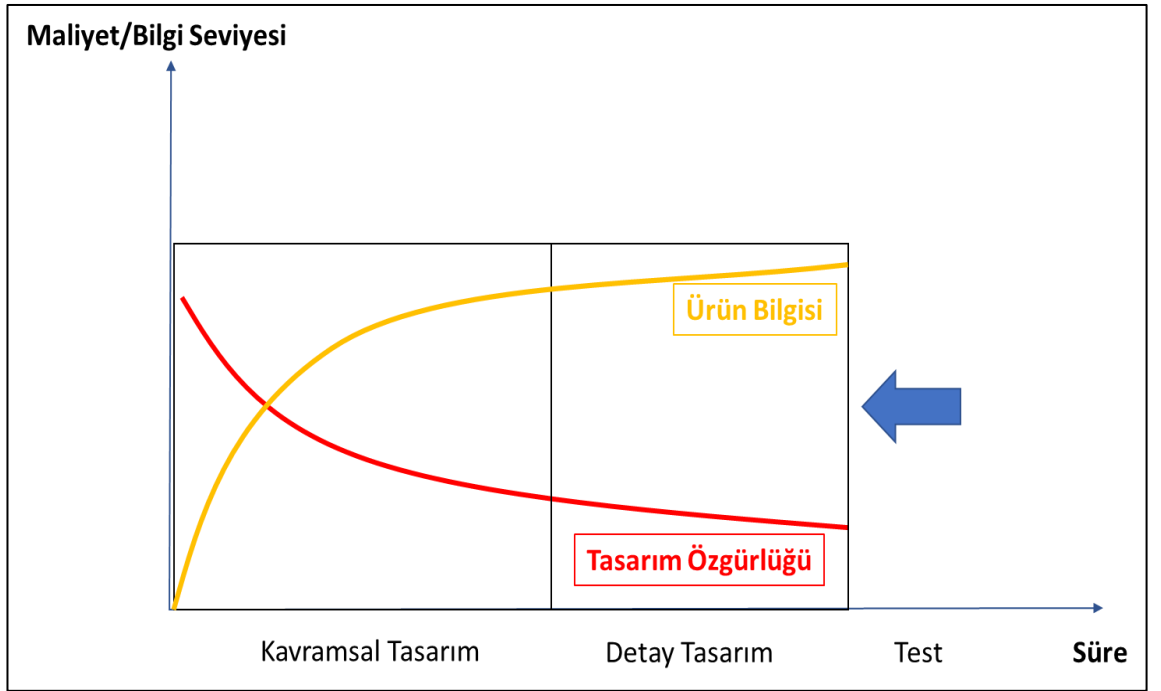
$$g(x) \leq 0 \quad : \text{Eşitsizlik kısıtı} \quad (3.11)$$

$$h(x) = 0 \quad : \text{Eşitlik kısıtı}$$


Topoloji optimizasyonu, yeni bir ürün geliştirme sürecinde ürünün tasarımında veya mevcut ürünün ağırlığının azaltılmasında taslak ürün boyutlarının kabaca elde edilmesini hedeflemektedir. Ürün hacmini belirli bölgelerde azaltarak istenen kısıtları sağlayarak tasarımın en hafif ağırlıkta elde edilmesini sağlamaktadır.

Topoloji optimizasyonu teorisinde, ürün katılığını maksimum yapacak tasarım uzayındaki boşlukların ve katı bölgelerin konfigürasyonu bulunmaya çalışılmaktadır. Ürün maliyetinin çoğu kavramsal tasarım aşamasında belirlenmektedir. Ancak, kavramsal tasarımlar ürünün nihai haliyle ilgili minimum bilgi içermektedir.

Bununla birlikte kavramsal tasarım sürecinde kullanılacak topoloji optimizasyonu çözücüsü maksimum tasarım özgürlüğü sunmaktadır. Aynı zamanda optimizasyon çözücülerini, yeniden tasarım maliyetlerini ve ürünün pazara sunulma süresini en aza indirmek için etkili tasarım araçları sağlamaktadır. Şekil 3.19’ da bu süreç tasvir edilmiştir.



Şekil 3.19. Kavramsal tasarım ve optimizasyon süreci



Şekil 3.20. Gradyent tabanlı optimizasyon çözücüsü yaklaşımı

Tez çalışmasında, topoloji optimizasyonu yazılımı olarak gradyent tabanlı Optistruct optimizasyon çözücüsü kullanılmıştır. Bu çözücü, X_i bir bağımsız başlangıç noktası olmakla birlikte, tasarım için ideal olabilecek diğer bir nokta olan X_{i+1} değerini bulabilmek adına X_i noktasındaki gradyenti $\nabla F(X_i)$ olan 3.12’de belirtilen negatif gradyent denklemi minimuma yakınsama sağlayana kadar topoloji optimizasyonu sırasında kullanılmaktadır. Ayrıca, süreç Şekil 3.20’ de betimlenmiştir.

$$X_{i+1} = X_i - \gamma \nabla F(X_i) = 0 \quad (3.12)$$


Topoloji optimizasyonu çözücüsü; amaç fonksiyonu $W(\rho)$ olan ve bu amaç fonksiyonunun 3.13’ de belirtildiği gibi minimum olmasını hedeflemekle birlikte, eleman yoğunluğu ρ_i , v_i , katılık matrisi katsayısı η , hedef hacmi \bar{V} ve sınırlandırma katsayısı ρ olan 3.14’ de ifade edilen denklemi baz almaktadır (Schramm ve ark. 2006)

$$\min: W(\rho) \quad (3.13)$$

$$V = \sum \rho_i v_i \leq \bar{V}, \eta \leq \rho_i \leq 1, i = 1, 2, \dots, n \quad (3.14)$$

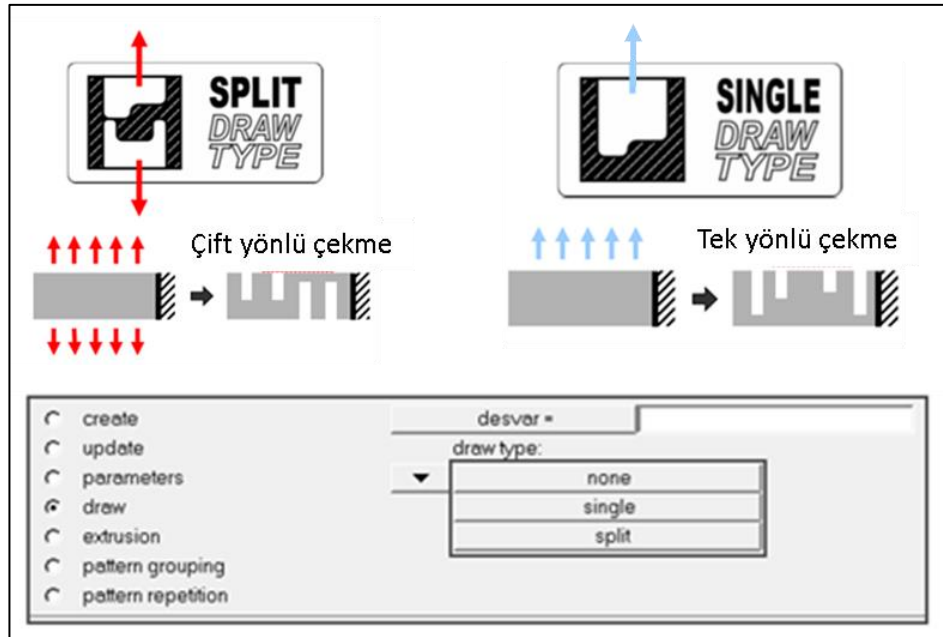
Topoloji optimizasyonu çözümleri, ayrıca Şekil 3.21’ de gösterildiği üzere aşırı mühendislik tasarımlarının da önüne geçebilecek ideal çözümleri ortaya koyabilmektedir.

Görselden de görüleceği üzere destek yapısının çok daha fazla sık olarak örülmüş olması yapının mukavemet anlamında daha iyi olacağı anlamını taşımamaktadır.




Şekil 3.21. Topoloji optimizasyonu yazılımı örneği- Aşırı mühendislik tasarımı (Altair.2021)

Mevcutta topoloji optimizasyonu için kullanılan Altair Optistruct gibi çözücülerde ve yazılımlarda ekstrüzyon, dövme, döküm ve sac presleme gibi geleneksel üretim metodolojileri için kısıtların belirlenebileceği Şekil 3.22’ de gösterildiği üzere bazı tanımlama alanları bulunmaktadır. Bu kısıtlar doğrultusunda da topoloji optimizasyonu yazılımı parça geometrisini tekrar düzenleyebilmektedir.



Şekil 3.22. Topoloji optimizasyonu yazılımı örneği-Kısıtlar

Dövme prosesine uygun tasarlanacak örnek bir ürün için topoloji optimizasyonu yazılımında çekme veya çıkarma yönü tek veya çift yönlü gibi kısıt olarak tanımlanabilmektedir. Bunun bir örneği Şekil 3.23’ de gösterilmiştir.




Şekil 3.23. Topoloji optimizasyonu yazılımı örneği-Çekme yönü örnekleme

Bununla birlikte toz yatak teknolojisi için kafes yapıların eklenmesi adına bazı parametreler göz önünde bulundurulabilmektedir. Belirlenmiş kafes yapı türleri ve kafes yapılarına ait boyutların dahil edilebildiği topoloji optimizasyonu çözümleri mevcuttur. Ancak mevcut durumda DED prosesi için geliştirilmiş herhangi bir topoloji veya farklı bir optimizasyon metodu doğrudan ortaya konulmamıştır.


3.2.3.2. Hibrit ürün için optimizasyon çalışmaları

Isı kaynağı modeli oluşturma aşamasından sonra 400 mm uzunluğuna sahip DED dolguları ile güçlendirilmiş hibrit bir kiriş parçası tasarımına başlayabilmek için topoloji optimizasyonu gerçekleştirilmiştir. Topoloji optimizasyonu için Şekil 3.24’ de gösterildiği gibi bir tasarım hacmi oluşturulmuştur. Topoloji optimizasyonu modeli, üç nokta eğme yükleme koşulları altında değerlendirilmiştir.



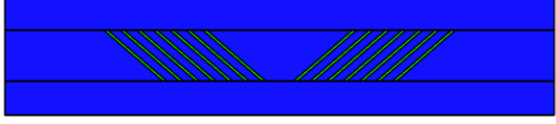
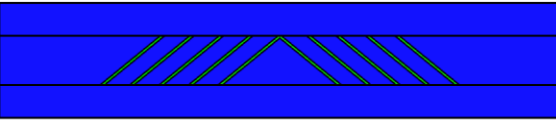
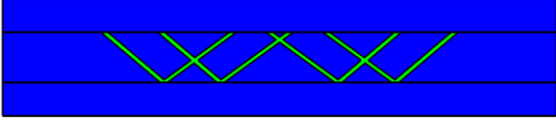
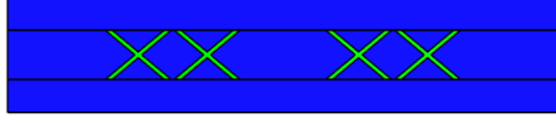
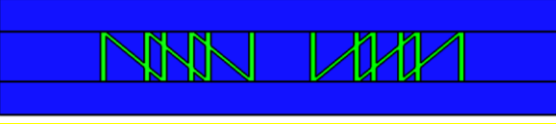
Şekil 3.24. Atkı elemanı optimizasyon modeli için sınır koşulları

Üç nokta eğme koşulunda parça alt kısımlarından iki adet mesnet yapısı ile tüm eksenlerdeki serbestlik dereceleri sabitlenmiş bir şekilde desteklenmektedir. Ana malzeme tasarım dışı alan olarak belirlenmiştir. Bu bölge, topoloji optimizasyonunda müdahale edilmeyecek alan olarak tanımlanmaktadır. Atkı parçasının iç kısmı ise, yani parçalar üzerinde lokal güçlendirmeler oluşturabilmek adına değiştirilebilir bölge, bir başka deyişle tasarım alanı olarak tanımlanmıştır.



Şekil 3.25. Topoloji optimizasyonu ve parçanın yeniden tasarlanması

Çizelge 3.4. Hibrit atkı parçasının yeniden tasarlanması için geometrik desenler

Model Adı	Model Desenleri
Semi Cross Left	
Semi Cross Right	
V Shape	
Full Cross	
S/N Shape	

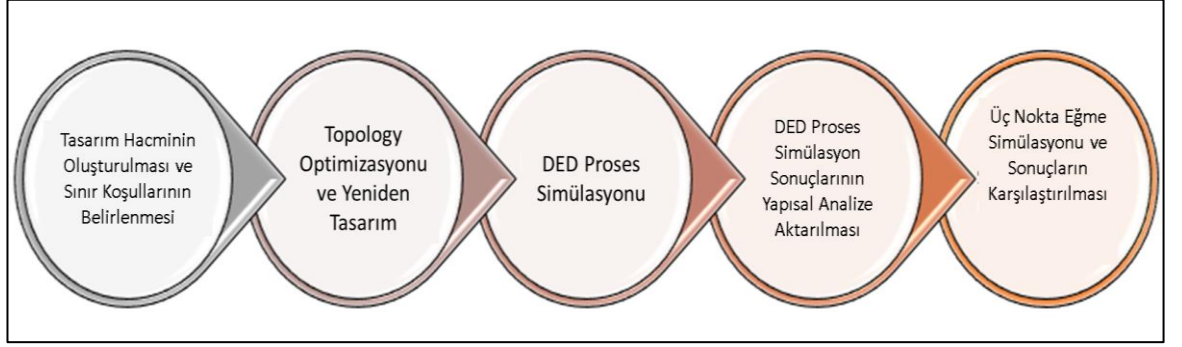
Topoloji optimizasyonu sonuçları Şekil 3.25' deki gibi elde edilmiştir. Bu aşamadan sonra hibrit giriş parçası üzerinde oluşturulacak DED dolgu yapılarının nasıl olacağına karar verilebilmesi adına Çizelge 3.4' te belirtilen yapılar 100 mm'lik bölgeleri için simetrik olarak türetilmiştir. Bu geometrik modeller yapay sinir ağları ile gerçekleştirilecek en iyileme çalışmalarında çeşitli boyutlara sahip olarak değerlendirilecektir.

3.2.4. Hibrit DED örnek ürün üretimi ve fiziksel testler

DED işlemi, bir ısı kaynağı gücü ile üretilen termal etkileri barındırmaktadır. DED prosesinde oluşan bu termal etkiler dikkate alınarak yapısal dayanıklılık analizinin (üç

nokta eğme simülasyonu) gerçekleştirilmesi amacıyla Simufact Welding yazılımında DED prosesi lazer dolgu yaklaşımı ile öncelikle çözümlenmiştir.

Bu işlem sonrasında termal etkiler ikinci bir analiz modelinde yapı üzerine aktarılmış ve üç nokta eğme simülasyonu gerçekleştirilmiştir. Şekil 3.26, modelleme ve analiz süreçlerini içeren hibrit ürünün geliştirme akışını göstermektedir.



Şekil 3.26. DED hibrit ürün geliştirme akışı

Basitleştirilmiş hibrit kiriş ürünü sol desanlı yarı çapraz DED dolgu modeli baz alınarak (dolgu modeli Çizelge 3.4' ten seçilmiştir) Şekil 3.27' de gösterildiği gibi üretilmiştir. Üretim için kullanılan DED makine konsepti, 2500 mm × 1000 mm düzlem alanını kullanabilen bir çalışma aralığına sahip olup, bir masa üzerine monte edilmiş altı eksenli bir robot aracılığıyla prosesi gerçekleştirmektedir.



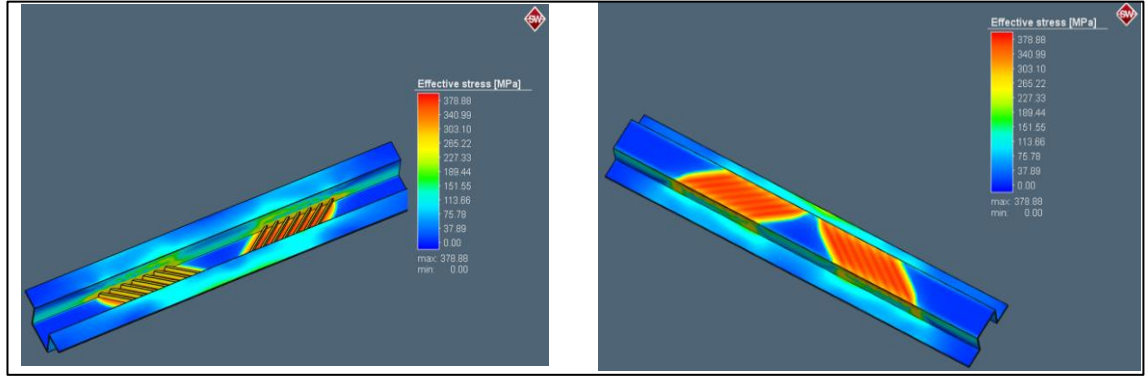
Şekil 3.27. Prototip üretimi. A) DED cihazı B) Hibrit DED atkı parçası

Tüm CAE modelleri, ısı girdisinin DED hibrit montajı üzerindeki bütünsel ve lokal etkisini hesaplamak için sonlu elemanlar yöntemini kullanan Simufact Welding Yazılımı üzerinde kurulmuştur. CAD yazılımı kullanılarak sadece kütle hesaplaması gerçekleştirilmiştir. Simülasyonlarda ve fiziksel testlerde 1.1 mm kalınlığında 355 MPa Kalite Çelik Malzeme kullanılmıştır. Baz malzemenin kimyasal bileşimi Çizelge 3.5’ de belirtilmiştir.

Çizelge 3.5. Hibrit kiriş ürününün ana malzemesinin kimyasal özellikleri


Element	Al	C	Fe	Mn	N	P	S	Si
% Kütle Oranı	0,05	0,17	98,127	1,6	0,005	0,017	0,011	0,02

DED prosesinde, ısı kaynağı gücü tarafından üretilen ısının bir sonucu olarak, temas halindeki yığılmış dolgu yüzeyleri yumuşamaktadır. Buna bağlı olarak parçanın soğuması ile birlikte hibrit bileşen üzerinde dolgu yığıma prosesi sonrasında Şekil 3.28’ de gösterildiği üzere kalıntı gerilmeler oluşmaktadır.



Şekil 3.28. DED proses simülasyonu-Yığıma sonrası kalıntı gerilmeler


Son olarak, DED dolgularıyla güçlendirilmiş hibrit ürün, fiziksel olarak bir mekanik dayanıklılık test sistemi kullanılarak zorlanmış bir yer değiştirmeye tabi tutulmuştur. Buradan elde edilen sonuçlar Şekil 3.29’ de gösterildiği gibi bilgisayar destekli analiz sonuçları ile değerlendirilmiştir.



Şekil 3.29. Prototip doğrulama çalışması. A) Fiziksel üç nokta eğme düzeneği B) Sanal üç nokta eğme görseli

3.2.5. Hibrit DED örnek ürün iç yapı incelemesi

Yönlendirilmiş enerji girdili katmanlı üretim prosesinde, ısı kaynağı gücü ile üretilen ısı sonucunda katmanlar arasında hızlı veya yavaş soğumanın da bir sonucu olarak, ana malzemeyle katmanlar arasındaki ve katmanların herbirinin kendi arasındaki oluşan yapılarının incelenmesi gerekmektedir. Oluşacak hata ve kusurlardan dolayı parça mukavemeti etkilenebilmektedir. Bu sebeple, üretilen prototip numunelerinin Şekil 3.30’da gösterildiği üzere kesme eksenini boyunca bölünmesi sağlanmış ve bu bölümlerden yine şekil üzerinde belirtildiği gibi bakalite alınarak iç yapı incelemesi gerçekleştirilmiştir.



Şekil 3.30. Prototip parça iç yapı incelemesi

3.3. En İyileme Çalışmaları

Tez çalışmasının bu bölümünde topoloji optimizasyonundan elde edilen geometrik DED dolgu modellerinin proses etkilerinin de göz önünde bulundurulması en iyileme çalışmalarından ve öncesinde ise deney tasarımlarının oluşturulması süreçlerinden bahsedilmektedir.

Taguchi ve benzer DOE yöntemleri kullanılarak üretilecek deney tasarımlarının sonuçları ile bu tez çalışmasında özellikle topografik geometri kısıtları ile harmanlanarak optimize edilmiş bir hibrit ürün elde edilmiş olacaktır.

3.3.1. Deney tasarım metodları

Deney Tasarımları; tek veya çok boyutlu parametre uzayında sayısal veya fiziki olarak deney şeklinde oluşturulmuş gerçek verilerin, verimli bir şekilde dağılım olmasını belirleyen yöntemlerdir. Mühendislik problemleri için yaygın olarak kullanılan deney tasarım yöntemleri Taguchi, monte carlo, latin hiperküp örnekleme metodlarıdır (Albak. 2020). Bu tez çalışmasında deneysel tasarım yöntemlerinden Taguchi ve latin hiperküp örnekleme (LHÖ) yöntemlerinin kullanımı tercih edilmiştir.

3.3.1.1. Taguchi deney tasarımı

Taguchi metodu, bir prosesin değişkenliğini azaltmayı hedeflemekle birlikte bu metodun genel amacı yüksek kaliteli düşük maliyetli ürünlerin ortaya konulmasını güçlü bir deney tasarımı ile sağlamaktır. (Mohamed ve ark. 2019).

Taguchi metodunun adımları genel olarak şu şekilde tanımlanmaktadır;

1. İlk önce proses amacı tanımlanmalıdır. Aynı zamanda, prosesin performans ölçümü için hedef bir değer de tanımlanabilir. Hedef sıcaklık, hız gibi ölçülebilen bir parametrenin belirli bir değere gelmesi veya sıcaklık, hız gibi bir parametrenin herhangi bir prosesi minimum veya maksimum hale getirmesi şeklinde olabilmektedir.

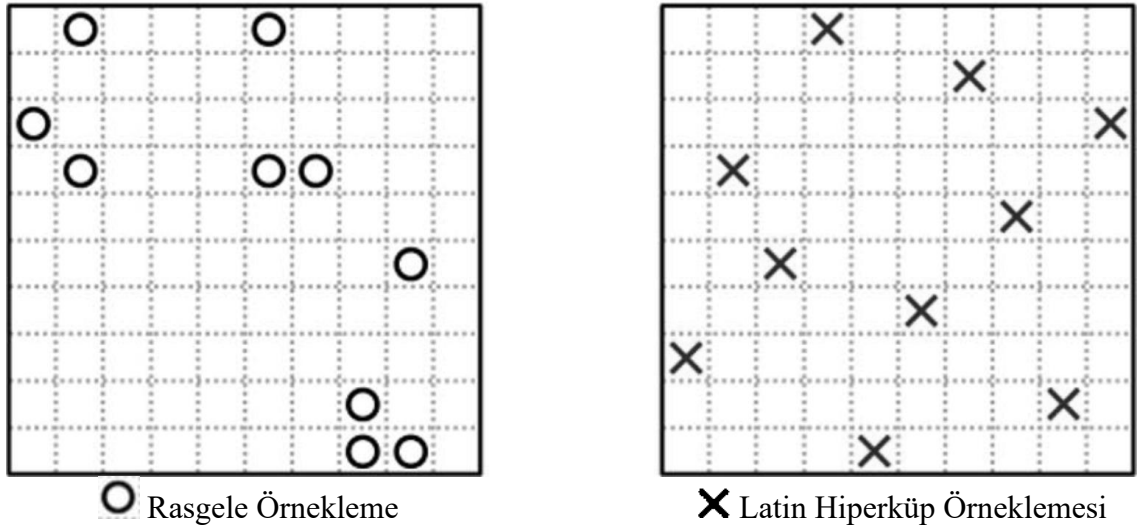
2. Prosesi veya tasarımı etkileyen parametreler belirlenir. Bu parametreler sıcaklık, basınç vb. gibi ürün veya prosesin performans kriterlerini etkileyecek değişkenlerdir. Her bir parametrenin kaç farklı düzeyde deneneceği belirlenir. Nokta sayısı arttıkça deney sayısı da artmaktadır.
3. Parametre sayısı ve deney yapılacak düzey sayısına göre Taguchi tarafından belirlenmiş ortogonal L matrisleri kullanılır.
4. İlgili L matrisi tablodan seçilir ve bu matris kullanılarak deneyler gerçekleştirilir.
5. Farklı parametrelerin performans ölçütlerine etkisini bulmak için Taguchi data analizi yapılır.

3.3.1.2. Latin hiperküp örnekleme

Latin hiperküp örnekleme, çıktı değişkenlerinin fonksiyonlarının beklentilerini tahmin etmek için girdi değerleri üretmek üzere kullanılacak bir örnekleme yöntemidir. LHÖ yönteminin avantajı az sayıda örneklem ile sistemi temsil etme kabiliyetinin yüksek olmasıdır.

Latin hiperküp örnekleme, 1979 yılında Los Alamos Ulusal Laboratuvarı'nda görev alan Michael McKay tarafından tanımlanmıştır. 1981 yılında ise Ronald Iman ve arkadaşları tarafından daha da geliştirilmiştir. Sonrasında da ayrıntılı bilgisayar kodları ve kılavuzları yayınlanmıştır. (McKay ve ark. 1979)

Latin Hiperküp Örnekleme yönteminde, örneklemin temsil noktalarının tamamının olduğundan emin olmak için arama alanı eşit olarak örneklendirilmektedir. LHÖ için, her boyut alt bölümlere ayrılır ve örnek noktalar Şekil 3.31' de temsili olarak gösterildiği gibi seçilmektedir. Çok boyutlu hiper düzlemde örneklenmiş noktalar için arama alanı kapsamı iyileştirilmiş olur (Preece ve ark. 2016).



Şekil 3.31. Latin hiperküp örnekleme karşılaştırması (Preece ve ark. 2016)

Öte yandan, bazı örnekleme metodlarında rasgele örnekleme yönteminde olduğu gibi, arama uzayının geniş alanlarının örneklenmemesine neden olabilir. Tüm alanların eşit olarak örneklenebilmesi, yapılan analiz çalışmalarının hassas ve doğru sonuçlanabilmesi adına son derece önemlidir.

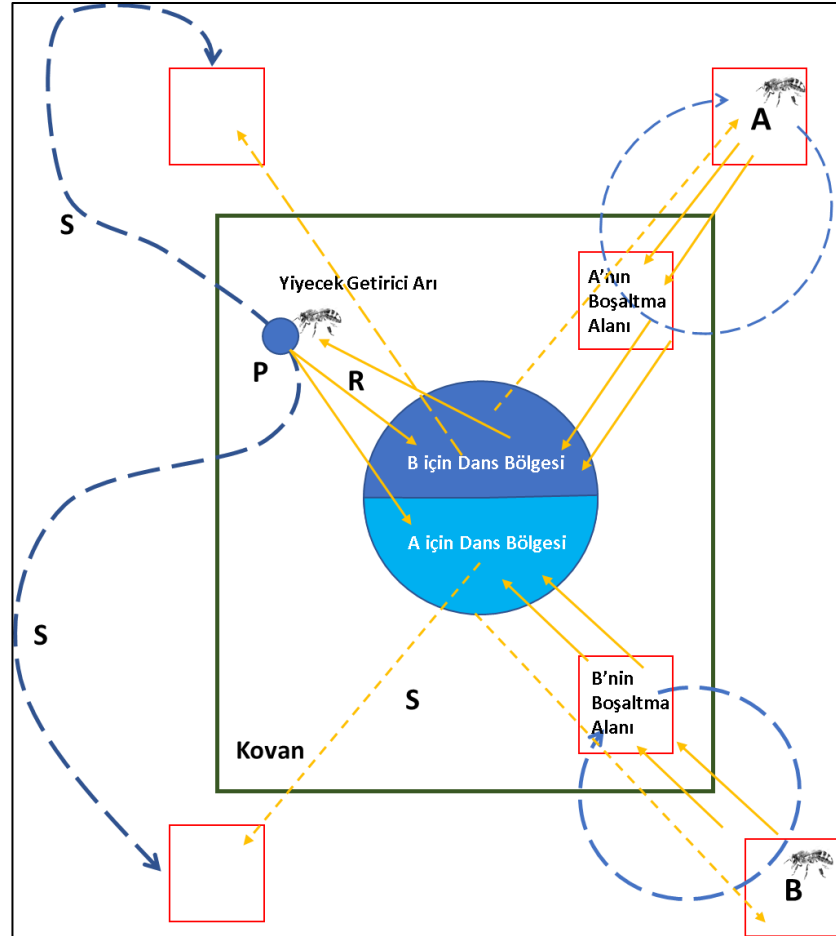
3.3.2. Optimizasyon yöntemleri

Optimizasyon tekniği, ürün veya proses geliştirilirken istenen tasarım ve proses parametrelerini elde etmek için güçlü bir araç olmakla birlikte en iyi çalışma koşulları için bir veri seti sunar. Optimizasyon, tasarım risklerini ve operasyonel maliyetleri azaltmaya yardımcı olmaktadır. Optimum çözümlerin güvenilirliği; amaç fonksiyonlarının formüle edilmesini ve seçilen optimizasyon tekniği için süreci tanımlayan ve tahmin eden matematiksel bir model geliştirilmesini gerektirir. Optimizasyon tekniklerinde değerlendirilecek değişkenler veya parametreler, sürekli veya ayrık olarak karşımıza çıkabilmektedir. Sürekli değişkenler, gerçek değeri olan herhangi bir basınç, sıcaklık, konsantrasyon vb. süreç değişkenleridir. Ayrık değişkenler ise dağıtım işlevi sadece tamsayı olan değişkenlerdir. Ayrık değişkenler olmadığında optimizasyon problemlerinin çözülmesi çok daha kolay olup optimizasyon tekniğinin güvenilirliği, ayrık değişkenlerin doğru tahmin edilmesine bağlıdır (Ghanim 2016).

Ayrık deęişkenlerin yer aldığı mühendislik problemleri, optimum sonucun elde edebilmesi için kullanılacak hesaplama işlemleri açısından zor problemlerdir. Bu tez çalışmasında da olduğu gibi dolgu geometrisi şekilleri gibi ayrık deęişkenlerin yer aldığı zor problemlerin çözümü için sezgisel yaklaşımlar geliştirilmiştir. Sezgisel yaklaşım algoritmalarının en yaygın kullanılanları; arı sürüsü algoritmaları, parçacık sürü optimizasyonu algoritması ve genetik algoritmalar olarak sıralanabilir (Sunca 2018).

3.3.2.1. Arı sürüsü algoritmaları

Yapay arı sürüsü algoritmaları, bal arıları özelinde onların davranışlarını temel alan ve 2005 yılında “sayısal optimizasyonda bal arısı sürüsüne dayalı düşünce” isimli teknik raporla literatüre tanıtılmış yöntemler grubudur. Genellikle koloniler halinde yaşayan arıların yiyecek arama yöntemlerinden esinlenilerek geliştirilen yöntemin sonraki yıllarda uygulama alanları giderek yaygınlaşmıştır (Özdemir 2013).



Şekil 3.32. Arı sürülerinin yiyecek arayışı davranışı (Akay, 2009)

Geliştirilen yapay arı kolonisi algoritmasında, kovandaki görevli arıların sayısı toplam yiyecek kaynağına eşit olmaktadır. Yiyecek kaynağındaki görevli arı kaynağındaki yiyecek miktarı bittiğinde kaşif arıya dönüşmektedir ve bununla birlikte işçi arılar ile gözcü arıların sayıları birbirine eşittir. Nektar miktarı ise çözümün kalitesini ifade etmektedir.

Geliştirilen yapay arı kolonisi algoritmasında, kovandaki görevli arıların sayısı toplam yiyecek kaynağına eşit olmaktadır. Yiyecek kaynağındaki görevli arı kaynağındaki yiyecek miktarı bittiğinde kaşif arıya dönüşmektedir ve bununla birlikte işçi arılar ile gözcü arıların sayıları birbirine eşittir. Nektar miktarı ise çözümün kalitesini ifade etmektedir.

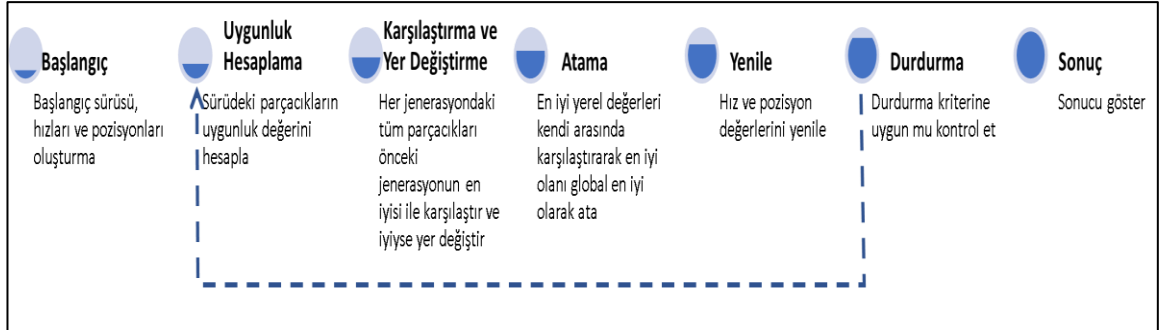
Yapay arı kolonisi algoritması, en fazla yiyeceğe sahip kaynağın yerini bulmaya çalışarak arama uzayındaki çözümlerden problemin minimumunu ya da maksimumunu veren noktayı yani bir başka deyişle çözümü bulmaya çalışmaktadır. Kovandaki kaşif arılar, yiyecek aranırken başlangıç olarak rastgele yiyecek aramaya başlarlar. Kaynağı bulan kaşif arı artık görev sahibi olan bir arı haline gelmiştir ve kovana nektar götürmeye başlarlar. Görevli arı kovana nektarını taşır ve yem getirdiği kaynaklar ilgili bilgiyi dans alanında yaptığı dans ile bekleyen gözcü arılara iletirler. Kaynağı bitmiş ise kendisi de gözcü arı haline gelecektir. Gözcü arılar dansları izledikten sonra yiyeceğin kalitesi doğrultusunda bir kaynağı tercih ederler (Küçükşille ve ark. 2011). Şekil 3.32' de süreç temsil edilmiştir.

Literatüre girdiği dönem itibari ile gerçek sayılara dayalı kısıtsız optimizasyon sorunlarının çözümü için oluşturulmuştur. Sürü zekasına dayalı basit ve esnek bir algoritmadır. Aynı zamanda kontrol parametresi azdır ve daha çok nümerik problemlerin çözümünde kullanılmaktadır.

3.3.2.2. Parçacık sürüsü algoritmaları

Parçacık sürü optimizasyonu, balıklar ve böcekler gibi sürü halinde hareket eden hayvanlardan esinlenerek geliştirilmiş bir optimizasyon yöntemi olmakla beraber yapay arı sürüsünde olduğu gibi, temel olarak sürü zekasına dayanan bir algoritmadır. Sürü halinde hareket eden hayvanlar, yiyecek ve güvenlik gibi durumlarda birçok davranış ve hareket sergilemekte olup, çoğunlukla rasgele olarak sergiledikleri bu davranışların

amaçlarına daha kolay ulaşmalarını sağladığı gözlemlenmiştir (Özsağlam ve ark. 2008). Parçacık sürüsü algoritmasının süreç adımları Şekil 3.33’ de gösterilmektedir.



Şekil 3.33. Parçacık sürü algoritmasının çalışma adımları (Özsağlam ve ark. 2008)

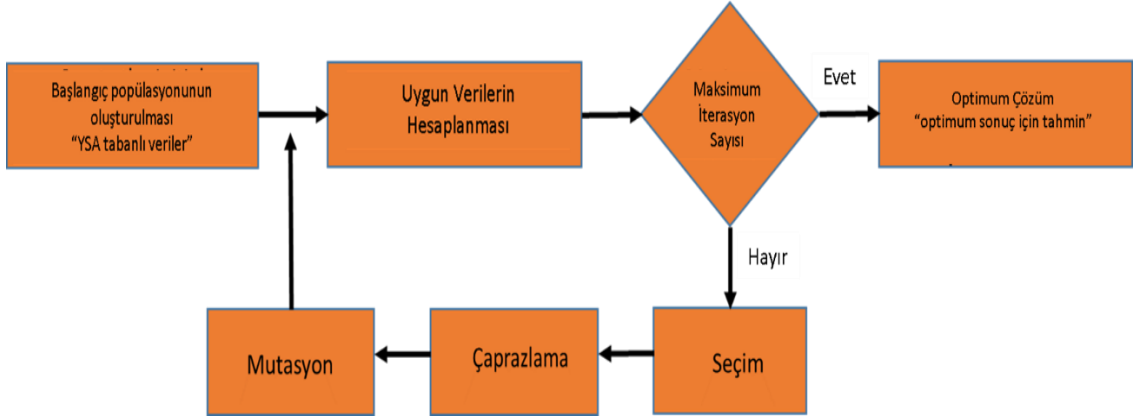
Bu algorithmada, bireyler arasındaki bilgi paylaşımı esas alınmakta olup, arama işlemi genetik algorithmalarda olduğu gibi nesil sayısı kadar yapılır. Herbir birey parçacık olarak isimlendirilir ve parçacıklardan oluşan popülasyona sürü denir. Herbir parçacık kendi pozisyonunu, bir önceki tecrübesinden yararlanarak sürüdeki en iyi pozisyona doğru ayarlar.

Bu algoritma, sürüde bulunan bireylerin pozisyonunun, sürünün en iyi pozisyona sahip olan bireyine yaklaştırılmasına dayanır. Parçacık sürüsü optimizasyonu; voltaj kontrolü ve motor parametrelerinin belirlenmesi gibi sürekli değişkenlerin yer aldığı birçok mühendislik probleminde uygulanmıştır (Wilke. 2005).

3.3.2.3. Genetik algorithmlar

Genetik Algorithmlar (GA), doğada gözlemlenen evrimsel mekanizmalara benzer mekanizmalar kullanarak çalışan evrimsel optimizasyon yöntemlerinden biridir (Holland. 1992). Genetik algorithmların; arama işlemini noktaların oluşturduğu bir başlangıç yığını içersinden gerçekleştirmesi diğer yöntemlerden farklı kılan en önemli özelliğidir (Chambers .1998).

Bu tez çalışmasında kullanılan genetik algoritma yapay sinir ağları ile oluşturulan popülasyonları seçim, çaprazlama ve mutasyon işlemlerinden geçirerek optimum çözüme ulaşmayı veya optimum çözümü tahminlemeyi hedeflemektedir. Genetik algoritma akışı Şekil 3.34 ile tasvir edilmiştir.



Şekil 3.34. Genetik algoritma akışı

Genetik Algoritmalar özellikle mekanik öğrenme gibi yapılarda ilki, gözlenmiş bir veri takımını anlamak ve yorumlamak, ikincisi de görülmemiş objelerin özelliklerini tahmin etmek olan iki temel amaç için model kurmayı hedeflemektedir. Uygun model seçimi için mühendislik problemi hakkındaki varsayımlarla başlamak yerine, doğrudan mevcut veriden hareketle bir araç kutusu yaklaşımını kullanmaktadır (Emel ve ark. 2002).

Genetik algoritmalar, parametrelerin kendisi ile değil parametre dizilerinin kodlanması ile çalışmaları, tek noktadan değil noktaların popülasyonundan araştırılmaları, sınırlayıcı kuralları değil olasılık kurallarını kullanmaları gibi avantajları ile diğer yöntemlerden ayrılmaktadır.

Bunun yanı sıra, birçok optimizasyon tekniğinde bir tek noktadan bir sonrakine değişim kuralı ile hareket edilirken, genetik algoritmalarda eşzamanlı olarak geniş veri tabanlı noktalarla çalışılmaktadır. Genetik algoritmalar bu yönleriyle, diğer optimizasyon yöntemleri ile kıyaslandığında globaldeki optimum noktaya daha kolay ulaşmaktadır.

Diğer optimizasyon yöntemleri optimum noktaya erişebilmek adına çalışmaya başlamak için gradient tekniklerine, türevlere vb analitik ve nümerik hesaplamalar gibi yardımcı bilgiye ihtiyaç duyarken genetik algoritmalar bu yardımcı bilgilere ihtiyaç duymazlar. Genetik algoritmaların sahip olduğu doğrudan kodlama kullanma, popülasyon odaklı araştırma gerçekleştirme, ek yardımcı bilgiye ihtiyaç duymama ve operatörlerin rastgele olması gibi özellikleri sayesinde, en optimum noktanın bulunması için kararlılığa katkıda bulunmaktadır (Yıldız. 2006).

3.3.3. Metamodelleme yöntemleri

Metamodelleme yöntemleri, yüksek çözüm zamanı gerektiren mühendislik simülasyonlarının hesaplama sürecini kısaltmak için önerilmiştir (Xiao ve ark. 2014). Temsili bir DED hibrit yapısının proses parametrelerini de göz önünde bulundurarak optimizasyonunu gerçekleştirmek, çok sayıda tasarım değişkeni içereceğinden doğrudan sonlu elemanlar yöntemi ile çözülmesi ve optimum parametrelerin elde edilmesi zor olmaktadır. Bu sebeple optimizasyon sürecinde metamodelleme yöntemleri kullanılarak az veri seti ile sürecin kısaltılması hedeflenmiştir.


Literatürde araştırmacılar tarafından farklı metodolojilere sahip çeşitli optimizasyon çalışmaları incelenmiştir. Yanıt yüzeyi yaklaşımı, radyal temel fonksiyonlar, Kriging ve yapay sinir ağları (YSA) vekil modelleme için yaygın olarak kullanılmaktadır.

3.3.3.1. Kriging yöntemi

Kriging, çeşitli fonksiyonel yapılara sahip simüle edilmiş yanıt yüzeylerinin bir üst modelini oluşturmak için kullanışlı ve esnek bir yöntemdir. Kriging, Şekil 3.35' de gösterildiği üzere birincil kovaryanslar tarafından kontrol edilen bir Gauss prosedürüne dayanan bir enterpolasyon yaklaşımıdır. Kriging, $p^T(x)\beta$ ifadesinin eğilim modelini, $Z(x)$ ifadesinin ise sistematik sapmayı belirttiği 3.15 denklemini kullanır (Acar. 2013).

$$\hat{y}(x) = p^T(x)\beta + Z(x) \quad (3.15)$$


Geleneksel bir Kriging modelinde sistemden alınacak bir yanıtın, durağan kovaryans fonksiyonu ile uzaysal rastgele bir süreç olduğu varsayımı yapılmaktadır. Durağan kovaryans, bir yanıtın yüzey düzgünlüğünün girdi uzayının her bölgesinde oldukça düzgün olduğunu kabul eder. Bu durum, analizi basitleştiren ve gerekli ön bilgi miktarını azaltan uygun bir varsayım koşuludur. Bununla birlikte, sistemden alınacak yanıtın yüzey düzgünlüğü seviyesinin tüm tasarım bölgesi boyunca önemli ölçüde değişebileceği durumlar da yaygındır (Xiong ve ark. 2007).



Şekil 3.35. Doğrusal trendde sahip bir Kriging metamodeli tahmini

3.3.3.2. Radyal tabanlı fonksiyonlar

Radyal tabanlı fonksiyonlar, oldukça doğrusal olmayan yaklaşım modellerinin yüksek tahmin özelliklerine sahiptir. Radyal tabanlı fonksiyon yöntemi, kendisini orijinden olan uzaklık ile tanımlayarak çalışmaktadır. Bir başka deyişle veriyi orijin noktasına veya seçilen bir merkez noktasına olan uzaklığına bağlı bir fonksiyon yapısı ile değerlendirmektedir (Fang ve ark. 2005).



Şekil 3.36. Radyal tabanlı fonksiyon (Mathworks RB.2021)

Radyal temelli fonksiyonlar her bir örnekleme noktasında simetrik ve ortalanmış olan temel fonksiyonların bir serisini kullanmakta olup, aslen dağınık çok değişkenli data interpolasyonu için geliştirilmiştir. Radyal tabanlı fonksiyonlardan, yapay sinir ağlarının da gelişmesi ile birlikte sinir ağı tasarımlarında faydalanılmıştır (Lewesley 2004). Radyal tabanlı fonksiyonlar; Gaussian, kuadratik, çoklu kuadratik, ters kuadratik, ters çoklu kuadratik ve spline olarak isimlendirilirler. Örnek bir radyal tabanlı fonksiyon Şekil 3.36’ da gösterilmiştir (Mathworks RB.2021).

3.3.3.3. Yanıt yüzey metodu

Yanıt yüzeyi metodolojisi, yüksek derecede matematiksel karmaşıklığa sahip tasarım ve proses optimizasyon problemleri için oldukça kullanışlı bir yöntemdir. Yanıt yüzeyi yaklaşımı, ideal bir yanıt bulmak için bir dizi tasarlanmış deneyi kullanmaktadır. Yanıt yüzey yöntemi, tasarım ve proses değişkenlerinin deney uzayını araştırırken, sistemin yanıtı ve üzerinde etkili olan bağımsız değişkenler veya parametreler arasındaki ilişkiyi belirlemek için kullanılan bir modelleme tekniği olmakla birlikte tasarım veya proses değişkenlerinin sistemin yanıtında istenilen en ideal etkiyi gösterdiği seviyelerinin tespit edilmesi için kullanılan optimizasyon tekniklerini içermektedir (Hou S. ve ark. 2008).




Şekil 3.37. Yanıt yüzey metodu temel işlem adımları

Yanıt yüzey yöntemi, Şekil 3.37’de belirtildiği gibi temelde eleme denemeleri, bölge araştırması ve prosesin/ürünün optimizasyonu olarak üç aşamadan oluşmaktadır. Eleme

aşamasında, daha az sayıda ve daha verimli olan örnekleme noktalarıyla esas deneme yapılmasına olanak sağlamaktadır. İkinci aşamada ise bölge araştırması gerçekleştirilmektedir. Buradaki amaç, eleme denemeleri ile belirlenen bağımsız değişkenlerin sistemin yanıtında oluşturdukları değerlerin, optimum noktaya yakın sonuçlar verip vermediğini gözlemlemektir. İşlem optimum noktaya yaklaştığında, yanıt yüzey yönteminin üçüncü aşaması başlar (Myers ve ark. 1995).

3.3.3.4. Yapay sinir ağları

Yapay sinir ağları (YSA) yöntemi, doğrusal olmayan tasarım değişkenleri arasında karmaşık ilişkiler üretebilen güçlü bir yöntemdir (Kazi ve ark.2022). Bu nedenle bu çalışmada, hibrit metal giriş parçalarının performansı üzerinde önemli bir etkiye sahip olan tasarım parametrelerine göre tepe kuvveti ve toplam kütle dikkate alınarak özgül enerji absorpsiyonunu optimize etmek için YSA yöntemi tercih edilmiştir.



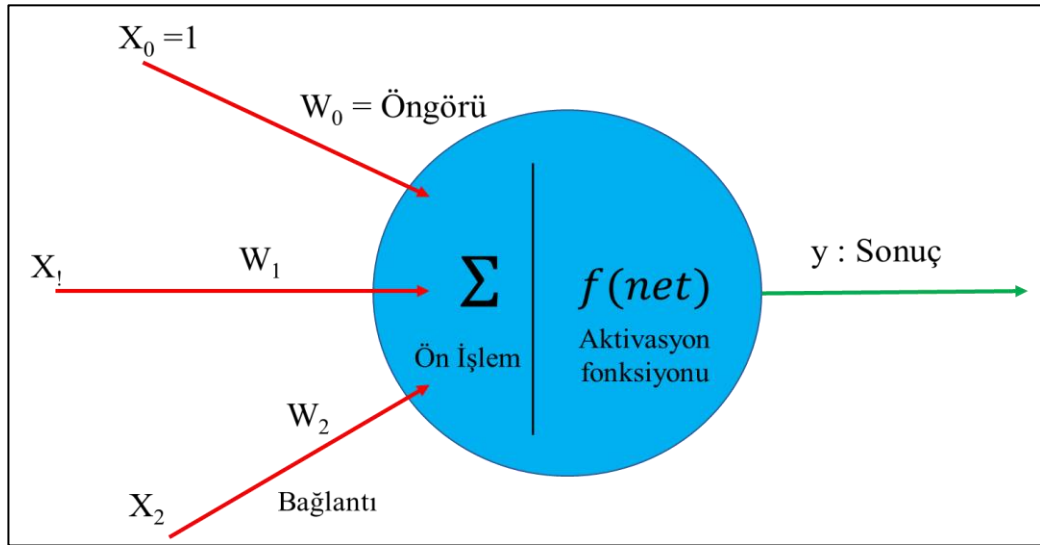
Şekil 3.38. Basit YSA yapısı (Mathworks NNA.2021)

Bir sinir ağı, beynin nörolojik olarak nasıl çalıştığının matematiksel bir modelidir. Beynin öğrenme sürecini taklit etmek için sinir hücrelerini matematiksel olarak modeller. Bir sinir ağı, katmanlara dahil edilen nöronlar adı verilen birbirine bağlı öğelerle yapılandırılmıştır, sinir ağı modellemesi için giriş ve çıkış verileri gereklidir. Basit bir YSA yapısı Şekil 3.38’ de gösterilmektedir. YSA, önceki veri kümelerinden öğrenebildiği ve pratik olarak herhangi bir doğrusal olmayan fonksiyona yaklaşabildiği için DOE YYM’ den daha etkili bir tekniktir. YSA yaklaşımı, genellikle tasarım ve üretimde uzmanların deneme yanılma yöntemiyle deneyime dayalı varsayımlar ve kısıtlamalar gerektiren sorunları çözmek için sunulur.

3.3.3.4.1. Yapay Sinir Hücresi

Yapay sinir hücreleri, yapay sinir ağlarını oluşturan temel yapılardır. Yapay sinir sistemlerinde her bir nöron “*perceptron*” olarak adlandırılır (Mathworks NNA.2021). Nöronlar, sinir ağlarının en temel ve en eski yapısı olarak bilinmektedir. Bir yapay nöronun modeli Şekil 3.36’ da görselleştirilmiştir. Görselde belirtilen mavi renkli bölge nöronu yani “*perceptron*” yapısını temsil etmektedir.

Nöronlar basit fonksiyonlara sahip birimler olup temel olarak; bağlantı elemanları, ön işlem ve aktivasyon fonksiyonundan oluşmaktadır (bkz. Şekil 3.39). Nöronlar, bağlantı elemanları üzerinden birbirleri ile iletişim kurmaktadır. Bağlantı elemanlarının herbirinin kendine özgü bir ağırlık oranı bulunmaktadır. Bağlantı ağırlıkları bilgileri depolayarak nöronları paralel ve ardışık bir biçimde birleştirmektedirler. Bu bağlantı ağırlıkları bir öğrenme işlemi ile belirlenmektedir ve öğrenme işlemi sonucunda aldıkları değerler bilginin en doğru biçimde diğer bir nöron yapısına aktarılmasını sağlamaktadır (Fırat ve ark. 2004).



Şekil 3.39. Örnek bir yapay nöron (Mathworks NNA.2021)

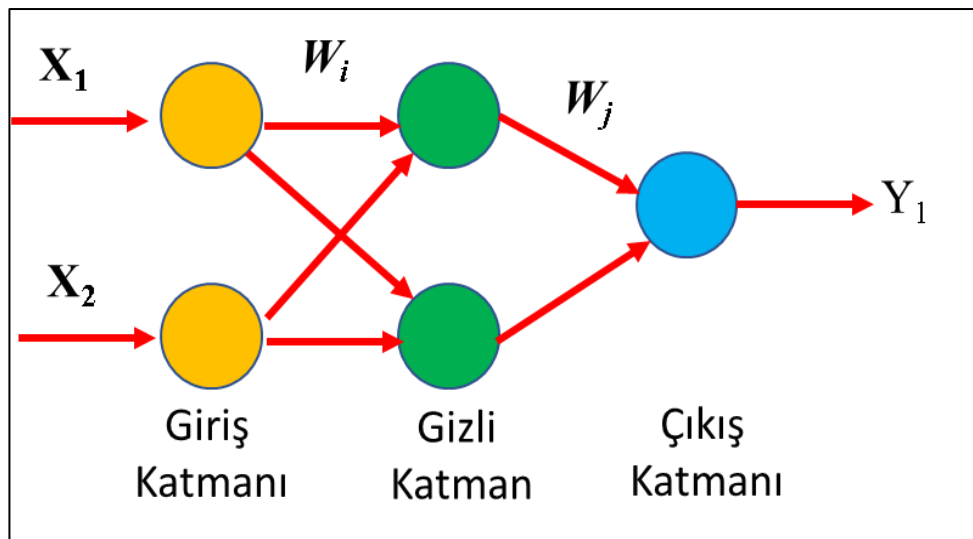
Bir nörona aktarılan bilgi diğer nöronlara aktarılırken, aynı parmağımızın bir acıyı hissettiği durumdaki örnekte olduğu gibi, aynı etki veya şiddette olmayabilir. Her bir nöron, sinir ağ sisteminde farklı katmanda yer almakla birlikte, bu katmanlar arasındaki bilgi iletiminin etkisini belirleyen bir katsayı bulunur. Şekil 3.36’ da da gösterilen X_0 , X_1

ve X_2 parametreleri nörona giriş yapılan bilgilerin özelliklerini ifade etmektedir. Bunların yanında W ile gösterilen ifadeler ise girilen bilgilerin hangi ağırlık oranı ile nörona gireceğini belirtmektedir.

Yapay sinir ağı yapısının hafızaları olarak nitelendirilen ağırlıklar, sistemde modele ait bilginin taşındığı noktalar olarak da tanımlanmaktadır. Yapay sinir ağlarının eğitilmesi, sisteme verilen örnek girdiler için beklenen çıktı değerlerini üretmesini sağlayacak ağırlık değerlerinin bulunması işlemidir. Dağınık biçimde bilgiyi taşıyan bu ağırlıkların alacağı değerler kendi başlarına bir anlam ifade etmemenin yanı sıra, sistemin performansı tamamen bu ağırlıkların almış olduğu değerlere yani ağırlık setine bağlı olmaktadır (Yıldız. 2016).

3.3.3.4.2. İleri beslemeli yapay sinir ağları

İleri beslemeli yapay sinir ağı yapısında yer alan her bir katmandaki nöronlar, sadece kendinden bir önceki katmanın nöronlarından gelen bilgi ile beslenmektedir. İleri beslemeli yapay sinir ağında bir katmandaki hücrelerin çıkışları bir sonraki katmana ağırlıklar üzerinden giriş olarak iletilmektedir (Öztürk 2020). Giriş katmanı, Şekil 3.40’da gösterildiği üzere deney setinden veya dış ortamdan aldığı bilgileri hiçbir değişikliğe uğratmadan sonraki katmandaki nöronlara iletir ve iletilen bu bilgiler katmanlarda işlenerek ağı çıktısı olarak belirlenir.



Şekil 3.40. İleri beslemeli sinir ağı

Deney ortamından alınan verileri işleyebilmek için ileri beslemeli yapay sinir ağları çeşitli eğitim algoritmalarından yararlanmaktadır. Geriye yayımlı olarak adlandırılan ileri beslemeli yapay sinir ağı, modellerin eğitilmesinde yaygın olarak Levenberg–Marquardt (TRAINLM), Scaled Conjugate Gradient (SCG) ve Quasi-Newton metodu (BFGS) olarak adlandırılan eğitim fonksiyonlarını kullanmaktadır (Nacar 2019) .

3.3.3.4.3. Levenberg-Marquart algoritması

Levenberg-Marquart algoritması, öğrenme algoritmaları arasındaki en başarılı olanlardan birisidir. Bu algoritmanın en büyük dezavantajı, tasarım ve proses parametreleri fazla olan bir yapay sinir ağı yapısında 3.16’ da ifade edilen denklemde yer alan Jakobiyan matrislerinin çok büyük bir matris yapısına bürünmesi ve bu matrislerin tersinin alınmasında karşılaşılabilecek hesaplama yükünün bu sebeple artıyor olmasıdır (Wilamowski ve ark. 2001).

$$w_{k+1} = w_k - (J_k^T J_k + \lambda I)^{-1} J_k e_k \quad k: 1, 2, \dots, n \quad (3.16)$$

Bu denklemde; w 1’den n ’ye kadar olan ağırlıkları içeren ağırlık vektörü, λ negatif olmayan kombinasyon veya öğrenme katsayısı, I birim matris, J Jakobiyan matrisi ve e hata vektörü olarak tanımlanmaktadır. Bu öğrenme algoritması, MATLAB yazılımında “trainlm” ifadesi ile temsil edilmektedir.

3.3.3.4.4. Scaled conjugate gradient algoritması

Battiti ve Masulli, tek adımlı Broyden-Fletcher-Goldfarb-Shanno (BFGS) hafızasız quasi-Newton algoritmasının bir varyasyonu olan alternatif bir öğrenme algoritması olarak standart eşlenik gradyan (standart conjugate gradient) yöntemini ortaya koymuşlardır. Parite problemi üzerinde test edildiğinde BFGS' nin geri yayılım algoritmasına kıyasla bir ivme sağladığı sonucuna varmışlardır. BFGS, uygun adım boyutunu belirlemek için bir satır taraması yapması gerektiğinden, öğrenme yinelemesi başına hesaplama karmaşıklığını önemli ölçüde artırır. Bir satır taraması, global hata fonksiyonunun veya türevinin alınması için yapılan hesaplamalarını içermekte olduğundan karmaşık bir hesaplama yapısına sahiptir (Moller 1993).

3.3.3.5. Yapay sinir ağıları ve yanıt yüzey metodu ile yapılan çalışmalar

Termomekanik analizler genellikle yüksek işlemci süresi gerektirmektedir. Bu durumun bir sonucu olarak, optimizasyon sürecinde termomekanik analizlerin doğrudan kullanılması mantıklı değildir. Öte yandan, YSA, hesaplama zorlukları olan karmaşık sistemleri modellemek için hesaplama maliyetini azaltmak ve optimizasyon verimliliğini ve yaklaşım doğruluğunu artırmak için yapay zeka tabanlı bir yaklaşım tekniği olarak kullanılabilir.

Yapay sinir ağıları, sistem doğrusallığı veya doğrusal olmama durumuna bakılmaksızın herhangi bir kesin ilişki talebi olmaksızın girdiler ve çıktılar arasındaki ilişkilerin tanınması ve öğrenilmesi ve aynı zamanda verilerdeki gürültüye ve ölçüm hatalarına karşı yüksek tolerans gibi bazı yönlerden faydaları ve verimliliği nedeniyle ön plana çıkmaktadır. (Rahman ve ark. 2018).

Çizelge 3.6. Girdiler ve çıktılar

Girdiler	Çıktılar
DED Dolgu Genişliği (DBW)	Toplam Kütle
DED Dolgu Yüksekliği (DBH)	Eklenmiş DED Malzeme Kütlesi
DED Dolguları Arası Mesafe (DBD)	Ana Malzeme Kütlesi
Ana Malzeme Kalınlığı (BMT)	Spesifik Enerji Emilimi
DED Dolgu Modelleri (PP)	Maksimum Kuvvet
Lazer / Isı Kaynağı Gücü (LP/HS)	Enerji Emilimi Oranı

Bu tez çalışmasında, hem yapay sinir ağıları hem de DOE yanıt yüzey metodu, topoloji tabanlı geometrik desenleri ve süreç parametrelerini tahmin etmek ve optimize etmek için vekil modeller olarak kullanılmıştır. DOE YYM çalışmaları ile ilgili deneysel sonuçlar alınmış ve sinir ağı modelleri için girdi seti olarak kullanılmıştır. Bu bölümde YSA ve YYM çalışmaları, DED süreç parametreleri dikkate alınarak incelenecektir. İlk olarak, Çizelge 3.6' da ve Şekil 3.12' deki gibi belirtilmiş giriş parametrelerine göre deney tasarımı tabloları oluşturulmuştur.

Çizelge 3.7. Taguchi DOE tablosu (Mohamed ve ark. 2019)

		Parametre Sayısı (P)								
		2	3	4	5	6	***	29	30	31
Seviye Sayısı	2	L4	L4	L8	L8	L8	***	L32	L32	L32
	3	L9	L9	L9	L18	L18	***			
	4	L'16	L'16	L'16	L16	L'32	***			
	5	L25	L25	L25	L25	L25	***			

Çizelge 3.8. YSA için Taguchi ile oluşturulmuş deney seti

NO	DBW (MM)	DBH (MM)	DBD (MM)	BMT (MM)	PP	LP/HS (W)
1	3	5	9	1,2	1	1000
2	3	7,5	18	1,4	2	1200
3	3	10	27	1,6	3	1300
4	3	12,5	36	1,8	4	1400
5	3	15	45	2	5	1500
6	4	5	18	1,6	4	1500
7	4	7,5	27	1,8	5	1000
8	4	10	36	2	1	1200
9	4	12,5	45	1,2	2	1300
10	4	15	9	1,4	3	1400
11	5	5	27	2	2	1400
12	5	7,5	36	1,2	3	1500
13	5	10	45	1,4	4	1000
14	5	12,5	9	1,6	5	1200
15	5	15	18	1,8	1	1300
16	6	5	36	1,4	5	1300
17	6	7,5	45	1,6	1	1400
18	6	10	9	1,8	2	1500
19	6	12,5	18	2	3	1000
20	6	15	27	1,2	4	1200
21	7	5	45	1,8	3	1200
22	7	7,5	9	2	4	1300
23	7	10	18	1,2	5	1400
24	7	12,5	27	1,4	1	1500
25	7	15	36	1,6	2	1000

Altı giriş parametresinin her biri için beş seviye belirlenmiştir. Öte yandan Çizelge 3.7’deki Taguchi tablosu dikkate alınarak altı parametrenin beş düzeyi için gerekli deney sayısı 25 adet veri olarak oluşturulmuştur. Oluşturulan DOE tablosu Çizelge 3.8’de verilmiştir. Taguchi modelleri Ek 1’de yer almaktadır.

Ancak Taguchi tabloları oluşturulmuş olmakla beraber her bir girdi parametresi için ara değerleri bulmak, değerlendirmek ve dolayısıyla daha doğru sonuçlar elde etmek için Latin Hiperküp Örnekleme kullanılmıştır. Latin hiperküp örnekleme (LHÖ), ortalama değerleri ve standart sapmaları tahmin etmek için çok etkilidir. Latin hiperküp örnekleme, yapısal güvenilirlik analizi için farklı önemli örnekleme yöntemlerinin verimliliğini artırmak için bir araç olarak önerilmektedir (Olsson ve ark. 2003). LHÖ tablosu Çizelge 3.9’de verilmiştir.

Çizelge 3.9. YSA için LHS ile oluşturulmuş deney seti

NO	DBW (MM)	DBH (MM)	DBD (MM)	BMT (MM)	PP	LP/HS (W)
1	6,91	5,37	36,81	1,1	4	1053
2	6,45	13,98	15,3	1,69	2	1266
3	3,36	10,09	10,97	1,51	5	1151
4	5,54	14,2	40,58	1,8	2	1362
5	4,53	6,25	27,71	1,33	5	1333
6	6,18	12,19	30,65	1,42	4	1217
7	4,71	11,62	26,89	1,95	3	1038
8	5,26	9,38	21,47	1,21	1	1485
9	3,54	8,43	19,49	1,01	1	1116
10	4,05	7,47	42,11	1,84	3	1424
11	3,08	11,65	37,19	1,53	1	1327,64

Üç nokta bükme performansında her parametrenin etkisini değerlendirmek için bir yanıt yüzeyi metodu (DOE YYM) analizi gerçekleştirilmiştir. DOE yanıt yüzeyi metodu akışı, değişkenlerin kısıtları dikkate alınarak Şekil 3.41’ de gösterildiği aralıklar temel alınarak gerçekleştirilmiştir.

$$\begin{array}{l}
 \text{max}\{ \text{SEA (DBW, DBH, DBD, BMT, PP, LP/HS)} \} \\
 \\
 \text{cons } \{ \text{PF (DBW, DBH, DBD, BMT, PP, LP/HS)} \leq 9, \text{TM(DBW, DBH, DBD, BMT, PP, LP/HS)} \leq 0.6 \} \\
 \\
 \text{variables } \left\{ \begin{array}{l}
 3 \leq \text{DBW} \leq 7 \\
 5 \leq \text{DBH} \leq 15 \\
 9 \leq \text{DBD} \leq 45 \\
 1.2 \leq \text{BMT} \leq 2 \\
 1 \leq \text{PP} \leq 5 \\
 1000 \leq \text{LP/HS} \leq 1500
 \end{array} \right.
 \end{array}$$


Şekil 3.41. Metamodelleme çalışmaları için girdi parametreleri aralıkları

Çizelge 3.10'da gösterilen veriler, girdi parametrelerini optimize etmek için DOE YYM yaklaşımından elde edilmiştir. Şekil 3.42’ de DOE yanıt yüzey metodunun önerdiği optimum çözüm için yapılan simülasyon çalışmalarından görseller belirtilmiştir. Şekil 3.43, parça üzerindeki ısıl işlem katkılarını gösteren yapısal performans açısından girdi parametrelerinin çıktıları nasıl etkilediğini göstermektedir.


Çizelge 3.10. Tasarım ve proses parametreleri için DOE YYM optimizasyon sonuçları

DBW	DBH	DBD	BMT	PP	LP/HS
3,53066	15	43,9946	1,2	5	1500

Bir YSA'nın genel mimarisi, üç tür katmanla ilişkili bağlantılı nöronların bir koleksiyonundan oluşur: giriş katmanı (inputs), gizli katmanlar (hidden layers) ve çıkış katmanı (outputs) (Abiodun ve ark. 2018) (Agatonovic ve ark. 2000). Tez çalışmasında oluşturulan yapay sinir ağı yapısı Şekil 3.44’ de gösterilmektedir.



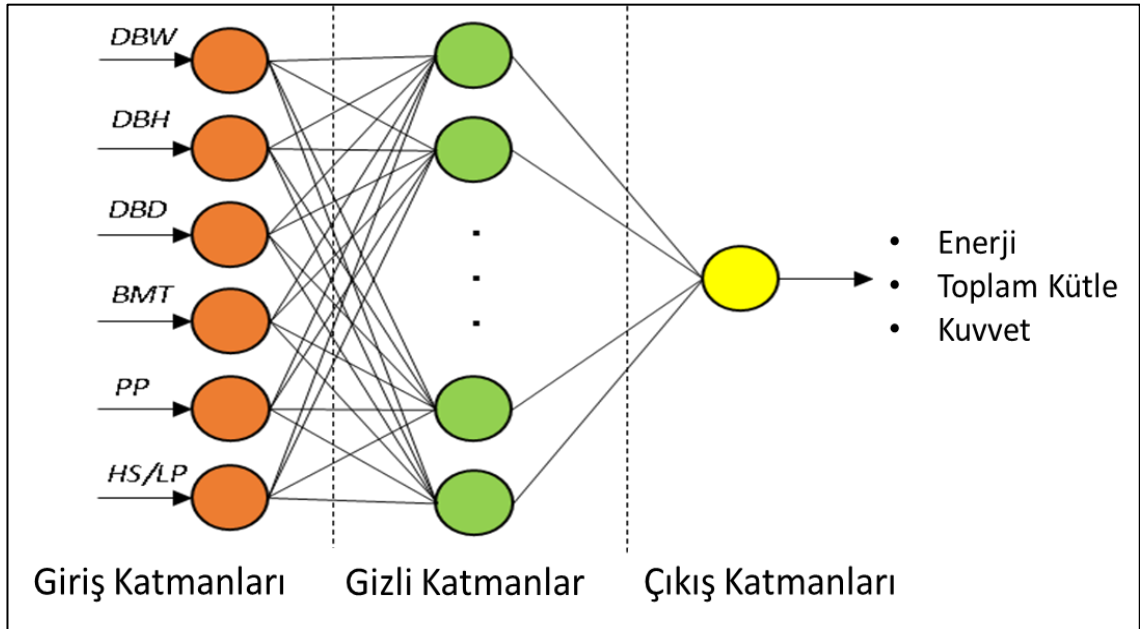
Şekil 3.42. DOE YYM öneri modeli simülasyon görseli



Şekil 3.43. DOE YYM İle elde edilmiş girdi parametreleri ile çıktılar arasındaki ilişki sonuçları

Oluşturulmuş yapay sinir ağı yapısının giriş katmanında dolgu özellikleri, ana malzeme özellikleri ve ısı kaynağı özellikleri yer almaktadır.Çıkış katmanında ise hedef kontrol çıktısı olan enerji ve kısıt olarak tanımlanacak toplam kütle ve kuvvet bileşenleri yer almaktadır.

Hibrit ürün en iyileme hedef ve kısıt fonksiyonları için uygun bir ileri beslemeli bu yapay sinir ağını geliştirmek için MATLAB yazılımı kullanılmıştır. En iyi yapay sinir ağı yapısını bulabilmek için Pearson korelasyon katsayısı (R) ve ortalama kare hata (MSE) değerleri incelenmiştir (Demirezen ve ark. 2020).



Şekil 3.44. DED prosesi için yapay sinir ağı mimarisi

Yapay sinir ağı yapısında kullanılan öğrenme oranı 0,01' den başlayıp 0,01'lik adımlarla 1' e kadar artan olarak belirlenmiştir. Bazı araştırmacılar 30' a kadar nöron sayısını araştırmış ve 4 ile 12 arasında nöron sayısı en iyi R değerlerini ve en düşük MSE' yi vermiştir. Dolayısıyla bu çalışmada nöron sayısı 1 ile 30 arasında tanımlanmıştır. Eğitim fonksiyonları, MATLAB yazılımında yerleşik eğitim algoritmaları olan “Levenberg–Marquardt” ve “Scaled Conjugate Gradient” seçilmiştir. YSA yapılarında kullanılan parametreler Çizelge 3.11' de verilmiştir.

Yapay sinir ağı yapısı, belirlenmiş giriş verilerininin 25 adeti Taguchi deney tasarımı ile 11 tanesi ise Latin hiperküp örnekleme yöntemiyle oluşturulmuş toplam 36 veri noktasından oluşmaktadır. Oluşturulmuş her bir girdi parametresi için ise çıktılar ısı kaynağı ve malzeme modeli doğrulanmış DED simülasyonlarından elde edilmiştir. Elde edilen bu sonuçlar Çizelge 3.12 de belirtilmiştir.

Çizelge 3.11. Yapay sinir ağı parametreleri

	Enerji	Toplam Kütle	Kuvvet
Türü	Feed-forward	Feed-forward	Feed-forward
Eğitim Fonksiyonu	Scaled Conjugate Gradient	Levenberg–Marquardt	Levenberg–Marquardt
Öğrenme Oranı	0,11	0,34	0,92
Gizli Katman Sayısı	1	1	1
Nöron Sayısı	9	4	10
Devir (Epoch) Sayısı	41	15	7

Yapay sinir ağı modellemesinde çapraz doğrulama yapabilmek için bir “hold-out” tekniği uygulanmıştır. Bu yöntemde metamodellemede kullanılacak verilerin bir kısmı doğrulama testi için kullanılırken diğer kalan kısmı ise sinir ağı modelini eğitmek için kullanılacak şekilde bölümlenir. Bu teknik, veri seti küçük olduğu için, yaklaşık 30 veri olduğu için tercih edilir (Abiodun ve ark. 2018) (Rahman ve ark. 2018). Toplamda, veri noktalarının %70'i, %15'i ve %15'i eğitim, test ve doğrulama için kullanılmıştır.

Optimum YSA yapısını bulmak için öğrenme hızı, nöron sayısı ve farklı eğitim fonksiyonları kullanılarak iç içe bir döngü tasarlanmıştır. YSA modeli ve tahminler, testin Pearson korelasyon katsayısı (R) 0,965' den yüksek olduğunda ve döngü boyunca daha iyi MSE değerleri bulunduğunda kaydedilecek şekilde uyarlanmıştır.

Çizelge 3.12. DED simülasyon sonuçları

NO	TOPLAM KÜTLE (KG)	DOLGU KÜTLESİ (KG)	ANA MALZEME KÜTLESİ (KG)	ENERJİ EMİLİMİ (J)*10 ⁻³	MAKSİMUM KUVVET (kN)	ENERJİ EMİLİM ORANI (J/GR)
1	0,466	0,050	0,417	3224,675	7,534	6,915
2	0,533	0,052	0,481	3524,955	8,555	6,614
3	0,625	0,069	0,556	2989,453	11,151	4,781
4	0,728	0,102	0,626	4441,836	9,856	6,101
5	0,820	0,125	0,695	5472,471	12,126	6,672
6	0,627	0,071	0,556	3901,674	8,554	6,222
7	0,744	0,119	0,626	4719,856	10,897	6,340
8	0,752	0,057	0,695	4829,942	10,567	6,422
9	0,464	0,047	0,417	3337,826	7,775	7,194
10	0,646	0,165	0,481	2686,896	7,317	4,162
11	0,731	0,036	0,695	5114,675	11,554	6,999
12	0,481	0,064	0,417	2995,542	7,115	6,231
13	0,573	0,092	0,481	3918,067	8,925	6,843
14	0,896	0,340	0,556	3578,904	8,656	3,994
15	0,768	0,142	0,626	4834,260	10,851	6,295
16	0,549	0,069	0,481	3989,573	9,350	7,262
17	0,599	0,043	0,556	4293,940	9,754	7,170
18	0,796	0,171	0,626	5290,903	11,950	6,644
19	0,833	0,138	0,695	5004,117	11,144	6,009
20	0,652	0,235	0,417	3375,056	7,781	5,179
21	0,674	0,048	0,626	4491,653	10,126	6,668
22	0,866	0,171	0,695	5649,581	12,379	6,525
23	0,677	0,261	0,417	3399,089	7,950	5,018
24	0,605	0,124	0,481	3411,902	8,154	5,640
25	0,705	0,149	0,556	3550,322	8,699	5,032
26	0,478	0,096	0,382	2401,577	6,151	5,023
27	0,758	0,171	0,587	3981,335	9,276	5,250
28	0,715	0,190	0,525	3771,246	9,843	5,275
29	0,700	0,075	0,626	3730,846	8,905	5,328
30	0,573	0,111	0,462	2646,130	6,185	4,616
31	0,690	0,196	0,494	2942,348	7,254	4,265
32	0,779	0,101	0,678	5027,678	12,935	6,455
33	0,514	0,094	0,421	2734,691	7,516	5,319
34	0,422	0,071	0,351	2177,822	5,526	5,163
35	0,695	0,056	0,640	5085,917	12,825	7,314
36	0,583	0,051	0,532	4067,507	10,460	6,978

Algoritma 3.1. Yapay sinir ağı için matlab kodu

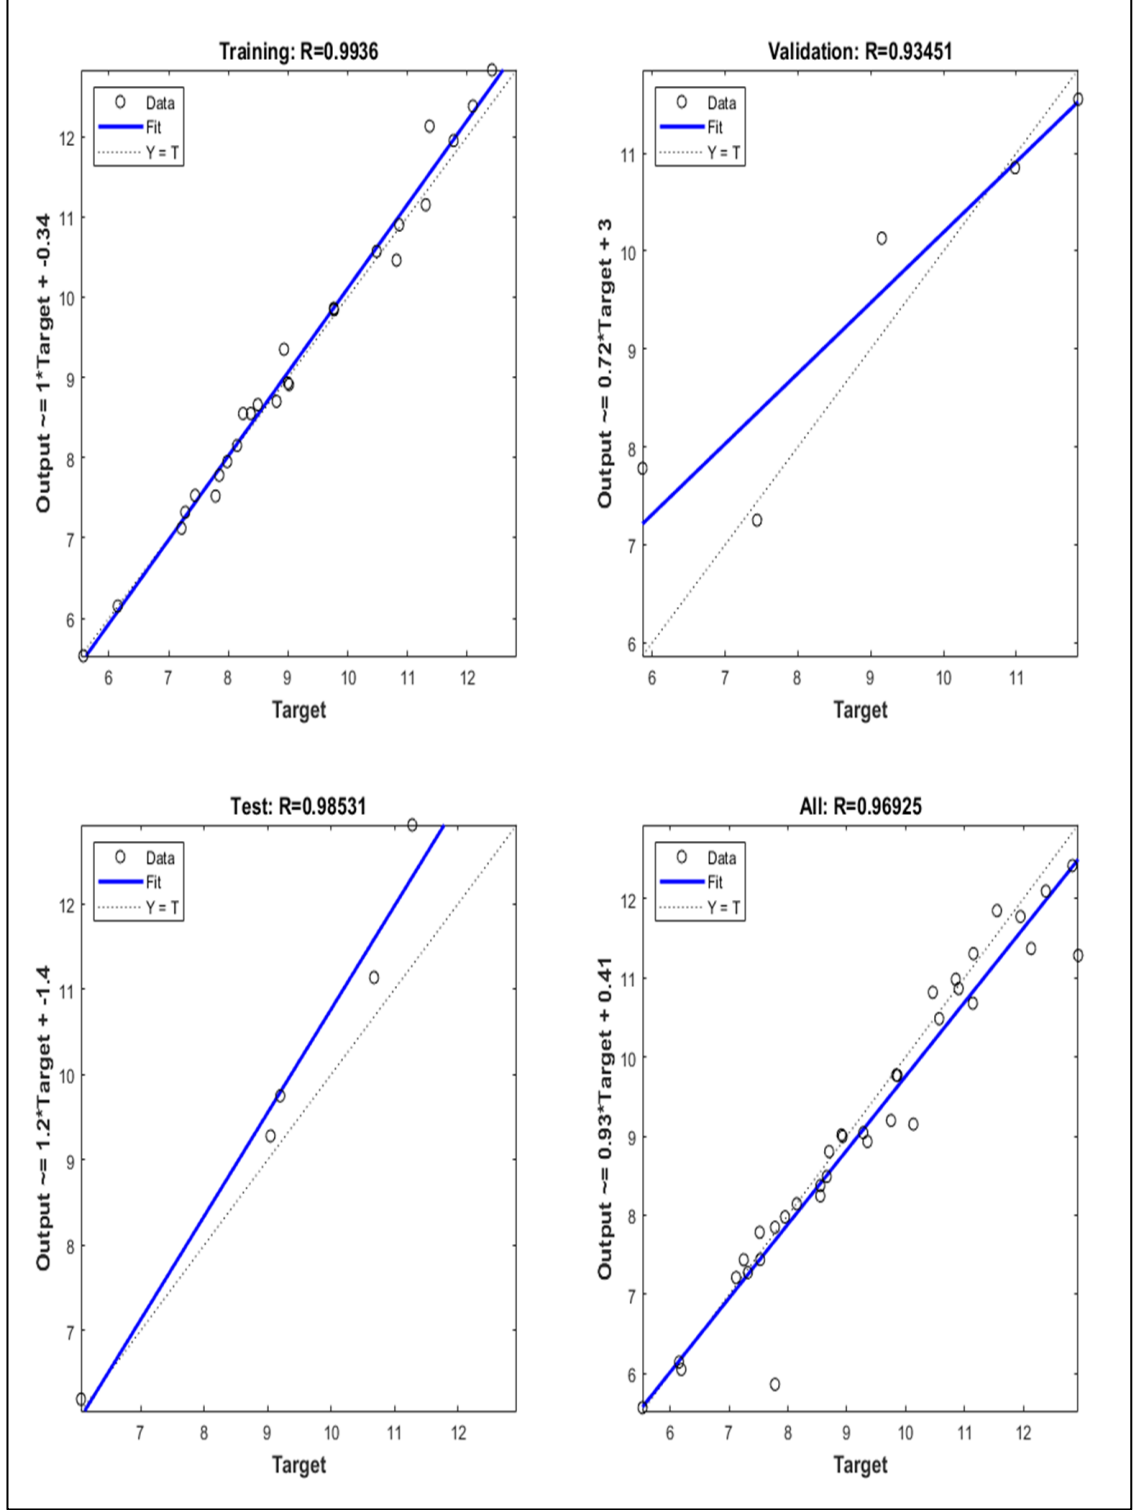
```
1· Input: Design Variables[DBW,DBH,DBD,BMT,PP,LP], Targets [TM, SEA, PF]
2· MSE_init=100000;
3· training_types= ["trainlm","traincg"];
4· for learning_rate = 0.01:0.01:1
5·   for trainFcns= 1:2
6·     create neural network=feedforward
7·     train network
8·     test network
9·     if R_Test > 0.965 and MSE < MSE_init
10·      MSE_init=MSE
11·      save network
12·    else
13·      end
14·    end
15·  end
16· end
```

R-değerinin yanında MSE'nin seçilmesinin nedeni, aşırı uyumu önlemek ve doğruluğu artırmaktır. Bu nedenle bu çalışmada, mevcut sinir ağı modelinin öğrenme algoritmasını değerlendirmek için hold-out tekniği kullanılmıştır. Mevcut sinir ağı modeli, daha yüksek tahmin kabiliyetine sahip bir YSA modeli sunmaktadır. Optimum YSA modelinin MATLAB yazılımı kodu Algoritma 3.1' de sunulmuştur.

MATLAB yazılımında uyarlanan döngü sonucunda elde edilen en iyi YSA yapılarının R-değeri eğrileri sırasıyla Şekil 3.45 - 3.47' de Kuvvet, Enerji ve Toplam Kütle için verilmiştir. 1' e yakın bir R değeri, kurulan modelin yüksek doğruluğa sahip olduğunu göstermektedir.

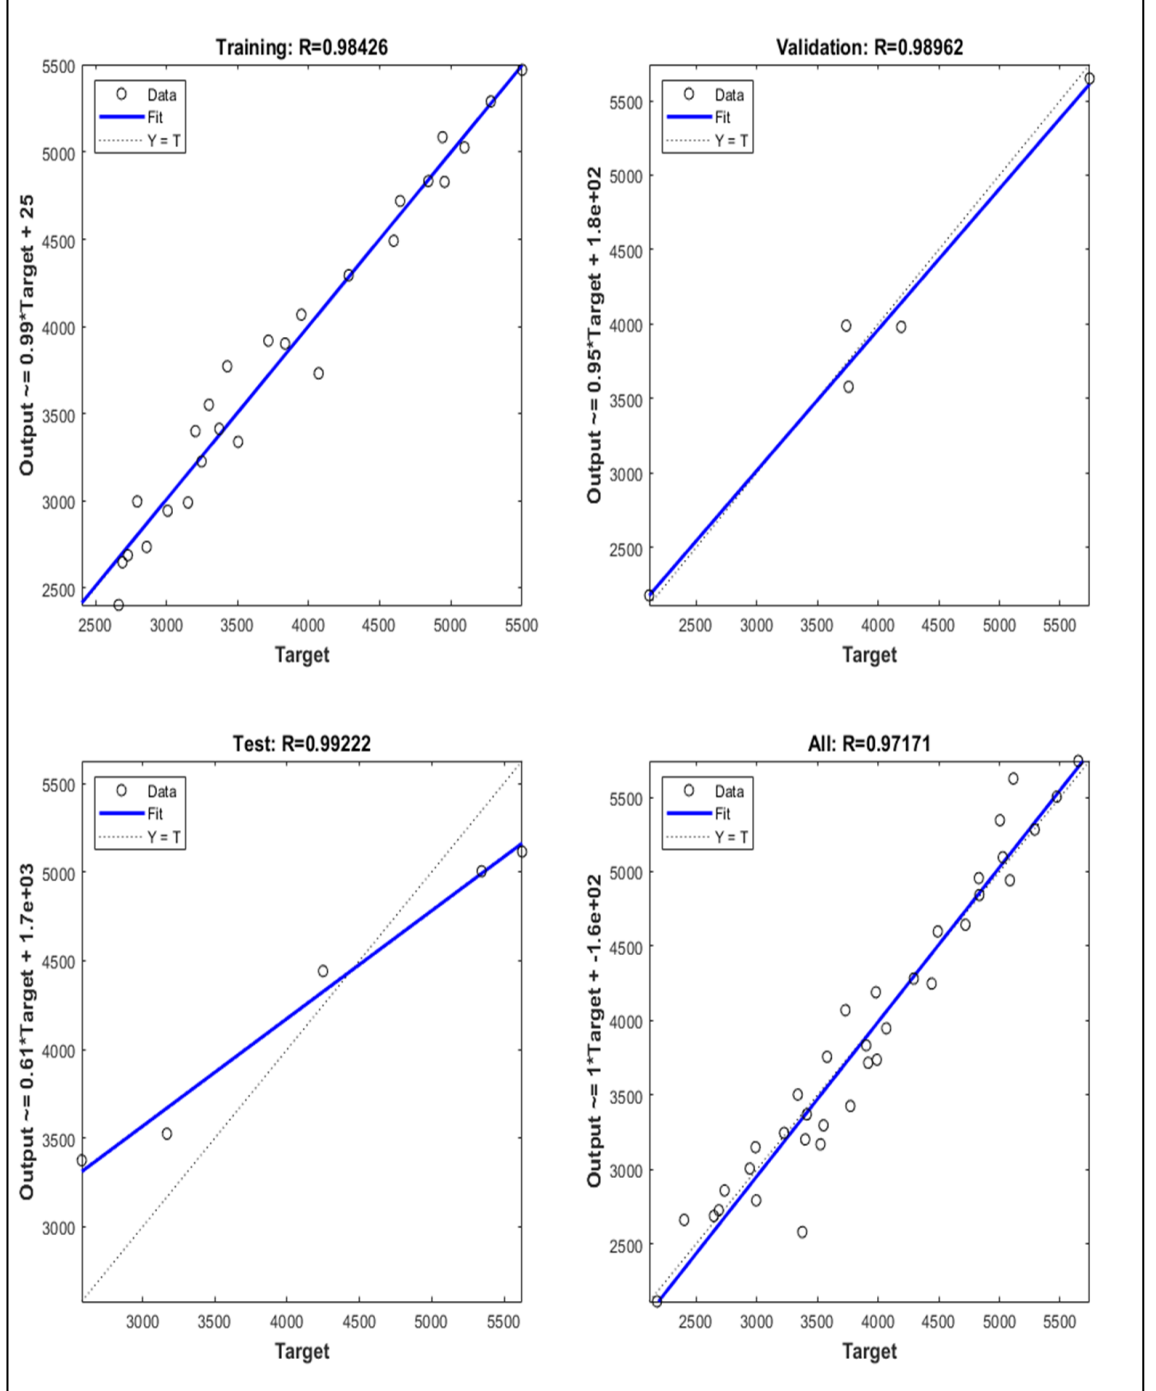
Spesifik enerji emilimi ve toplam kütle için en küçük R değerleri sırasıyla 0,97171 ve 0,98207 dir ve bu nedenle yüksek bir korelasyona sahiptirler. Doğrulama çalışmasında, maksimum kuvvet için en küçük R değeri 0,93451 olmasına rağmen, DED proses analizlerinde malzeme ayrıklaştırmadaki zorluklar sebebiyle kullanılan ısı girdisi ve akış

eğrileri ile yüksek doğrusal olmayan bir problem yapısı içerdiğinden yine de yeterli bir doğrulama sunmaktadır.

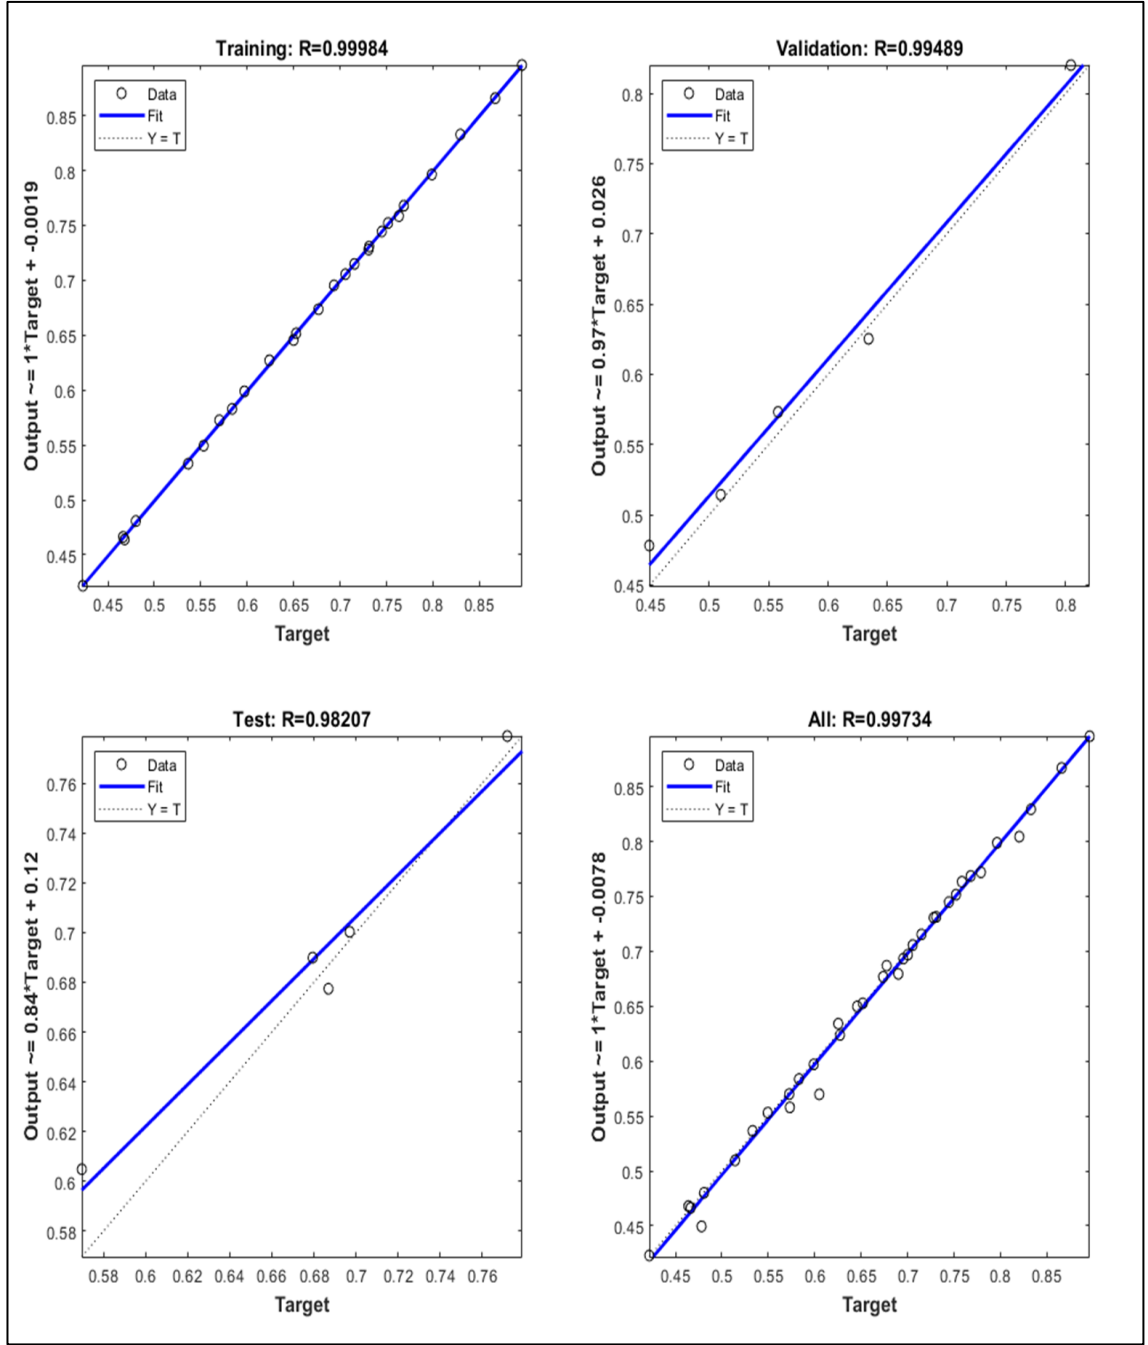


Şekil 3.45. Maksimum kuvvet çıktısında en iyi yapay sinir ağı yapıları için R-değer eğrileri

Bununla birlikte yapay sinir ağı algoritması sonrasında hibrit giriş yapısının optimizasyonu bir genetik algoritma ile gerçekleştirilmiştir. Bu iki yaklaşımın bir arada uygulanması ile DOE YYM yaklaşımı için tanımlanan kısıtlamalar altında, genetik algoritma, Çizelge 3.13’ de gösterildiği gibi girdi parametrelerini tahmin etmiştir.



Şekil 3.46. Spesifik enerji emilimi çıktısında en iyi yapay sinir ağı yapıları için R-değer eğrileri



Şekil 3.47. Toplam kütle çıktısında en iyi yapay sinir ağı yapıları için R-değer eğrileri

Çizelge 3.13. DED prosesi tasarım ve proses parametreleri için YSA + GA optimizasyon sonuçları

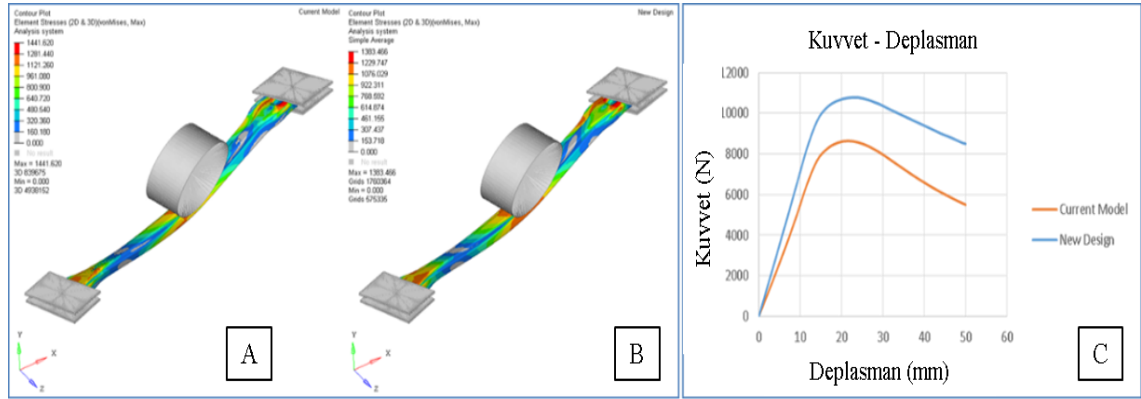
DBW	DBH	DBD	BMT	PP	LP/HS
4,3542	5,8669	45	1,6724	1	1342,10

4. BULGULAR

4.1. Hibrit DED Ürün Parça Seçimi Bulguları

DED prosesinde optimizasyon çalışmaları kapsamında büyük boyutlu parçanın belirlenmesi aşamasında, lokal olarak güçlendirilmiş bir otomotiv kapı barı DED yöntemiyle hibrit bir şekilde fiziksel ön prototip olarak üretilmiştir. Bununla birlikte, topoloji optimizasyonu çalışması ile hangi bölgelerin daha güçlü olması gerekliliği belirlenmiştir.

Aynı zamanda kritik gerilme bölgelerinin (hot spot stress zones) belirlenebilmesi adına Simufact yazılımı kullanılarak DED proseslerinin simülasyon çalışması gerçekleştirilmiştir.




Şekil 4.1. Çarpışma analizi sonuçları. **A)** Mevcut model gerilim sonuçları **B)** Önerilen modele ait gerilim sonuçları **C)** İki modelin kuvvet-deplasman eğrisi kıyaslaması

Sanal olarak DED prosesinden gelecek etkilerin de göz önünde bulundurulduğu haliyle çarpışma analizleri gerçekleştirilmiş ve sanal analiz sonuçlarında Şekil 4.1’ de görüleceği üzere mevcut tasarıma göre %30’ a yakın bir performans iyileşmesi gözlemlenmiştir. Bu sonuçlar doğrultusunda kapı barına benzer bir şekilde basitleştirilmiş ve üç nokta eğme testi koşulları altında incelenebilecek DED dolgularıyla lokal olarak güçlendirilmiş hibrit basitleştirilmiş bir yapı ile ilerlenebileceği gözlemlenmiştir.

Öte yandan kapı barı için yapılan termomekanik analiz çalışmalarının sonuçları incelendiğinde lokal güçlendirme için eklenmiş olan DED dolgularının ana sac

malzemesi ile Şekil 4.2' den de görüleceği üzere parça üzerine eklenmiş olan DED doltam penetrasyon sağladığı gözlemlenmiştir.




Şekil 4.2. Kapı barı proses simülasyonu


4.2. Dilüsyon Simülasyonu Bulguları

Parça seçimi sırasında yapılan temel ısı kaynağı modellemesinin güçlendirilmesi ve daha doğru çalışabilirliğinden emin olunabilmesi için DED prosesi için kritik parametrelerden biri olan dilüsyon oranının termomekanik analizlerle karşılaştırılması çalışmaları gerçekleştirilmiştir. Bu karşılaştırma çalışmasında, fiziksel olarak ölçülen sonuçlar ile Şekil 4.3' de gösterilen simülasyon sonuçları kullanılarak tahmin edilen dilüsyon oranları arasında paralel bir eğim olduğu gözlemlenmiştir.

Dilüsyon oranlarının belirlenmesi ve DED dolgu analizlerinde kullanılan ısı kaynağı modellemesinin doğrulama çalışmalarında Şekil 4.4' de gösterildiği gibi sonlu elemanlar yöntemi kullanılmıştır. Özellikle toz yatak ergitmeli sistemler veya toz püskürtmeli sistemlerde üretilen dolgu yapılarının daha gerçeğe uygun bir şekilde modellenmesi adına akışkan hacmi oranı yönteminin kullanılabileceği ancak yapılacak simülasyonların oldukça uzun sürmesinden dolayı çok dar veya küçük bir alanda gerçekleştirilmesi gerektiği gözlemlenmiştir.



Şekil 4.3. Farklı tarama hızlarında ısı kaynağı gücünün dilüsyon oranına etkisi



Şekil 4.4. DED dolgu simülasyonu


Yüksek bilgisayar kapasitesi ve uzun çözüm sürelerine ihtiyaç duyması sebebiyle, akışkan hacmi oranı yöntemi tüm parçanın üzerindeki proses etkilerinin incelenebilmesi

ve sonrasında bu termal etkilerin yapısal dayanım analizlerinde kullanılmak üzere aktarılması için tam bir uyumluluk gösterme kabiliyetine sahip değildir.

4.3. Hibrit DED Ürün Fiziksel Test Bulguları

Parça seçimi ve ısı kaynağı modelleme çalışmalarının doğrulanmasının ardından, bu aşamada basitleştirilmiş DED dolgularıyla lokal olarak güçlendirilmiş kiriş parçası sol “*semi-cross left*” deseninde 2 adet hibrit ürün ve 1 adet düz ürün olarak imal edilmiştir. Üretilen prototip numuneler maksimum 50 kN yük kapasiteli bir aktüatöre sahip bir piston vasıtasıyla zorlanmış bir deplasman koşulu verilerek üç nokta eğme olarak fiziksel teste tabii tutulmuştur.

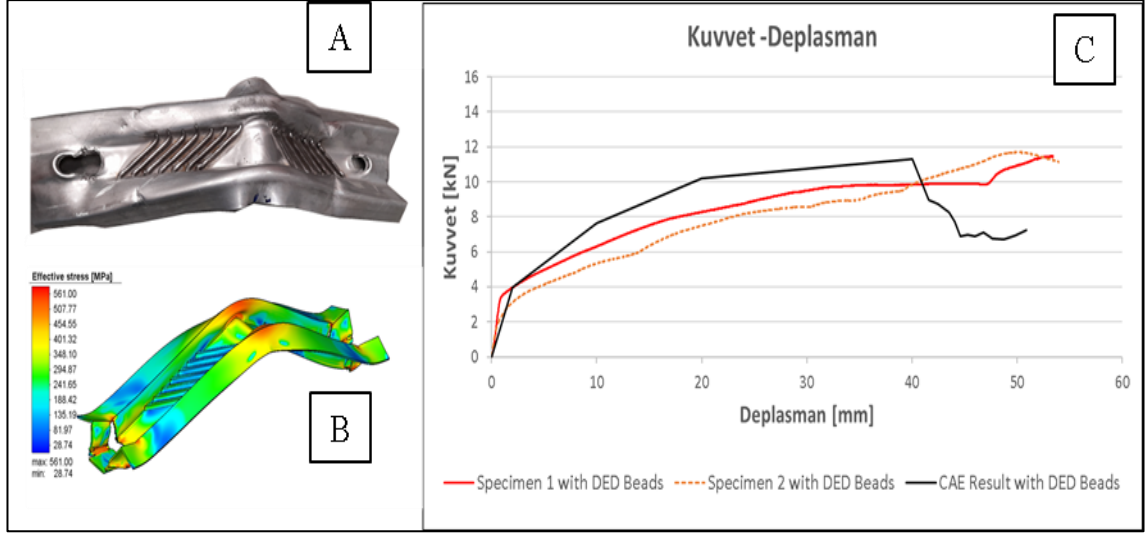
Üç nokta eğme testinden elde edilen sonuçlar ve üretilmiş prototiplere ait görseller Şekil 4.5’ de açıklanmıştır. Görselden de görüleceği üzere test sonucunda oluşan kuvvet-deplasman eğrisinde hasar bölgesi ve efektif enerji emiliminin gerçekleştiği iki bölge oluşmaktadır. Parçalar hasar bölgesinde yırtılma veya hasar ile karşılaşması ve bu hasarın parçaların enerji emilimi performansında kararsızlığa sebep olmasından dolayı etkin enerji absorpsiyon bölgesi altındaki enerji absorpsiyon değerleri karşılaştırılmıştır.



Şekil 4.5. Test bulguları. A) Test edilen prototip ürünler B) Üç nokta eğme fiziksel test sonuçları

Parça üzerine eklenen DED dolgularının enerji emilimi değerinde toplamda % 76’ ya kadar, tepe kuvvetinde (maksimum kuvvet) ise % 66 artış sağlayabileceği

gözlemlenmiştir. Enerji ve tepe kuvveti üzerinde bir optimizasyon çalışması ile DED prosesi kullanılarak performans artışının ağırlık azalmasına yol açabileceği görülmüştür.




Şekil 4.6. Fiziksel ve sanal sonuçların kıyaslanması. **A)** Fiziksel test sonrası numune **B)** Sanal analiz sonrası numune **C)** Fiziksel ve sanal analiz sonuçlarına ait kuvvet-deplasman grafiği karşılaştırması

Öte yandan, CAE sonuçları gerçek test sonuçlarıyla karşılaştırıldığında, hem ısı kaynağı hem de yapısal simülasyon durumları için sayısal modellerin Şekil 4.6' da gösterilen etkin enerji absorpsiyon bölgesi boyunca düzgün çalıştığı görülmektedir. Bu korelasyon çalışmasının ardından, yapay sinir ağları ve yanıt yüzey metodu gibi metamodelleme çalışmaları için deney tasarımları ve yapay zeka destekli öğrenme yeteneklerinin geliştirilmesi için kodlama çalışmalarına geçilmiştir.

4.4. Hibrit DED Ürün İç Yapı İnceleme Bulguları

Lokal olarak DED dolgularıyla güçlendirilmiş prototip parçalarında yüksek enerji emilimi ve tepe kuvvet performansı gözlemlenmişti. Bununla birlikte, bu performansın kalıcı ve sürdürülebilir olmasını garanti altına alabilmek adına yığılmış DED dolgularının ana malzeme üzerinde ve her bir yığılan katmanın kendi içinde tutarlı bir birleşmeye sahip olmasının kontrolü gerekmektedir.




Şekil 4.7. Fiziksel duvar kesitlerinin makro muayene ve penetrant test görselleri. **A)** Ön prototipte görülen gözenek hatası **B)** Bakalitte alınmış duvar kesitlerinin penetrant testi **C)** ve **D)** PT testi yapılmış duvarların makro görüntüleri

Özellikle tel beslemeli DED yöntemlerinde tel besleyici hataya açık olduğundan kullanmanın da bazı zorlukları olduğu görülmüştür. Duvar içlerinde katmanlar arası birleşmeme ve gözenek gibi hataların kontrolü için DED dolgu duvarları, Şekil 4.7' de görüldüğü gibi makro inceleme ve penetrant testine tabi tutulmuştur. Duvarlarda herhangi bir birleşme hatası görülmemiştir. Bu durum, ısı girdisinin bir önceki katman ile birleşme için yeterli olduğunu göstermektedir.

Duvar kesitinin taban bölgesinde (bkz. Şekil 4.7) iki adet gözenek görülmüştür. Altlıkta kalan bir kirlilik ilk katmanlarda gözeneğe neden olabildiği deneyimlenmiştir. Ancak sürekliliği olmayan boyutu küçük ve tekil gözenekler katmanlı imalatta major bir hata olarak kabul edilmemektedir. Şekil 4.7 (A)'da kirlilik nedeni ile tespit edilen gözenek nedeniyle deney numuneleri yenilenmiştir. Profiller katmanlı üretim öncesi alkol ile temizlenerek Şekil 4.7 (C) ve (D) 'de olduğu gibi gözenek hatalarının oluşumu engellenmiştir.

4.5. Hibrit DED Ürün İçin Metamodelleme Bulguları

Bu çalışma kapsamında yapay sinir ağı yöntemi, DED işlem parametre etkilerini de içeren 400 mm boyutlu DED dolguları ile güçlendirilmiş basit bir hibrit kiriş parçasının optimum tasarım parametrelerini tahmin etmek için amaç ve kısıt fonksiyonlarının üst modellerini geliştirmek için önerilmiştir. Bununla birlikte yanıt yüzey metodu çalışması da metamodelleme çalışmalarının karşılaştırılması adına gerçekleştirilmiştir.



Şekil 4.8. YYM toplam kütle yanıtı için pareto analizi

Yanıt yüzey metoduyla yapılan metamodelleme çalışmaları kapsamında geliştirilecek DED dolgularıyla kısmi olarak güçlendirilmiş hibrit ürün yapısının toplam ağırlığının etkilendiği parametre ve parametre çiftleri için pareto analizi Şekil 4.8 ile belirtilmiştir. Yapılan pareto analizinde özellikle ana malzemenin kalınlığı toplam ağırlığı etkileyen en kritik parametrelerden biri olarak karşımıza çıktığı gözlemlenmiştir.

Çizelge 4.1, DOE YYM yaklaşımının toplam kütle ve enerji için küçük veri setini %20'nin üzerindeki bir korelasyon hatasıyla değerlendirebildiğini göstermektedir. Öte yandan, enerji ve toplam kütle sonuçları ile karşılaştırıldığında ise göreceli olarak tepe kuvvet (maksimum kuvvet) değerini makul ve kabul edilebilir bir korelasyon hatası ile tahmin edebilmiştir.

Bir sonraki adım olarak, girdi parametreleri ve DED sürecindeki simülasyon, proses sonuçlarının yapısal analize aktarılması, üç nokta eğme simülasyonu ve sonuçların karşılaştırılması gibi alt adımları izleyerek genetik algoritma ve yapay sinir ağlarının hibrit olarak kullanıldığı metodoloji sonrası elde edilen sonuçlar değerlendirilmiştir. Yapay sinir ağı ve genetik algoritmaların hibrit kullanıldığı sonuçlar, Çizelge 4.2' de belirtildiği gibi doğrulanmıştır.

Çizelge 4.1. Kuvvet, enerji emilimi ve toplam kütle değerleri için DOE RSM yaklaşımı sonuçları

	DOE YYM Yaklaşımı	CAE/CAD Sonuçları	Korelasyon (% hata)
KUVVET (kN)	7,115	7,951	11,75%
ENERJİ (Joule)	3,889	2,877	-26,15%
TOPLAM KÜTLE (kg)	0,464	0,5636	21,46%

Korelasyon çalışmaları, ısı ve malzeme modeli doğrulanmış CAE analizleri yardımı ile hesaplanarak gerçekleştirilmiştir. YSA + GA yaklaşımının, bu araştırmada incelenen her çıktı için % 80' in üzerinde korelasyon ile kabul edilebilir sonuçlar sunduğu gözlemlenmiştir.

Çizelge 4.2. Kuvvet, enerji emilimi ve toplam kütle değerleri için YSA yaklaşımı sonuçları

	YSA Yaklaşımı (YSA + GA)	CAE/CAD Sonuçları	Korelasyon (% Hata)
KUVVET (kN)	9,009	10,70	18,86%
ENERJİ (Joule)	4,794	4,232	-11,72%
TOPLAM KÜTLE (kg)	0,601	0,6055	0,75%

Çizelge 4.3. DOE RSM ve YSA+GA yaklaşımlarının karşılaştırılması

	DOE YYM Hata	YSA + GA Hata	% İyileşme/Kötüleşme Oranları YSA + GA 'ya göre
KUVVET (kN)	11,75%	18,86%	-60,51
ENERJİ (Joule)	-26,51%	-11,72%	+55,79
TOPLAM KÜTLE (kg)	21,46%	0,75%	+96,50

Çizelge 4.3, aynı kısıtlamalar ve koşullar altında, YSA + GA yaklaşımının enerji ve toplam kütle tahmini için daha iyi sonuçlar verdiğini göstermektedir. Bunun yanı sıra, DOE YYM' nin tepe kuvveti tahminindeki performansı, YSA + GA yaklaşımı sonuçlarından daha güvenilir olduğu bulunmuştur.

5. SONUÇLAR

Bu tez çalışmasının amacı, DED dolgularıyla hibrit olarak oluşturulmuş ürün için optimum tepe kuvveti ve toplam kütle kısıtlamalarını göz önünde bulundurarak, basit bir sac malzeme ve katmanlı üretim dolguları gibi iki yapının entegrasyonu ile oluşturulan nihai parçanın spesifik enerji emilimi gibi özelliklerini geliştirmek için için bir yaklaşım sunmaktır. Bu doğrultuda oluşturulan küçük bir eğitim veri seti kullanarak, hem girdilerin hem de çıktılarının yüksek boyutlu ve doğrusal olmadığı bu problem için bir DOE YYM ve sinir ağı tabanlı vekil modelleri oluşturulmuş ve hesaplama açısından son derece verimli bir yaklaşım geliştirilmiştir.

Bu çalışmada önerilen yapay zeka destekli yaklaşımın, kontrol edilebilir tasarım ve süreç parametrelerini içeren bir DED dolgularıyla lokal güçlendirilmiş büyük yapıya sahip hibrit bir ürünün geliştirilmesi için literatürdeki mevcut boşluğu doldurmaya yardımcı olacağı açıktır.

Bu çalışmada, önerilen yaklaşım kullanılarak yerel olarak güçlendirilmiş bir yarı çapraz parça üretilmiştir. Hibrit DED giriş prototiplerinden sonra yapısal test düzeneği üzerinde yapılan fiziksel testler sonucunda, lokal olarak güçlendirilmiş giriş parçasının düz modele göre çok daha fazla enerji emilim kapasitesine ve tepe kuvvet değerine sahip olduğu ve % 65' in üzerinde bir performans artışı olduğu tespit edilmiştir.

Tez çalışmasında oluşturulmuş YSA + GA optimizasyon yaklaşımı, basitleştirilmiş büyük boyutlu bir hibrit DED parçasının spesifik enerji emilim değeri için tepe kuvvet ve toplam kütle kısıtlamalarının dikkate alındığı bir ürün performansı tahminini küçük boyutlu bir veri seti ile gerçekleştirmiş, hesaplama süresi ve üretim maliyetlerinin düşürülmesi için verimli bir yöntem olarak sunulmuştur.

Tez çalışmasında oluşturulan yapay sinir ağı modelleri; DED dolgu yüksekliği, genişliği ve mesafesi, ana sac malzeme kalınlığı, dolgu model tipi ve ısı kaynağı gücü gibi farklı değişkenlerin giriş hibrit ürün performansı üzerindeki etkilerini kabul edilebilir ve iyi bir doğrulukla tahmin edebilmektedir. Önerilen YSA+GA' nın, hibrit üretim teknolojileri olarak yerel bir güçlendirilmiş ürün oluşturmak için kullanılabilecek topoloji tabanlı

geometrik desenler ve süreç parametreleri oluşturmak için umut verici bir yaklaşım olduğu görülmektedir.

Önerilen YSA + GA modeli, enerji ve toplam kütle için DOE YYM yönteminden daha yüksek tahmin yeteneğine sahip vekil bir model sunmaktadır. Öte yandan, DOE YYM yaklaşımı, tepe kuvvet değerleri için daha yakın tahminler oluşturmaktadır. Bu çalışma, yapay sinir ağı tabanlı bir optimizasyon yaklaşımının, DED süreci ile üretilen hibrit ürünler üzerinde tasarım optimizasyon çalışmalarında kullanılabileceğini göstermektedir.

Bu çalışmada sunulan tekniklerin bazı sınırları vardır. Titanyum alaşımları gibi diğer alaşımlarda model tahminlemede hata artabilir. Aynı spesifik enerji yoğunluğu için, demir bazlı alaşımlara kıyasla titanyum bazlı alaşımlar için daha fazla malzeme erir. CAE modelini fiziksel sonuçlarla ilişkilendirmek için ısı kaynağı modelini eriyik havuzu şekillerine göre yeniden tanımlamak ve akış eğrilerini uygun şekilde elde etmek gerekebilir.

Sonuç olarak, tez çalışmasında sunulan basitleştirilmiş DED yöntemiyle lokal olarak güçlendirilmiş bir kirişin yapay zeka destekli topoloji optimizasyon modeli, özellikle havacılık ve otomotiv gibi endüstriler için benzer yapıdaki atkı parçalarının veya sistem bileşenlerinin tasarım aşamasında kavramsal tasarım elde etmek için hem performanslı hem de hızlı bir yöntem olarak sunulmuştur.

KAYNAKLAR

3Dmpwire. (2021). <https://www.3dmpwire.com/project-details/goals-and-objectives/> (Erişim Tarihi: 28.12.2021)

Abiodun, O.I., Jantan, A., Omolara, A.E., Dada, K.V.; Mohamed, N.A.E.; Arshad, H. (2018). State-of-the-art in artificial neural net-work applications: A survey. *Heliyon* 2018, 4, e00938. <https://doi.org/10.1016/j.heliyon.2018.e00938>.

Acar, E. (2013). Effects of the correlation model, the trend model, and the number of training points on the accuracy of Kriging metamodels. *Expert Systems*, 30(5): 418-428.

Agatonovic-Kustrin, S., Beresford, R. (2000). Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research. *J. Pharm. Biomed. Anal.* 2000, 22, 717–727. [https://doi.org/10.1016/S0731-7085\(99\)00272-1](https://doi.org/10.1016/S0731-7085(99)00272-1).

Ahn, DG.(2021). Directed energy deposition (DED) process: state of the art. *Int. J. of Precis. Eng. and Manuf.-Green Tech.* 8, 703–742. <https://doi.org/10.1007/s40684-020-00302-7>

Akay, B. (2009). Nümerik optimizasyon problemlerinde yapay arı kolonisi (artificial bee colony) algoritmasının performans analizi. *Doktora Tezi*, Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Kayseri.

Albak, İsa E. (2020). Arka aksın yeni yaklaşımlar ile tasarımının en iyilenmesi. *Doktora Tezi*, Faculty Of Engineering And Physical Sciences, Automotive Engineering, The University Of Bursa Uludag, Bursa, Türkiye.

Almonti, D., Mingione, E., Tagliaferri, V., Ucciardello, N. (2022). Design and analysis of compound structures integrated with bio-based phase change materials and lattices obtained through additive manufacturing. *Int. J. Adv. Manuf. Technol.*, 119, 149–161. <https://doi.org/10.1007/s00170-021-08110-2>.

Altair. (2021). Altair Hyperworks, OptiStruct User guide.

Altıparmak, S.C., Yardley, V.A., Shi, Z., Lin, J. (2021). Challenges in additive manufacturing of high-strength aluminium alloys and current developments in hybrid additive manufacturing. *Int. J. Lightweight Mater. Manuf.*, 4, 246–261. <https://doi.org/10.1016/j.ijlmm.2020.12.004>.

Aziz, A. N., Adnan, N.A.A., Abd Wahab, D., Azman, A.H. (2021). Component design optimisation based on artificial intelligence in support of additive manufacturing repair and restoration: current status and future outlook for remanufacturing. *J. Clean. Prod.* 2021, 296, 126401. <https://doi.org/10.1016/j.jclepro.2021.126401>.

Bulut, E., Albak, E.İ., Sevilgen, G., Öztürk, F., (2022). Prediction and optimization of the design decisions of liquid cooling systems of battery modules using artificial neural networks. *Int. J. Energy Res.* 2022, 46, 7293–7308. <https://doi.org/10.1002/er.7637>.

Chambers, L. D. (Ed.) (1998). Practical handbook of genetic algorithms: complex coding systems 3, *CRC press*.

Childerhouse, T., Jackson, M. (2019). Near net shape manufacture of titanium alloy components from powder and wire: a review of state-of-the-art process routes. *Metals*, 9(6):689. <https://doi.org/10.3390/met9060689>

Çallı, M., Albak, E.İ., Öztürk, F. (2022) Prediction and Optimization of the Design and Process Parameters of a Hybrid DED Product Using Artificial Intelligence. *Applied Sciences*, 12(10):5027. <https://doi.org/10.3390/app12105027>

Çallı, M., Onaylı, A., Karagöz, T., Bıyıklı, M. (2020). An application of directed energy deposition manufacturing method on an automotive component. 5. *International Conference on Material Science and Technology (IMSTEC 2020)*, 16-18 October 2020, Kapadokya, Nevşehir.

Debroy T., Wei H. L., Mukherjee T., Elmer J. W., Milewski J. O., Beese A. M., Wilson-Heid A., De A. and Zhang W. (2018). Additive manufacturing of metallic components - process, structure, and properties. *Progress in Materials Science*, vol. 92, pp. 112-224.

Demirezen, G., Fung, A.S., Deprez, M. (2020). Development and optimization of artificial neural network algorithms for the prediction of building specific local temperature for HVAC control. *Int. J. Energy Res.*, 2020, 44, 8513–8531. <https://doi.org/10.1002/er.5537>.

Diegel, O., Nordin, A., Motte, D. (2020). A Practical guide to design for additive manufacturing. 1st ed., *Springer Series in Advanced Manufacturing*, Springer: Berlin/Heidelberg, Germany.

DigitalAlloys. (2021). <https://manufactur3dmag.com/powder-vs-wire-a-guide-to-metal-additive-manufacturing-by-digital-alloys/> (Erişim Tarihi: 25.09.2021)

Emel, G. G., Taşkın, Ç. (2002). Genetik algoritmalar ve uygulama alanları. *Uludağ Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, Cilt XXI, Sayı 1, 2002, s. 129-152

Fang, H., Rais-Rohani, M., Liu, Z., Horstemeyer, M.F. (2005). A comparative study of metamodeling methods for multiobjective crashworthiness optimization. *Comput. Struct.*, 2005, 83, 2121–2136.

Fırat, M., Güngör, M. (2004). Askı madde konsantrasyonu ve miktarının yapay sinir ağları ile belirlenmesi. *İMO Teknik Dergi*, 2004 3267-3282, Yazı 219

Ghanim, M. A. (2016). Optimization technique. *Technical Report*, Missouri University of Science and Technology. October. DOI: 10.13140/RG.2.2.16302.56643

Godec, M., Malej, S., Feizpour, D., Donik, Č., Balažic, M., Klobčar, D., Pambaguian, L., Conradi, M., Kocijan, A. (2021). Hybrid additive manufacturing of Inconel 718 for future

space applications. *Mater. Charact.*, 172, 110842.
<https://doi.org/10.1016/j.matchar.2020.110842>.

Goldak, J., Akhlagi, M. (2005). Computational welding mechanics. *Springer: Ottawa, ON, Canada*.

Gradl, P., Mireles, O. (2018). Intro to additive manufacturing for propulsion systems. *AIAA Joint Propulsion Conference*,
(<https://ntrs.nasa.gov/api/citations/20180006357/downloads/20180006357.pdf>)
(Eriřim Tarihi:14.11.2021)

Gümüs, S., Lackner, J. M., Polat, ř., Kraschitzer, W., Hanning, H., Bayram, A., Kaya, M., řallı, M., Alkan, A. (2018). Failure behavior of PA12 based SLS lattice structure with macro-porosity. *MATEC Web of Conferences*, 188, 03007.
<https://doi.org/10.1051/mateconf/201818803007>

Holland, J.H. (1992). Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence. *MIT Press: Cambridge, MA, USA*.

Hou, S., Li, Q., Long, S., Yang, X., Li, W. (2008). Multiobjective optimization of multi-cell sections for the crashworthiness design. *Int. J. Impact Eng.*, 35, 1355–1367.

ISO/ASTM 52900. (2018). Additive manufacturing general principles terminology. *International Organization for Standardization, Geneva, Switzerland*.
<https://www.iso.org/obp/ui/#iso:std:iso-astm:52900:dis:ed-2:v1:en>
(Eriřim Tarihi: 10.02.2022).

Kazi, M.-K., Eljack, F., Mahdi, E. (2022). Design of composite rectangular tubes for optimum crashworthiness performance via ex-perimental and ANN techniques. *Compos. Struct.* 2022, 279, 114858. <https://doi.org/10.1016/j.compstruct.2021.114858>.

Küçüksille, E. U., Tokmak, M. (2011). Yapay arı kolonisi algoritması kullanarak otomatik ders çizelgeleme. *Fen Bilimleri Enstitüsü Dergisi*,15-3(2011). 203-210, Süleyman Demirel Üniversitesi.

Kwon, O., Kim, H.G., Ham, M.J., Kim, W., Kim, G.H., Cho, J.H., Kim, N.I., Kim, K., (2020). A deep neural network for classification of melt-pool images in metal additive manufacturing. *J. Intell. Manuf.* 2020, 31, 375–386 <https://doi.org/10.1007/s10845-018-1451-6>.

Lee, Y., Zhang, W. (2016). Modeling of heat transfer, fluid flow and solidification microstructure of nickel-base superalloy fabricated by laser powder bed fusion. *Additive Manufacturing*, 12, 178–188. <https://doi.org/10.1016/j.addma.2016.05.003>

Levesley, J. (2004). Reviewed works on radial basis functions: theory and implementations by buhmann m. d. mathematics of computation. *American Mathematical Society*, Jul. 2004, Vol. 73, No. 247, pp. 1578- 1581.

- Manjunath, B.N., Vinod, A.R., Abhinav, K., Verma, S.K., Sankar, M.R. (2020). Optimisation of process parameters for deposition of colmonoy using directed energy deposition process. *Mater. Today Proc.*, 2020, 26, 1108–1112. <https://doi.org/10.1016/j.matpr.2020.02.222>.
- Marrey, M., Malekipour, E., El-Mounayri, H., Faierson, E.J. (2019). A framework for optimizing process parameters in powder bed fusion (pbf) process using artificial neural network (ann). *Procedia Manuf.*, 2019, 34, 505–515.
- Mathworks NNA. (2021). <https://www.mathworks.com/help/deeplearning/ug/neural-network-architectures.html> (Eriřim Tarihi: 12.11.2021)
- Mathworks RB. (2021). <https://www.mathworks.com/help/deeplearning/ug/radial-basis-neural-networks.html> (Eriřim Tarihi: 12.11.2021)
- McKay, M.D., Beckman, R.J., Conover, W.J. (1979). A comparison of three methods for selecting values of input variables in the analysis of output from a computer code. *Technometrics*, 21(2): 239-245.
- Meng, L., Zhang, W., Quan, D., Shi, G., Tang, L., Hou, Y., Breitkopf, P., Zhu, J., Gao, T. (2020). From topology optimization design to additive manufacturing: today's success and tomorrow's roadmap. *Arch. Comput. Methods Eng.* 2020, 27, 805–830. <https://doi.org/10.1007/s11831-019-09331-1>.
- Milewski, J.O. (2017). Additive manufacturing of metals: from fundamental technology to rocket nozzles, medical implants, and custom jewelry. *1st ed.; Springer Series in Materials Science*, 258; Springer: Berlin/Heidelberg, Germany.
- Mohamed, S.A.N., Zainudin, E.S., Sapuan, S.M., Deros, M.A.M., Arifin, A.M.T. (2019). Integration of Taguchi-Grey relational analysis technique in parameter process optimization for rice husk composite. *BioResources*, 2019, 14, 1110–1126
- Moller, F. M. (1993). A scaled conjugate gradient algorithm FOR fast supervised learning. *Neural Networks*, Vol. 6, pp. 525-533.
- Myers, R.H., Montgomery, D.C. (1995). Response surface methodology, process and product optimization using designed experiments. *2nd ed. John Wiley and Sons*, New York, NY.
- Nacar, İ. D. (2019). Doğrusal ve doğrusal olmayan metotlarla bir adım ileri rüzgar şiddeti öngörüsü. *Yüksek Lisans Tezi*, Enerji Enstitüsü, İstanbul Teknik Üniversitesi, İstanbul.
- Neikter, M. (2017). Microstructure and texture of additive manufactured Ti-6Al-4V. *Lisans Tezi*, Department of Engineering Sciences and Mathematics, Luleå University of Technology, Sweden.

Olsson, A., Sandberg, G., Dahlblom, O. (2003). On Latin hypercube sampling for structural reliability analysis. *Struct. Saf.* 2003, 25, 47–68. [https://doi.org/10.1016/S0167-4730\(02\)00039-5](https://doi.org/10.1016/S0167-4730(02)00039-5).

Özdemir, M. (2013). Zaman kısıtı altında takım oryantiring problemlerinin yapay arı kolonisi yaklaşımı ile çözümü. *Yüksek Lisans Tezi*, İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, İstanbul.

Özsağlam, M.Y., Çunkaş, M. (2008). Optimizasyon problemlerinin çözümü için parçaçık sürü optimizasyonu algoritması. *Politeknik Dergisi*, Cilt:11 Sayı: 4 s.299-305.

Öztürk, Ç. (2020). Regresyon ve yapay sinir ağları ile fotovoltaik panel yüzey sıcaklığı tahmini. *Yüksek Lisans Tezi*, Enerji Enstitüsü, İstanbul Teknik Üniversitesi, İstanbul.

Panchenko O. V., Zhabrev L. A., Kurushkin D. V., Popovich A. A. (2018). Macrostructure and mechanical properties of al – si, al – mg – si, and al – mg – mn aluminum alloys produced by electric arc additive growth. *Translated from Metallovedenie i Termicheskaya Obrabotka Metallov*, No. 11, pp. 63 – 69, November. DOI 10.1007/s11041-019-00351-z

Pehlivanoglu, Y.V. (2017). Optimizasyon - temel kavramlar & yöntemler https://ae.ieu.edu.tr/documents/optimizasyon_volkan.pdf (Erişim tarihi: 05.01.2022)

Piscopo, G., Iuliano, L. (2022). Current research and industrial application of laser powder directed energy deposition. *Int. J. Adv. Manuf. Technol.*, 119, 6893–6917. <https://doi.org/10.1007/s00170-021-08596-w>.

Preece, R., Milanović, J. V. (2016). Efficient estimation of the probability of small-disturbance instability of large uncertain power systems. *IEEE Transactions on Power Systems*, Vol. 31, No. 2, March 2016

Primo, T., Calabrese, M., Del Prete, A., Anglani, A. (2017). Additive manufacturing integration with topology optimization methodology for innovative product design. *Int. J. Adv. Manuf. Technol.* 2017, 93, 467–479. <https://doi.org/10.1007/s00170-017-0112-9>.

Rahman, A.A., Zhang, X. (2018). Prediction of oscillatory heat transfer coefficient for a thermoacoustic heatexchanger through arti-ficial neural network technique. *Int. J. Heat. Mass Transfer* ,124, 1088 – 1096.

Ramlab. (2021). <https://www.ramlab.com/resources/ded-101/#processes> (Erişim tarihi: 21.11.2021)

Schramm, U., Zhou, M. (2006). Recent developments in the commercial implementation of topology optimization. *IUTAM Symposium on Topological Design Optimization of Structures, Machines and Materials: Status and Perspective*, 239-248.

Segerstark, A. (2017). Laser metal deposition using alloy 718 powder. *Doktora Tezi*, Production Technology, University West, Sweden.

Shah, K. (2011). Laser direct metal deposition of dissimilar and functionally graded alloys. *Doktora Tezi*, Faculty of Engineering and Physical Sciences, Mechanical, Aerospace And Civil Engineering, The University Of Manchester, Manchester, UK.

Sunca, Ş. (2018). Ağırlıklandırılmış myriad filtrelerin genetik, parçacık sürüsü ve yapay arı kolonisi algoritmaları ile optimizasyonu. *Yüksek Lisans Tezi*, Fen Bilimleri Enstitüsü, Erciyes Üniversitesi, Kayseri.

Suryatal, B.K., Sarawade, S.S., Deshmukh, S.P. (2021). Fabrication of medium scale 3D components using stereolithography system for rapid prototyping. *J . King Saud Univ. Eng. Sci.*, <https://doi.org/10.1016/j.jksues.2021.02.012>.

Wahab, D.A., Azman, A.H. (2019). Additive manufacturing for repair and restoration in remanufacturing: an overview from object design and systems perspectives. *Processes*, 2019, 7, 802. <https://doi.org/10.3390/pr7110802>.

Wei, H.L., Mukherjee, T., Zhang, W., Zuback, J.S., Knapp, G.L., De, A., Deb Roy, T. (2021). Mechanistic models for additive manufacturing of metallic components. *Progress in Materials Science, Volume 116*, 100703, ISSN 0079-6425, <https://doi.org/10.1016/j.pmatsci.2020.100703>.

Wilamowski, B., Iplikci, S., Kaynak, O., Efe, M. (2001). An algorithm for fast convergence in training neural networks. *International Joint Conference on Neural Networks. Proceedings (Cat. No.01CH37222)*. doi: 10.1109/ijcnn.2001.938431

Wilke D. N. (2005). Analysis of the particle swarm optimization algorithm. *Master Thesis*, Mechanical and Aeronautical Engineering, University of Pretoria, South Africa.

Xi, W., Song, B., Zhao, Y., Yu, T., Wang, J. (2019). Geometry and dilution rate analysis and prediction of laser cladding. *Int. J. Adv. Manuf. Technol.*, 103, 4695–4702 <https://doi.org/10.1007/s00170-019-03932-7>.

Xiao, N.C., Li, Y.F., Yang, Y., Yu, L., Huang, H.Z. (2014). A novel reliability method for structural systems with truncated random variables. *Structural Safety*, 50: 57-65.

Xinbo Q., Chen, G., Li, Y., Cheng, X., Li, C. (2019). Applying neural-network-based machine learning to additive manufacturing: current applications, challenges, and future perspectives. *Elsevier Eng.* 2019, 5, 721–729.

Xiong, Y., Chen, W., Apley, D., Ding, X. (2007). A non-stationary covariance-based Kriging method for metamodeling in engineering design. *Int. J. Numer. Methods Eng.*, 2007, 71, 733–756.

Yang, Y., Gong, Y., Li, C., Wen, X., Sun, J. (2021). Mechanical performance of 316 L stainless steel by hybrid directed energy deposition and thermal milling process. *J. Mater. Process. Technol.*, 291, 117023. <https://doi.org/10.1016/j.jmatprotec.2020.117023>.

Yıldız A. R. (2006). Tasarım optimizasyon problemlerinin çözümü için çok amaçlı arama tabanlı bir sistemin geliştirilmesi. *Doktora Tezi*, Uludağ Üniversitesi, Fen Bilimleri Enstitüsü, Bursa.

Yıldız B. S. (2016). Otomotiv sektöründe yenilikçi ürün tasarımı için yeni nesil bütünleşik tekniklerin geliştirilmesi. *Doktora Tezi*, Fen Bilimleri Enstitüsü, Bursa Teknik Üniversitesi. Bursa

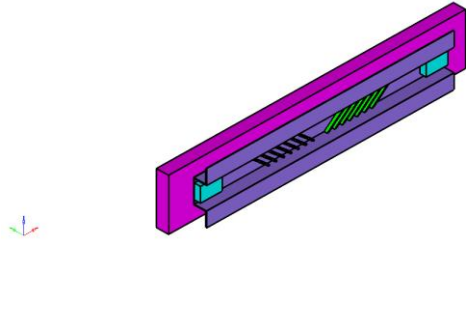
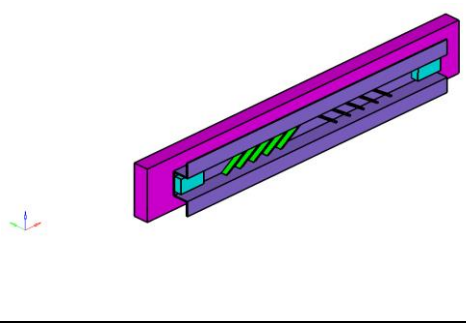
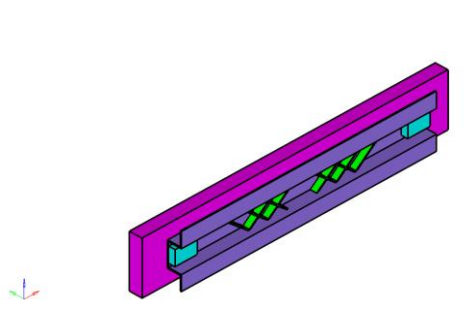
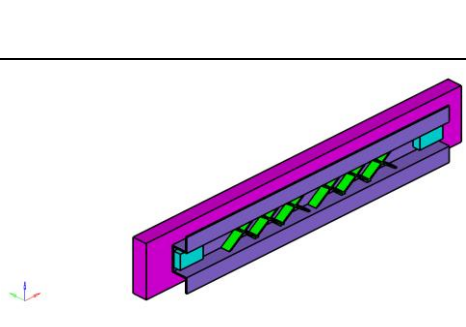
Zhang, Y., Jarosinski, W., Jung, Y.G., Zhang, J. (2018). Additive manufacturing processes and equipment. *In Additive Manufacturing*; Elsevier: Amsterdam, The Netherlands; pp. 39–51. <https://doi.org/10.1016/b978-0-12-812155-9.00002-5>.

Zhongji, S., Xipeng, T., Descoins, M., Mangelinck, D., Tor, S., Lim, C. (2019). Revealing hot tearing mechanism for an additively manufactured high-entropy alloy via selective laser melting. *Scripta Materialia*, 168. 129-133. 10.1016/j.scriptamat.2019.04.036.

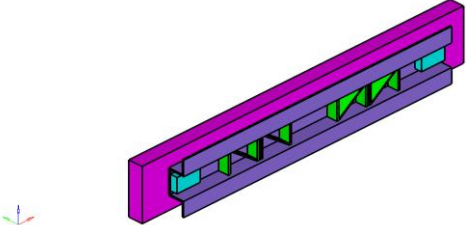
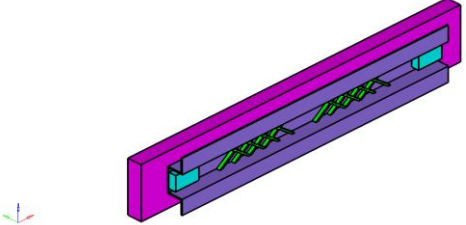
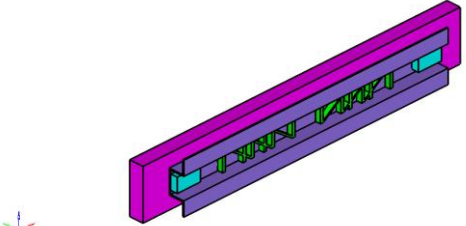
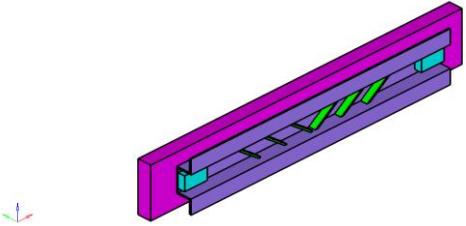
Zhu, Z., Ferreira, K., Anwer, N., Mathieu, L., Guo, K., Qiao, L. (2020). Convolutional neural network for geometric deviation pre-diction in additive manufacturing. *Procedia CIRP*, 2020, 91, 534–539.

EKLER

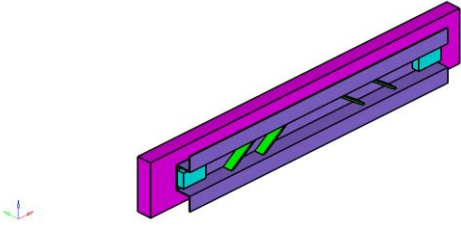
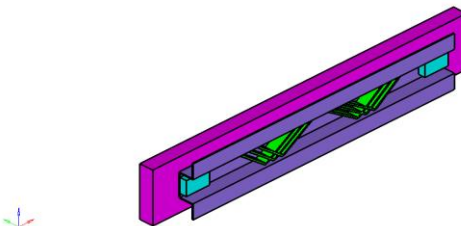
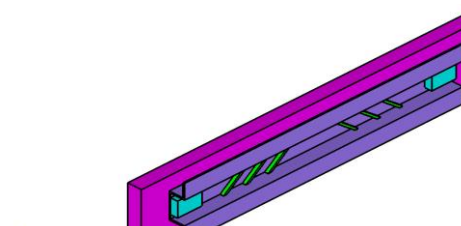
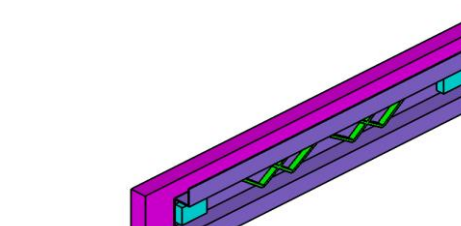
EK 1. Taguchi modelleri

Model Adı	Model Görsele
DBW3_DBH5_DBD9_BMT1.2_PP1_LP 1000	
DBW3_DBH7.5_DBD18_BMT1.4_PP2_ LP1200	
DBW3_DBH10_DBD27_BMT1.6_PP3_ LP1300	
DBW3_DBH12.5_DBD36_BMT1.8_PP4_ _LP1400	

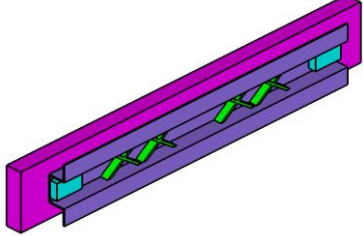
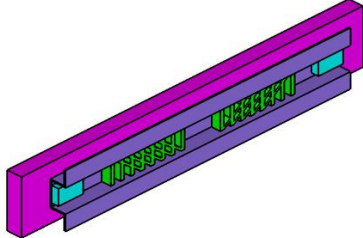
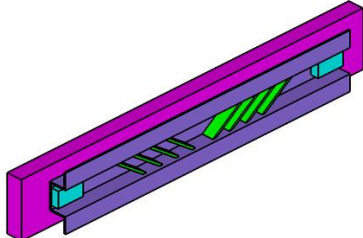
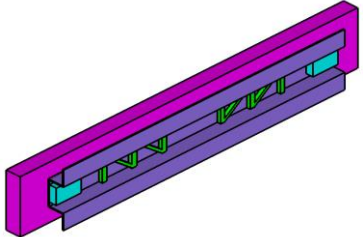
EK 1. Taguchi modelleri (devam)

Model Adı	Model Görseli
DBW3_DBH15_DBD45_BMT2_PP5_L P1500	
DBW4_DBH5_DBD18_BMT1.6_PP4_ LP1500	
DBW4_DBH7.5_DBD27_BMT1.8_PP5_ LP1000	
DBW4_DBH10_DBD36_BMT2_PP1_L P1200	

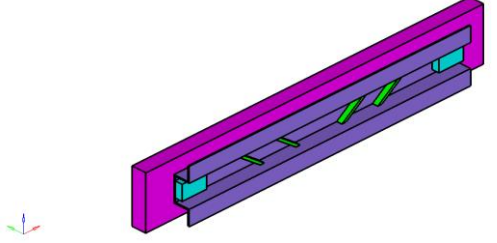
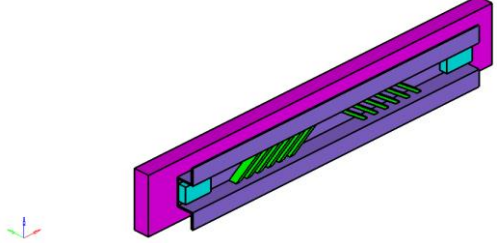
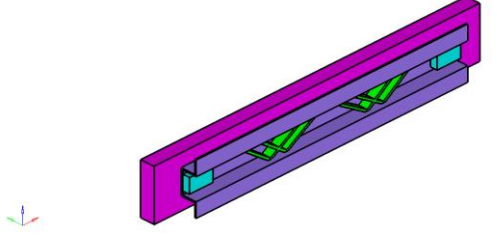
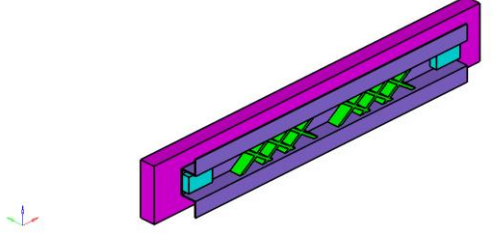
EK 1. Taguchi modelleri (devam)

Model Adı	Model Görseli
DBW4_DBH12.5_DBD45_BMT1.2_PP2_LP1300	
DBW4_DBH15_DBD9_BMT1.4_PP3_LP1400	
DBW5_DBH5_DBD27_BMT2_PP2_LP1400	
DBW5_DBH7.5_DBD36_BMT1.2_PP3_LP1500	

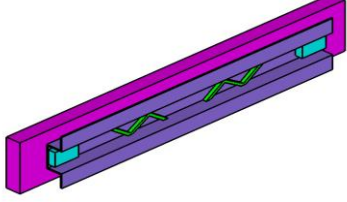
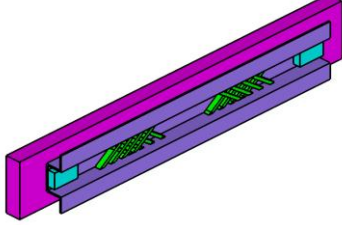
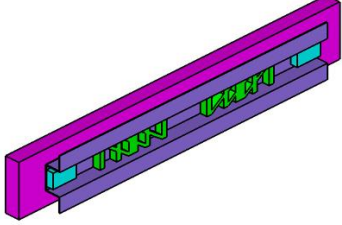
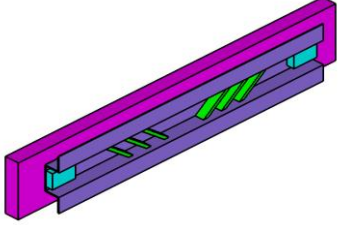
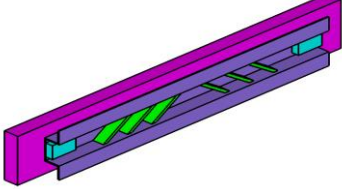
EK 1. Taguchi modelleri (devam)

Model Adı	Model Görsele
DBW5_DBH10_DBD45_BMT1.4_PP4_LP1000	
DBW5_DBH12.5_DBD9_BMT1.6_PP5_LP1200	
DBW5_DBH15_DBD18_BMT1.8_PP1_LP1300	
DBW6_DBH5_DBD36_BMT1.4_PP5_LP1300	

EK 1. Taguchi modelleri (devam)

Model Adı	Model Görseli
DBW6_DBH7.5_DBD45_BMT1.6_PP 1_LP1400	
DBW6_DBH10_DBD9_BMT1.8_PP2 _LP1500	
DBW6_DBH12.5_DBD18_BMT2_PP 3_LP1000	
DBW6_DBH15_DBD27_BMT1.2_PP 4_LP1200	

EK 1. Taguchi modelleri (devam)

Model Adı	Model Görsele
DBW7_DBH5_DBD45_BMT1.8_PP3_LP1200	
DBW7_DBH7.5_DBD9_BMT2_PP4_LP1300	
DBW7_DBH10_DBD18_BMT1.2_PP5_LP1400	
DBW7_DBH12.5_DBD27_BMT1.4_PP1_LP1500	
DBW7_DBH15_DBD36_BMT1.6_PP2_LP1000	

ÖZGEÇMİŞ

Adı Soyadı : Metin ÇALLI

Yabancı Dil : İngilizce, Almanca

Eğitim Durumu

Lisans : Bursa Uludağ Üniversitesi

Yüksek Lisans : İstanbul Teknik Üniversitesi

Çalıştığı Kurum/Kurumlar :Coşkunöz Holding Ar-Ge – 2012-Devam Ediyor (İleri Tasarım ve İmalat Geliştirme Müdürü)
NGN Bilgi İletişim Hizmetleri – 2009-2011 (Bilgi İşlem & Sistem Uzmanı)
Mercedes-Benz Türk A.Ş. – 2007 (Staj)
Aksa Jeneratör – 2006 (Staj)

İletişim (e-posta) : metinçalli@yahoo.com

Doktora Dönemi Yayınlar:

- Prediction and Optimization of the Design and Process Parameters of a Hybrid DED Product Using Artificial Intelligence. Applied Sciences 2022.
- Application Of A Newly Developed Press Hardened Steel For The Automotive Suspension Parts. Materials in Car Body Engineering 2021
- Otomotiv Sektöründe Tel Beslemeli Eklemeli İmalat ile Analiz ve Doğrulama Çalışması. OTEKON 2020
- Effect Of Welding Force And Speed Parameters On Friction Stir Welded Aa6061-T6 Alloy Hardness And Microstructure Properties. IMSTEC 2021
- Thermomechanical Simulation Analysis Of Inconel 718 Alloy Parts Produced By Additive Manufacturing, TICMET 2020
- An Application of Directed Energy Deposition Manufacturing Method on An Automotive Component. IMSTEC 2020
- Failure Behavior Of PA12 Based SLS Lattice Structure with Macro-Porosity. MATEC 2018
- Bölgesel İklim Özelliklerinin Atık Su Çamuru Bertarafında Kullanılan İkincil Yakıt Tüketimine Etkisi, IV. Enerji Verimliliği Kongresi Ekim 2017

- Boron Çeliğinden Üretilmiş Torsiyon Tipi Arka Aks Ara Bağlantı Borusunun Elektrik Direnç Yöntemi İle Isıl İşlemi. XX. ULUSAL MEKANİK KONGRESİ 2017
- Bir Otomotiv Parçasının Ilık Şekillendirme Prosesi ile Magnezyum Sac Malzemedden Üretilmesi. IMSEC 2017
- Otomotivde Sürtünme Karıştırma Punta Kaynağı Uygulamaları ve Sanal Analizleri. IMSEC 2017

Diğer Sunum ve Yayınlar:

- Bir Taşıtın Lastik Zemin İlişkisi ve Yalpa Hareketi - Otekon 2012
- Process Simulation of Tube Stamping on HyperWorks Platform- Altair Technology Conference 2013 Torino/ İTALYA
- Otomotivde Kompozit Malzemedden Üretilmiş Yan Kapı Barının Sayısal Analiz ve Test Çalışmaları - Matit 2013
- Development and Optimization of a Lower Control Arm (LCA) Using High Strength Steels - Altair Technology Conference 2014 Münich/ ALMANYA
- Development of High Performance Front Structure of a Vehicle - Otekon 2014
- Salıncak Kolu Parçasının Yüksek Mukavemetli Saclardan Geliştirilmesi Ve Optimizasyonu- Otekon 2014
- Otomobil Kapı Barı Parçasının Yüksek Mukavemetli malzemelerden Üretimi Ve Test Değerlerinin Karşılaştırılması- OTEKON 2014
- V Formlanmış Arka Aks Bağlantı Borusu Üretim Süreci ve Formlama Analizleri - Otekon 2014
- HyperForm'da Yüksek mukavemetli çelikten üretilmiş bir araç komponentinde formlama çalışması - Altair Teknoloji Konferansı 2014 Bursa
- A Study on DOE of Tubular Rear Axle Twist Beam Using Hyperstudy, Altair Technology Conference 2015 Paris/ FRANSA
- İkizlenme Mekanizmasına Sahip Yüksek Mukavemetli Twip Çelikleri Ve Otomotivde Kullanımlarının Geliştirilmesi, OTOSEM 2015
- Bir Binek Araç İçin Yarı Bağımsız Arka Süspansiyon Geliştirme Ve Doğrulama Çalışması, OTOSEM 2015

Alınan Patentler:

- 2018/01965 Kompozit bileşenleri için bir ısıtma ve güçlendirme prosesi
- 2017/07982 Yüksek Gerilime Karşı Bir Aks Yapılanması
- 2016/20183 Güçlendirilmiş Kompozit Malzeme ve Bu Malzemenin Üretim Yöntemi
- 2015/16700 Bir darbe sönümleyici.
- 2015/16005 Bir salıncak kolu üretim yöntemi.
- 2015/01346 Bir darbe sönümleyici.
- 2015/00916 Bir salıncak kolu üretim yöntemi.
- 2014/04618 Bir enerji sönümleyici.
- 2013/13503 Enerji emilimi arttırılmış bir tampon profili.
- 2012/12005 Askı sacı.