

**YAPAY ZEKA TABANLI OPTİMİZASYON ALGORİTMALARI İLE
AISI 1050 ÇELİĞİNİN YÜZEY PÜRÜZLÜLÜK DEĞERİNİN
HESAPLANMASI**

YÜKSEK LİSANS TEZİ

ERAY MERT TEKİN

**MERSİN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ
ANABİLİM DALI**

**MERSİN
TEMMUZ-2017**

**YAPAY ZEKA TABANLI OPTİMİZASYON ALGORİTMALARI İLE
AISI 1050 ÇELİĞİNİN YÜZEY PÜRÜZLÜLÜK DEĞERİNİN
HESAPLANMASI**

YÜKSEK LİSANS TEZİ

ERAY MERT TEKİN

**MERSİN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

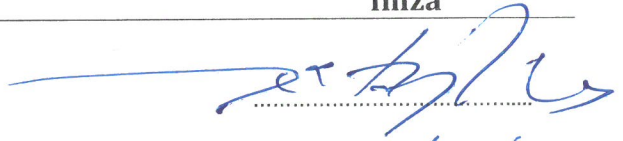


**ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ
ANABİLİM DALI**

**Danışman
Prof. Dr. Ali AKDAĞLI**

**MERSİN
TEMMUZ-2017**

ONAY

Eray Mert TEKİN tarafından Prof. Dr. Ali AKDAĞLI'nın danışmanlığında hazırlanan "Yapay Zeka Tabanlı Optimizasyon Algoritmaları İle AISI 1050 Çeliğinin Yüzey Pürüzlülük Değerinin Hesaplanması" başlıklı çalışma aşağıda imzaları bulunan jüri üyeleri tarafından 20. 07. 2017 tarihinde yapılan Tez Savunma Sınavı sonucunda oy birliği/~~çokluğu~~ ile Yüksek Lisans tezi olarak kabul edilmiştir.

Görevi	Ünvanı, Adı Soyadı	İmza
Başkan	Prof. Dr. Ali AKDAĞLI	
Üye	Prof. Dr. Nurhan KARABOĞA	
Üye	Yrd. Doç. Dr. Berat Barış BULDUM	

Yukarıdaki Jüri kararı Fen Bilimleri Enstitüsü Yönetim Kurulu'nun ...14/...08/2017 tarih ve 2017.31/...1009..... sayılı kararıyla onaylanmıştır.


Prof. Dr. Ayla ÇELİK
Fen Bilimleri Enstitüsü Müdürü

Bu tezde kullanılan özgün bilgiler, şekil, çizelge ve fotoğraflardan kaynak göstermeden alıntı yapmak 5846 sayılı Fikir ve Sanat Eserleri Kanunu hükümlerine tabidir.

ETİK BEYAN

Mersin Üniversitesi Lisansüstü Eğitim-Öğretim Yönetmeliğinde belirtilen kurallara 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 kullandığımı,
- Kullanılan verilerde herhangi bir tahribat yapmadığımı,
- Bu tezin herhangi bir bölümünü Mersin Üniversitesi veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı,
- Tezin tüm telif haklarını Mersin Üniversitesi'ne devrettiğimi,

beyan ederim.

ETHICAL DECLARATION

This thesis is prepared in accordance with the rules specified in Mersin University Graduate Education Regulation and I declare to comply with the following conditions:

- I have obtained all the information and the documents of thesis in accordance the academic rules,
- I presented all visual, auditory and written informations and results in accordance with scientific ethics.
- I refer in accordance with the norms of scientific works about the case of exploitation of others' works.
- I used all of the referred works as the references.
- I did not do any tampering in used data.
- I did not present any part of this thesis as an another thesis at Mersin University or another university.

I transfer all copyrights of this thesis to Mersin University

20 Temmuz 2017/20 July 2017

İmza/Signature


Eray Mert TEKİN

ÖZET

YAPAY ZEKA TABANLI OPTİMİZASYON ALGORİTMALARI İLE AISI 1050 ÇELİĞİNİN YÜZEY PÜRÜZLÜLÜK DEĞERİNİN HESAPLANMASI

Endüstride önemli bir malzeme olan çelik kolayca üretilip şekillendirilebilmektedir. Bunun yanında mekanik özellikleri de dikkate alındığında imalat sektöründe oldukça yaygın kullanılmaktadır. Çelik imalatında yüzey pürüzlülüğü önemli bir faktördür ve yüzey pürüzlülüğünü etkileyen birçok parametre vardır. Bu çalışmada, AISI 1050 çeliğinin yüzey pürüzlülüğünün hesaplanmasında yakın zamanda yapay zekâ optimizasyon algoritması olarak geliştirilen yapay arı koloni algoritması kullanılarak elde edilen yeni ve basit bir matematiksel ifade sunulmuştur. Bu ifadenin yanında yapay sinir ağları kullanılarak geliştirilen bir model de önerilmiştir. Bir CNC işleme merkezi yardımıyla kesme hızı, ilerleme hızı ve kesme derinliği gibi kesme parametrelerinden oluşan deney verileri kullanarak matematiksel ifade ve model geliştirilmiştir. Matematiksel ifade ortaya çıkarılırken birçok formülasyon denenmiştir. Denemelerin sonucunda ifadenin basit olmasının yanında kabul edilebilecek hatayla hesaplanabilmesi sebebiyle sunulmuş olan ifade de karar kılınmıştır. Bu ifadenin bilinmeyen katsayıları optimum bir şekilde belirlenirken çoğu probleme başarılı çözümler sunan yapay arı koloni algoritması kullanılmıştır. Geliştirilen formülden elde edilen sonuçlar daha önce literatürde bildirilen yöntem ile karşılaştırılmıştır. Yapay arı kolonisi ile önerilen ifade %2,95 ortalama hata oranı ile yüzey pürüzlülüğünü hesaplamaktadır ve literatürdeki ifadeyle kıyaslandığında daha uyumlu olduğu gözlemlenmiştir. Ayrıca kesme parametrelerinin AISI 1050 çeliğinin yüzey pürüzlülüğü üzerindeki bireysel etkilerini değerlendirmek adına bir parametrik çalışma gerçekleştirilmiştir. Bu parametrik çalışmanın sonuç verileri tablo ve şekil olarak gösterilmiştir. Bunlara ek olarak kesme parametrelerine bağlı olarak AISI 1050 çeliğinin yüzey pürüzlülüğünün tahminini gerçekleştiren yapay sinir ağı modeli sunulmaktadır. Yapay sinir ağının eğitimi aynı deneysel veriler yardımıyla Levenberg-Marquardt algoritması kullanılarak gerçekleştirilmiştir. Ağ ortalama %3,10 hata ile yüzey pürüzlülüğü tahmininde bulunmuştur. Son olarak çeşitli algoritmalar ile yapay sinir ağı modelleri oluşturulmuştur ve bunların yüzey pürüzlülüğü tahminindeki başarı yüzdelerinin karşılaştırması tablo ve şekillerle sunulmuştur.

Anahtar Kelimeler: AISI 1050 çeliği, yüzey pürüzlülüğü, yapay arı kolonisi, yapay sinir ağı, modelleme, optimizasyon

Danışman: Prof. Dr. Ali AKDAĞLI, Mersin Üniversitesi, Elektrik-Elektronik Mühendisliği Ana Bilim Dalı

ABSTRACT

CALCULATION OF SURFACE ROUGHNESS VALUE OF AISI 1050 STEEL WITH OPTIMIZATION ALGORITHMS BASED ARTIFICIAL INTELLIGENCE

The steel which is an important material of the industry can be easily produced and shaped. In addition, considering its mechanical properties, it is widely used in the manufacturing sector. Surface roughness is an important factor in steel manufacture and there are many parameters that affect surface roughness. In this study, a new and simple formulation achieved using the artificial bee colony (ABC) that recently developed as an artificial intelligence optimization algorithm has been proposed in computing the surface roughness of the AISI 1050 steel. In addition to, it is proposed in a model developed using artificial neural networks. Experiment data consisting of the various cutting parameters with the help of a CNC machining namely the cutting speed, rate of feed and depth of cut center were performed in terms of the surface roughness. Various formulations have been tried while finding mathematical expression. As a consequence of the experiments, the expression presented was decided because it was simple and it could be calculated with an acceptable error. The unknown coefficients belonging to the formulation were optimally calculated by using ABC algorithm. The results obtained from the developed formula were compared with the method previously reported in the literature. The proposed formula with the ABC has calculated the surface roughness with an average error rate of %2,95 and has observed to be more compatible when compared with the expression in the literature. After that parametric study was carried out to evaluate the individual effects of the cutting parameters on the surface roughness of the AISI 1050 steel. The results of this parametric study are shown in tables and figures. Furthermore, it is presented an artificial neural network model that estimates the surface roughness of the AISI 1050 steel depending on the cutting parameters. The artificial neural network was used to train using the Levenberg-Marquardt algorithm with the same experimental data. The network has estimated surface roughness with an average error of %3,10. Finally, artificial neural network models have created with various algorithms and their surface roughness estimates have presented in comparative tables and figures of percentage success.

Key Words: AISI 1050 steel, surface roughness, artificial bee colony, artificial neural network, modeling, optimization

Advisor: Prof. Dr. Ali AKDAĞLI, Department of Electrical-Electronics Engineering, University of Mersin

TEŞEKKÜR

“Yapay Zeka Tabanlı Optimizasyon Algoritmaları İle AISI 1050 Çeliğinin Yüzey Pürüzlülük Değerinin Hesaplanması” başlıklı yüksek lisans tez çalışmasının planlanmasında ve yürütülmesinde desteğini esirgemeyen, ilminden ve akademik tecrübesinden yararlandığım, bilimsel katkıları ile bana yön veren ve yardımcı olan, insani değerleri ile de örnek aldığım, birlikte çalışmaktan onur duyduğum çok değerli danışmanım sayın Prof. Dr. Ali AKDAĞLI'ya teşekkürlerimi ve saygılarımı sunarım.

Gerçekleştirmiş olduğum çalışmalarda verdiği destek ve gösterdiği ilgiden dolayı değerli Öğretim Görevlisi Dr. Deniz ÜSTÜN'e ve yapmış olduğu katkılardan dolayı sayın Yrd. Doç. Dr. Barış BULDUM'a teşekkürlerimi ve saygılarımı sunarım.

Bu süreçte verdiği yardım ve desteklerden dolayı değerli Tayfun KÜTÜK'e ve Çağdaş YILMAZ'a da teşekkürlerimi sunarım.

Hayatımın her anında yanımda olan, bugünlere gelmemde en büyük pay sahipleri, annem Ayşe TEKİN'e, babam Erdal TEKİN'e ve kardeşim Melis TEKİN'e sonsuz teşekkür eder, sevgi ve saygılarımı sunarım.

İÇİNDEKİLER

	Sayfa
İÇ KAPAK	i
ONAY	ii
ETİK BEYAN	iii
ÖZET	iv
ABSTRACT	v
TEŞEKKÜR	vi
İÇİNDEKİLER	vii
TABLO DİZİNİ	ix
ŞEKİLLER DİZİNİ	x
KISALTMALAR ve SİMGELER	xi
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMALARI	3
2.1. Çelikler	6
2.2. AISI Standardizasyonu	6
2.3. Az Alaşımli Çelikler	7
2.3.1. Düşük Karbonlu Çelikler	8
2.3.2. Orta Karbonlu Çelikler	8
2.3.3. Yüksek Karbonlu Çelikler	8
2.4. AISI 1050 Çeliği	8
2.5. Yüzey Kalitesi	9
2.6. Yüzey Pürüzlülüğü	9
2.6.1. Yüzey Pürüzlülüğünü Etkileyen Faktörler	10
2.7. Optimizasyon ve Yapay Zekaya Dayalı Optimizasyon Algoritmaları	11
2.7.1. Optimizasyon Kavramı	11
2.7.1.1. Yapay Arı Kolonisi Algoritması	12
2.7.1.1.1. Başlangıç Yiyecek Kaynaklarına ait Bölgelerin Üretilmesi	13
2.7.1.1.2. Görevli Arıların Yiyecek Kaynağı Bölgelerine Yönlendirilmesi	13
2.7.1.1.3. Gözcü Arılar için Olasılık Değerlerinin Hesaplanması	15
2.7.1.1.4. Gözcü Arılar için Yiyecek Kaynağı Bölgesinin Seçimi	15
2.7.1.1.5. Kâşif Arı Üretimi Ve Tükenmiş Kaynağın Terkedilmesi	16
2.7.1.2. ABC Algoritmasının Adımları	16
2.8. Yapay Sinir Ağları	19
2.8.1. Yapay Sinir Ağının Tarihçesi	20
2.8.2. Yapay Sinir Ağının Uygulama Alanları	21
2.8.2. Yapay Sinir Ağının Yapısı	22
2.8.2.1. Girişler	23
2.8.2.2. Ağırlıklar	23
2.8.2.3. Toplama Fonksiyonu	23
2.8.2.4. Aktivasyon Fonksiyonu	23
2.8.2.5. Çıkışlar	24
2.8.3. Yapay Sinir Ağında Öğrenme	24
2.8.3.1. Danışmanlı Öğrenme	25
2.8.3.2. Danışmansız Öğrenme	25
2.8.4. Levenberg-Marquardt Algoritması	25
3. MATERYAL ve YÖNTEM	28
3.1. AISI 1050 Çeliğinin Yüzey Pürüzlülüğü İfadesinin ABC Algoritmasıyla Türetilmesi	28
3.2. AISI 1050 Çeliğinin Yüzey Pürüzlülüğünü Tahmin Etmek İçin YSA Modelinin Oluşturulması	31
4. BULGULAR ve TARTIŞMA	34

4.1. AISI 1050 Çeliğinin Yüzey Pürüzlülüğü İçin ABC Algoritmasıyla Türetilen İfadenin Bulguları	34
4.2 AISI 1050 Çeliğinin Yüzey Pürüzlülüğünü Tahmin Etmek İçin YSA Modelinden Elde Edilen Bulgular	39
5. SONUÇLAR ve ÖNERİLER	45
KAYNAKLAR	46
ÖZGEÇMİŞ ve ESERLER	50



TABLULAR DİZİNİ

	Sayfa
Tablo 2.1. AISI 1050 çeliğindeki bulunan alaşım elementleri.	8
Tablo 2.2. Standartlaştırılmış sınıf numaraları ve pürüzlülük değerleri.	10
Tablo 3.1. AISI 1050'nin yüzey pürüzlülüğü deneyinin sonuçları.	29
Tablo 3.2. Deneyde kullanılan üç ana parametrenin değer aralıkları.	29
Tablo 3.3. AISI 1050 çeliğinin kimyasal ve mekanik özellikleri.	29
Tablo 3.4. Bu çalışmada kullanılan ABC algoritmasının optimizasyon parametreleri.	30
Tablo 3.5. ABC algoritması ile belirlenen AISI 1050 çeliğinin yüzey pürüzlülüğü ifadesi için katsayı değerleri.	30
Tablo 3.6. Oluşturulan YSA modelinin parametreleri.	33
Tablo 4.1. Eşitlik (3.6) ile bulunan yüzey pürüzlülüğünün karşılaştırmalı sonuçları.	34
Tablo 4.2. Kesme hızının yüzey pürüzlülüğü üzerindeki etkisinin parametrik çalışması.	36
Tablo 4.3. Kesme derinliğinin yüzey pürüzlülüğü üzerindeki etkisinin parametrik çalışması.	37
Tablo 4.4. İlerleme hızının yüzey pürüzlülüğü üzerindeki etkisinin parametrik çalışması.	38
Tablo 4.5. YSA ile tahmin edilen yüzey pürüzlülüğünün deney sonuçları ile karşılaştırması.	39
Tablo 4.6. Çeşitli eğitim algoritmaları ile eğitilen modellerin parametreleri.	41
Tablo 4.7. Çeşitli eğitim algoritmaları ile eğitilen modellerin en düşük tohum değerleri.	41
Tablo 4.8. Çeşitli eğitim algoritmaları ile eğitilen modellerin deneysel veriler için tahmin edilen yüzey pürüzlülük değeri ve hesaplanan OYH'ları.	41
Tablo 4.9. Çeşitli eğitim algoritmaları ile eğitilen modellerin 3 adet test verisi ile tahmin edilen yüzey pürüzlülük değeri ve hesaplanan OYH'ları.	42
Tablo 4.10. AISI 1050 çeliğinin yüzey pürüzlülük değerini hesaplama ve tahmin etme çalışmalarının karşılaştırılması.	44

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 2.1. Yapay zekaya tabanlı optimizasyon teknikleri.	12
Şekil 2.2. ABC algoritmasının genel akış şeması.	17
Şekil 2.3. Yapay sinir ağı modeli.	20
Şekil 2.4. Yapay nöronun detaylandırılmış yapısı.	22
Şekil 2.5. Aktivasyon fonksiyonlarının bazıları.	24
Şekil 3.1. ÇKA'nın yapısı.	31
Şekil 3.2. Tasarlanan YSA modelinin katmanlarının yapısı.	32
Şekil 4.1. Hesaplanan ve deneysel yüzey pürüzlülüğü değerleri.	35
Şekil 4.2. Hesaplanan ve deneysel yüzey pürüzlülüğü değerleri arasındaki ilişki.	35
Şekil 4.3. Kesme hızı ile yüzey pürüzlülüğü arasındaki ilişki.	36
Şekil 4.4. Kesme derinliği ile yüzey pürüzlülüğü arasındaki ilişki.	37
Şekil 4.5. İlerleme hızı ile yüzey pürüzlülüğü arasındaki ilişki.	38
Şekil 4.6. YSA ile tahmin edilen yüzey pürüzlülüğünün deney sonuçları ile karşılaştırması.	40
Şekil 4.7. Çeşitli eğitim algoritmaları ile eğitilen modellerin deneysel verilerinin eğitim ve test değerlerinin grafiksel karşılaştırılması.	43

KISALTMALAR ve SİMGELER

Kısaltma / Simge	Tanım
AB	Ateş Böceği
ABC	Yapay Arı Kolonisi
AEEME	Amerikan Elektrik Elektronik Mühendisliği Enstitüsü
AISI	American Iron Steel Institute
AI	Artificial Intelligence
ANN	Artificial Neural Network
ANOVA	Analysis Of Variance
CCD	Central Composite Design
CNC	Computer Numeric Control
ÇKA	Çok Katmanlı Algılayıcı
DEA	Diferansiyel Evrim Algoritması
DE	Differential Evolution
DoE	Design of Experiments
FG	Farksal Gelişim
GA	Genetik Algoritma
GRA	Grey Relational Analysis
HSS	High Speed Steel
ISRR	In-Process Surface Roughness Recognition
KK	Karınca Kolonisi
MDE	Modified Differential Evolution Algorithm
MRR	Material Removal Rate
OYH	Ortalama Yüzde Hatası
PSO	Parçacık Sürü Optimizasyonu
Ra	Yüzey Pürüzlülüğü
RaE	DeneySEL Yüzey Pürüzlülüğü
RBF	Radial Base Function
SAE	Society of Automotive Engineers
TYM	Tepki Yüzey Metodolojisi
YZO	Yapay Zeka Optimizasyon

1. GİRİŞ

Çelik, imalat endüstride önemli bir malzemedir. Kolayca üretilip şekillendirilebilmesinin yanında mekanik özellikleri de dikkate alındığından imalat sektöründe oldukça yaygın bir şekilde kullanılmaktadır [1]. İmalat sektörü geçmişten günümüze çok yol kat ederek hızlı bir şekilde gelişmiştir ve hala üzerine koyarak yenilenmeye devam etmektedir. Endüstriyel üretimdeki talep ile rekabet, hızlı üretimi ve düşük maliyetin gerekliliğini ortaya çıkarmıştır. İmalatı gerçekleştirilecek üründe ilk aşama bu malzemenin tasarımıdır. Ardından hangi üretim metodunun uygulanacağı belirlenir ve kalite kontrol basamağında üretim süreci biter. Bu aşamaların içinde talaş kaldırma uygulaması imalat sanayinin merkezi olarak görülebilir. Bunun nedeni talaş kaldırma uygulaması endüstriyel işlemlerin yanında bilimsel çalışmalara konu olmuş üzerinde birçok araştırma yapılmıştır [2]. Endüstriyel üretimdeki rekabetçi ortamdan dolayı imalatın sürekli daha iyi seviyelere çıkması beklenmiştir. Bu sebepten endüstriyel üretimdeki gelişmeler hız kazanmıştır ve imalat yöntemlerinde klasik metotlardan modern metotlara geçilmiştir. Fakat imalatta modernleşme sürecine girilmiş olsa dahi önemini yitirmeyen birkaç klasik metot vardır. Bu metotların içerisinde en yaygını olan tornalama metodu talaşlı üretim devam ettiği müddetçe varlığını sürdürecektir [2]. Tornalama metodu sayesinde işlenecek malzemeye geometrik ve boyutsal nitelikler kazandırılmaktadır. Çoğu üretim alanında olduğu gibi talaş kaldırma işleminde de verimlilik önemli bir konudur. Hem üretici hem de tüketici için düşük maliyet ve yüksek performans aranan kriterlerin başında gelmektedir. Bunların yanında kaliteyi etkileyen unsurların biriside iyi bir yüzey pürüzlülüğüdür. En iyi hedefe ulaşma isteği olan optimizasyonla burada karşılaşırız. Optimizasyon sayesinde pahalı malzemelerdeki masraf optimum seviyelere çekilmiş olur.

Çelikler bileşimine bağlı olarak %0,2 ile %2,1 oranında karbon içermektedir ve içerisinde bulunan karbon miktarına göre mekanik ve fiziksel özellikleri değişim göstermektedir. Bileşimindeki karbon miktarına göre sınıflandırıldığında içerisinde %0,2 ile %0,6 karbon bulunan orta karbonlu çelikler ekonomik açıdan değerlidir. Bundan dolayı gelişmekte olan teknoloji ile bilimsel metotlar tercih edilerek üretilmesi arzu edilen bir durumdur. Orta karbonlu çeliklerin optimize edilerek üretilmesi onu rakiplerine göre daha avantajlı bir konuma getirmektedir.

Bu çalışmada, literatürde bulunan [3] çalışmasındaki AISI 1050 orta karbonlu çeliğinin yüzey pürüzlülüğü ile ilgili deneysel verileri kullanılmıştır. AISI 1050 orta karbonlu çelik malzeme için yüzey pürüzlülük değerinin hesaplanmasında yapay arı koloni (ABC-Artificial Bee Colony) algoritması kullanılarak en iyi sonucu verecek matematiksel ifade elde edilmiştir. Bu ifade ise kesme hızı, besleme hızı ve kesme derinliği gibi kesme parametrelerine dayalı olarak

geliştirilmiştir. ABC algoritması literatüre bakıldığında birçok farklı problem için uygulanmış ve yüksek başarıyla problemlerin üstesinden gelmiştir. Bu sebeple matematiksel ifadeyi türetmek için ABC algoritması kullanılmıştır. Ayrıca kullanılan bu veriler ile bir yapay sinir ağı (YSA/ANN-Artificial Neural Network) modeli önerilip çeşitli öğrenme algoritmalar ile modellenip karşılaştırmaları yapılmıştır.



2. KAYNAK ARAŞTIRMALARI

Orta karbonlu çelikler, ısı işlemlerine duyarlı oldukları için üretim endüstrisinde yaygın olarak kullanılan alaşım çeliklerinden biridir. Ayrıca, orta karbonlu çeliklerin mukavemetleri düşük karbonlu çeliklerin mukavemetinden daha iyidir ve orta karbonlu çeliklerin sünekliği, düşük karbonlu çeliklerin yakınındadır. Bu avantajlardan dolayı orta karbonlu çelikler imalat sanayisinde tercih edilebilir [4].

Esmeye ve arkadaşlarının çalışmasında, diferansiyel evrim algoritması (DEA) da dahil olmak üzere regresyon analizine dayanan CNC cep frezeleme işlemi için bir optimizasyon stratejisi bulmayı amaçlamışlardır. Kesme hızı, ilerleme hızı ve kesme derinliği gibi frezeleme parametreleri, dönel merkezi kompozit tasarım (CCD) kullanılarak tasarlamışlardır. AISI 1050 orta karbonlu çelik, hava akışı koşullarında zikzak kesme yolu stratejisini kullanarak 8 mm çaplı yüksek hızlı çelik (HSS) düz uçlu kesici aletle işlenmiştir. Frezeleme parametrelerinin etkisini incelemişlerdir. Frezeleme parametrelerinin bir fonksiyonu olarak yüzey pürüzlülüğü için model, tepki yüzey metodolojisini (TYM) kullanılarak elde etmişlerdir. Ayrıca, kuadratik matematiksel modelin gücünü ve yeterliliğini, ANOVA yöntemiyle kanıtlamışlardır. Son olarak, tasarım parametreleri, diferansiyel evrim algoritması (DEA-Differential Evolution Algorithm) olarak adlandırılan, optimizasyon algoritması kullanılarak yüzey pürüzlülüğünü optimize etmişlerdir [3].

Routara ve arkadaşlarının çalışmasında EN-8 çeliğinin CNC tornalama işleminde minimum yüzey pürüzlülüğünü sağlayan optimum kesme koşullarını belirlemek için tepki yüzeyi metodolojisi uygulanmıştır. İşlem parametreleri açısından ikinci dereceden matematik modeller ve yüzey pürüzlülüğü tahmini için TYM'nin deneysel sonuçlarını kullanmışlardır. Deneyi, EN-8 çeliğinin işlenmesi için kaplanmış karbür aracı ile gerçekleştirmişlerdir. Modellerin yüzey pürüzlülüğü üzerindeki yeterliliği, ANOVA ile oluşturulmuştur. Optimal kesme parametrelerini bulmak için Genetik Algoritma (GA-Genetic Algorithm) kullanılarak yüzey pürüzlülüğü tahmin modelini optimize etmek için bir girişim yapılmıştır [5].

Buldum ve arkadaşlarının çalışmasında, GRA ve Taguchi yönteminin kombinasyonunu kullanarak maksimum MRR ile minimum kesme kuvveti ve yüzey pürüzlülüğünü araştırmışlardır. Deneysel etki alanı içinde optimize edilecek amaç fonksiyonları elde etmek için ortogonal Taguchi metoduna dayalı dokuz deney gerçekleştirmişlerdir. Amaç fonksiyonlarını, kesme kuvveti, MRR ve yüzey pürüzlülüğü gibi kesme sürecinin parametreleri ile ilişkili olarak seçmişlerdir. Kesim sürecinin kalite özellikleri üzerine etki eden faktörlerin önemini ANOVA ile nicel olarak değerlendirmişlerdir. Optimum sonuçlar, ilave deneyler yapılarak doğrulanmıştır. Bu

şekilde daha iyi yüzey pürüzlülüğü ve düşük kesme kuvveti ile kesme parametrelerinin doğru seçildiğini göstermişlerdir [6].

Fabricio ve arkadaşlarının çalışmasında sertleştirilmiş SAE 52100 çeliğinin tornalama işleminde pürüzlülük oranının tahmininde RBF'nin sinir ağları ile uygulanabilirliğini ortaya koymuşlardır ve ağ parametrelerini tasarlamak için Taguchi'nin ortogonal dizilerini kullanmışlardır. Deneyleri, her deneyden elde edilen en iyi ağın performansını karşılaştırmak için farklı boyutlarda eğitim setleri ile gerçekleştirmişlerdir. Bazı tasarım faktörlerini göz önüne almışlardır. Bunlar, radyal birim sayısı, radyal merkezlerin seçimi için algoritma ve radyal fonksiyonun yayılma faktörünün seçimi için algoritma olmuştur. Elde edilen yapay sinir ağı modelleri ile yüzey pürüzlülüğünü doğru, hassas ve uygun fiyatlı bir şekilde tahmin edebilme kabiliyetine sahip olduklarını göstermişlerdir. Bulguları sonucunda, ağ tasarımı için kritik olan faktörlerin, önerilen görev için ağ performansı üzerinde önemli etkisi olduğunu göstermişlerdir. Sundukları bu çalışmada, deneylerin tasarımı metodolojisinin, en yaygın olan deneme yanılma yaklaşımına göre daha iyi pürüzlülük tahmini için RBF ağlarının tasarımıyla daha iyi bir yaklaşım oluşturmuşlardır [7].

Benardos ve Vosniakos'a göre genel üretim problemi, verilen ekipman, maliyet ve zaman kısıtlamaları ile önceden tanımlanmış bir ürün kalitesinin elde edilmesi olarak tanımlanabilir ve bir ürünün yüzey pürüzlülüğü gibi bazı kalite özellikleri için bu gereksinimlerin karşılanmasını sağlamak zordur. Bernardos ve Vosniakos, yüzey pürüzlülüğünün tahmini için kullanılan çeşitli metotları ve uygulamaları sunmuşlardır. Çalışmalarının sonucunda elde edilen faydalar, üretim sürecinin daha üretken ve rekabetçi hale gelmesine ve aynı zamanda, işlenen iş parçasının yeniden işlenmesinin azalmasına olanak sağlamışlardır. Avantaj ve dezavantajlarıyla her yaklaşımı özetlemişlerdir. Bu yaklaşımları, işleme teorisine, deneysel araştırmaya, tasarlanmış deneylere ve yapay zekaya (AI) dayalı olarak sınıflandırmışlardır [8].

Özel ve Karpat, çeşitli kesme koşulları için işleme süresince yüzey pürüzlülüğü ve takım kenarı aşınmasını tahmin etmek için sinir ağı modellemesini kullanmışlardır. Regresyon modellerini, aynı zamanda sürece özgü parametreleri elde etmek için geliştirmişlerdir. Literatürden elde edilen sertleştirilmiş AISI 52100 çeliğinin tornalamış deney verileri ve sertleştirilen AISI H-13 çeliği ile gerçekleştirilen deneylerden elde edilen deney verilerini kullanmışlardır. Ölçülen yüzey pürüzlülüğü ve takım kenarı aşınması verilerini, sinir ağı modellerini eğitmek için kullanmışlardır. Diğer kesme koşulları için yüzey pürüzlülüğü ve takım kenarı aşınmasının tahmininde eğitilmiş sinir ağı modellerinden yararlanmış ve bu sinir ağı modellerinin regresyon modelleri ile karşılaştırılmasını da yapmışlardır. Tahmin edici sinir ağı modellerinin, eğitildikleri aralıkta yüzey pürüzlülüğü ve takım kenarı aşınması için daha iyi tahminlerde bulabileceğini de söylemişlerdir. Tahmini sinir ağı modellemesini, sert torna

işlemlerinde görülen takım aşınmasını ve yüzey pürüzlülüğünü tahmin etmek için genişletmişlerdir. Besleme hızını azaltarak daha iyi yüzey pürüzlülüğünü sağlamışlardır fakat bu azalış ile iş parçasının aşınmasını biraz hızlandırmışlardır. Kesme hızının arttırmaları iş parçasının aşınmasında belirgin bir artışa neden olmuş, ancak daha iyi yüzey pürüzlülüğünü elde etmişlerdir. İş parçasının sertliğini arttırarak, daha iyi yüzey pürüzlülüğünü sağlamışlardır ancak iş parçasının aşınmasını hızlandırmışlardır. Genel olarak, honlanmış kenar geometrisine sahip CNB uçları ile hem yüzey pürüzlülüğünü hem aşınma bakımından daha iyi sonuçlar almışlardır [9].

Franco ve arkadaşlarına göre işlenmiş parçanın yüzey kalitesi birçok faktöre bağlıdır. Bu faktörlerin bir fonksiyonu olarak yüzey profili ve yüzey pürüzlülüğünü tahmin etmek için bir sayısal model sunmuşlardır. Çalışmalarında radyal, aksel deformasyonlar gibi alet hatalarının ve yuvarlak kesme aletlerinin etkisi üzerine odaklanmışlardır. 4 diş sayısı, 12 mm'lik çap 0,5 mm'lik kesme derinliği, 120 m/dak'lık kesme hızı ve 0,4-1,4 mm/devir'lik besleme ile ilgili sonuçları analiz etmişlerdir. Modellerinin geçerliliğini doğrulamak için freze deneyleri yapmışlardır. Deneysel ve teorik yüzey profilleri arasındaki tutarsızlıkların, yüzey profili boyunca deforme olmamış talaş kalınlığının değişimi gibi farklı faktörlerin bir sonucu olduğu varsaymışlardır [10].

Lou ve Chen, yüzey frezeleme sistemleri için, uç frezeleme işlemi gerçekleşirken kesme koşulları altında titreşim sinyallerinin ölçülmesi için ivme ölçer kullanmışlar işlem sırasında yüzey pürüzlülüğünün (Ra) önceden tahmin edilmesine yönelik yeni bir yaklaşımı açıklamışlardır. Verilerin analizinde ve model oluşturmada, sinirsel bulanık sistem kullanarak gerçekleştirmişlerdir. Deneyin sonucunda, mil hızı, ilerleme hızı, kesme derinliği ve titreşim değişkenleri sayesinde yüzey pürüzlülüğünü (Ra) etkili bir şekilde tahmin edebildiğini görmüşlerdir. Yüzey pürüzlülüğünü, sinirsel bulanık sistem kullanarak ISRR tarafından %96 doğruluk oranı ile de tahmin edilebileceğini öne sürmüşlerdir [11].

Benardos ve Vosniakos, CNC yüzey frezelemede yüzey pürüzlülüğünün (Ra) öngörülmesi için bir sinir ağı modelleme yaklaşımı sunmuşlardır. Ağların performansını kontrol etmek ve denetlemek için kullanılan verileri, CNC freze tezgahında yapılan deneylerden türetmişlerdir. Deneyde, kesme derinliği, diş başına besleme hızı, kesme hızı, kesici takımın aşınması, kesme sıvısının kullanımı ve kesme kuvvetinin üç bileşeni gibi faktörleri dikkate almışlardır. Levenberg-Marquardt algoritması ile eğitilmiş ileri beslemeli yapay sinir ağlarını (YSA) kullanmışlardır. Faktörlerin en etkili olanını DoE ilkelerini kullanılarak belirlemişlerdir. 5 × 3 × 1 ANN'ye dayanan, yüzey pürüzlülüğünün karesel hata ortalaması %1,86 olarak tahmin etmişlerdir [12].

Zou ve arkadaşlarının sunduğu çalışmada, sınırlandırılmamış optimizasyon problemlerini çözmek için modifiye diferansiyel evrim algoritmasını (MDE) önermişlerdir. Zou ve arkadaşlarına göre gauss dağılımı ve tekdüzensel dağılımda ortak bir nokta vardır, bu rasgelelik veya belirsizliktir. Bu özellikten dolayı MDE, ölçek faktörünü ve çaprazlama oranını ayarlamak için her iki dağılımı da kullanır ve bu da tüm popülasyonun çeşitliliğini arttırmaktadır. Sürüdeki kaliteyi garanti altına almak için MDE dışında bir arşiv kullanılmıştır ve bu harici arşivde yüksek kalitede bazı çözümler aday çözümler için seçilebilecektir. MDE, yeni çözümler üretmek için iki ortak mutasyon stratejisi benimser ve küresel en iyi çözümün evrim süreci boyunca mutasyon için kullanılmasını önermektedir. Bu, önerilen algoritmanın yakınsamasını iyileştirmek için yararlıdır. Ek olarak, tüm diğer aday çözümler açısından merkezi bir çözüm oluşturmuşlardır. Deneysel sonuçlar, MDE algoritmasının bazı sınırlandırılmamış optimizasyon problemleri için diğer DE algoritmalarından daha iyi amaç fonksiyonu değerlerini verebildiğini ve böylece sınırlandırılmamış optimizasyon problemlerinin çözümünde etkin bir alternatif olduğunu göstermişlerdir [13].

2.1. Çelikler

Çelik dünyadaki en çok kullanılan malzemelerden biri olup sert, güçlü ve mavimsi gri metal alaşımıdır. Bileşimine bağlı olarak %0,2 ile %2,1 karbon içerebilen çelikler genelde sünektirler. Isıl işlem uygulanarak sertliği, dayanımı gibi bazı karakteristik özellikleri ihtiyaca göre değiştirilebilir. Bu özelliklerin değiştirilebilir olmasını sağlayan en önemli element karbondur. Çelik, Fe-C alaşımıdır. Ayrıca magnezyum, krom, vandalyum, tungsten, kükürt, silikon, fosfor ve oksijen gibi alaşım elementleri de belli oranda içerisinde mevcuttur. Çelik genellikle imalat ve yapı malzemesi olarak kullanılmaktadır. Çeliğin içindeki alaşım elementlerinin miktarı onun sünekliliğini, sertliğini ve çekme mukavemetini etkilemektedir [14, 15].

2016 yılında dünyada üretilmiş olan çelik 1,628 milyon tondur. Ayrıca ABD 78,61 milyon tonluk, Çin 808,37 milyon tonluk, Japonya 104,77 milyon tonluk, çelik üretmişlerdir. 2016'da Türkiye'de üretimi gerçekleştirilen çelik miktarı ise 33,163 milyon ton olmuştur [16].

2.2. AISI Standardizasyonu

AISI (American Iron And Steel Institute) Amerikan standardizasyonudur ve en çok kullanılan sistem olup kimyasal analiz esasına dayanmaktadır. 1'den 9'a kadar olan rakamlarla 4 veya 5 basamaklı sayı sistemi kullanılmaktadır. Sistemde ilk iki rakam çelik türünü, son iki rakamı içerisinde bulunan karbon yüzdesinin yüz katını göstermektedir. Örneğin; 1050 çeliğinde 10 karbonlu çelik türünü, 50 içerisindeki bulunan karbon yüzdesinin yüz katını göstermektedir. Yani 1050 çeliğinde %0,5 oranında karbon bulunmaktadır.

Bu standardizasyondaki çelik türleri şu şekildedir;

- 10XX = Sade Karbonlu Çelikler
- 11XX = Otomat Çelikleri
- 13XX = Manganlı çelikler
- 2XXX = Nikelli Çelikler
- 3XXX = Krom-Nikel Alaşımli Çelikler
- 303XX = Isiya ve Korozyona Dayanıklı Çelikler
- 4XXX = Molibden Alaşımli Çelikler
- 41XX = Molibden-Kromlu Alaşımli Çelikler
- 43XX = Molibden-Krom-Nikel Alaşımli Çelikler
- 46XX = Molibden-Nikel Alaşımli Çelikler
- 5XXX = Krom Alaşımli Çelikler
- 514XX = Isiya ve Korozyona Dayanıklı Çelikler
- 515XX = Isiya ve Korozyona Dayanıklı Çelikler
- 6XXX = Krom-Vanadyum Alaşımli Çelikler
- 7XXX = Krom-Wolfram Alaşımli Çelikler
- 8XXX = Nikel-Krom-Molibden Alaşımli Çelikler
- 92XX = Silis ve Mangan Alaşımli Çelikler.

2.3. Az Alaşımli Çelikler

Az alaşımli çeliklerin yapısında toplamda %5'ten az alaşım elementi bulunmaktadır. Yüksek dayanımlı yapı ve imalat çelikleridir. Çeliğin içerisinde bulunan karbon miktarına göre mekanik ve fiziksel özellikleri değişmektedir. Bu sebeple yüzdelerine göre karbonlar üç gruba ayrılır. Bunlar;

1. Düşük Karbonlu Çelikler
2. Orta Karbonlu Çelikler
3. Yüksek Karbonlu Çeliklerdir.

2.3.1. Düşük Karbonlu Çelikler

İçerisinde en fazla %0,2 oranında karbon içeren çeliklerdir [17]. Bu çelikler yumuşak yapılı ve çekme mukavemetleri düşüktür. Ayrıca kaynak olma özellikleri çok iyiye sertleştirilebilme yetenekleri azdır. Somun, civata, ıslah edilebilir makine parçaları imalatı, yapı inşaat sektörü gibi alanlarda kullanılabilir.

2.3.2. Orta Karbonlu Çelikler

İçerisinde %0,2 ile %0,6 arasında karbon içeren çeliklerdir [18]. Düşük karbonlu çeliklere göre çekme mukavemeti yüksektir. Kaynak olma ve sertleştirilebilme özellikleri orta derecedir. Bu orta karbonlu çeliklerden dingil, gemi şaftı, ray, kazma, kürek, yük kancası, transmisyon mili gibi malzemeler imal edilmektedir.

2.3.3. Yüksek Karbonlu Çelikler

Bileşiminde %0,6 ile %2,1 arasında karbon içeren çeliklerdir [19]. Çeliğin içerisindeki karbon miktarına göre sertten çok serte doğru bir özellik ortaya koyarlar. Düşük ve orta karbonlu çeliklere göre çekme mukavemetleri ve sertleştirilebilmeleri daha iyidir. Ancak bunların yanında kaynak olabilme özellikleri oldukça zayıftır. Yüksek mukavemetli makine parçaları, ege, ağaç testeresi, kepçe dişlisi, greyder bıçağı gibi malzemelerin yapımında kullanılmaktadır.

2.4. AISI 1050 Çeliği

AISI 1050 çeliği orta karbonlu çelik sınıfına girmektedir. İçerisinde ortalama %0.42 ile %0,5 oranında karbon bulundurmaktadır. AISI 1050 çeliğinin içerisinde bulunan diğer alaşım elementleri Tablo 2.1’de gösterilmiştir [20].

Tablo 2.1. AISI 1050 çeliğindeki bulunan alaşım elementleri.

Silyum (Si)=%0,212	Molibden (Mo)=%0,00752
Krom (Cr)=%0,0776	Nikel (Ni)=%0,0972
Mangan (Mn)=%0,730	Alüminyum (Al)=%0,0110
Fosfor (P)=%0,0197	Kobalt (Co)=%0,00603
Kükürt (S)=%0,0390	Bakır (Cu)=%0,297

AISI 1050 çeliğinin ısı işlem durumu aşağıdaki gibidir;

- Sıcak şekillendirme 1100-850°C,
- Yumuşak tavlama 650- 700°C,

- Normalize 840-870°C,
- Sertleştirme 820- 860°C,
- Menevileşme 530- 670°C,
- Sertleştirme ortamı su ve yağdır [21].

AISI 1050 çeliği imalat sektöründe geniş yer tutmaktadır. AISI 1050 çeliği orta sertlikteki makine, motor parçaları, frezeli miller, krom kaplı miller, dişli takımları, kaplama takımları, somun, civata, cer (vagon çeki kancası) kanca, tırtıllı merdane, kazma gibi ürünlerin imalatında kullanılmaktadır [22].

2.5. Yüzey Kalitesi

Talaşlı imalatta üretilmiş olan malzemeler insan gözüyle incelendiğinde malzemenin yüzeyi düzmüş gibi gelebilir fakat aslında malzemenin yüzeyindeki gerçek sürtünme alanı malzemenin alanından daha küçüktür [23]. Yüzey pürüzlülüğünün kalite kontrolüne onun çok önemli olduğu şartlarda gereksinim duyulmaktadır. Bundan dolayı uluslararası yüzey pürüzlülük standartları ortaya çıkmıştır. Ülkemize gelince TS 2040 numaralı yayın ile yüzey kaliteleri bir standartla ilişkilendirilmiştir. Ardından bu standardı TS 2495, TS 971, TS 2578, TS 6956 ve TS 930 standartları takip etmiştir [24].

2.6. Yüzey Pürüzlülüğü

Elde bulunan malzemeyi şekillendirme işlemi esnasında; kesicinin cinsine, seçilmiş olan metoda ve işleme koşullarına bağlı olarak kimyasal, fiziksel faktörlerin ve kesici iş parçasının arasındaki mekanik hareketlerden dolayı malzemenin yüzeyinde istenmeyen işleme izleri olmaktadır. Bu olay nominal yüzey çizgisinin üzerinde ve aşağısında düzensiz şekilde olan sapmalar meydana getirmektedir ve buna da yüzey pürüzlülüğü tanımı yapılmaktadır [25]. Tornalama işlemlerinin bitirme aşamasında oldukça önemli bir parametre olan yüzey pürüzlülüğü çoğunlukla kesici aletin burun yarıçapıyla ve ilerlemesiyle belirlenir [26, 27]. Büyük ilerleme işlemi ile kısa sürede kesme işlemi kötü bir yüzey oluştururken, büyük bir kesici takım burun yarıçapı ise daha iyi bir yüzey oluşturabilir. Kesici takım burun yarıçapının çok büyük olması durumunda bu kesici titreşime, yeterli olmayan talaş kaldırmaya ve kesici takım ömrünün kılmasına neden olabilir. Bundan dolayı ilerleme değeri ve kesici takımın burun yarıçapı sınırlandırılabilir. Yüzey pürüzlülüğüne ait genel formül Eşitlik (2.1)'de gösterilmiştir [27]. Bu eşitlikte R_a (μm) yüzey pürüzlülüğünü, f (mm/dak) ilerleme değerini ve r_ϵ (mm) ise kesici takımın burun yarıçapını temsil etmektedir [26].

$$R_a = \frac{f^2 \times 0.0321}{r_\epsilon} \quad (2.1)$$

Çoğu makine parçalarının performanslarını yükseltmek için hassas işlenmiş yüzeylere ihtiyaç duyulur. Bundan dolayı, istenilen yüzey kalitesini elde edilmek için referans alınacak standart yüzey pürüzlülük değerleri ile belirlenmiştir ve bu değerler sembollerle gösterilmiştir. TS 2040'la pürüzlülük değerleri, numara ve sınıfları standartlaştırılmıştır ve bunlar Tablo 2.2'de gösterilmiştir [28].

Tablo 2.2. Standartlaştırılmış sınıf numaraları ve pürüzlülük değerleri [24, 28].

Pürüzlülük Sınıfı Numarası(N)	N12	N11	N10	N9	N8	N7	N6	N5	N4	N3	N2	N1	
Pürüzlülük Değeri (R_a)	μm	2000	1000	500	250	125	63	32	16	8	4	2	1
	μm	50	25	12.5	6.3	3.2	1.6	0.8	0.4	0.2	0.1	0.05	0.025

Çoğu alanda yüzey pürüzlülüğü oldukça önemli bir parametre olmuştur. Önemli olduğu bu alanlardan bazıları [24];

- Sürtünmeli yataklar,
- Korozyonlu ortamında çalışan malzemeler,
- Yuvarlanmalı yataklar,
- Kaplanan ve boyanan yüzeyler,
- Sızdırmazlık yüzeyleri,
- Plastik enjeksiyon kalıp yüzeyleri,
- Masterlar vb.dir.

2.6.1. Yüzey Pürüzlülüğünü Etkileyen Faktörler

Yüzey pürüzlülüğünü birden çok faktör etkileyebilmektedir. Bu faktörlerin önemli olanları aşağıda verilmiştir:

- İlerleme mekanizmasındaki düzen bozuklukları,
- İşlenecek olan malzemenin yapısındaki bozukluklar,
- Hassas ve kırılğan parçaların işlenmesi esnasında düzensiz talaş akışı,
- Kesme hızı düşük bir şekilde işlenen ve kolayca şekillendirilebilen parçaların yüzeyindeki yırtılmalar,
- Talaş akışından kaynaklanan bozukluklar,
- Kesme ve ilerleme hızlarında meydana gelmiş olan düzensizlikler,
- Kesim işlemi sırasındaki kesme derinliği,
- Kesici takımın soğutulma ve yağlanma şartları,

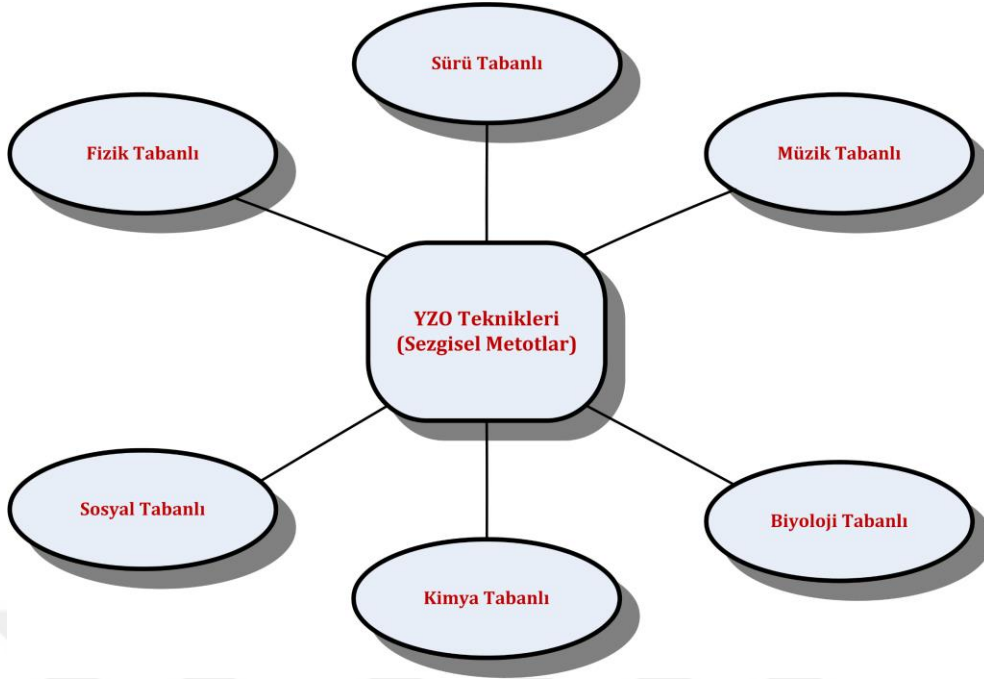
- İşlenecek olan parçanın kimyasal bileşimi ve atomik yapısı,
- Kesme aletinin dizaynı, geometrisi ve kesme kapasitesi,
- Kalıp ve bağlama aparatları,
- İşlenecek olan parçadan talaş kaldırma biçimi,
- Yatak ve iş takımlarındaki oluşacak geometrik deformasyonlar, gibi [24].

2.7. Optimizasyon ve Yapay Zekaya Dayalı Optimizasyon Algoritmaları

2.7.1. Optimizasyon Kavramı

Yakın tarihte, yazılım ve bilgisayar teknolojisinin hızlı bir şekilde gelişmesiyle çeşitli alanlardaki problemlerin çözülmesi için optimizasyon teknikleri ortaya konmuştur [29]. Ortaya konan bu optimizasyon teknikleri çözülmesi güç problemler için yardımcı nitelikte olmuştur. Doğada hayatını sürdüren canlılar aslında optimizasyon kavramını günlük yaşayışlarında kullanmaktadır. Optimizasyon ayrıca karar biliminde ve sistem analizinde kullanılan başlıca yöntemdir [30]. En iyi hedef olarak da bilinen optimizasyon, matematiksel ifadelerin çözümünde optimum veya en iyi çözümü arayan bir bilim dalı olmuştur [31]. Başka bir deyişle optimizasyon, sistemin girişine karşılık minimum veya maksimum çıkışı vermek için çalışan matematiksel bir ifade olarak bilinmektedir [32].

Sezgisel optimizasyon metotları olarak da bilinen yapay zekaya tabanlı optimizasyon algoritmaları, istenen hedefi bulmak ya da bir amaç için doğadan ilham alınarak geliştirilen etkili tekniklerdir ve yakınsama özellikleri vardır. Fakat bu yakınsama özelliğiyle problemlerin üstesinden nasıl geldikleri hala bilinmemektedir. Bununla birlikte YZO algoritmaları kesin çözüm sağlayamayabilecekleri gibi bu kesin çözüme en yakın çözümü bulabilmektedirler. Sezgisel optimizasyon algoritmalarına öğrenme ve çözüm bulma işlemlerinde kullanılabilirliğinden kaynaklı gereksinim duyulmuştur [33]. Yapay zeka tabanlı algoritmalar anlaşılabilirlik açısından bakıldığında oldukça basittir. Bu zamana kadar geliştirilmiş YZO algoritmaları altı sınıfta toplanabilir. Bunlar, fizik tabanlı, biyoloji tabanlı, müzik tabanlı, kimya tabanlı, sosyal tabanlı ve sürü tabanlı optimizasyon teknikleridir.



Şekil 2.1. Yapay zekaya tabanlı optimizasyon teknikleri.

Günümüzde farklı alanlardaki kompleks optimizasyon problemlerinin en iyi sonucunu bulmak için sürü zekâsı tabanlı çeşitli yapay zeka tabanlı optimizasyon algoritmaları geliştirilmiştir. Parçacık sürü optimizasyonu (PSO-Particle Swarm Optimization) algoritması, Karınca kolonisi (AC-Ant Colony) algoritması, yarasa algoritması, DEA, GA ve ABC algoritması geliştirilmiş olan YZO tabanlı algoritmaların birkaçıdır [34–40].

Storn ve Prince, yaptıkları çalışmalar sonucunda güçlü bir arama yeteneği olan DEA literatüre kazandırmışlardır. Bilimde ve çoğu mühendislik alanlarındaki kompleks özelliği olan optimizasyon problemlerine karşı başarıyla uygulamaları yapılmıştır. DEA ile alakalı son çalışmalara göre DEA yakınsama, sağlamlık ve hız bakımından birçok optimizasyon algoritmasından daha da iyi olduğu sunulmuştur [41]. Karaboğa'nın matematiksel optimizasyon problemleri için geliştirdiği ABC algoritması bal arılarının besin arayışı sırasında göstermiş oldukları davranışlardan ilham almıştır. ABC algoritması kısıtsız optimizasyon problemleri üzerine başarılı biçimde uygulanmıştır ve deneylerde PSO, FG algoritmalarına kıyasla sonuçların daha iyi olduğu gözlemlenmiştir [40].

2.7.1.1. Yapay Arı Kolonisi Algoritması

Optimizasyon ile ilgili bulunan ya da geliştirilen yeni metotlar dünyamızdaki zeki varlıkların davranışsal biçimlerinin araştırılmasıyla ortaya çıkmıştır. Çeşitli alanlarda yaygın bir şekilde tercih edilen ve optimizasyon metotları içerisinde kuvvetli bir yere sahip olan ABC algoritması, bal arılarının besin arayışı sırasında oluşturdukları davranışların gözlemlenmesiyle geliştirilen oldukça etkin yapay zeka optimizasyon algoritmaları arasındadır. ABC algoritmasını

geliştirmiş olan Karaboğa'nın özümsemiği modelde arama işini kabul edilen bir takım kurallarla gerçekleştirmiştir. ABC algoritmasının kolonisi 3 temel gruptan meydana gelmektedir. Bunlar, görevli arılar, gözcü arılar ve kaşif arılardır. Tüm yiyecek kaynaklarının besini görevlendirilmiş olan bir görevli ya da bir gözcü arı tarafından toplanmaktadır. Öte yandan görevlendirilmiş arıların sayısı besin kaynaklarının sayısına eşittir. Bunun yanında görevli arılar ile gözcü arıların sayısında eşit olmaktadır [42]. Yiyecek kaynağındaki besini bitmiş olan ve bir yiyecek kaynağına atanmış arı kaşif arıya dönüşür. Bu dönüşümün amacı yep yeni bir yiyecek kaynağı bulmaktır. Optimizasyon probleminin çözümü, çözüm uzayında belli olan yiyecek kaynaklarının yerleri ile temsil edilir. Çözümün uygunluğunu veya kalitesini yiyecek kaynağındaki besin miktarı belirlemektedir. Bu nedenle ABC algoritması, çözüm uzayındaki besin miktarı en çok olan yiyeceğe doğru yönelerek optimizasyon problemi için amaç olan en uygun minimum veya maksimum değeri veren konumu yani çözümü bulmaya çalışmaktadır [40, 42].

2.7.1.1.1 Başlangıç Yiyecek Kaynaklarına ait Bölgelerin Üretilmesi

ABC algoritması, başlangıçtaki yiyecek kaynaklarının yerlerini tayin etmede rasgele bir üretim yapmaktadır. Yani başlangıç yerleri kovanın çevresindeki yiyecek kaynaklarına göre rasgele üretilmektedir. ABC algoritmasındaki bu rasgele yer üretimi her parametrenin ayrı ayrı alt ve üst sınırlarının arasında rasgele değer üreterek gerçekleştirilmektedir [43].

Bu işlemin matematiksel gösterimi Eşitlik(2.2)'deki gibidir.

$$x_{ij} = x_j^{\min} + rand(0,1)(x_j^{\max} - x_j^{\min}) \quad (2.2)$$

Yukarıdaki denklemde $i = 1 \dots SN$, $j = 1 \dots D$ dir. Burada, D optimize edilmek istenen parametre sayısı, SN ise yiyecek kaynağının sayısını göstermektedirken x_j^{\min} j. parametrenin alt sınırı ve x_j^{\max} j. parametrenin üst sınırı olarak belirlenmektedir. Algoritmada başlangıç aşamasının ardından bütün yiyecek kaynaklarına gözcü ve görevli arı atamalarını yaparak daha iyi yiyecek kaynağını bulmak amacıyla arama işlemlerine geçilmektedir. Yapay arı koloni algoritmasının durdurma işlemi (MCN) maksimum çevrim sayısı, kabul edilebilir hata değeri (ϵ) ya da standart bir durdurma şartı ile sağlanabilir [43].

2.7.1.1.2. Görevli Arıların Yiyecek Kaynağı Bölgelerine Yönlendirilmesi

Önceden de belirtildiği gibi her bir yiyecek kaynağının besini o kaynak için görevlendirilmiş bir gözcü ya da bir görevli arı tarafından toplanmaktadır. Dolayısıyla görevlendirilmiş arı sayısı ile yiyecek kaynaklarının sayısı birbirine denktir. İşçi arı görevlendirildiği yiyecek kaynağının komşuluğunda yeni bir yiyecek kaynağı belirler. Belirlenen

bu yeni kaynağın besin kalitesini değerlendirir. Görevlendirilmiş olduğu yiyecek kaynağının komşuluğunda belirlediği yeni kaynağın besin kalitesi iyi ise yeni yiyecek kaynağını hafızasında tutar. Yeni kaynağın mevcut kaynağa göre belirlenmesine ait benzetim Eşitlik (2.3)'de gösterilmiştir [43].

$$v_{ij} = x_{ij} + \phi_{ij}(x_{ij} - x_{kj}) \quad (2.3)$$

Bu denkleme göre, x_i ile gösterilen her bir kaynak için çözümün tek bir parametresi (rastgele seçilmiş olan j parametresi) değiştirilip x_i komşuluğunda v_i yiyecek kaynağı bulunur. Eşitlik (2.2)'de verilen j parametresi, $[1, D]$ aralığında rastgele üretilmiş olan bir tamsayıdır. Rastgele seçilmiş olan j parametresi değiştirilirken, aynı şekilde rasgele seçilmiş x_k ($k \in \{1, 2, \dots, SN\}$) komşu çözümünün j parametresi ile mevcut olan kaynağın j parametresinin farkı alını $[-1, 1]$ arasında rastgele değer alan ϕ_{ij} sayısı ile ağırlıklandırılarak mevcut kaynağın j parametresine eklenir. Eşitlik (2.3)' da görüldüğü üzere x_{ij} ve x_{kj} 'nin aralarındaki fark azalmaya devam ettikçe yani çözümler birbirine benzedikçe, x_{ij} parametresinin değişim miktarı da azalacaktır. Bunların sonunda üretilmiş olan v_{ij} 'nin daha evvel belli olan parametre sınırlarını aşması halinde j . parametrenin alt ve üst sınır değerlerine ötelenmektedir. Bu işleme ait benzetim Eşitlik (2.4)' da gösterilmiştir [43].

$$v_{ij} = \begin{cases} x_j^{\min}, & v_{ij} < x_j^{\min} \\ v_{ij}, & x_j^{\min} \leq v_{ij} \leq x_j^{\max} \\ x_j^{\max}, & v_{ij} > x_j^{\max} \end{cases} \quad (2.4)$$

Parametre vektörü olan v_i sınırlar içerisinde belirlenmiş olan yeni bir yiyecek kaynağının yerini temsil etmektedir. Bu yeni yiyecek kaynağının kalitesini hesaplayarak bir uygunluk değeri belirlemektedir. Yiyecek kaynaklarına ait uygunluk değerleri Eşitlik (2.5)'da verile ifade ile gerçekleştirilmektedir.

$$fitness_i = \begin{cases} 1/(1 + f_i), & f_i \geq 0 \\ 1 + abs(f_i), & f_i < 0 \end{cases} \quad (2.5)$$

Burada, f_i , yeni üretilmiş olan v_i kaynağına, yani yeni çözümün maliyet değeridir ve x_i ile v_i arasındaki uygunluk değerine diğer bir değişle besin miktarına bakarak bir aç gözlü (*Greedy*) seçim işlemi yapılır. Yeni bulunan v_i çözümü, eski çözümden daha iyi ise görevli arı eski çözümün konum bilgisi hafızasından silinerek yeni çözümün konum bilgisini hafızasına kaydeder. Aksi bir

durum ortaya çıkarsa görevlendirilmiş olan arı eski yiyecek kaynağına yani x_i 'ye gitmeye devam eder. Geliştiremediği her denemede ise geliştirememeye sayacını ($trial_i$) bir artırır ve geliştirdiği durumlarda da bu sayacı sıfırlamaktadır [43].

2.7.1.1.3. Gözcü Arılar için Olasılık Değerlerinin Hesaplanması

Bir çevrimin ardından tüm görevli görevli arılar araştırmalarını tamamlayıp kovanlarına dönerler. Kovanda buldukları yiyecek kaynaklarına ait besinin miktarları hakkında gözcü arılarla bilgi paylaşımı yaparlar. İşçi arının gerçekleştirmiş olduğu dans sayesinde gözcü arı, yiyecek kaynaklarına ait aktarılan bilgiden faydalanıp yiyecek kaynaklarının besin miktarları ile orantılı bir olasılığa göre kaynak seçimi yapar. Olasılıkla orantılı kaynak seçim işlemi, yiyeceklerin besin miktarına karşı uygunluk değerleri kullanılarak gerçekleştirilmektedir. Bu kaynak seçimi bazı yöntemler kullanılarak gerçekleştirilmektedir ve ABC algoritmasında bu seçme, rulet tekerleği yöntemi kullanılarak yapılmaktadır [43]. Rulet tekerleğinde her parçanın açısı uygunluk değeriyle orantılandırılmıştır. Bir kaynağın uygunluk değerinin bütün kaynaklarının toplamına oranı o kaynağın diğerlerine kıyasla seçilme olasılığı olduğunu vermektedir Eşitlik (2.6)'de olasılık değerlerinin hesaplanmasına ilişkin ifade gösterilmiştir.

$$p_i = \frac{fitness_i}{\sum_{j=1}^{SN} fitness_j} \quad (2.6)$$

Bu denkleme göre, i . kaynağın kalitesini $fitness_i$, j . kaynağın kalitesini $fitness_j$ görevlendirilmiş arıların sayısı ise SN ile temsil edilmiştir. Yukarıdaki olasılık hesabında, bir kaynağın besin miktarı arttıkça yani uygunluk değeri arttıkça, bu kaynağın bulunduğu bölgeyi seçecek arıların sayısı artacaktır.

2.7.1.1.4. Gözcü Arılar için Yiyecek Kaynağı Bölgesinin Seçimi

Olasılık değerlerinin algoritmada hesaplanmasının ardından bu değerler ile rulet tekerleğine göre yapılan seçim işleminde her kaynak için $[0, 1]$ aralığında rasgele sayı üretilmektedir. Eğer p_i değeri bu rasgele üretilen değerden büyükse görevli arılar gibi gözcülerde Eşitlik (2.3)'ü kullanıp bu kaynağın bölgesinde yeni bir çözüm üretirler. Üretilen yeni çözüm değerlendirilip ve kalitesi hesaplanmaktadır. Ardından aç gözlü seçim işlemi olan yeni ve eski çözümün uygunlukları karşılaştırılıp en iyi çözümün seçildiği adım uygulanmaktadır. Eğer yeni çözüm daha iyiyse eski çözümün yerini bu yeni çözüm alınır ve çözüm geliştirememeye sayacı ($trial_i$) sıfırlanmaktadır. Şayet eski çözüm daha iyiyse bu eski çözüm hafızada muhafaza edilir ve

çözüm geliştirememeye sayacı bir yükseltilir. Bu işlemler gözcü arıların tamamı yiyecek kaynağı bölgelerine yayılana kadar sürdürülmektedir [43].

2.7.1.1.5. Kâşif Arı Üretimi Ve Tükenmiş Kaynağın Terkedilmesi


Bir çevrimin bitiminde bütün görevli ve gözcü arılar arama işlemlerini tamamlamasının ardından çözüm geliştirememeye sayaçları kontrol edilmektedir. Bir arının bir kaynaktan besin tüketip tüketmediğini çözüm geliştirememeye sayaçları sayesinde anlaşılır. Çözüm geliştirememeye sayacı belli bir eşik değerinin üzerinde ise bu kaynaktaki görevli arının tükenmiş olan o çözümü terk edip başka çözüm araması lazımdır. Buradan anlaşılacağı gibi bitmiş olan kaynağın görevli arısının kâşif arıya dönüşmesi demektir. İşçiden kâşif arıya dönüşümün ardından bu kâşifler için rasgele çözüm arama süreci başlamaktadır (Eşitlik (2.2)). Tükenen kaynağın saptanması için kullanılmış olan eşik değeri ABC algoritmasının önemli bir parametresidir ve “*limit*” olarak tanımlanmaktadır [43].

2.7.1.2. ABC Algoritmasının Adımları

ABC algoritması araştırması sırasında dört ayrı işlem kullanmaktadır [43].

- 1) Diğer kaynaklara kıyasla daha iyi kaynakların belirlenmesi için çalışan Eşitlik (2.6) ile olasılık değerlerinin hesaplanıp kullanıldığı küresel seçim işlemi,
- 2) İşçi ve gözcü arıların şekil, koku, renk gibi besin kaynağının türünün belirlenmesini sağlayan, görsel bilgi yardımıyla bir bölgeye geçişinin ardından o bölgedeki kaynağa karar verilmesine yardım eden bölgesel olasılık tabanlı seçim işlemi,
- 3) Daha iyi kaynağı belirlemek için görevli ve gözcü arıların kullandığı aç gözlü seçim işlemi,
- 4) Eşitlik (2.2) ile kâşif arıların gerçekleştirdiği rasgele seçim işlemi.

ABC algoritmasının genelleştirilmiş akış şeması Şekil 2.2’de verilmiştir.



Şekil 2.2. ABC algoritmasının genel akış şeması.

Yukarıda genel hatları ile ABC algoritmasının fazları ve her bir faza ait olan işleyiş anlatılmıştır. Aşağıda ABC algoritmasının genel işleyişi ile ilgili sözde kodlar verilmiştir [43].

Başla

Adım 1: İterasyon sayacını $iter=1$ eşitle; ve $x_{i,j}$ çözümleri ile birlikte NP sayısı kadar başlangıç popülasyonunu rastgele oluştur. Başlangıç parametreleri $limit$ değerini ata ve $trial$ sayacını $trial_i=0$ eşitle.

Adım 2: Popülasyondaki her bir birey için amaç değerlerini f_i değerlendir ve uygunluk değerlerini ($fitness_i$) Eşitlik (2.5)'i kullanarak hesapla

Adım 3: **while** Durdurma kriteri sağlanmıyor ise **do**

// İşçi arı fazı

for $i = 1$ to $NP/2$

```
Rasgele  $k, j$  değerlerini seç ve  $i \neq k$   
[-1, 1] değerleri aralığında rastgele  $\Phi_{i,j}$  değerini seç  
Eşitlik (2.3)'i kullanarak yeni  $v_i$  değerini üret.  
Yeni  $v_i$  için  $f_{v_i}$  amaç fonksiyon değerini hesapla  
Yeni  $f_{v_i}$  değeri için Eşitlik (2.5)'i kullanarak fitness $_{v_i}$  uygunluk değerini hesapla  
 $x_i$  ve  $v_i$  arasında açgözlü seçim sürecini uygula  
Eğer çözüm geliştirilmedi ise;  
trial $_i = \mathbf{trial}_i + 1$ , geliştirildi ise; trial $_i = 0$   
end for  
Her bir  $x_i$  çözümü için Eşitlik (2.6)'i kullanarak  $p_i$  olasılık değerlerini hesapla  
// Gözcü arı fazı  
 $i = 1$ ;  
 $t = 0$ ;  
while  $t < NP/2$   
  if  $\text{rand} < p_i$   
     $t = t + 1$ ;  
    Rasgele  $k, j$  değerlerini seç ve  $i \neq k$   
    [-1, 1] değerleri aralığında rastgele  $\Phi_{i,j}$  değerini seç  
    Eşitlik (2.3)'i kullanarak yeni  $v_i$  değerini üret.  
    Yeni  $v_i$  için  $f_{v_i}$  amaç fonksiyon değerini hesapla  
    Yeni  $f_{v_i}$  değeri için Eşitlik (2.5)'i kullanarak fitness $_{v_i}$  uygunluk değerini hesapla  
     $x_i$  ve  $v_i$  arasında açgözlü seçim sürecini uygula  
    Eğer çözüm geliştirilmedi ise;  
    trial $_i = \mathbf{trial}_i + 1$ , geliştirildi ise; trial $_i = 0$   
  end if  
   $i = i + 1$ ;  
  if  $i == ((NP/2) + 1)$   
     $i = 0$ ;  
  end if  
end while  
// İzci arı fazı  
if  $\max(\mathbf{trial}_i) > \mathbf{limit}$   
  Eşitlik (2.2)'yi kullanarak rastgele yeni bir çözüm üret ve  $x_i$  çözümü ile yer değiştir.  
  Yeni  $x_i$  için amaç fonksiyonunu  $f_i'$  yi hesapla  
  Yeni  $f_i$  değeri için Eşitlik (2.5)'i kullanarak fitness $_i$   
end if
```

Elde edilen en iyi çözümü hafızaya kaydet

iter = iter + 1;

end while

end.

2.8. Yapay Sinir Ağları


İnsan zekasının bilgisayara göre daha iyi gerçekleştirdiği durumları bilgisayar tarafından yapılabilmesi adına çalışan bilimsel disipline yapay zekâ adı verilmiştir. İnsanın düşünme olayını ve bir takım doğal süreci ele alan yapay zekâ bazı makineleri kullanarak taklit etmeye dayanmaktadır.

Bilgisayar sistemi olan yapay sinir ağları, insan beynine has olan öğrenme ile yeni olgular oluşturma, keşfetme ve türetme gibi yetenekleri yardımsız bir şekilde otomatik olarak yapma amacıyla geliştirilmiştir. Bu özellikleri klasik programlama metotları ile gerçekleştirmek oldukça zorlayıcıdır. Bundan dolayı, YSA'ları programlanması oldukça güç ya da programlanamayan durumlar için geliştirilen adapte edilebilir bilgi işlemeyle ilgilenen bilim dalıdır [44].

YSA, insanın biyolojik sinir sisteminin çalışma prensibini temel alıp benzetilerek tasarlanmış programlardır. Benzetilmiş YSA hücreleri yani nöronları içermektedirler.ve nöronlar birbirine tutunarak bir ağ oluşturmaktadırlar. Bu nöronların hafızada tutma, datalar arasındaki bağlantıyı ortaya çıkarma gibi yetenekleri vardır. Başka bir deyişle, yapay sinir ağları bir insanın düşünmesine ve gözlemlemesine dayanan normal yetkinliklerini gerektiren sorunlara çözüm sağlamaktadır. İnsanın gözlem ve düşünme yetkinlerini gerektiren problemlere çözüm üretebilmesinin esas nedeni yaşayıp ya da deneyip öğrenme yetkinliğidir.

Öğrenme biyolojik olarak, nöronların arasında olan sinaptik bağların düzenlenmesi ile olmaktadır. İnsan oğlu doğumundan başlayarak yaşayıp öğrenme sürecinin içine girer ve beyin devamlı bir gelişme sağlar. Yaşayarak tecrübe edildikçe sinaptik bağlar düzenlenir bunun yanında yeni bağlar da oluşturulabilir. Böylece öğrenme işlemi gerçekleşmiş olur. Bu YSA'da da geçerliliğini devam ettirir. YSA'nın öğrenmesi eğitime ile olmaktadır. Yani giriş çıkış datalarının işlenmesiyle, eğitim algoritmasının bu dataları kullanıp bağlantı ağırlıklarını yakınsama gerçekleşene kadar yeniden düzenlemesiyle olmaktadır.

YSA'ları, ağırlıklanmış olarak bağlantılanmış birçok nörondan meydana gelen matematiksel sistemlerdir. Bir nöron, aktivasyon ya da transfer fonksiyonu olarak bilinen bir denklemsel ifadedir. Bu nöron, başka işlem elemanlarından (nöronlardan) sinyalleri alıp birleştirir, dönüştürür ardından bir sayısal çıktı oluşur [44]. Genel olarak bir yapay sinir ağı modeli Şekil 2.3' te gösterilmiştir.



Şekil 2.3. Yapay sinir ağı modeli.

2.8.1. Yapay Sinir Ağının Tarihçesi

YSA üzerine yapılan çalışmalar 1940 yıllarında başlamıştır. İlk defa YSA modeli bir matematikçi ve sinir doktoru tarafından ortaya konmuştur [45]. Bu iki bilimci beyinin hesaplama yetkinliğinden faydalanarak, elektrik devresi ile basitçe bir sinir ağı gerçekleştirmişlerdir. “Organization of Behavior” adlı kitapta öğrenme ile alakalı temel bir teori sunulmuştur [46]. 1957’de Frank Rosentblatt Perceptron’u geliştirdikten sonra YSA alanında ilerlemeler hız kazanmıştır [47]. Perceptron, beyinsel fonksiyonları modelleyebilmek için yapılmış uygulamalar sonucunda ortaya çıkmış eğitilebilen tek katmanlı, tek çıktıya sahip bir YSA’dır. 1959’a gelindiğinde Widrow ve Hoff tarafından ADALINE, MADALINE diye isimlendirdikleri metotları geliştirmişlerdir [48, 49]. MADALINE telefon iletkenlerindeki yanıkları ortadan kaldıran bir süzgeç gibi kullanılmış, gerçek hayattan sorunlara uygulanan ilk YSA’dır ve hala kullanımı sürmektedir.

XOR problemi iki girdili bir çıktılı problemdir. İki girdi aynı olduğu zaman sıfırı farklı olduğu zaman bir sonucunu vermesi istenen bir ağ tasarım problemidir. Minsky ile Papert Perceptron’un XOR problemi üzerinde başarısız olduğunu görmüşlerdir. Bu başarısızlığın iki katmanlı ileri beslemeli ağlar ile aşılabileceğini öne sürmüşlerdir ve tek katmanlı ağların sahip olduğu sınırlamanın sonlandığını ortaya koymuşlardır [50]. Ancak gizli katmanlara ait ağırlıkların ne yolla değiştirilebileceği hakkında bir metot önermemişlerdir. Bu probleme Rummelhar ve ekibi 1986’da geri yayılım yöntemi ile çözüm üretmişlerdir [51].

1982 senesinde Hopfield ağların önemli sınıflarının temellerini matematiksel olarak gerçekleştirmiştir [52]. 1984'e gelindiğinde Kohonen tarafından danışmansız öğrenen ağlar geliştirildi. Rumelhart ve McClelland 1986 yılında çok katmanlı olan ağlar için geri yayımlı öğrenme algoritmasını geliştirmişlerdir [53].

AEEME tarafından 1987 senesinde sinir ağları konulu ilk uluslararası konferansın üzerinde katılımcı ile yapılmıştır [54]. Hecht-Nielsen üç katmanlı bir ileri beslemeli yapay sinir ağının evrensel fonksiyon yaklaşırma yetkinliğini 1990'da kanıtlamışlardır.

Günümüzde ise hemen hemen her disiplinde yapılan çalışmalarda YSA'nın kullanımı sürmektedir.

2.8.2. Yapay Sinir Ağının Uygulama Alanları

YSA modelleme, sınıflandırma, tahmin üzerine birçok alanda uygulanmaktadır. Başarıyla yapılmış uygulamalara bakıldığında kompleks, net olmayan, eksikliği veya kusuru olan, hata oranının yüksek olduğu durumlarda çokça kullanıldığı görülmüştür. Bunun için geliştirilmiş YSA genelde aşağıdaki fonksiyonları içermektedir [44].

- Muhtemel fonksiyon türetimi
- Optimizasyon
- Sınıflandırma
- Kontrol sistemi
- İlişkilendirme ya da örüntü denkleştirme
- Sinyal filtreleme
- Veri sıkıştırma
- Örüntü tanıma
- Doğrusal olmayan sinyal işleme ve sistem modelleme

Gündelik hayatımızda çoğu sektörün değişik alanlarında YSA uygulamaları yapılmıştır [55]. Yapılmış bu uygulamalardan birkaçı kısaca şunlardır;

Otomotivde; otomatik yol takibi, yol şartlarına bağlı sürme işlemi analizi, vb.

Savunma sanayinde; hedefi belirleme, sonar sensör uygulamaları, silahın hedefe yönlendirilmesi, görüntü işleme vb.

Uzay alanında; otomatik pilot sistemleri, uçuşla ilgili simülasyonlar vb.

Bankacılık sektöründe; kredi başvuru değerlendirmeleri, kredi sistemlerinin geliştirilmesi, müşterilerin analizi vb.

Sağlık alanında; ilaçların etkilerinin analizi, göğüs kanserinin ve kalp kriz gibi hastalıkların erken tespiti ve devamında tedavisi, MR, EEG gibi cihazların kalitelerinin iyileştirilmesi vb.

Üretim sektöründe; imalat proses kontrolü, malzeme tasarımı, mukavemet analizleri, makine parçalarının yıpranmalarının analizi vb.

Finans alanında; bütçelerin kestirilmesi, hedefin saptanması, paha değerinin tahmini vb.

Robotik alanda; yörünge kontrolü, uzaktan kumanda uygulamaları, en iyi rotayı seçme vb.

Telekomünikasyon alanında; filtreleme, veri ve görüntü karşılaştırmaları, gürültülerin sönümlendirilme işlemi, trafikteki yoğunluğun kontrolü vb.

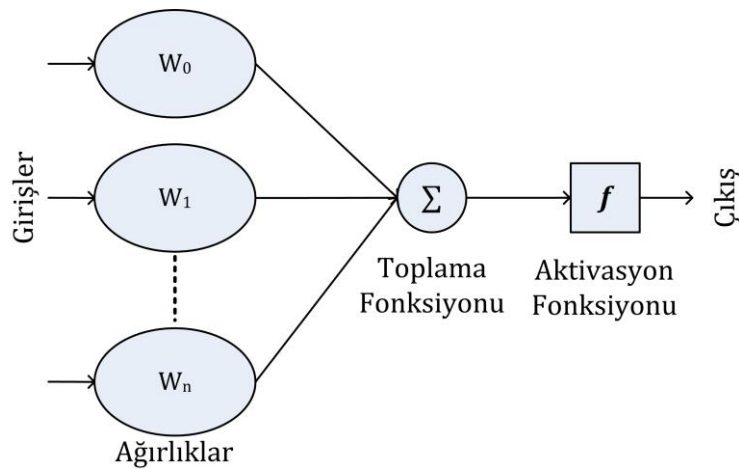
Güvenlik alanında; parmak izi uygulamaları, kredi kartlarına düzenlenen hilelerin belirlenmesi, göz ve yüz taraması vb.

Bu örnekler daha da çoğaltılabilmektedir. Buradan görüldüğü üzere yaşamımızın çoğu alanında YSA'nın varlığı mevcuttur. Zaman ilerledikçe YSA uygulamaları artarak gelişmektedir [55].

2.8.2. Yapay Sinir Ağının Yapısı

Daha öncede belirtildiği gibi YSA hücreleri biyolojik sinir hücreleri ile benzer özelliklerde olup nöronlar sinir sistemimizdeki gibi birbirleri arasında bağlar kurup YSA'larını oluşturmaktadırlar. Sinir sistemimizde olduğu gibi giriş bilgileri alınıp, bu bilgilerin derlenip işlenmesinin ardından çıktı bilgilerinin iletimi olarak gerçekleşen yapı YSA'larında da aynı şekilde gerçekleşmektedir [55].

Bir YSA hücresi beş ana bölümden oluşmuştur. Şekil 2.4'te görüldüğü gibi bir YSA'nın bölümleri; girişler, ağırlıklar, toplama fonksiyonu, aktivasyon (transfer) fonksiyonu ve çıktıdır.



Şekil 2.4. Yapay nöronun detaylandırılmış yapısı.

2.8.2.1. Girişler

YSA'na dışarıdan gelen verilerdir. Bu veriler nöronlar vasıtasıyla alınıp tıpkı biyolojik sinir hücrelerindeki gibi toplanmak için nöron çekirdeğine yollanırlar.

2.8.2.2. Ağırlıklar

Hücrelerin arasında olan bağların sayısal olarak değerlerini ağırlıklar belirlemektedir. Hücreye gelmiş olan verinin sistemdeki değerini ve ayrıca hücrenin üstündeki etkisini gösterir. Nöronların üzerinden çekirdeğe varmadan önce yapay sinir hücresine gelen veriler sahip oldukları bağların ağırlıkları ile çarpılarak çekirdeğe gönderilir. Bunun sayesinde girişlerin istenen çıkış üzerindeki etkisi ayarlanabilmektedir. Ağırlıklar sıfır, pozitif ya da negatif değerler olabilmektedir. Eğer bir verinin ağırlığı sıfır ise o giriş verisinin çıkış üzerinde hiçbir etkisi olmadığını göstermektedir.

2.8.2.3. Toplama Fonksiyonu


Nöronlara iletilmiş olan net verilerin hesaplanmasına yardım eden toplama fonksiyonudur. Bu fonksiyon yapay sinir hücrelerine ait olan ağırlıklar ile çarpılıp gelen girişleri toplayıp yapay sinir hücrelerinin kendilerinin net girişini hesaplayan fonksiyondur. Eşitlik (2.7) toplama fonksiyonuna bir örnektir.

$$\text{Net} = \sum_{i=1}^N X_i W_i \quad (2.7)$$

2.8.2.4. Aktivasyon Fonksiyonu

YSA'larında, toplama fonksiyonu ile oluşan net toplam, çıkış verilerini ortaya çıkarmadan önce aktivasyon fonksiyonuna gönderilmesi lazımdır. Aktivasyon fonksiyonu genellikle doğrusal olmayan fonksiyonlardan belirlenir. YSA'larının doğrusal olmaması aktivasyon fonksiyonlarının doğrusal olmamasından dolayıdır. Doğrusal fonksiyonlarda çıkışın giriş verileriyle doğru orantılı olması sebebiyle seçilmemektedir. Bu doğrusal fonksiyonlar ilk yapay sinir ağı denemelerinin kötü sonuçlarına neden olmuştur [50].

Diğer önemli konu seçilecek olan transfer fonksiyonlarının türevlerinin kolay hesaplanmalarıdır. Özellikle geri beslemeli olan ağların transfer fonksiyonun türevi de işleme dahil olduğundan dolayı hesaplaması basit bir fonksiyon seçimi yapılmaktadır. Çoğunlukla tercih edilen aktivasyon fonksiyonları sigmoid, eşik, hiperbolik tanjant gibi fonksiyonlar olmuştur ve bunlar Şekil 2.5'te gösterilmiştir.



Şekil 2.5. Aktivasyon fonksiyonlarının bazıları.

Bir aktivasyon fonksiyonunun sonucu genellikle işlem elemanının çıkışı olur. Elde edilmiş olan çıkış ya sonuç olarak dışa aktarılır ya da yeni bir girdi gibi başka nöronlara gönderilir.

2.8.2.5. Çıkışlar

Aktivasyon fonksiyonu ile elde edilmiş olan değerler nöronların çıkış değerlerini belirlemektedir. YSA sisteminin çıkışı olarak da kullanılacak değerler sistemin içinde tekrar başka input olarak da kullanılabilir. Çıkış değeri bir veya birden fazla olabilmektedir.

2.8.3. Yapay Sinir Ağında Öğrenme

Klasik veri işleme metotlarının birçoğu programlama vasıtasıyla hesaplama işlemine dayanır. Başka bir deyişle bir problemi çözmek için o probleme dayalı bir algoritma türetilmelidir. Bununla birlikte bu metotlar net olmayan problemleri çözüme kavuşturamazlar. YSA'larıysa belli bir probleme dayalı programlanmamasına rağmen o problemi çözebilmeyi öğrenebilir.

Genel tabirle öğrenme, YSA'nın giriş uyarıcılarıyla kendisini istenilen sonuçları üretmek için ayarlamasıdır. Öğrenme tüm YSA'ların temeli olup işlem elemanı ile ağ yapısı tasarlanmasının ardından YSA'nın öğrenme süreci başlar. Öğrenme işlemi ağ içerisindeki nöronların değişimiyle değil nöronların arasında olan bağlantı ağırlıklarının değişimi ile gerçekleşir. Bir nöronun

çıkışına bakıldığında, o nöronun transfer fonksiyonunun sabit olması şartıyla çıkışını, sadece giden işaretin ağırlığı ve giriş bağlantı ağırlığı tarafından belirlenmektedir. Ağırlıklar, nöronun gelen sinyali doğru cevaplama ve performansının yükseltilmesi için oldukça önemli elemanlardır.

Öğrenmenin metotları iki bölümde incelenebilir.

2.8.3.1. Danışmanlı Öğrenme

Yapay sinir ağına istenen çıktı ile gerçek çıktı karşılaştırılır. YSA rasgele değişmekte olan bağlantı ağırlıklarını daha sonraki döngüde gerçek çıktı ile istenen çıktının arasındaki farkı azaltmak için düzenler. Tüm işleme elemanlarının anlık olarak hatalarını minimuma indirmeye gayret eder. Bu işlem kabul edilebilecek doğruluk seviyesine gelene kadar ağırlıklar sürekli düzenlenir.

2.8.3.2. Danışmansız Öğrenme

Bu öğrenmede çıkış hakkında hiç bilgisi olmayan sistem girdi verilerine göre kendi kendini örneklemektedir. Danışmansız şekilde eğitilebilecek ağlar istenen çıktı bilgisi olmaksızın girdi verilerinin özellikleri yardımıyla ağırlıkların derler. Hebbian öğrenme, Grossberg öğrenme, Kohonen'in özöğütlemeli harita ağı danışmansız öğrenme metotlarına örnek olarak gösterilebilir.

2.8.4. Levenberg-Marquardt Algoritması

Levenberg-Marquardt algoritması bir geri yayılım algoritmasıdır ve YSA'da en çok tercih edilen algoritmadır [56]. Geriye yayılım öğrenmesi esnasında ağ, tüm giriş örüntülerini, çıkış nöronlarında sonuç üretmek için gizli katmanların nöronlarından geçirmektedir. Ardından çıkış katmanında olan hataları bulmak amacıyla, elde ettiği sonuç ile beklenen sonucu kıyaslar. Daha sonrasında çıkış hatasının türevi çıkış katmanından gizli katmanlara geriye doğru yönlendirilir. Hata değerlerinin ortaya çıkmasının ardından nöronların ağırlıkları kendi hatalarına göre düzenlenir. Bu ağırlıkları değiştiren denklemler, ağın performans fonksiyonunu en küçük olacak şekilde derlenir.

İleri beslemeli ağlardaki kullanılmakta olan öğrenme algoritmaları, performans fonksiyonunu en küçük yapacak olan ağırlıkları düzenleyebilmek amacıyla, performans fonksiyonunun gradyenini kullanmaktadırlar. Geri yayılım algoritması ise tüm sinir ağı boyunca gradyen hesaplamasını geriye doğru gerçekleştirir. Gradyen azalması algoritması en basit geri yayılım algoritmasıdır. Gradyen azalması algoritmasında bağ ağırlıkları performans

fonksiyonunun azalmasına göre ayarlanmıştır. Ancak bu metot birçok problemin çözümünde yavaş kalmaktadır ve bundan daha hızlı, yüksek verimli algoritmalar mevcuttur.

Hızlı olan algoritmalar genel şekilde iki bölümde incelenebilir. İlk bölümde olan algoritmalar, deneme yanılmaya dayalı metotlar uygulayarak klasik gradyen azalması tekniğinden daha iyi çözüm sunabilir. Öğrenme hızı değişen geriye yayılım, momentum terimli geriye yayılım ve esnek geriye yayılım algoritmaları deneme yanılma metodunu kullanan geri yayılım algoritmalarındandır. İkinci bölümdeki hızlı algoritmalara gelindiğinde, klasik sayısal optimizasyon metotları kullanılmaktadır. Bunlar, Newton öğrenme algoritmaları, eşlenik gradyen öğrenme algoritması ile Levenberg-Marquardt öğrenme algoritmasıdır. Öğrenme algoritmaları kendilerinden önce geliştirilmiş olan algoritmalar için alternatif olmuştur. Daha önceki algoritmaların iyi olduğu taraflar geliştirilmiş, kötü olduğu tarafları ise azaltmaya çalışmıştır. Levenberg-Marquardt algoritması, Gradyen azalması ile Newton öğrenme algoritmalarının iyi olduğu yönlerinden meydana gelmiştir ve ayrıca bu algoritmaların kısıtlamalarını yok etmiştir. Eşlenik gradyen algoritması için alternatif olarak geliştirilen Newton metotlarında esas adım Hessian matrisinin elde edilmesidir. Bu matris, performans fonksiyonunun ağırlıklara göre ikinci dereceden türevinden oluşmaktadır [55].

$$H(n) = \frac{\partial^2 E(n)}{\partial w^2(n-1)} \quad (2.8)$$

Eşitlik (2.8)'de H Hessian matrisini, E performans fonksiyonunu, w ağırlığının ağırlığını temsil etmektedir. Performans fonksiyonu şartlara göre toplam ani hata ya da ortalama karesel hata şeklinde alınabilmektedir. İleri beslemeli ağların birçoğunda performans fonksiyonu olarak ortalama karesel hata kullanılır.

$$E(n) = E_{ort}(n) = \frac{1}{N} \sum_{n=1}^N \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (2.9)$$

Eşitlik (2.9)'da eğitim kümesinin toplam örüntü sayısı N, hata işareti e_j , ağdaki çıktı katmanının tüm nöronlarını içermekte olan kümeyi de C sembolü ile ifade edilmektedir.

$$e_j(n) = d_j(n) - y_j(n) \quad (2.10)$$

Eşitlik (2.10) da istenen değeri d_j , ağın çıkışını y_j gösterilmiştir ve hata işareti bu şekilde bulunabilmektedir. Hessian matrisinin hesaplanmasının ardından onun tersi bulunup ağırlıklar

tekrardan yenilenebilir. Fakat Hessian matrisi ileri beslemeli ve kompleks bir YSA için hesaplanması güç olan bir matristir. Newton yöntemlerinde ikinci dereceden türevin hesaplanması olmadan işlem yapan bir sınıf mevcuttur. Bu sınıftaki Quasi-Newton yöntemleri olarak bilinen metotlar, Hessian matrisinin yaklaşık bir şeklini algoritmanın tüm iterasyonlarında kullanmaktadır. Aynı şekilde Levenberg-Marquardt algoritması da Hessian matrisinin yaklaşık bir değerini kullanmaktadır. Levenberg-Marquardt algoritmasındaki bu yaklaşık değer Eşitlik (2.11)'deki gibi bulunmaktadır.

$$H(n) = J^T(n)J(n) + \mu I \quad (2.11)$$

Eşitlik (2.11)'de I birim matrisi, μ Marquardt parametresidir. Buradaki J Jakobiyen matrisi ağ hatasının ağırlıklara dayalı birinci dereceden türevinden meydana gelir.

$$J(n) = \frac{\partial e(n)}{\partial w(n-1)} \quad (2.12)$$

Eşitlik (2.12)'de ağ hatalarının vektörü e olarak gösterilmiştir. Hessian matrisine göre Jakobiyen matrisi kolayca hesaplanabildiğinden dolayı tercih edilmektedir. Ağın gradyeni Eşitlik (2.13) ile hesaplanırken ağırlıklar Eşitlik (2.14)'te belirtilen formüle göre değiştirilmektedir.

$$g(n) = J^T(n)e(n) \quad (2.13)$$

$$w(n+1) = w(n) - [H(n)]^{-1}g(n) \quad (2.14)$$

Genel anlamda LM algoritması yavaş yakınsama probleminden etkilenmemektedir. LM algoritmasında maç performans fonksiyonunu çok küçük yapacak olan ağırlık değerini bulabilmektir [55, 56].

3. MATERYAL ve YÖNTEM

Mekanik dayanım açısından iyi performans gösteren AISI 1050 orta karbonlu çelik, üretim sürecinde yaygın olarak kullanılan karbonlu çeliklerden biridir. Bu tez çalışmasının amacı, AISI 1050 çeliğinin yüzey pürüzlülüğünü hesaplamak için ABC algoritması ile basit ve yeni bir formül elde etmektir. Bu amaçla, literatürde [3] kaynağından deneysel veriler alınmıştır. Alınan verileri bir CNC yardımıyla kesme hızı, kesme hızı, kesme derinliği ve kesme derinliği gibi çeşitli kesme parametrelerinden oluşan yirmi deney, yüzey pürüzlülüğü açısından gerçekleştirilmiştir. Yüzey pürüzlülüğü formülü için oluşturulan denklemdeki bilinmeyen katsayıların değerleri, sürü zekasına dayalı ABC algoritması kullanılarak belirlenmiştir. Sunulan formülü kullanarak elde edilen sonuçlar, literatürde daha önce bildirilen yöntem ile karşılaştırılmıştır. Ayrıca kesme hızının, kesme derinliğinin ve besleme hızının yüzey pürüzlülüğü üzerindeki bireysel etkisini değerlendirmek için bir takım parametrik çalışma da yapılmıştır. Yüzey pürüzlülüğünün hesaplanması için önerilen formülasyonun avantajı sofistike bir matematiksel hesaplama gerektirmemesi ve yüzey pürüzlülüğü AISI 1050 çeliğinin kesme parametrelerine göre kolayca değerlendirilebilmesidir. Ayrıca bu formülasyon, AISI 1050 çeliğinin yüzey pürüzlülüğünün hesaplanmasında doğru değerlerin elde edilmesini de sağlamaktadır.

3.1. AISI 1050 Çeliğinin Yüzey Pürüzlülüğü İfadesinin ABC Algoritmasıyla Türetilmesi

Yüzey pürüzlülüğü (RaE-Experimental Avarage Surface Roughness) ifadesini elde etmek için, Tablo 3.1'de verilen deneysel veriler kullanılmıştır. Bu verileri elde etmek amacıyla yirmi adet deney yapılmıştır ve bu deneylerden elde edilen sonuçlara göre yüzey pürüzlülüğü 0,95-6,55 μm aralığında değişmektedir. Deney kesme hızı v (dev / dak), ilerleme hızı f (mm \times dak-1), kesme derinliği d (mm) parametreleri ile gerçekleştirilmiştir. AISI 1050 orta karbonlu çelik plakanın cep frezelemesi, yüksek hız çeliğinden yapılmış 8 mm uçlu bir kesme aleti kullanılarak bir FANUC CTEK CNC yatay işleme merkezinde yürütülmüştür. Bu çalışmada kullanılan karbon çelik plaka 472 \times 184 \times 40 mm³ boyutlarına sahiptir. Cepler, 4 mm'de sabit kademede işlenmiştir. Kırk cep, çelik levha üzerinde, tasarım matrisinde verilen kesme derinliğine uygun olarak işlenmiştir ve her cebin boyutu 30 \times 30 mm²'dir. Ayrıca yapılmış olan deneysel çalışmada yüzey yanıt yöntemi (RSM-Response Surface Methodology) kullanılmıştır. Bu çalışmada kullanılan iş malzemenin kimyasal ve fiziksel özellikleri Tablo 3.3'te listelenmiştir. Tablo 3.2'de ise deneyde kullanılan üç ana parametrenin değer aralıkları belirtilmiştir [3].

Tablo 3.1. AISI 1050'nin yüzey pürüzlülüğü deneyinin sonuçları [3].

Deney Sayısı	Kesme Parametreleri			RaE (μm)
	Kesme hızı v (dev/dak)	İlerleme hızı f (mm/dak)	Kesme derinliği d (mm)	
1	1650,00	450,00	2,00	2,33
2	2325,00	625,00	2,75	4,59
3	975,00	275,00	2,75	4,61
4	2785,21	450,00	2,00	2,31
5	1650,00	450,00	2,00	2,33
6	2325,00	625,00	1,25	1,24
7	1650,00	744,31	2,00	2,35
8	1650,00	450,00	2,00	2,33
9	1650,00	450,00	0,74	0,95
10	1650,00	450,00	2,00	2,30
11	1650,00	450,00	2,00	2,32
12	1650,00	450,00	3,26	6,55
13	2325,00	275,00	1,25	1,02
14	1650,00	155,69	2,00	2,09
15	514,79	450,00	2,00	2,88
16	975,00	275,00	1,25	1,28
17	2325,00	275,00	2,75	4,42
18	975,00	625,00	1,25	1,16
19	975,00	625,00	2,75	4,21
20	1650,00	450,00	2,00	2,33

Tablo 3.2. Deneyde kullanılan üç ana parametrenin değer aralıkları [3].

Parametreler	Değer aralığı	
	Minimum	Maksimum
v : Kesme Hızı (dev/dak)	514,79	2785,21
f : İlerleme Hızı (mm/dak)	155,69	744,31
d : Kesme Derinliği (mm)	0,74	3,26

Tablo 3.3. AISI 1050 çeliğinin kimyasal ve mekanik özellikleri [3].

Kimyasal bileşim (wt.-%)	C	P	S	Mn	Cr	Si
	0,47	0,04	0,04	0,80	0,11	0,10
Mekanik özellikler	Akma dayanımı (MPa)	Çekme dayanımı (MPa)	Uzama (%)	Brinell sertliği (HB)		
	580	690	15	197		

Yüzey pürüzlülüğü ile ilgili deneysel parametreler kullanılarak en iyi formülasyon yapısı oluşturulmuştur. Bu formülasyonda, kesme hızı, ilerleme hızı ve kesme derinliği parametrelerine bağlı olarak bilinmeyen katsayılardan (a_i) oluşan yüzey pürüzlülüğü denklemi inşa edilmiştir. ABC yönteminde aşağıdaki ortalama yüzde hatası (OYH) denklemini kullanarak hata minimize edilmiştir.

$$OYH = \sum_{k=1}^{DS} \left[100 \times \left| \frac{RaE_{den_k} - RaE_{hes_k}}{RaE_{den_k}} \right| \right] \quad (3.1)$$

Eşitlik (3.1)'deki denklemde, sırasıyla RaE_{den} ve RaE_{hes} , deneysel ve hesaplanan yüzey pürüzlülüğü değerleridir. Gerçekleştirilmiş olan çalışmada ABC algoritmasının optimizasyon parametrelerinin atanmış değerleri Tablo 3.4'te verilmiştir.

Tablo 3.4. Bu çalışmada kullanılan ABC algoritmasının optimizasyon parametreleri [57].

ABC algoritmasının parametreleri	Atanan değerler
Boyut sayısı (D)	5
Popülasyon büyüklüğü (NP)	60
Deneme Sayısı	NP*D
Maksimum iterasyon sayısı	2000

Yüzey pürüzlülüğünü elde etmek için birçok denklem denemesi yapılmıştır. Bu denklemlerden çözüme yakın olanlarının bazıları aşağıdaki eşitliklerdir. Daha önce denenmiş ve aşağıda verilmiş olan eşitliklerinden en iyi sonuç Eşitlik (3.6) ile sağlamıştır. Matematiksel ifadelerin katsayıları ise optimum olarak belirlenmiş olup bu katsayılar Tablo 3.5'te verilmiştir.

$$RaE_{hes} = a_1 + a_2 \cdot f + a_3 \cdot d + a_4 \cdot v + d^{a_5} + \frac{a_6}{f} \quad (3.2)$$

$$RaE_{hes} = a_1 + a_2 \cdot f + a_3 \cdot d + a_4 \cdot v + d^{a_5} \quad (3.3)$$

$$RaE_{hes} = a_1 + a_2 \cdot f + a_3 \cdot d + \frac{a_4}{v} + d^{a_5} \quad (3.4)$$

$$RaE_{hes} = a_1 + \sin\left(-\frac{a_2}{f}\right) + a_3 \cdot d + \frac{a_4}{v} + v^{a_5} + \left(\frac{a_6}{v \cdot d}\right)^{a_7} \quad (3.5)$$

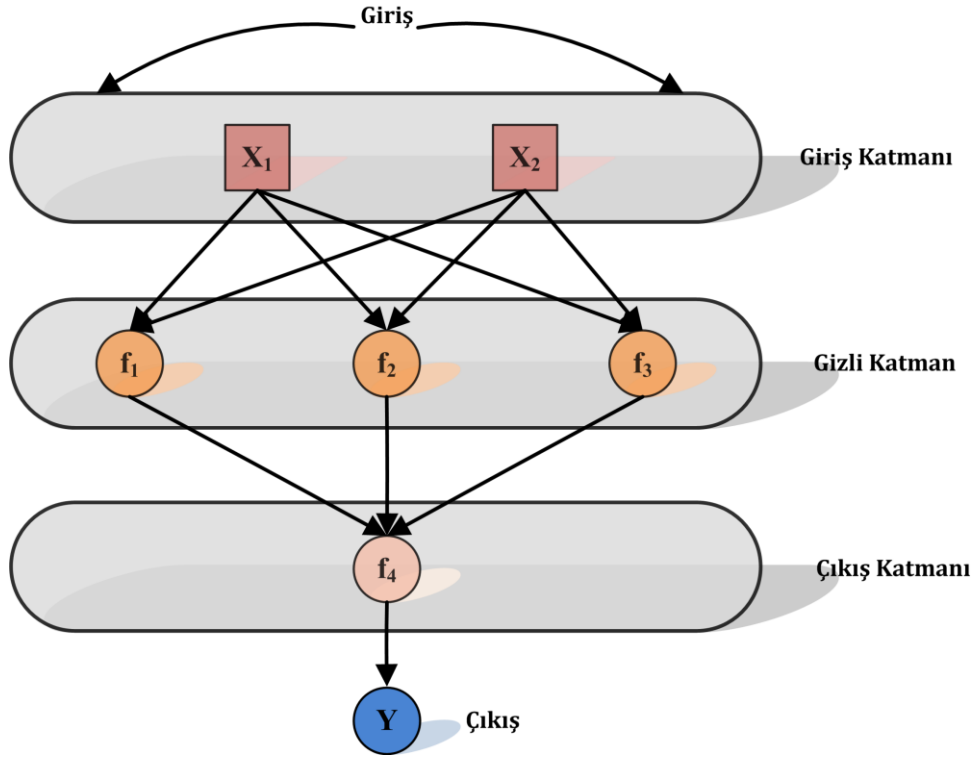
$$RaE_{hes} = a_1 + \frac{a_2}{f} + a_3 \cdot d + \frac{a_4}{v} + d^{a_5} \quad (3.6)$$

Tablo 3.5. ABC algoritması ile belirlenen AISI 1050 çeliğinin yüzey pürüzlülüğü ifadesi için katsayı değerleri.

İndeks (i) a_i	1	2	3	4	5	6	7
Eşitlik (3.2)	2,362	-0,0011	-1,276	-0,0001	1,888	-172,178	-
Eşitlik (3.3)	1,614	0,0001	-1,490	-0,0001	1,935	-	-
Eşitlik (3.4)	1,287	0,0001	-1,526	285,916	1,943	-	-
Eşitlik (3.5)	1,527	-30,189	-1,432	-114,484	1,935	993,802	9,174
Eşitlik (3.6)	1,422	-35,670	-1,512	281,245	1,940	-	-

3.2. AISI 1050 Çeliğinin Yüzey Pürüzlülüğünü Tahmin Etmek İçin YSA Modelinin Oluşturulması

Bu tez çalışmasında ABC algoritması kullanılarak yüzey pürüzlülüğü değerinin hesaplanmasında kullanılacak matematiksel bir ifade türetilmiştir. Ayrıca bu problemde uygulanmak üzere ek olarak YSA tabanlı bir model de oluşturulmuştur. Biyolojik sinir ağı sistemine benzetilerek geliştirilmiş olan yapay sinir ağı iyi bir doğruluk değeri elde edebilen hesaplama modelidir. Birçok YSA çeşidi vardır. Yapılan bu çalışmada ÇKA kullanılmıştır. ÇKA'nın ağ yapısı LM (Levenberg-Marguardt), BFG (BFGS Quasi-Newton), RP (Resilient Backpropagation), SCG (Scaled Conjugate Gradient) gibi algoritmalar yardımıyla eğitilebilmektedir. Gerçekleştirilen çalışmada iyi yakınsama ile hızlı öğreneme gösteren LM algoritmasıyla eğitilmiştir [58, 59]. Şekil 3.1'e göre ÇKA giriş katmanı, çıkış katmanı, bir ya da birden fazla gizli katmanla oluşturulmuş olabilir.



Şekil 3.1. ÇKA'nın yapısı.

Giriş katmanının nöronları, giriş sinyalleri olan x_i 'yi gizli katmandaki nöronlara yayarlar. Gizli katmandaki nöron olan j 'nin tümü, giriş katmanındaki ilgili bağlantıların kuvvetleriyle ağırlıklandırılır, ardından bu değer eşik değeri ile toplanıp aktivasyon fonksiyonu (transfer fonksiyonu) olan f ile işleme tabi tutulur. Bu işlemin matematiksel ifadesi Eşitlik (3.7)'te gösterilmiştir.

$$y_j = f(\sum w_{ji}x_i + b) \quad (3.7)$$

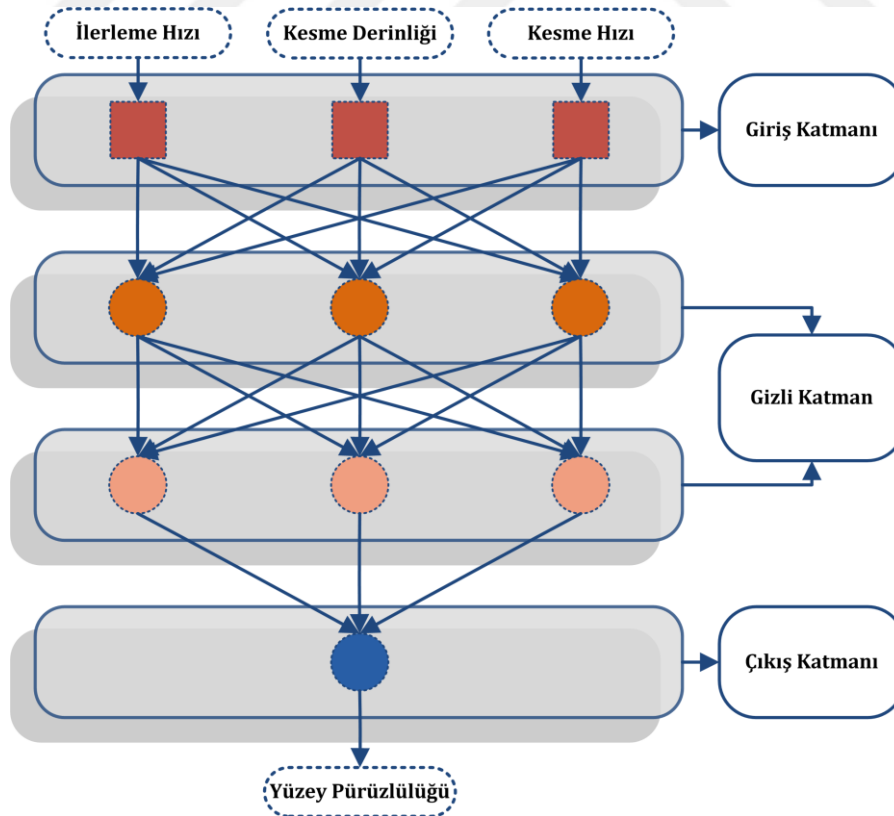
Eşitlik (3.7)'teki f fonksiyonu basit bir eşik fonksiyonu, sigmoid fonksiyonu, hiperbolik tanjant fonksiyonu, purelin fonksiyonu, radyal temel fonksiyonu gibi fonksiyonlar. olabilmektedir [60, 61]. Çıkış katmanının çıkışı da benzer bir şekilde hesaplanmaktadır. Sinir ağının eğitimi, öğrenme algoritmalarından biri kullanılıp ağ ağırlıklarının ayarlanması ile gerçekleştirilmektedir. Eğitimdeki öğrenme algoritması, t zamanındaki, i ve j nöronlarının arasında olan bağların ağırlıklarındaki Δw_{ij} değişimlerini vermektedir. Eşitlik (3.8) ve Eşitlik (3.9)'da LM öğrenme algoritmasında ağırlıklar için kullanılan matematiksel formül verilmiştir.

$$w_{ji}(t + 1) = w_{ji}(t) + \Delta w_{ji}(t) \quad (3.8)$$

$$\Delta w_{ji} = [J^T(w)J(w) + \mu I]^{-1} J^T(w) E(w) \quad (3.9)$$

Eşitlik (3.9)'da J jakobiyen matrisini, μ momentum parametresi, I , birim matrisini ve $E(w)$ hata fonksiyonunu göstermektedir. Jakobiyen matrisi ağırlıkların biaslara göre hatalarının birinci türevine eşittir. μ sabiti başarılı işlemden sonra azaltılır fakat bir tek hata karelerinin toplamı arttığı zaman arttırılır.

Oluşturulan modelde giriş katmanında 3 tane nöron, gizli katmanda 3 nörondan oluşan iki adet katman ve çıkış katmanında da 1 tane nöron bulunmaktadır. Oluşturulmuş olan bu model Şekil 3.2'de gösterilmiştir.



Şekil 3.2. Tasarlanan YSA modelinin katmanlarının yapısı.

Tablo 3.6. Oluşturulan YSA modelinin parametreleri.

YSA modelinin parametreleri	Atanan değerler
Çevrim sayısı	100
Minimum eğim	10^{-7}
Moment parametresi (μ)	0,005
μ artış	10
μ azalış	0,1
Maksimum μ	10^{10}

Oluşturulan YSA modelinin parametreleri Tablo 3.6’da verilmiştir. Ayrıca giriş katmanı, gizli katman ve çıkış katmanında sırasıyla tanjant sigmoid, tanjant sigmoid ve purelin fonksiyonları kullanılmıştır. Modelin eğitimi sırasında kesme parametreleri olan, ilerleme hızı, kesme derinliği ve kesme hızı parametreleri modelin girişleri olarak tanımlanırken yüzey pürüzlülüğü değeri de modelin çıkışı olarak tanımlanmıştır.

3.3. MATLAB® (MATrix LABoratory)

1985 yılında C.B. MOLER tarafından geliştirilmiştir. MATLAB® (MATrix LABoratory), mühendislik hesaplamalarında ve özelliklede pozitif bilimde, matris tabanlı matematik ortamlarında etkin bir şekilde kullanılan bir yazılım dilidir. ABD merkezli MathWorks firmasının geliştirilmeye devam ettiği MATLAB®, fourier analizi, istatistik ve optimizasyon gibi pek çok matematiksel işlemleri hızlı ve etkili olarak yapmasının yanında, 2D ve 3D grafik çizimlerini de iyi şekilde gerçekleştirebilmektedir [62].

4. BULGULAR ve TARTIŞMA

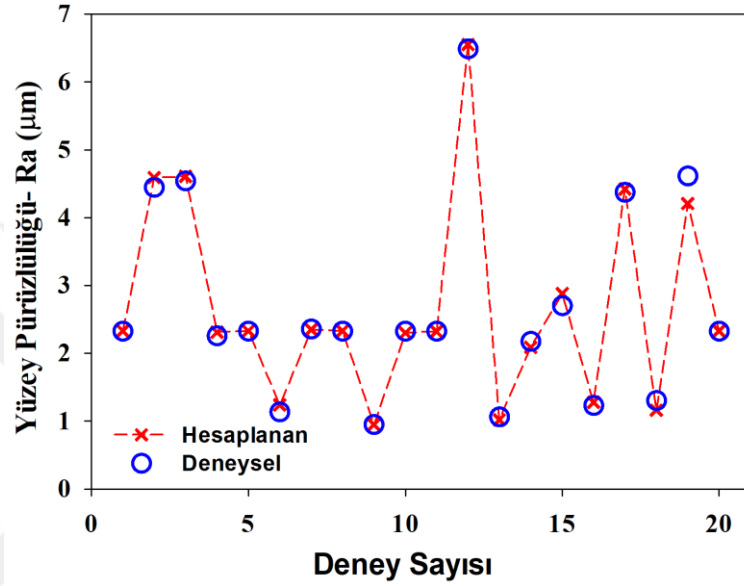
4.1. AISI 1050 Çeliğinin Yüzey Pürüzlülüğü İçin ABC Algoritmasıyla Türetilen İfadenin Bulguları

ABC algoritmasıyla elde edilmiş olan Eşitlik (3.6) kullanılarak yapılan hesaplamalara göre, deneysel RaE ve hesaplanan RaE arasındaki OYH %2,95 olarak elde edilmiştir. Ayrıca Eşitlik (3.2), Eşitlik (3.3), Eşitlik (3.4) ve Eşitlik (3.5)'in OYH'ları sırasıyla %4,91, %4,05, %3,37, %3,56 olarak tespit edilmiştir. Eşitlik (3.6) ile elde edilmiş yüzey pürüzlülüğü ifadesinin sonuçları Şekil 4.1'de çizilmiştir. Deneysel ve hesaplanan sonuçlar arasındaki gözlemlenen bu iyi uyum yeni yüzey pürüzlülüğü formülünün doğruluğunu desteklemektedir. Ayrıca önerilen yüzey pürüzlülüğü ifadesinin uyumu, korelasyon katsayısı (R^2) ile gözlemlenmiştir. Deneysel RaE ve hesaplanan RaE arasındaki yakınlık korelasyon katsayısı açısından yüksek bir değer ile 0,99 olarak hesaplanmış Şekil 4.2'de grafiksel olarak verilmiştir. Önerilen ifadenin geçerliliğini doğrulamak için, bu çalışmada hesaplanan yüzey pürüzlülüğü sonuçları, daha önce literatürde yayınlanan AISI 1050 çeliğinin hesaplanan sonucu [3] ile karşılaştırılmıştır. Bu karşılaştırma sonuçları ve buna karşılık gelen yüzdelik hataları Tablo 4.1'de verilmektedir.

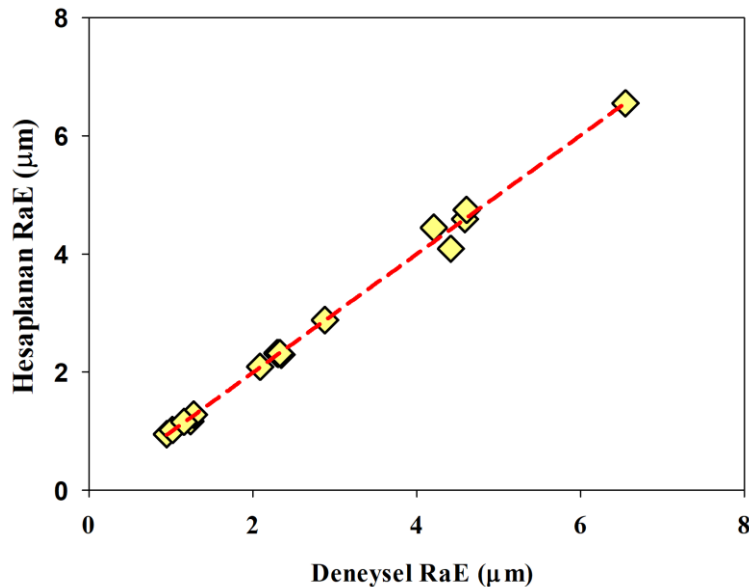
Tablo 4.1. Eşitlik (3.6) ile bulunan yüzey pürüzlülüğünün karşılaştırmalı sonuçları.

Deney Sayısı	Yüzey Pürüzlülüğü				Hata (%)	
	RaE (μm)					
	Deneysel	Hesaplanan	[3]		ABC	[3]
	[3]	ABC	[3]		ABC	[3]
1	2,33	2,33	2,33		0,00	0,00
2	4,59	4,45	4,58		3,05	0,22
3	4,61	4,54	4,66		1,52	1,08
4	2,31	2,26	2,45		2,16	5,96
5	2,33	2,33	2,33		0,00	0,00
6	1,24	1,14	1,27		8,06	2,42
7	2,35	2,36	2,22		0,43	5,47
8	2,33	2,33	2,33		0,00	0,00
9	0,95	0,95	6,49		0,00	583,32
10	2,30	2,33	2,33		1,30	1,30
11	2,32	2,33	2,33		0,43	0,43
12	6,55	6,49	6,49		0,92	0,89
13	1,02	1,06	0,90		3,92	11,57
14	2,09	2,18	2,14		4,31	2,59
15	2,88	2,70	2,45		6,25	15,01
16	1,28	1,23	1,37		3,91	7,03
17	4,42	4,37	4,38		1,13	1,00
18	1,16	1,30	1,26		12,07	8,45
19	4,21	4,61	4,38		9,50	4,13
20	2,33	2,33	2,33		0,00	0,00
OYH (%)					2,95	32,54

Tablo 4.1'deki sonuçlar neticesinde, önermiş olunan ifade ile hesaplanan yüzey pürüzlülük değerlerinin, daha önceki verilen öneriye göre daha çok geliştirildiği görülmektedir. Deneysel ve hesaplanan yüzey pürüzlülüğünün değerleri arasındaki bu iyi uyum, ABC algoritması kullanılarak elde edilen yüzey pürüzlülüğü ifadesinin geçerliliğini desteklemektedir. Burada sunulan ifade sayesinde, sofistike fonksiyonların karmaşık matematiksel dönüşümleri gerektirmedikinden, bilimsel bir hesap makinesini kullanarak AISI 1050 çelik yüzey pürüzlülüğü kolayca hesaplanabilmektedir.



Şekil 4.1. Hesaplanan ve deneysel yüzey pürüzlülüğü değerleri.




Şekil 4.2. Hesaplanan ve deneysel yüzey pürüzlülüğü değerleri arasındaki ilişki.

Önerilmiş olan formülasyondaki parametrelerin yüzey pürüzlülüğüne etkisinin incelenmesi için bir parametrik çalışma gerçekleştirilmiştir. Aşağıda gösterilen grafikler önerilen

formülasyon yardımıyla elde edilmiştir. Yapılmış olan çalışmada grafiklerin çizmek için kullanılan parametrelerin değerleri hesaplanırken, üç parametreden ikisinin alt ve üst değerlerine göre ortalaması alınıp bir değere sabitlenmiştir. Parametrik çalışmada incelenecek olan parametrenin değeri ise alt ve üst değerlerinin aralığında sabit aralıklarla artırılarak belirlenmiştir. Bu şekilde o parametrenin yüzey pürüzlülüğüne olan etkisi araştırılmıştır. Tablo 4.2’de kesme hızının parametrik çalışmasına ait veriler gösterilmiştir. Tablo 4.2’de görüldüğü üzere ilerleme hızı ve kesme derinliğinin değerleri sırasıyla 294,31 mm / dak ve 1.26 mm olarak belirlemiştir. Bu şekilde, yüzey pürüzlülüğü ve kesme hızı arasındaki ilişki gözlemlenmiştir. Şekil 4.3’ te ise kesme hızının yüzey pürüzlülüğüne etkisi grafiksel olarak sunulmaktadır. Tablo 4.2 ve Şekil 4.3’ten çıkarılan sonuca göre kesme hızı değeri arttıkça yüzey pürüzlülüğünün azaldığı görülmektedir. Bu azalış özellikle 500-1250 dev / dak aralığında belirgin şekildedir.

Tablo 4.2. Kesme hızının yüzey pürüzlülüğü üzerindeki etkisinin parametrik çalışması.

Örnek Sayısı	v (dev/dak)	f (mm/dak)	d (mm)	Hesaplanan Ra (μm)
1	514,79	294,31	1,260	1,51
2	741,83	294,31	1,260	1,34
3	968,87	294,31	1,260	1,25
4	1195,92	294,31	1,260	1,20
5	1422,96	294,31	1,260	1,16
6	1650,00	294,31	1,260	1,13
7	1877,04	294,31	1,260	1,11
8	2104,08	294,31	1,260	1,09
9	2331,13	294,31	1,260	1,08
10	2558,17	294,31	1,260	1,07
11	2785,21	294,31	1,260	1,06

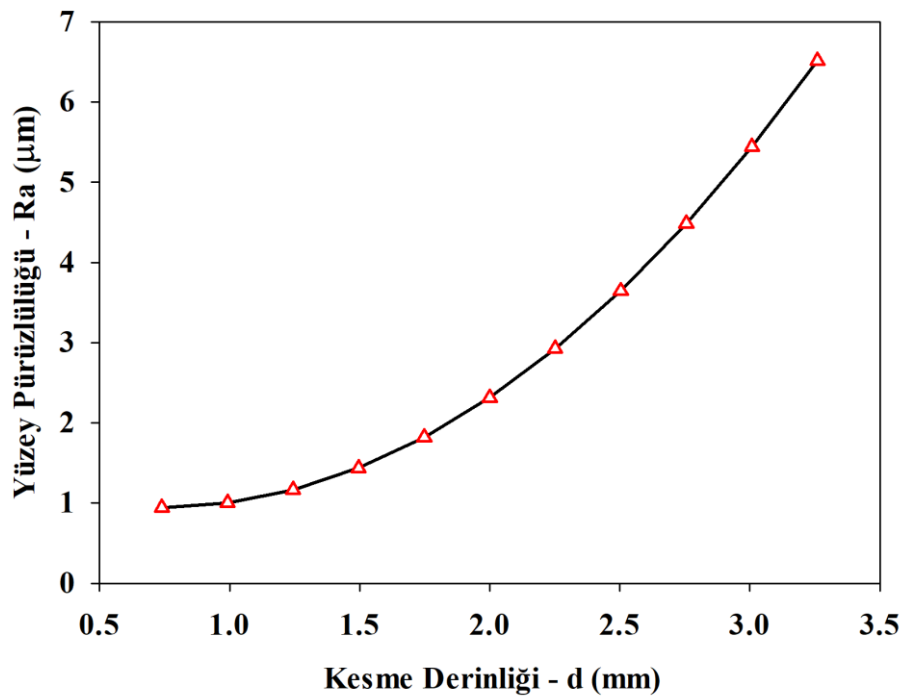


Şekil 4.3. Kesme hızı ile yüzey pürüzlülüğü arasındaki ilişki.

Tablo 4.3'te kesme derinliğinin parametrik çalışmasına ait veriler gösterilmiştir. Tablo 4.3'ten görüldüğü üzere ilerleme hızının ve kesme hızının değerleri sırasıyla 294,31 mm / dak ve 1135,21 dev/dak olarak belirlemiştir. Bu sayede, yüzey pürüzlülüğü ve kesme derinliği arasındaki ilişki gözlemlenmiştir. Şekil 4.4'te ise kesme derinliğinin yüzey pürüzlülüğüne etkisi grafiksel olarak sunulmaktadır. Tablo 4.3 ve Şekil 4.4'ten çıkarılan sonuca göre kesme derinliğinin değeri arttıkça yüzey pürüzlülüğünün de arttığı görülmektedir ve bu istemediğimiz bir durumdur. Yüzey pürüzlülüğündeki bu artış 1,5-3,5 mm kesme derinliği aralığında daha belirgin olduğu gözlemlenmektedir.

Tablo 4.3. Kesme derinliğinin yüzey pürüzlülüğü üzerindeki etkisinin parametrik çalışması.

Örnek Sayısı	v (dev/dak)	f (mm/dak)	d (mm)	Hesaplanan Ra (μm)
1	1135,21	294,31	0,740	0,99
2	1135,21	294,31	0,992	1,03
3	1135,21	294,31	1,244	1,19
4	1135,21	294,31	1,496	1,47
5	1135,21	294,31	1,748	1,86
6	1135,21	294,31	2,000	2,36
7	1135,21	294,31	2,252	2,97
8	1135,21	294,31	2,504	3,70
9	1135,21	294,31	2,756	4,53
10	1135,21	294,31	3,008	5,47
11	1135,21	294,31	3,260	6,52




Şekil 4.4. Kesme derinliği ile yüzey pürüzlülüğü arasındaki ilişki.

Tablo 4.4'te ilerleme hızının parametrik çalışmasına ait veriler gösterilmiştir. Tablo 4.4'ten görüldüğü üzere kesme derinliğinin ve kesme hızının değerleri sırasıyla 1,260 mm ve 1135,21 dev/dak olarak belirlenmiştir. Böylece, yüzey pürüzlülüğünün ile ilerleme hızı arasındaki ilişki gözlemlenmiştir. Şekil 4.5'te ise ilerleme hızının yüzey pürüzlülüğüne etkisi grafiksel olarak gösterimi verilmiştir. Tablo 4.4 ve Şekil 4.5'ten çıkarılan sonuca göre ilerleme hızı arttıkça yüzey pürüzlülüğünün de arttığı görülmektedir ve bu da istenmeyen bir durumdur. Yüzey pürüzlülüğündeki bu artış 200-600 mm/dak ilerleme hızı aralığında daha belirgin olduğu gözlemlenmektedir.

Tablo 4.4. İlerleme hızının yüzey pürüzlülüğü üzerindeki etkisinin parametrik çalışması.

Örnek Sayısı	v (dev/dak)	f (mm/dak)	d (mm)	Hesaplanan Ra (μm)
1	1135,21	155,69	1,260	1,10
2	1135,21	214,55	1,260	1,16
3	1135,21	273,41	1,260	1,20
4	1135,21	332,28	1,260	1,22
5	1135,21	391,14	1,260	1,24
6	1135,21	450,00	1,260	1,25
7	1135,21	508,86	1,260	1,26
8	1135,21	567,72	1,260	1,27
9	1135,21	626,59	1,260	1,27
10	1135,21	685,45	1,260	1,28
11	1135,21	744,31	1,260	1,28



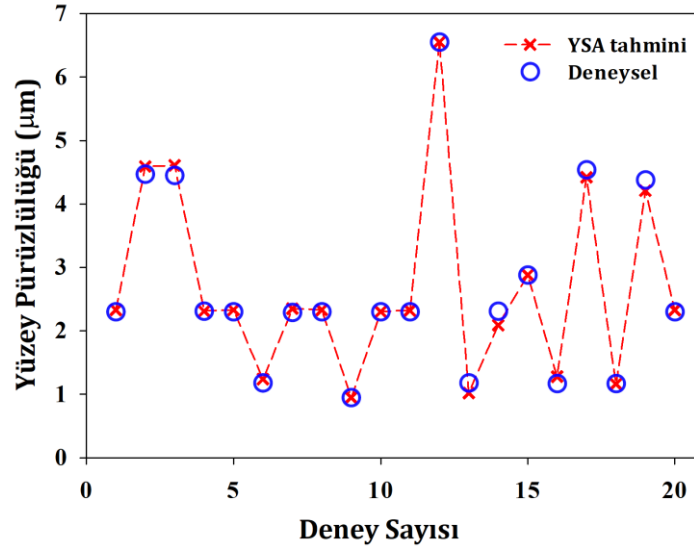
Şekil 4.5. İlerleme hızı ile yüzey pürüzlülüğü arasındaki ilişki.

4.2 AISI 1050 Çeliğinin Yüzey Pürüzlülüğünü Tahmin Etmek İçin YSA Modelinden Elde Edilen Bulgular

Oluşturulan çok katmanlı YSA modeli, yapılmış olan deneyler için yüzey pürüzlülüğü tahmininde bulunmak üzere, Tablo 3.1 de verilmiş olan giriş ve çıkış değerleri arasındaki bağlantıya göre eğitilmiştir. Şekil 3.2'deki katman yapısına sahip YSA modeli tarafından öngörülen AISI 1050 çeliğinin yüzey pürüzlülüğünün OYH değeri 3,10 olarak elde edilmiştir. Bu sonuç bize YSA'nın başarılı olduğu gösterir. Tablo 4.5 ve Şekil 4.6'da karşılaştırmalı olarak verilmiştir.

Tablo 4.5. YSA ile tahmin edilen yüzey pürüzlülüğünün deney sonuçlar ile karşılaştırması.

Deney Sayısı	Yüzey Pürüzlülüğü RaE (μm)		Yüzde hata
	Deneysel [3]	YSA	
1	2,33	2,3	1,29
2	4,59	4,47	2,61
3	4,61	4,45	3,47
4	2,31	2,31	0,00
5	2,33	2,3	1,29
6	1,24	1,18	4,84
7	2,35	2,29	2,55
8	2,33	2,3	1,29
9	0,95	0,95	0,00
10	2,30	2,3	0,00
11	2,32	2,3	0,86
12	6,55	6,55	0,00
13	1,02	1,18	15,69
14	2,09	2,31	10,53
15	2,88	2,88	0,00
16	1,28	1,17	8,59
17	4,42	4,54	2,71
18	1,16	1,17	0,86
19	4,21	4,38	4,04
20	2,33	2,3	1,29
OYH (%)			3,10



Şekil 4.6. YSA ile tahmin edilen yüzey pürüzlülüğünün deney sonuçları ile karşılaştırması.

Bu tezin kapsamında son olarak çeşitli öğrenme algoritmaları yardımıyla eğitilmiş YSA modellerinin yüzey pürüzlülüğü tahmini için sergiledikleri performansları karşılaştırılmıştır. Aynı şekilde performans kriteri olarak OYH değeri esas alınmıştır. Buna göre 7 adet YSA oluşturulmuştur ve bunlar LM (Levenberg-Marquardt), BFG (BFGS Quasi-Newton), RP (Resilient Backpropagation), SCG (Scaled Conjugate Gradient), CGB (Conjugate Gradient with Powell/Beale Restarts), CGF (Fletcher-Powell Conjugate Gradient), OSS (One Step Secant) algoritmaları kullanılarak eğitilmiştir. Oluşturulmuş bu modellerin giriş katmanında 3 adet nöron, gizli katmanda 3 ve 4 nörondan oluşan iki adet katman ve çıkış katmanında 1 nöron bulunmaktadır. Bunun yanında giriş katmanı ve gizli katmanda tanjant sigmoid fonksiyonu, çıkış katmanındaysa purelin fonksiyonu kullanılmıştır. Tablo 4.6'da eğitimde kullanılan modellere atanan parametre değerleri verilirken Tablo 4.7'de eğitilen modellerin tohum değerleri gösterilmektedir. Oluşturulmuş 7 modelin eğitimi ve testi [3]'de verilmiş olan veriler kullanılarak yapılmıştır. 7 farklı algoritma ile eğitilmiş olan modelin tahmini yüzey pürüzlülüğü değerleri ve ortalama yüzde hataları Tablo 4.8 ve Tablo 4.9 de verilmiştir. Ayrıca eğitimde kullanılan her bir algoritma için eğitim ve test sonuçlarının karşılaştırmalı grafiksel gösterimi MATLAB ile çizdirilmiştir. Eğitim ve test sonuçları olan Tablo 4.8 ve Tablo 4.9 incelendiğinde en iyi çözümün LM algoritması tarafından verildiğini açıkça görülmektedir.

Tablo 4.6. Çeşitli eğitim algoritmaları ile eğitilen modellerin parametreleri.

YSA modellerinin parametreleri	Atanan değerler
Çevrim sayısı	500
Minimum eğim	10^{-7}
Deneme sayısı	400
Moment parametresi (μ)	0,0001
μ artış	10
μ azalış	0,1
Maksimum μ	10^{10}

Tablo 4.7. Çeşitli eğitim algoritmaları ile eğitilen modellerin en düşük tohum değerleri.


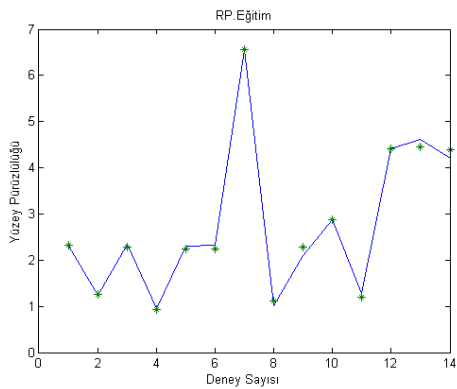
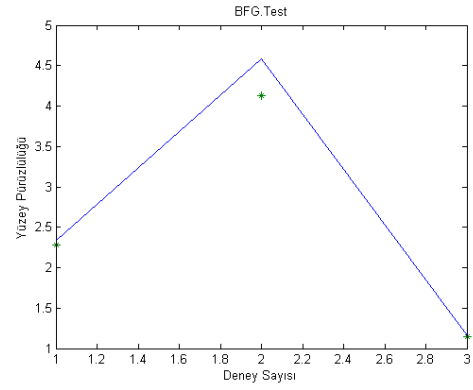

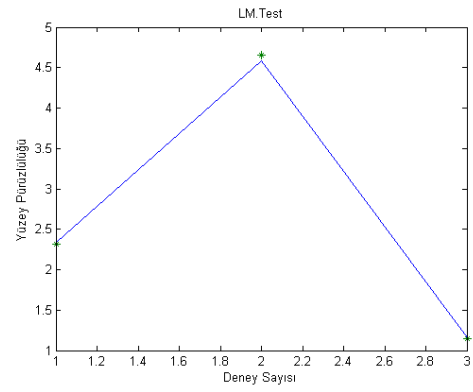
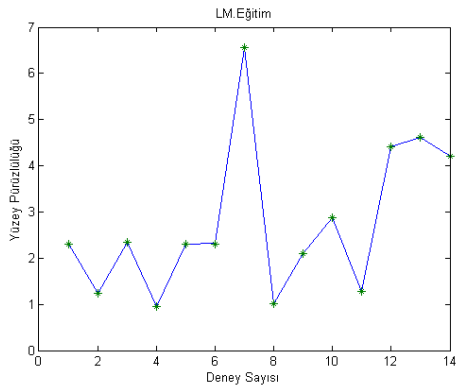
YSA algoritmaları	En düşük tohum değerleri
LM	493499820
BFG	$1,074374218000000 \times 10^9$
RP	3,398506129692411
SCG	$1,699071216000000 \times 10^9$
CGB	556659358
CGF	$1,253543293000000 \times 10^9$
OSS	$1,141668146000000 \times 10^9$


Tablo 4.8. Çeşitli eğitim algoritmaları ile eğitilen modellerin deneysel veriler için tahmin edilen yüzey pürüzlülük değeri ve hesaplanan OYH'ları.

Deneysel Ra(μm)	LM		BFG		RP		SCG		CGB		CGF		OSS	
	LM _T (μm)	LM _H (%)	BFG _T (μm)	BFG _H (%)	RP _T (μm)	RP _H (%)	SCG _T (μm)	SCG _H (%)	CGB _T (μm)	CGB _H (%)	CGF _T (μm)	CGF _H (%)	OSS _T (μm)	OSS _H (%)
2,31	2,30	0,43	2,26	2,16	2,32	0,43	2,04	11,69	2,25	2,60	2,02	12,55	2,09	9,52
1,24	1,24	0,00	1,12	9,68	1,25	0,81	1,20	3,23	1,09	12,10	1,19	4,03	1,26	1,61
2,35	2,34	0,43	2,24	4,68	2,27	3,40	2,57	9,36	2,61	11,06	2,39	1,70	2,20	6,38
0,95	0,94	1,05	0,99	4,21	0,92	3,16	1,00	5,26	0,86	9,47	1,07	12,63	1,11	16,84
2,30	2,31	0,43	2,27	1,30	2,24	2,61	2,29	0,43	2,33	1,30	2,30	0,00	2,23	3,04
2,32	2,31	0,43	2,27	2,16	2,24	3,45	2,29	1,29	2,33	0,43	2,30	0,86	2,23	3,88
6,55	6,54	0,15	6,55	0,00	6,55	0,00	5,99	8,55	5,13	21,68	5,04	23,05	6,04	7,79
1,02	1,02	0,00	1,16	13,73	1,11	8,82	1,17	14,71	1,03	0,98	1,18	15,69	1,27	24,51
2,09	2,08	0,48	2,31	10,53	2,28	9,09	2,34	11,96	2,08	0,48	2,21	5,74	2,27	8,61
2,88	2,88	0,00	2,88	0,00	2,88	0,00	2,82	2,08	2,42	15,97	2,64	8,33	2,39	17,01
1,28	1,27	0,78	1,18	7,81	1,19	7,03	1,07	16,41	1,05	17,97	1,22	4,69	1,31	2,34
4,42	4,42	0,00	4,42	0,00	4,40	0,45	4,43	0,23	4,56	3,17	4,74	7,24	4,54	2,71
4,61	4,61	0,00	4,56	1,08	4,45	3,47	4,93	6,94	4,61	0,00	4,87	5,64	4,80	4,12
4,21	4,20	0,24	4,27	1,43	4,38	4,04	4,09	2,85	4,76	13,06	4,90	16,39	4,74	12,59
OYH:	0,32		4,20		3,34		6,79		7,88		8,47		8,64	

Tablo 4.9. Çeşitli eğitim algoritmaları ile eğitilen modellerin 3 adet test verisi ile tahmin edilen yüzey pürüzlülük değeri ve hesaplanan OYH'ları.

Deneysel Ra(μm)	LM		BFG		RP		SCG		CGB		CGF		OSS	
	LM _T (μm)	LM _H (%)	BFG _T (μm)	BFG _H (%)	RP _T (μm)	RP _H (%)	SCG _T (μm)	SCG _H (%)	CGB _T (μm)	CGB _H (%)	CGF _T (μm)	CGF _H (%)	OSS _T (μm)	OSS _H (%)
2,33	2,31	0,86	2,27	2,58	2,24	3,86	2,29	1,72	2,33	0,00	2,30	1,29	2,23	4,29
4,59	4,65	1,31	4,13	10,02	4,53	1,31	4,73	3,05	4,71	2,61	4,78	4,14	4,48	2,40
1,16	1,15	0,86	1,14	1,72	1,16	0,00	1,17	0,86	1,11	4,31	1,24	6,90	1,30	12,07
OYH:	1,01		4,77		1,72		1,88		2,31		4,11		6,25	





Şekil 4.7. Çeşitli eğitim algoritmaları ile eğitilen modellerin deneysel verilerinin eğitim ve test değerlerinin grafiksel karşılaştırılması.

Şekil 4.7’de yeşil nokta modelin tahmin ettiği değeri mavi sürekli çizgi ise deneysel verinin değerini göstermektedir.

Yapılan çalışmaların sonucu Tablo 4.10'da karşılaştırmalı olarak sunulmuştur. Bu tablodan gözlemleniyor ki hem ABC algoritması yardımıyla ortaya konan matematiksel ifade hem de YSA modeli literatürdeki [3] sonucuna kıyasla daha iyi sonuçlar elde etmiştir.

Tablo 4.10. AISI 1050 çeliğinin yüzey pürüzlülük değerini hesaplama ve tahmin etme çalışmalarının karşılaştırılması.

Deney Sayısı	Yüzey Pürüzlülüğü <i>RaE</i> (μm)				Hata (%)		
	Deneysel	[3]	YSA	ABC	[3]	YSA	ABC
	[3]						
1	2,33	2,33	2,3	2,33	0,00	1,29	0,00
2	4,59	4,58	4,47	4,45	0,22	2,61	3,05
3	4,61	4,66	4,45	4,54	1,08	3,47	1,52
4	2,31	2,45	2,31	2,26	5,96	0,00	2,16
5	2,33	2,33	2,3	2,33	0,00	1,29	0,00
6	1,24	1,27	1,18	1,14	2,42	4,84	8,06
7	2,35	2,22	2,29	2,36	5,47	2,55	0,43
8	2,33	2,33	2,3	2,33	0,00	1,29	0,00
9	0,95	6,49	0,95	0,95	583,32	0,00	0,00
10	2,30	2,33	2,3	2,33	1,30	0,00	1,30
11	2,32	2,33	2,3	2,33	0,43	0,86	0,43
12	6,55	6,49	6,55	6,49	0,89	0,00	0,92
13	1,02	0,90	1,18	1,06	11,57	15,69	3,92
14	2,09	2,14	2,31	2,18	2,59	10,53	4,31
15	2,88	2,45	2,88	2,70	15,01	0,00	6,25
16	1,28	1,37	1,17	1,23	7,03	8,59	3,91
17	4,42	4,38	4,54	4,37	1,00	2,71	1,13
18	1,16	1,26	1,17	1,30	8,45	0,86	12,07
19	4,21	4,38	4,38	4,61	4,13	4,04	9,50
20	2,33	2,33	2,3	2,33	0,00	1,29	0,00
OYH (%)					32,54	3,10	2,95

5. SONUÇLAR ve ÖNERİLER

Bu tez çalışmasının kapsamında orta karbonlu AISI 1050 çeliğinin yüzey pürüzlülüğü üzerinde etkili olan üç parametre araştırılmış ve bu parametrelere bağlı yüzey pürüzlülüğü hesabında kullanılabilecek, ABC algoritması kullanılarak türetilmiş olan matematiksel bir formül ve YSA kullanılıp gerçekleştirilmiş bir model önerilmiştir. Sunulan matematiksel ifadenin ve modelinin yüzey pürüzlülüğü tahmininde göstermiş olduğu başarı, literatürdeki benzer bir problemde kullanılmak için paylaşılmış olan diğer bir ifadeyle kıyaslanmıştır. Bu çalışmada önerilen matematiksel ifade ve YSA modelinin yüzey pürüzlülüğü değerlerinin hesaplanmasında kullanılabileceği sonucuna varılmıştır. Çalışmanın sonundaysa oluşturulmuş olan YSA modeli çeşitli eğitim algoritmaları ile eğitilmiş ve bu modellerin yüzey pürüzlülüğünü tahmin etmelerinde başarı performansları karşılaştırmalı olarak gösterilmiştir.

İmalat sektöründe üretilen malzemenin kaliteli olabilmesini etkileyen önemli unsurlardan biriside yüzey pürüzlülüğüdür. Bu nedenle talaşlı imalat metoduyla üretilen malzenin ve malzemenin kalitesini etkileyen parametrelerin üstüne fazlaca çalışma yapılması gerekmekte olan bir husustur. Bu çalışma kapsamında üç adet kesme parametresinin yüzey pürüzlülüğü üzerindeki etkileri irdelenmiştir. Daha sonraki yapılacak çalışmaların konusu diğer kesme parametrelerin ve kesme kuvvetlerinin de içeren kapsamlı bir modelleme çalışması ortaya koyulabilir ve ayrıca imalat sektöründeki çok kullanılmakta olan çeşitli malzemerlede bu çalışma genişletilebilir. Üretilmiş tüm malzemelerin değişik kimyasal ve fiziksel nitelikleri olduğunu düşündüğümüzde her bir malzeme için ayrı ayrı modelleme çalışmasına ihtiyaç duyulacaktır.

KAYNAKLAR

- [1]. Karagöz, Ş. (2007). *Su Verilmiş ve Temperlenmiş Çelikler Üzerine Mikroyapısal İncelemeler* ss. 731–733, Kocaeli.
- [2]. Buldum, B. B. (2013). *AZ91 Magnezyum Alaşımının İşlenebilirliğinin İncelenmesi*. Doktora Tezi, Gazi Üniversitesi, Ankara.
- [3]. Eşme, U., Kemal, M. (2016). Modeling and optimization of CNC milling of AISI 1050 steel by a regression based differential evolution algorithm (DEA). *Materials Testing*, 58, 7–8.
- [4]. Gale, W., Totemeir, T. C. (2004). *Smithells Metals Reference Book*. *Smithells Metals Reference Book*. Burlington, Butterworth-Heinemann.
- [5]. Routara, B., Sahoo, A., Parida, A., Padhi, P. (2012). Response surface methodology and genetic algorithm used to optimize the cutting condition for surface roughness parameters in CNC turning. *Procedia engineering*, 38, 1893–1904.
- [6]. Buldum, B., Eşme, U., Külekci, M. K., Şik, A. (2012). Use of Grey-Taguchi Method for the Optimization of Oblique Turning Process of AZ91D Magnesium Alloy. *Materials Testing*, 54 (11–12), 779–785.
- [7]. José, F., Paulo, A., Paiva, D., Paulo, P., Roberto, J., Borges, M. (2012). Expert Systems with Applications Optimization of Radial Basis Function neural network employed for prediction of surface roughness in hard turning process using Taguchi 's orthogonal arrays. *Expert Systems with Applications*, 39, 7776–7787.
- [8]. Benardos, P. G., Vosniakos, G. C. (2003). Predicting surface roughness in machining: A review. *International Journal of Machine Tools and Manufacture*, 43 (8), 833–844.
- [9]. Özel, T. T., Karpat, Y. Y. (2005). Predictive modeling of surface roughness and tool wear in hard turning using regression and neural networks. *International Journal of Machine Tools and Manufacture*, 45 (4–5), 467–479.
- [10]. Franco, P., Estrems, M., Faura, F. (2004). Influence of radial and axial runouts on surface roughness in face milling with round insert cutting tools. *International Journal of Machine Tools and Manufacture*, 44 (15), 1555–1565.
- [11]. Lou, S. J., Chen, J. C. (1999). In-process surface roughness recognition (ISRR) system in end-milling operations. *International Journal of Advanced Manufacturing Technology*, 15 (3), 200–209.
- [12]. Benardos, P. G., Vosniakos, G. C. (2002). Prediction of surface roughness in CNC face milling using neural networks and Taguchi's design of experiments. *Robotics and Computer-Integrated Manufacturing*, 18 (5–6), 343–354.
- [13]. Zou, D. X., Wu, J. H., Gao, L. Q., Li, S. (2013). A modified differential evolution algorithm for unconstrained optimization problems. *Neurocomputing*, 120, 469–481.
- [14]. Coşar, D. (2014). *8622RH ve 20MnCr5 çeliklerinin aşınma ve mekanik özelliklerine gaz*

- karbürleme işleminin etkisinin incelenmesi*. Yüksek Lisans Tezi, Eskişehir Osmangazi Üniversitesi, Eskişehir.
- [15]. Baday, Ş. (2016). Küreselleştirme Isıl İşlemi Uygulanmış AISI 1050 Çeliğinin Tornalanmasında Esas Kesme Kuvvetlerinin Yapay Sinir Ağları İle Modellenmesi. *Technological Applied Sciences*, 11 (1), 1–9.
- [16]. Çarboğa, C. (2010). *Düşük karbonlu çeliklere bor ilavesinin mikroyapı ve mekanik özellikler üzerine etkisi*. Gazi Üniversitesi FBE. Doktora Tezi, Gazi Üniversitesi, Ankara.
- [17]. Wang, Z., Tao, N., Li, S., Wang, W., Liu, G., Lu, J., Lu, K. (2003). Effect of surface nanocrystallization on friction and wear properties in low carbon steel. *Materials Science and Engineering: A*, 352 (1–2), 144–149.
- [18]. Chen, X., Jiao, R., Kim, K. S. (2005). On the Ohno-Wang kinematic hardening rules for multiaxial ratcheting modeling of medium carbon steel. *International Journal of Plasticity*, 21 (1), 161–184.
- [19]. Hirotsu. (1972). Crystal structure and morphology of the carbide precipitated from martensitic high carbon steel during the first stage of tempering. *Acta Metallurgica*, 20 (4), 645–655.
- [20]. Dilipak, H., Yilmaz, V. (2012). AISI 1050 Çeliğinin Karbür Takımlarla Frezelemesinde Oluşan Titreşimlerin İncelenmesi Ve İstatistiksel Analizi. *Gazi Üniversitesi Mühendislik-Mimarlık*, 22 (2), 285–294.
- [21]. Danilevsky, V. (1987). *İmalat mühendisliği*. Ankara: Yorum Basım Yayın
- [22]. MKEK. (1978). *MKE Normu Özel Nitelikte Çelik Türleri Kataloğu*. Ankara MKE Basımevi.
- [23]. Balcı, B. (2008). *AISI 304 Östenitik Paslanmaz Çelik Malzemenin İşlenmesinde Yüzey Pürüzlülüğünün İncelenmesi*. Yüksek Lisans Tezi, Karabük Üniversitesi, Karabük.
- [24]. Kına, M. (2011). *Silindirik Yüzeylerin Taşlanmasında Değişik Helis Açılı Taşların Yüzey Pürüzlülüğüne ve Daireselle Etkisi*. Yüksek Lisans Tezi, Dumlupınar Üniversitesi, Kütahya.
- [25]. İşbilir, F. (2006). *Takım ömrünün sebep-sonuç diyagramları ile açıklanması, yüzey pürüzlülüğü ve takım ömrüne etkili faktörlerin analizi*. Yüksek Lisans Tezi, Gazi Üniversitesi, Ankara.
- [26]. Javidi, D. A. (2008). Influence of Machining on the Surface Integrity and Fatigue Strength of 34CrNiMo6 Steel. *International Journal of fatigue*, 147.
- [27]. Hagiwara, M., Chen, S., Jawahir, I. (2009). Contour finish turning operations with coated grooved tools: Optimization of machining performance. *Journal of Materials Processing*, 209 (1), 332–342.
- [28]. Güllü, A. (1995). *Silindirik taşlamada istenen yüzey pürüzlülüğünü elde etmek için taşlama parametrelerinin bilgisayar yardımı ile optimizasyonu*. Doktora Tezi, Gazi Üniversitesi, Ankara.

- [29]. Andreas, A., Wu-Sheng, L. (2009). *Practical Optimization: Algorithms and Engineering Applications*. Kanada: Springer.
- [30]. Nocedal, J., Wright, S. J. (1999). *Numerical Optimization*. New York: Springer-Verlag. Berlin, Heidelberg.
- [31]. Horst, R., Tuy, H. (1990). *Global Optimization Deterministic Approaches*. Berlin: Springer-Verlag. Berlin, Heidelberg.
- [32]. Haupt, R. L., Haupt, S. E. (2004). *Practical genetic algorithms*. Kanada: Wiley-Interscience.
- [33]. Karaboga, D., Gorkemli, B. (2011). A combinatorial Artificial Bee Colony algorithm for traveling salesman problem. *International Symposium on Innovations in Intelligent Systems and Applications* (ss. 50–53). İstanbul: Yıldız Teknik Üniversitesi.
- [34]. Kennedy, J., Eberhart, R. C. (1995). Particle swarm optimization. *Proceedings of IEEE International Conference on Neural Networks, 1995* . 4. 1942–1948.
- [35]. Dorigo, M., St, T. (2010). *Ant Colony Optimization: Overview and Recent Advances*. Handbook of metaheuristics, 146, 227–263. ABD, Springer.
- [36]. Fister, I., Yang, X. S., Brest, J. (2013). A comprehensive review of firefly algorithms. *Swarm and Evolutionary Computation*, 13 , 34–46.
- [37]. Storn, R., Price, K. (1997). Differential Evolution – A Simple and Efficient Heuristic for global Optimization over Continuous Spaces. *Journal of Global Optimization*, 11 (4), 341–359.
- [38]. Holland, J. (1992). *Adaptation in Natural and Artificial Systems: An Introductory Analysis with Applications to Biology, Control and Artificial Intelligence*. London: Massachusetts Teknoloji Enstitüsü.
- [39]. Yang, X.-S. (2010). A New Metaheuristic Bat-Inspired Algorithm. *Nature Inspired Cooperative Strategies for Optimization (NICSO 2010)*. 284, 65–74.
- [40]. Karaboga, D., Basturk, B. (2007). A powerful and efficient algorithm for numerical optimization: Artificial bee colony algorithm. *Journal of Global Optimization*, 39 (3), 459–471.
- [41]. Storn, R. (2008). Differential Evolution Research—Trends and Open Questions. *Advances in Differential Evolution*, 143. 1–31.
- [42]. Karaboğa, D. (2005). *An Idea Based On Honey Bee Swarm For Numerical Optimization*. Erciyes Üniversitesi, Kayseri.
- [43]. Karaboğa, D. (2014). *Yapay Zeka Optimizasyon Algoritmaları* (3.Basım). Ankara: Nobel Yayın.
- [44]. Oztemel, E. (2012). *Yapay Sinir Ağları*. İstanbul: Papatya Yayıncılık.
- [45]. Mcculloch, W. S., Pitts, W. (1943). A Logical Calculus of The Ideas Imminent In Nervous Activity. *Bulletin of Mathematical Biophysics* 5 (4), 115–133.

- [46]. Hebb, D. O. (1950). The organization of behavior: A neuropsychological theory. New York: John Wiley and Sons, Inc., 1949. 335 . *Science Education*, 34 (5), 336-337.
- [47]. Gönül, Y., Ulu, Ş., Bucak, A., Bilir, A. (2015). Yapay sinir ağları ve klinik araştırmalarda kullanımı. *Genel Tıp Dergisi*, 25, 104-111.
- [48]. Saplıoğlu, K., Çimen, M. (2010). Yapay Sinir Ağlarını Kullanarak Günlük Yağış Miktarının Tahmini. *Journal of Engineering Science and Design*, 1 (1), 14-21.
- [49]. Kürker, F., Özerdem, M. (2014). F Dalgacık Dönüşümü Kullanılarak Fare EEG İşaretlerinde Epileptik Nöbet Tespiti. *Tıbbi Tanı ve Tedavi Sistemlerinde Sinyal İşleme Uyg.*, 78-81.
- [50]. Minsky, M., Papert, S. (1969). *Perceptrons: An Introduction to Computational Geometry*. Cambridge.
- [51]. Rumelhart, D. E., Hinton, G. E., Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323 (6088), 533-536.
- [52]. Hopfield, J. J. (1982). Neural networks and physical systems with emergent collective computational abilities. *Proceedings of the National Academy of Sciences*, 79 (8), 2554-2558.
- [53]. Pinker, S., Prince, A. (1988). On language and connectionism: Analysis of a parallel distributed processing model of language acquisition. *Cognition*, 28 (1-2), 73-193.
- [54]. Elmas, Ç. (2003). *Yapay sinir ağları:(kuram, mimari, eğitim, uygulama)*. Ankara : Seçkin Yayıncılık.
- [55]. Etike, E. (2009). *Yapay Sinir Ağı Temelli Model Esaslı Kontrol Algoritmasının Bir Polimer Reaktörüne Uygulanması*. Yüksek Lisans Tezi, Ankara Üniversitesi, Ankara.
- [56]. Bolat, S., Kalenderli, Ö. (2003). Levenberg-Marquardt Algoritması Kullanılan Yapay Sinir Ağı İle Elektrot Biçim Optimizasyonu. *Turkish Symposium on Artificial Intelligence and Neural Networks*. Tannn.
- [57]. Eray Mert Tekin, Deniz Üstün, Berat Barış Buldum, A. A. (2017). A Closed Form Equation Obtained By Artificial Bee Colony For The Surface Roughness Of Aisi 1050 Steel. *International Journal of Research in Engineering & Advanced Technology*, 5 (3), 11-16.
- [58]. Hagan, M. T., Menhaj, M. B. (1994). Training Feedforward Networks with the Marquardt Algorithm. *IEEE Transactions on Neural Networks*, 5 (6), 989-993.
- [59]. Bishop, C. M. (1997). *Neural Networks for Pattern Recognition*. *Journal of the American Statistical Association* (. 92).
- [60]. Haykin, S. (1999). *Neural networks: A Comprehensive Foundation*. Pearson Education.
- [61]. Jang, J. (1992). Self-learning fuzzy controllers based on temporal backpropagation. *IEEE Transactions on neural networks*, 3 (5), 714-723.
- [62]. MathWork, (1994). 25 Temmuz 2017 tarihinde www.mathworks.com adresinden erişildi.

ÖZGEÇMİŞ

Adı ve Soyadı : Eray Mert TEKİN

Doğum Tarihi : 22.10.1991

E-mail : eraymertekin@gmail.com

Öğrenim Durumu :

Derece	Bölüm/Program	Üniversite	Yıl
Lisans	Elektrik-Elektronik Mühendisliği	Fırat Üniversitesi	2010-2014
Yüksek Lisans	Elektrik Elektronik Mühendisliği	Mersin Üniversitesi	2015-2017

İş Tecrübelerim :

Şirket	İşe Başlama	İşten Ayrılış
Mag Yapı Denetim (Nevşehir) Kontrol Mühendisi	18/10/2014	15/07/2015
Mersin Ege Elektrik (Mersin) Elektrik-Elektronik Mühendisi	24/07/2015	11/10/2015
Akış Yapı Denetim (Mersin) Kontrol Mühendisi	02/11/2015	28/03/2016
İşba Elektrik Mak.San Müh. (Mersin) Elektrik-Elektronik Mühendisi	28/03/2016	17/07/2016
Erdem Yapı Denetim (Mersin) Kontrol Mühendisi	29/11/2016	Devam ediyor

ESERLER (Makaleler ve Bildiriler)

1. **Tekin, E.M.**, Ustun, D., Buldum, B.B., Akdaglı, A., “The Prediction of Surface Roughness Values for AISI 1050 Steel Using Artificial Neural Network”, International Mediterranean Science and Engineering Congress (IMSEC 2017) accepted.

Uluslararası Hakemli Dergilerde Yayımlanan Makaleler (Diğer İndisler)

1. **Tekin, E.M.**, Ustun, D., Buldum, B.B., Akdaglı, A., “A Closed-Form Equation Obtained by Artificial Bee Colony for The Surface Roughness of AISI 1050 Steel”, International Journal of Research in Engineering & Advanced Technology, 5, 11–16, (2017).