



e-ISSN: 2667-4165 • CİLT / VOLUME: VI • SAYI / ISSUE: II • ARALIK / DECEMBER 2023

AFYON KOCATEPE ÜNİVERSİTESİ ULUSLARARASI MÜHENDİSLİK TEKNOLOJİLERİ VE UYGULAMALI BİLİMLER DERGİSİ

Afyon Kocatepe University
International Journal of
Engineering Technology and
Applied Sciences

www.dergipark.org.tr/tr/pub/akuumbd



AFYON KOCATEPE ÜNİVERSİTESİ
ULUSLARARASI MÜHENDİSLİK TEKNOLOJİLERİ ve UYGULAMALI BİLİMLER DERGİSİ
Afyon Kocatepe University
International Journal of Engineering Technology and Applied Sciences

Afyon Kocatepe University International Journal of Engineering Technology and Applied Sciences

<http://dergipark.org.tr/akuumubd>

e-ISSN:2667-4165

Afyon Kocatepe University
International Journal of Engineering Technology and
Applied Sciences (AKU-IJETAS)

Volume: VI / Number: 2 / December - 2023

Owner / Publisher: Prof. Dr. Ayhan EROL for Afyon Kocatepe University

Editor in Chief Prof. Dr. Ayhan EROL

Co- Editor in Chief Assoc. Prof. Dr. Ahmet YONETKEN

Published Afyon Kocatepe University, December 2023,

ijetas@aku.edu.tr

This work is subject to copyright. All rights are reserved, whether the whole or part of the material is concerned. Nothing from this publication may be translated, reproduced, stored in a computerized system or published in any form or in any manner, including, but not limited to electronic, mechanical, reprographic or photographic, without prior written permission from the Publisher Afyon Kocatepe University www.ijetas.aku.edu.tr ijetas@aku.edu.tr The individual contributions in this publication and any liabilities arising from them remain the responsibility of the authors. The publisher is not responsible for possible damages, which could be a result of content derived from this publication.

CONTACT INFORMATION

Afyon Kocatepe University International Journal of Engineering Technology and Applied Science Afyon Kocatepe University, Technology Faculty, 03200 Afyonkarahisar, TURKEY

Phone: +90-272-2281446 /ext.

Fax: +90-272 228 1449

e-mail : ijetas@aku.edu.tr, aerol@aku.edu.tr

Welcome to AKU-IJETAS

Dear Researchers;

Afyon Kocatepe University International Journal of Engineering and Applied Sciences ler has been published in Turkish and English since 2018 with 2 issues. Our journal will accept Turkish and English articles as 2 issues a year and the articles will be evaluated by at least two referees with the same system. Our magazine from December 2018; it offers many advantages to readers due to the practical and practical access to the authors as well as the process of publishing and publishing quickly and easily; The electronic journal (e-ISSN:2667-4165) accepts 2 numbers per year (June and December) in Turkish and English. The names of the judges evaluating the articles are not notified to the authors. The referees cannot see the names of the authors. The studies are evaluated as at least two referees. Our authors, who want to send articles, can register their original scientific articles online and follow the process by registering on our magazine page. Our journal is accepted as original and previously published research articles.

We are waiting for your contributions as both referee and writer. I thank you in advance for your support and I wish you success in your work.

Prof. Dr Ayhan EROL

Chief Editor

Danışma Kurulu / Editörler/ Editorial Board

Adem KURT	Gazi University	TURKEY
Ahmet AKSOY	Akdeniz University	TURKEY
Ahmet YILDIZ	Afyon Kocatepe University	TURKEY
Alexander ONUFRAK	Pavol Jozef Safarik University	SLOVAKIA
Anas Sarwar QURESHI	Agriculture University	PAKISTAN
Artay YAGCI	Afyon Kocatepe University	TURKEY
Asım Gokhan YETGIN	Dumlupinar University	TURKEY
Behçet GULENC	Gazi University	TURKEY
Bojan ZLENDER	Maribor University	SLOVENIA
Cahit GURER	Afyon Kocatepe University,	TURKEY
David NOZADZE	Georgian Technical University	GEORGIA
Diñçer BURAN	Süleyman Demirel University	TURKEY
Dunja PERIC	Kansas State University, Manhattan	ABD
Dusan ORAC	Kosice Technical University	SLOVAKIA
Elena Cristina RADA	Trento University	ITALY
Gabor PAY	University College of Nyiregyhaza	HUNGARY
Gratiela BOCA DANA	Technical University Cluj Napoca	ROMANIA
Hazizan Md AKİL	Sains Malaysia University	MALAYSIA
Huseyin Ali YALIM	Afyon Kocatepe University	TURKEY
Huseyin AKBULUT	Afyon Kocatepe University	TURKEY
Huseyin BAYRAKCEKEN	Afyon Kocatepe University	TURKEY
Ilhan KOŞALAY	Ankara University	TURKEY
Ioan ABRUDAN	Technical University Cluj Napoca	ROMANIA
Ivan KURIK,	Technical University Zilina	SLOVAKIA
Iveta VASKOVA	Kosice Technical University	SLOVAKIA
João Pedro SILVA	Leiria Polytechnic Institute	PORTUGAL
Lucian Ionel CIOCA	Lucian Blaga University of Sibiu	ROMANIA
Marco RAGAZZI	Trento University	ITALY
Martina HRUBOVCAKOVA	Kosice Technical University	SLOVAKIA
Matjaž ŠRAML	Maribor University	SLOVENIA
Merlinda EBIBI	Mother Teresa University	MACEDONIA
Mihai BANICA	Technical University Cluj Napoca	ROMANIA
Mircea HORGOS	Technical University Cluj Napoca	ROMANIA
Monica Lopez ALONSO	University of GRANADA	SPAIN
Muhammed YURUSOY	Afyon Kocatepe University	TURKEY
Mustafa ERSOZ	University of Selcuk	TURKEY
Mustaque HOSSAIN	Kansas State University, Manhattan	ABD
Nadras OTHMAN	Sains University	MALAYSIA
Nicolae UNGUREANU	Technical University Cluj Napoca	ROMANIA
Neritan TURKESHI	Mother Teresa University	MACEDONIA
Olivera PETKOVSKA	Mother Teresa University	MACEDONIA

Olga OROSOVA	Pavol Jozef Safarik University	SLOVAKIA
Otar ZUMBURIDZE	Georgia Technical University	GEORGIA
P. Trinatha RAO	Gitam University	INDIA
Peter MONKA	Technical University Kosice	SLOVAKIA
Prasanna RAMAKRISNAN	Neo Education Institu	MALAYSIA
Ramazan KAÇAR	Karabük University	TURKEY
Radu COTETIU	Technical University Cluj Napoca	ROMANIA
Regita BENDIKIENĖ	Kaunas Technology University	LITVANIA
Renata PANOCOVA	Pavol Jozef Safarik University	SLOVAKIA
Rıdvan UNAL	Afyon Kocatepe University	TURKEY
Robert CEP	Technical University Ostrava	CZECH
Serdar SALMAN	Marmara University	TURKEY
Serhat BASPINAR	Afyon Kocatepe University	TURKEY
Sermin OZAN	Fırat University	TURKEY
Sezai TAŞKIN	Celal Bayar University	TURKEY
Snezhina ANDONOVA	Sauth-West University	BULGARIA
Suleyman GUNDUZ	Karabük University	TURKEY
Stanislaw LEGUTKO	Poznan University of Technology	POLAND
Tomasz NIZNIKOWSKI	Lomza State University Applied Science	POLAND
Tomaz TOLLAZZI	Maribor University	SLOVENIA
Ugur CALIGULU	Fırat University	TURKEY
Yılmaz YALCIN	Afyon Kocatepe University	TURKEY
Yuksel OĞUZ	Afyon Kocatepe University	TURKEY
Zoran TRIFUNOV	Mother Teresa University	MACEDONIA

CONTENTS

Page

HDPE Boruların Alın Kaynağında Kaynak Parametrelerinin Birleşme Mukavemetine Etkisinin Yüzey Cevap Metodu ile Optimizasyonu

Muhammet DAĞLI, Ahmet DEMİRER, Esra YUMAT.....95-109

Floroetilenpropilen (FEP)/Grafen Hidrofobik Kaplamaların Üretim Parametrelerinin Optimizasyonu

*Batuhan ÖZAKIN, Mustafa PEHLİVAN, Orhan Deniz ACER
.....110-117*

AA5754 Alüminyum Alaşımının Bilyeli Dövme Prosesi ile Mekanik Özelliklere Etkisi ve Dövme Üzerine Cr+6 Kaplamanın Korozyon Özelliklerine Bakış

Mesut BOZKURT, Ahmet DEMİRER..... 118-131

Dirençli Punta Kaynağı Prosesinin KNN ve CART Makine Öğrenimi Teknikleri ile Değerlendirilmesi

Sena PEKŞİN, Soydan SERTTAŞ.....132-145

AKÜ İJETAS Cilt 6(2) (2023) Aralık (95-109 s)
DOI:10.53448/akuumbd.1289128

AKU İJETAS Vol 6(2) (2023) December (95-109 pp)

Araştırma Makalesi / Research Article
e-ISSN 2667-4165 (<https://dergipark.org.tr/akuumbd>)

HDPE Boruların Alın Kaynağında Kaynak Parametrelerinin Birleşme Mukavemetine Etkisinin Yüzey Cevap Metodu ile Optimizasyonu

Muhammet DAĞLI^{1*}, Ahmet DEMİRER², Esra YUMAT³

¹Sakarya Uygulamalı Bilimler Üniversitesi, Lisansüstü Eğitim Enstitüsü, Makine Mühendisliği, Türkiye

²Sakarya Uygulamalı Bilimler Üniversitesi, Teknoloji Fakültesi, Makine Mühendisliği, Türkiye

³Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Kimya Mühendisliği, Türkiye

e-posta*: muhammetdagli@gmail.com
e-posta: ademirer@subu.edu.tr
e-posta: yumatesra@gmail.com

ORCID ID: <https://orcid.org/0000-0002-1336-903X>
ORCID ID: <https://orcid.org/0000-0003-1252-9203>
ORCID ID: <https://orcid.org/0000-0002-7662-9142>

Geliş Tarihi: 05.05. 2023 ; Kabul Tarihi: 07.07. 2023

Öz

Anahtar Kelimeler
Alın kaynak; PE100;
Yüzey Cevap
Metodu.

Yapılan çalışmada HDPE malzeme sınıfından olan ve yeraltı su ve gaz naklinde yoğun olarak kullanılan PE100 malzemenin deneysel olarak alın kaynak işlemi gerçekleştirilmiştir. Çalışmada üç farklı kaynak sıcaklığı, üç farklı birleştirme basıncında ve üç farklı ısıtma süresi kullanılarak kaynaklı bağlantı gerçekleştirilmiştir. Elde edilen veriler istatistiksel veri analiz programında (Design Expert 12®) değerlendirilerek ele alınmıştır. Çalışmada değişken seçimimiz ve parametrelerimiz farklı olup "Yüzey cevap metodu" (RSM) ile optimizasyonu gerçekleştirilmiştir. Elde edilen optimum parametreler ile üretilmiş olan numuneler hem çekme testi hem de hidrostatik mukavemet testlerine tabi tutularak sonuçlar değerlendirilmiştir. Alın kaynağı sonucunda optimum parametreler (223°C, 15 bar, 120 sn) belirlenmiş ve maksimum çekme dayanımı değerinin, 19,50 MPa olduğu tespit edilmiştir.

Optimization of the Effect of Welding Parameters on Joint Strength in Butt Welding of HDPE Pipes by Surface Response Method

Abstract

Keywords
Butt welding;
PE100; Response
Surface Method
(RSM).

In the study, butt welding process of PE100 material, which is of HDPE material class and is used extensively in underground water and gas transportation, has been carried out experimentally. In the study, welded joints were performed using three different welding temperatures, three different joint pressures and three different heating times. The data obtained were evaluated and handled in the statistical data analysis program (Design Expert 12®). In the study, our variable selection and parameters are different, and optimization was carried out with the "Response Surface Methodology" (RSM). The samples produced with the optimum parameters obtained were subjected to both tensile test and hydrostatic strength tests and the results were evaluated. As a result of butt welding, optimum parameters (223°C, 15 bar, 120 sec) were determined and the maximum tensile strength value was determined to be 19.50 MPa.

1. Giriş

Günümüzde çeşitli sıvıların (petrol, doğalgaz ve içme suyu vb.) dağıtım hatlarında, polietilen borular yüksek dayanıklılık, korozyon direnci, esneklik ve hafiflik gibi avantajlarından dolayı yaygın olarak kullanılmaktadır (Walsh, 2017). Ek olarak yüksek yoğunluklu polietilen (HDPE) hammaddesi, alçak yoğunluklu polietilene kıyasla daha yüksek mekanik özelliklere sahip olduğu için yüksek basınca maruz bırakılacak uygulamalarda sıklıkla kullanılmaktadır (Frederick ve diğerleri, 2009). Boruların birbirine eklenmesi amacı ile elektro ve alın olmak üzere iki tür füzyon çeşidi kullanılmaktadır (Chen ve diğerleri, 1997). Sıcak alın kaynak füzyon işlemi, birbiri ile birleştirilecek her iki borunun da temas yüzeylerinde yumuşama noktasına ulaşılan kadar ısıtılmasını içeren bir termo-füzyon yöntemidir (Doaei, 2018). Ek olarak, farklı et kalınlığındaki boruların birleştirilmesi için elektrofüzyon metodu kullanılırken, aynı et kalınlığındaki borular için ise, sıcak eleman alın kaynağı kullanılmaktadır (Akkurt, 2013).

Bu konuda yapılmış makale çalışmaları literatürde taranarak aşağıda verilmiştir.

Sheng ve arkadaşlarının yapmış olduğu çalışmada, alın kaynak işlemi ile birleştirilmiş olan polietilen boruların bağlantı bölgelerinde oluşan soruna yönelik kaynak işlemi kusurlarının etkisi araştırılmıştır. Orta yoğunlukta polietilen (MDPE) hammaddesi ile üretilmiş borular kullanılmıştır. MDPE hammaddeli alın kaynak yöntemi ile birleştirilmiş olan boruların, boru bağlantılarının kalitesi kaynak hatalarından önemli derecede etkilenmektedir. Bu makalede yanlış kaynak işlemi sonucunun, MDPE boru bağlantıları üzerindeki etkisini göstermek amacı ile, çekme, eğme, ezilme ve yorulma testleri uygulanıp yorumlanmıştır. Üç farklı çapta (\emptyset 110-225-315) SDR11, MDPE borular kullanılmıştır. Çekme testi, \emptyset 110 ve 315 mm boruların alın kaynak işlemi sonrası elde edilen numunelere uygulanmıştır. Her bir çap için ayrı ayrı üçer numune alınıp çekme testine tabi tutulmuştur. Birinci numunede, kaynak işlemi sorunsuz yapılmıştır. İkinci numunede ise, yapılan kusurlu kaynak işlemi sonrası küresel hata oluşmuştur.

Üçüncü numune, yanlış kaynak işlemi sonucu oluşan çizgisel kusura sahip numunedir. Eğme ve ezilme testleri de bu şekilde yapılarak sonuçlar tartışılmıştır. Elde edilen verilerden, sadece bir tane oluşan kaynak hatasının bile uzun süreli kullanımda boruların bağlantı bölgelerinde arızalanmaları hızlandırdığı sonucuna ulaşmışlardır (Sheng ve diğerleri, 2016).

Tarek ve arkadaşlarının yapmış olduğu bilimsel çalışmada ise, polietilen boru malzemeleri için uygulanan gerinim oranı (%birim şekil değiştirme), kalınlık ve kaynağın kırılma tokluğu (J-R) eğrisi üzerindeki etkisi incelenmiştir. Makalenin amacı, alın kaynak metodu ile bağlantı işlemleri gerçekleştirilmiş olan HDPE (SDR11, \emptyset 315 mm) boruların gerinim oranı, numune kalınlığı ve kaynağın kırılma tokluğu üzerindeki etkisinin araştırılmasıdır. Çekme testi alın kaynak işlemli numunelere ve kaynak olmamış numunelere uygulanıp karşılaştırılmıştır. Çekme testi numuneleri, farklı vida hızları (10-500 mm/dk) kullanılarak gerçekleştirilmiştir. Deneysel çalışmalarda kullanılan alın kaynak işlemi parametreleri şu şekildedir: kaynak sıcaklığı 220°C, ısıtma basıncı 13 bar, dengeleme süresi 13sn, ısıtma süresi 286 sn, basınç oluşturma süresi 15 sn, soğuma süresi 2100 sn ve füzyon süresi 2115 sn olarak belirlenmiştir. Çalışma sonucunda, çekme cihazı vida hızının hem kaynaklı hem kaynaklı olmayan numunelerin kırılma tokluğu üzerinde önemli bir etkiye sahip olduğu gözlemlenmiştir (Tarek ve diğerleri, 2014).

Bir başka deneysel çalışmada ise, Chai Z. ve arkadaşları spor havuzunda su temini için kullanılacak HDPE boru hattının sıcaklık alan dağılımı simülasyonu üzerine inceleme yapmışlardır. \emptyset 200 mm HDPE (SDR17), boru malzemeleri kullanılmıştır. Kaynak basıncı (0,2 MPa), ısıtma süresi (70-120 sn), ısıtıcı çıkarma süresi (6-8 sn), soğutma süresi (10-16 dk) ve farklı kaynak sıcaklık değerleri (190-240°C) kullanılarak alın kaynak işlemleri gerçekleştirilmiştir. En iyi kaynak kalitesi için çalışılması gereken parametreler, 0,2 MPa kaynak basıncı, 210-230°C

kaynak sıcaklığı aralığı olarak belirlemişlerdir (Chai ve diğerleri, 2018).

Uzun ve Kocamanın yapmış olduğu başka bir literatür çalışmasında ise, HDPE 100 boruların sıcak eleman alın kaynağıyla birleştirilmesinde kaynak sıcaklığı parametresinin birleştirme mukavemetine etkisi incelenmiştir. Malzeme olarak dış çapı $\varnothing 120$ mm olan SDR12 HDPE 100 borular kullanılmıştır. Sadece kaynak sıcaklıkları değiştirilerek (200°C , 225°C ve 250°C), diğer kaynak parametreleri sabit tutulup, sıcak plaka kaynak işlemi gerçekleştirilmiştir (yanaştırma ve birleştirme basıncı 6 bar, yanaştırma süresi 25 sn, ısıtma süresi 120 sn, ısıtıcı çıkartma ve birleştirme süresi 6 sn ve soğutma süresi 12 sn). Farklı kaynak sıcaklık parametreleri ile alın kaynak işlemine tabi tutulan borulardan standarda uygun olarak hazırlanmış olan deney numunelerine çekme testi uygulanmıştır. Çekme deneyi sonuçlarına göre, kaynak sıcaklığı 225°C olarak seçilen birleştirmede, diğerlerine göre daha yüksek çekme mukavemeti (18 MPa) değeri elde edilmiştir (Uzun & Kocaman, 2018).

Cocard ve arkadaşları istatistiksel veri analiz programı (minitab) kullanarak, yüzey cevap metodu ile Polietilen (HDPE-PE100) boru hatları için optimum kaynak prosedürünün oluşturulması üzerine çalışma yapmışlardır. $\varnothing 110$ mm SDR 11 HDPE boru kullanılmıştır. Değişken parametreleri olarak, (yanaştırma basıncı (P_1) 0,6-2 MPa, yanaştırma süresi (t_1) 10-30 sn, ısıtma süresi (t_2) 80-140 sn, birleştirme süresi (t_3) 10-780 sn ve kaynak sıcaklığı 200 - 230°C) kullanılarak, toplamda 32 adet deney gerçekleştirilmiştir. Ek olarak numuneler çekme testine tabi tutulmuştur. Deneysel çalışmalar sonucu optimum çalışma parametreleri, P_1 : 1,55 MPa, t_1 : 30sn, t_2 : 140 sn, t_3 : 212sn ve kaynak sıcaklığı : 200°C olarak bulunmuştur (Cocard ve diğerleri, 2009).

Akkurt ve arkadaşı sıcak alın kaynak yöntemi ile farklı sıcaklıklarda birleştirilen PE doğalgaz transfer hatlarının güvenilirliklerinin araştırılması üzerine çalışma yapmışlardır. 125 mm çaplı PE100 boruların birleştirme işlemleri farklı ortam sıcaklıklarında (-25°C ile $+60^{\circ}\text{C}$ arasında) gerçekleştirilmiştir. Ortam

sıcaklığı hariç tüm parametreler sabit olarak seçilmiştir. Ortam sıcaklık farklarının kaynak kalitesine etkisi araştırılmıştır. Numuneler hem çekme hem de hidrostatik iç basınç testine tabi tutulmuştur. Yapılan çalışmalar sonucu, ortam sıcaklığının kaynak kalitesi üzerinde önemli bir etkiye sahip olduğu görülmüştür. Yapılan çekme testlerinde -15°C ve altındaki ortam sıcaklıklarında yapılan kaynak işlemlerinde kaynak bölgesinde kopmalar meydana gelirken, diğer tüm ortam sıcaklıklarında kaynak bölgesi dışında kopmalar meydana gelmektedir (boru üzerinde). En iyi kaynak işlemi 45°C civarındaki ortam sıcaklığında bulunmuştur. Maksimum çekme kuvveti 8000 N, kopma kuvveti ise 4000 N olarak bulunmuştur. Hidrostatik iç basınç testlerinde ise, -15 , -20 ve -25°C ortam sıcaklığında kaynak işlemi gerçekleştirilen numunelerin iç basınç testi sonucunda kaynak bölgesi kısımlarında kopmalar meydana gelirken, -10°C üzerindeki sıcaklık ile gerçekleştirilen kaynak işlemi sonrası iç basınç testi uygulanan numunelerde ise kopma kaynak kısmı dışında (boru kısmında) gerçekleşmiştir (Akkurt & Saraç, 2015). Pathak ve arkadaşları ise HDPE boru ($\varnothing 82$ mm, 8 mm kalınlık) elektrofüzyon ve alın kaynak proseslerinin denenmesi ve optimizasyonu üzerinde çalışma yapmıştır. Deneysel çalışmalar istatistiksel veri analiz programı olan minitab kullanılarak, elektrofüzyon ve alın kaynak içinde ayrı ayrı 9 deney gerçekleştirilmiştir. Elektrofüzyon kaynak için değişken parametreler, kaynak voltajı (38,5-40,5V), temas süresi (140-160 sn), soğuma süresi (8-12 dk) olarak belirlenmiş ve sıcaklık dağılımına olan etkileri incelenmiştir. Alın kaynak işlemi için ise, değişken parametreler olarak kaynak sıcaklığı (210 - 220°C), yaklaşma basıncı (18-22 bar) ve kaynak basıncı (20-30 bar) olarak belirlenmiş, sıcaklık dağılımı ve gerilme direncine olan etkileri incelenmiştir. Yapılan deneysel çalışmalar sonucu elektrofüzyon ($39,5$ - 150°C -12 dk) ve alın kaynak (215°C – 18 bar- 20 bar) yöntemleri için, optimum parametreler belirlenmiştir (Pathak & Pradhan, 2020).

Design Expert programının kullanıldığı literatür taramaları ise aşağıda açıklanmaktadır;

Ergül ve arkadaşlarının yapmış olduğu bir başka çalışmada ise, üç farklı akım değeri (4, 8 ve 12 A), akım uygulama süresi (3, 6 ve 9 saat) ve ortam sıcaklığında (20, 25 ve 30 °C) Box-Behnken tasarımı dikkate alınarak yapılmıştır. Deneylerden elde edilen yanıtlar Design Expert 11.0.5 programında analiz edilerek HST (sargı en sıcak nokta sıcaklığı) için matematiksel bir tahmin modeli geliştirilmiş ve parametrelerin optimum değerleri elde edilerek maksimum HST tahmin edilmiştir (Ergül ve diğerleri, 2019).

Hilmioğlu'nun yapmış olduğu bir başka çalışmada ise, sıcaklık (60, 70, 80 °C), katalizör miktarı (0.1-0.55-1 %) ve reaktan başlangıç molar oranının (1:1, 3:1, 5:1) asit dönüşümü üzerindeki etkileri Design Expert programı kullanılarak incelenmiştir. Etil asetat sentezi Design Expert program ile optimize edilmiştir. Deneysel veriler ile model verilerinin birbirleriyle uyumlu olduğu görülmüştür (Hilmioğlu, 2022).

Bu makalede yapılan çalışmada HDPE malzeme sınıfından olan ve yeraltı su ve gaz naklinde yoğun olarak kullanılan PE100 malzemenin deneysel olarak alın kaynak işlemi gerçekleştirilmiştir. Çalışmada üç farklı kaynak sıcaklığı, üç farklı birleştirme basıncı ve üç farklı ısıtma süresi kullanılarak HDPE 100 boruların kaynaklı bağlantıları gerçekleştirilmiştir. Elde edilen veriler istatistiksel veri analiz programında (Design Expert 12®) değerlendirilerek ele alınmıştır. Çalışmada değişken seçiminiz ve parametrelerimiz farklı olup "Yüzey cevap metodu" (RSM: Response Surface Metot) ile optimizasyonu gerçekleştirilmiştir. Elde edilen optimum parametreler ile üretilmiş olan numuneler hem çekme testi hem de hidrostatik mukavemet testlerine tabi tutularak sonuçlar değerlendirilmiştir. Çalışmanın literatürden özgünlüğü ise, deneysel verilerin cevap (çekme dayanımı) üzerindeki etkisinin Design Expert programı kullanılarak incelenmesidir. Ek olarak yapılan çekme ve hidrostatik basınç testi öncesi ve sonrası numunelerin verisel karşılaştırmaları gerçekleştirilmiştir.

2. Malzeme ve Yöntem

2.1. Malzeme


Sıcak elaman alın kaynak yöntemiyle birleştirilen HDPE (PE100) borunun özellikleri Tablo 1'de verilmiştir. Birleştirilecek borunun et kalınlığı 10 mm, dış çapı Ø110 mm (SDR11) ve boyu 100 mm olarak seçilmiştir.

Tablo 1. HDPE (PE100) boru malzemesinin mekanik özellikleri


Teknik Özellikler	PE 100	Birim	Standart
Yoğunluk	0,957	g/cm ³	ISO 1183
Viskozite değeri	360	cm ³ /g	ISO 1628-3
Erime Akış Hızı (MFR) 190°C/5 KG	0,20-0,60	g/10dak	ISO 1133
Karbon siyahı oranı	2-2,3	%	ISO 6964
Karbon siyah dağılımı	3		ISO 18553

2.2. Yöntem

İlk aşamada kaynak ile birleştirilecek olan PE100 malzemeden boru numuneler elektrikli testere yardımı ile 200 cm boyunda kesilmiştir. Alın kaynak işlemi için numuneler kaynak makinasına Şekil 1'de ki gibi konumlandırılarak yapılmaktadır. Şekil 2'de bu konumlama işleminin bir fiştür yardımı ile boruların aynı eksene nasıl getirildiği gösterilmektedir. Alın kaynak işleminde kullanılan kaynak makinesinin özellikleri de Tablo 2'de verilmiştir.



Şekil 1. Plastik alın kaynak işlemi aşamaları görseli (Shapheek & Shrivastava, 2020)




Şekil 2. PE100 boruların alın kaynak işlemi için fiyestüre alınması görseli

Tablo 2. Plastik Alın Kaynak Makinesi Özellikleri

Kaynatabileceği Maksimum Et Kalınlığı (Basınç Grubu)	PN 16
Isıtıcı Elektrik Gücü	230 V – 1,5 kW
Tıraşlayıcı Elektrik Gücü	230 V – 0,81kW
Toplam Elektrik Sarfiyatı	2,3 kW

Alın kaynak işlemi kısaca tarif edersek üç adımda gerçekleşir. İlk adımda birleştirilecek boru yüzeylerinin paralellığı için tıraşlanması, ikinci adımda ısıtıcı disk formundaki elemanın birleştirilecek boruların arasına yerleştirilmesi ile



Şekil 3. Sıcak eleman alın kaynak işleminin basınç-süreye bağlı uygulama aşaması

Deneysel çalışmamızda istatistiksel veri analiz programı olarak Design Expert12® yazılım programı kullanılmıştır. Yüzey Cevap Yöntemi olan istatistiksel veri analiz programı ile sistemin cevabını etkileyen çok sayıda değişken bir arada ve eşzamanlı olarak incelenebilmekte ve prosesin işlem parametrelerindeki değişime verdiği cevap-yanıt en az sayıda deneme yapılarak en iyi şekilde

ergime noktasına getirilmesi işlemi ve sonrasında ise ısıtıcı diskin aradan çıkarılarak boruların basınçla birbirine eksen boyunca itilerek katılma süresince bekletilmesi işlemidir. İlk adımdaki tıraşlama işlemi sonrasında Şekil 3'te görüldüğü üzere ısıtıcı disk araya girerek bir yanıştırma işlemi, P_1 basıncı altında ve t_1 süresi boyunca yapılmaktadır. Daha sonra ise, ikinci aşama olan basınçsız ($P:0$) ısıtma bölümünde ise, basınç uygulanmadan Tablo 3'te verilen değişken ısıtma süreleri ile ısıtma işlemi yapılmıştır.

Basınçsız ısıtma işleminden sonra, t_3 süresince hızlı bir şekilde ısıtıcı çıkarılmakta ve daha sonra borular birbirlerine yanıştırılarak t_4 süresi boyunca birleştirilmektedir. Son kademede ise, cihaz Tablo 3'te belirlenen değişken P_3 basınç değerine ayarlanarak, bu basınçta ve t_5 süresince alın kaynak işlemi soğumaya (katılasmaya) bırakılmıştır.

tanımlanabilmesi amacı ile Box-Behnken metodu tercih edilmiştir. İlk olarak, programa Tablo 3'te belirlenmiş olduğumuz değişkenlerin minimum ve maksimum değerleri girilmiştir. Çalışmada Tablo 4'te belirtilen parametreler sabit tutulmuştur. Program tarafından beşi tekrarlı olmak kaydı ile toplam 17 deney önerilmiştir (Tablo 6).

Tablo 3. Değişken deney parametreleri ve seviyeleri

Değişkenler	Semboller	Seviye		
		-1 (Minimum değer)	0 (Orta değer)	+1 (Maksimum değer)
Kaynak sıcaklığı (°C)	A	200	225	250
Birleştirme basıncı (bar)	B	5	10	15
Isıtma süresi (sn)	C	40	80	120

2.2.1. İstatistiksel Veri Analizi

Bu çalışmada, Ø110 SDR 11, (Standart boyut oranı, borunun basınca karşı dayanıklılığının derecelendirilme yöntemi) HDPE (PE100) boruların; kaynak sıcaklığı, birleştirme basıncı ve ısıtma süresi gibi (değişken) parametrelerinin maksimum çekme dayanımına (MPa) olan etkisi Varyans Analizi (ANOVA), Yüzey Cevap Metodu (RSM) kullanılarak değerlendirilmiştir. RSM, bağımsız değişkenler ve bu değişkenlere bağlı olarak tasarlanan deney sisteminin verdiği cevaplar arasındaki ilişkiye göre sistemin değişken-cevap profilinin belirlendiği bir optimizasyon tekniğidir (Nigiz, 2019). Yüzey cevap metodu ile çok değişkenli parametrelerin kullanıldığı sistemlerde, zaman ve malzeme tasarrufu sağlanarak optimum çalışılması gereken şartlar sistem tarafından belirlenmektedir.

Çalışmamızda kullanılan istatistiksel veri analiz programı olan yüzey cevap metodunun amacı,

proses boyunca belirlenen noktalar arasında değişimlerin proses cevabına-yanıtına etkisini belirlemektir. Böylece belirlenen aralıklarda olası değişkenlerin cevabını deney yapmaya gerek kalmadan öngörmek mümkündür. Çalışma sonunda öngörülen optimum parametreler doğrulama deneyleri ile kontrol edilmiştir.

Bu çalışmamızda, üç değişken faktör; kaynak sıcaklığı, birleştirme basıncı ve ısıtma süresi olup cevap ise maksimum çekme dayanımı değeridir.

Bu çalışmadaki deney tasarımı için, RSM ile oluşturulan deney sistemlerinde en az deney sayısını oluşturan Box-Behnken tasarımı tercih edilmiştir. Çalışmada kullanılacak deneysel tasarım belirlendikten sonra maksimum çekme dayanımına etki eden parametreler, seviyeler belirlenmiş ve Tablo 3'te; sabit tutulan deney parametreleri ise Tablo 4'te verilmiştir.

Tablo 4. Sabit tutulan deney parametreleri


Sabit Parametreler	Birimler	Değerler	Semboller
Yanaştırma Süresi	(sn)	25	t ₁
Yanaştırma Basıncı	(bar)	5	P ₁
Isıtıcı Çıkarma Süresi	(sn)	5	t ₃
Birleştirme Süresi	(sn)	5	t ₄
Soğutma Süresi	(dk)	15	t ₅
Yürüme Basıncı*	(bar)	10	-

* Yürüme basıncı: Her iki boruyu karşı karşıya getirirken oluşan basınçtır.

2.2.2. Çekme Testi

PE100 plastik borular Sıcak Alın Kaynak Makinesi ile Tablo 6'da belirtilen parametreler kullanılarak birleştirilmiştir. Birleştirilerek elde edilen kaynaklı boruların üzerinden standartlarda belirlenmiş olan ölçülerde hazırlanmış olan numuneler her bir test için oda sıcaklığında (23°C) ve %50 nem ortamında çekme testine tabi tutulmuştur. Çekme deney numuneleri TS ISO 13953/ ISO 11414 standardına göre hazırlanmıştır (Şekil 4).

Numunelerin et kalınlığı 25 mm'den küçük olduğu için, Tip A testi uygulanmıştır (Şekil 5). Çekme cihazı teknik özellikleri Tablo 5'te verilmiştir. Numunelere çekme cihazında 5 ± 1 mm/min. çekme hızı uygulanmıştır. Deney numunelerinin test sonucunda maksimum çekme dayanımı (MPa) değerleri bulunmuştur (Tablo 6). Ayrıca çekme testi ile deney numunelerinin sünek veya gevrek kırılmalarına bakılarak, kaynak prosesi hakkında bilgi edinilmiştir.





A	Toplam uzunluk (en az)	180
B	Uçlardaki genişlik	60 ± 3
C	Kenarı paralel olan dar kısmın uzunluğu	Uygulanmaz
D	Dar kısmın genişliği	25 ± 1
E	Yarıçap	$5 \pm 0,5$
G	Tutma yerleri arasındaki ilk mesafe	90 ± 5
H	Kalınlık	Tam et kalınlığı
I	Çekme deliklerinin çapı	20 ± 5

Şekil 4. Makine ile işlenmiş Tip A çekme deney numunelerinin boyutları (Ölçüler mm'dir.)



Şekil 5. Çekme testine tabi tutulacak numune görselleri

Tablo 5. Çekme Cihazı ve Teknik Özellikleri

	Çekme kapasitesi (kN)	2000 kN PLC Kontrollü
	Çekme hızı (mm/min)	5 ± 1
	Marka /Model	TINIUS OLSEN

2.2.3. Hidrostatik İç Basınç Testi

Boruların zaman içinde basınç karşısındaki davranışlarının kısaltılmış ortam şartlarında incelendiği testtir. Borulara yüksek basınç şartları uygulanarak 50 yıllık bir sürede borudaki oluşabilecek değişimler gözlemlenmektedir. Kaynak parametreleri verilen optimum ve optimuma yakın toplamda 3 deney numunesi, TS EN ISO 1167-2 standardına göre hazırlanarak, 165 saat 80°C'de sıcak su havuzunda teste tabi tutulmuştur. Standartlara uygun seçilen numuneler iki ucundan kapama başlıkları ile sızdırmayacak şekilde kapatılmıştır. İçinde hava kalmayınca kadar şartlandırıcı yardımıyla istenilen sıcaklığa getirilmiş su ile doldurulur. Ardından ağırlık sebebiyle ovalleşmemesi için basınç test başlıkları ile desteklenerek şartlandırılmış ortama tamamen daldırılarak numune teste hazır hale getirilerek işlem gerçekleştirilmiştir. Şekil 6 ve 7'de iç basınç öncesi ve sonrası numune görseli verilmektedir.



Şekil 6. Hidrostatik iç basınç testi hazırlık görseli



Şekil 7. Hidrostatik iç basınç testi sonrası numune görseli

3. RSM Analizi ve Sonuçların İrdelenmesi

Bu çalışmada yapılan deneylerin tamamı, istatistiksel veri analiz programıyla belirlenen parametreler ile gerçekleştirilmiştir. Program tarafından beşi tekrarlı olmak üzere toplam 17 adet farklı değişken parametrede deneyler yapılmıştır. Farklı değişken parametreler kullanılarak gerçekleştirilen deneylerden elde edilen numunelere uygulanan çekme testi sonucu bulunan maksimum çekme dayanım değerleri programa aktarılmıştır (Tablo 6).

Tablo 6. RSM ile belirlenen değişkenler ve deney sonuçları

Deney Numarası	Faktör 1 Kaynak Sıcaklığı (°C)	Faktör 2 Birleştirme Basıncı (bar)	Faktör 3 Isıtma Süresi (sn)	Cevap Çekme Dayanımı (N/mm ²)
1	200	15	80	18,67
2	250	15	80	17,96
3	250	5	80	17,50
4	250	10	40	17,60
5	225	15	40	19,03
6	225	10	80	19,00
7	225	10	80	19,01
8	225	10	80	19,00
9	225	10	80	19,02
10	200	10	120	18,70
11	225	5	120	18,96
12	225	5	40	18,77
13	200	5	80	18,30
14	225	10	80	19,00
15	250	10	120	18,00
16	200	10	40	18,49
17	225	15	120	19,50

Program tarafından belirlenen regresyon modeli Denklem (1)'deki gibi oluşturulmuştur.

$$\begin{aligned} \text{Max. Çekme Dayanımı} = & +19,01 - (0,3875 * A) + (0,2038 * B) + (0,1588 * C) + \\ & (0,0225 * AB) + (0,0475 * AC) + (0,0700 * BC) - \\ & (0,8830 * A^2) - (0,0155 * B^2) + (0,0745 * C^2) \end{aligned} \quad (1)$$

Bu denkleme göre, A faktörü yani kaynak sıcaklığı en etkin faktör olarak görülmektedir. Kaynak sıcaklığı değerindeki artış, çekme dayanım değeri üzerinde negatif yönde bir etki oluşturmaktadır.

Fakat B (birleştirme basıncı) ve C (ısıtma süresi) faktörleri ise çekme dayanımı üzerinde pozitif bir

etkiye sahiptir. Bu faktörlerin sayısal oranlarındaki artış, çekme dayanım değerleri üzerinde de doğru orantılı bir artışa sebep olmaktadır. Elde edilen modelin denklemini ANOVA analizinde kontrol edildiğinde Kuadratik Model'in (Tablo 7) bu tasarım için uygun olduğu görülmüştür. Önerilen model için, "F" anlamlılık değeri daha yüksek, hata değeri olasılığı ise 0,05'ten daha düşük bulunmuştur. Bu verilerde, modelimizin deneysel çalışmamız için uygun olduğunu göstermektedir (Yılmaz&Ertürk, 2021).

Tablo 7. Anova analizi ile model belirleme görseli

Kaynak	Kareler Toplamı	Serbestleşme Derecesi (df)	Kareler Ortalaması	F Değeri	p Değeri
Lineer	1,73	3	0,5783	2,26	0,1304
2FI	0,0306	3	0,0102	0,0309	0,9922
Kuadratik	3,30	3	1,10	4986,35	<0,0001
Kübik	0,00123	3	0,0004	5,10	0,0746

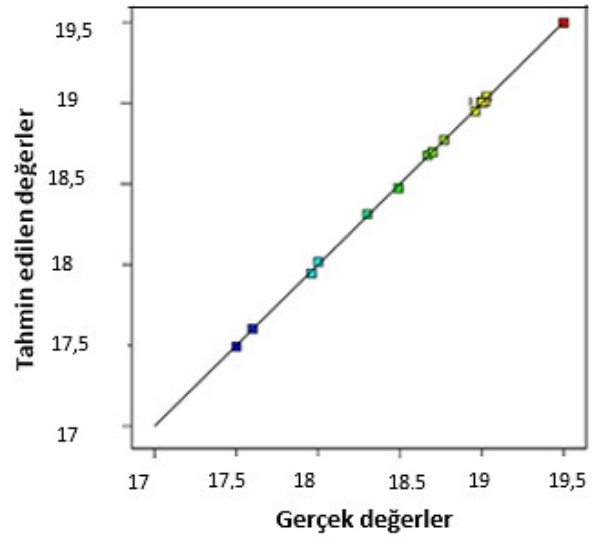
Tablo 8. Kuadratik model için ANOVA tablosu

Kaynak	Kareler Toplamı	Serbestleşme Derecesi (df)	Kareler Ortalaması	F Değeri	p Değeri	
Model	5,07	9	0,5630	2550,96	<0,0001	Anlamlı
Kaynak Sıcaklığı (A)	1,20	1	1,20	5442,56	<0,0001	
Birleştirme Basıncı (B)	0,3321	1	0,3321	1504,72	<0,0001	
Isıtma Süresi (C)	0,2016	1	0,2016	913,45	<0,0001	
AB	0,0020	1	0,0020	9,17	0,0191	
AC	0,0090	1	0,0090	40,89	0,0004	
BC	0,0196	1	0,0196	88,80	<0,0001	
A ²	3,28	1	3,28	14873,99	<0,0001	
B ²	0,0010	1	0,0010	4,58	0,0695	
C ²	0,0234	1	0,0234	105,88	<0,0001	
Artan	0,0015	7	0,0002			
Model uygunsuzluğu	0,0012	3	0,0004	5,10	0,0746	Anlamlı Değil
Hata	0,0003	4	0,0001			
Toplam	5,07	16				
Standart Sapma		0,0149		R ²	0,9997	
Ortalama		18,62		Ayarlanmış R ²	0,9993	
Varyasyon katsayısı (%)		0,0798		Tahmin Edilen	0,9960	
				Yeterli Hassasiyet	175,8542	

Elde edilen modelin ve modeldeki katsayıların doğruluğunu belirleyen F testi ve parametrelerin maksimum çekme dayanımına katkısını belirlemek için varyans analizi (ANOVA) yapılmış sonuçları Tablo 8’de verilmiştir. Anova analizi sonucu elde edilen Tablo 8’de değişkenlerin cevap üzerindeki etkisinin önem derecesi ‘F-değeri’ ve ‘Kareler toplamı’ değerleri ile kıyaslanır. ‘F-değeri’ ve ‘Kareler toplamı’ değerleri sayısal olarak büyük olan faktör cevap üzerindeki en etkili faktördür. F değeri ne kadar artarsa model doğruluğu da aynı oranda artmaktadır (Nigiz, 2018). P değerinin (hata değeri olasılığı) 0,05’ten küçük olması önemlidir. $p < 0,05$ ise, program tarafından Numunelere çekme cihazında 5 ± 1 mm/min. çekme hızı uygulanmıştır. önerilen deneylerin laboratuvar şartlarında elde edilen sonuçların %95’inin program tarafından elde edilen model ile açıklanabileceğini göstermektedir (Myers&Montgomery,1995).Tablo 8 incelendiğinde 2550,96 F değeri ile modelin ve A (Kaynak Sıcaklığı), B (Birleştirme basıncı), C (Isıtma süresi), model parametrelerinin anlamlı olduğu ($p < 0.0001$) görülmektedir. R^2 (ayarlanmış) = 0,9997 değeri de deneysel cevaptaki varyansın %99,97’sinin ikinci dereceden modelle açıklanabileceğini ifade etmektedir.

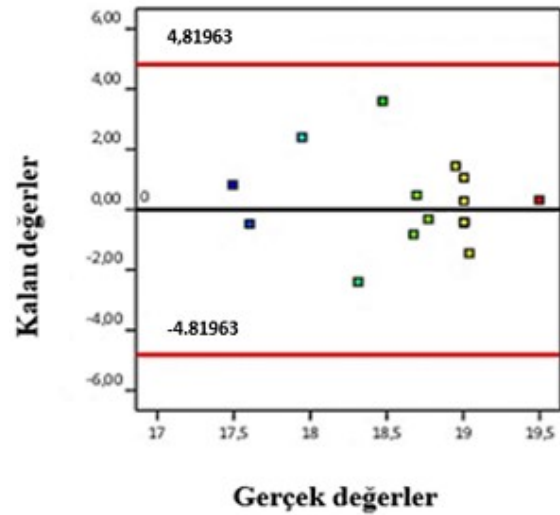
Ek olarak, yüksek regresyon katsayısı (R^2)’nin 1’e yakın olması model tarafından öngörülen değerlerin deneysel veriler ile uyum içerisinde olduğunu göstermektedir (Nigiz, 2018).

Deneysel ve RSM denklemi kullanılarak elde edilen tahmini maksimum çekme dayanımı değerlerinin Şekil 8’de görüleceği gibi uyumlu olduğu gözlemlenmiştir. Bu, modelde kullanılan kuadratik regresyon modelinin deney tasarımındaki herhangi bir değişkendeki cevap faktörlerini hesaplamak için uygun olabileceğini göstermektedir. Şekil 8’deki modele göre gerçek ve tahmin edilen dönüşümlerin uyumlu olduğu görülmektedir. Tahmin edilen değer ile gerçek dönüşüm değerlerinin dağılımına bakıldığında normallik koşulunun sağlandığı görülmektedir. Grafikte bulunan çizgiden herhangi bir sapma görülmemektedir (Yılmaz & Ertürk, 2021).



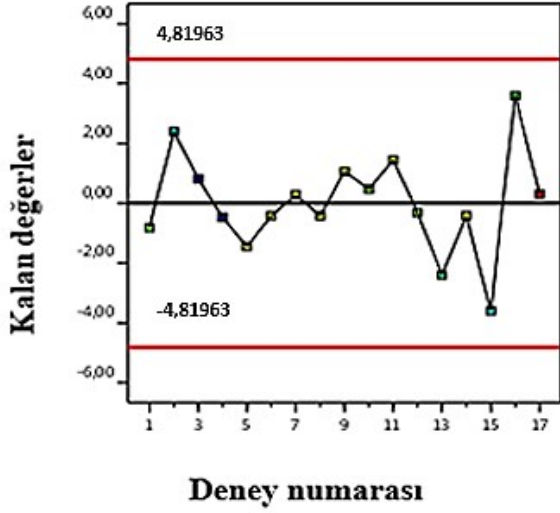
Şekil 8. Deneysel ve RSM maksimum çekme dayanımı değerleri kıyaslaması

Şekil 9’da gerçek değerler ile kalan değerlerin uyumluluğu gösterilmektedir. Verilerimizin grafik üzerindeki kırmızı limit değerleri arasında olması uygun olduğu anlamına gelmektedir. Grafiğin dağılımı da limit değerlerinin dışına taşmamıştır, sonuç olarak uygun bulunmuştur (Uzunoğulları, 2010; Shapheek & Shrivasta, 2020).



Şekil 9. Gerçek ve kalan değerler grafiği

Şekil 10’da tüm deneyler kırmızı sınır çizgileri arasında ve herhangi bir sınır aşımı bulunmamaktadır. Bu sebeple program tarafından tekrar edilmesi gereken bir deney ön görülmemiştir.

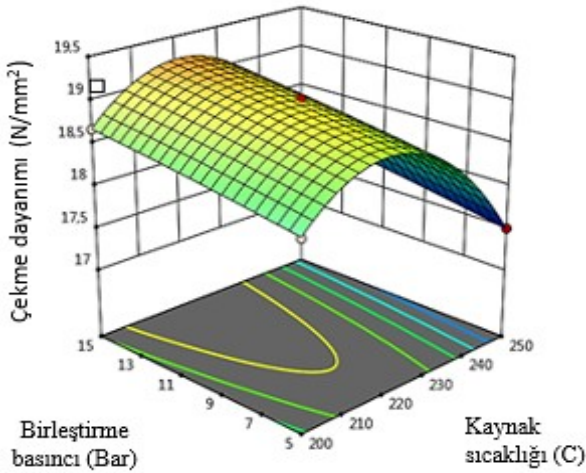


Şekil 10. Deney numarası ve kalan değerler grafiği

3.1. Proses değişkenlerinin RSM'ye etkisi

3.1.1 Kaynak sıcaklığı ve birleştirme basıncının çekme dayanımına etkisi

Şekil 11'de 3D yüzey grafiği ile ısıtma süresi 80 sn'de sabit tutulup, birleşme basıncı ve kaynak sıcaklığı değişkenlerinin maksimum çekme dayanımı üzerindeki etkisi görülmektedir.



Şekil 11. Sabit ısıtma süresinde (80 sn), kaynak sıcaklığı ve birleşme basıncının maksimum çekme dayanımı üzerindeki eş zamanlı etkisi

Üç boyutlu grafikte kaynak sıcaklığı değerinin artması ile maksimum çekme dayanımı değerleri başlangıçta artış göstermiş fakat 230°C 'nin üzerine çıkıldığında ise, cevap değerleri giderek azalmıştır.

230°C'ye kadar olan uygulamalarda, yapı içerisinde kristal olarak bulunan zincirlerin çoğu ısı etkisi ile amorf forma dönüşmektedir. Böylece zincirler birbirleri üzerinden kolayca akarak iyi bir yapışma mukavemeti sergilemekte ve homojen bir yapı oluşmaktadır.

Daha sonra uygulanan soğutma işlemi ile zincirlerin çoğu kristal forma dönüşmüş olup üzerlerine uygulanan çekme kuvvetine dayanımları daha fazla olmaktadır. PE100 malzeme, yüksek molekül ağırlığına sahip yarı kristal yapıda ve mekanik özellikleri diğer polietilen malzemelere göre yüksek bir polimer malzemedir.


Fakat 230°C'nin üzerinde kaynak sıcaklığı uygulandığında, Tablo 6'daki veriler ışığında maksimum çekme dayanımı değerlerinde düşme eğilimi görülmektedir.

Bunun sebebi ise, yüksek sıcaklık artışı ile yapı içerisindeki zincirlerde konformasyonel bozulmalar meydana geldiği düşünülmektedir. Bu durumda çekme dayanım değerlerini düşürmektedir.


Birleştirme basıncı değerlerindeki artış ile maksimum çekme dayanımı verilerinde doğru orantılı bir artış gözlenmiştir. Bunun sebebi ise, uygulanan basınç kuvveti ile eriyik halde bulunan polimer zincirlerine daha iyi yönlendirme yapılarak, yapı içerisinde düzgün bir form almasının sağlandığı düşünülmektedir. Böylece yapı içerisinde kristal (düzenli) bölge oranı artış gösterecek ve buna bağlı olarak mekanik özelliklerde artış olacaktır.

3.1.2. Kaynak sıcaklığı ve ısıtma süresinin çekme dayanımına etkisi

Şekil 12'de ısıtma süresi değişiminin cevap üzerinde çok büyük bir etki oluşturmadığı tespit edilmiş olup bu sürenin gereğinden uzun tutulması durumunda, alın kaynak bölgesinin aşırı erimesi ile polimer zincirinde bozulmalar meydana gelebilecektir.



Şekil 12. Sabit birleşme basıncında (10 bar), kaynak sıcaklığı ve ısıtma süresinin max. çekme dayanımı üzerindeki eş zamanlı etkisi



Şekil 13. Optimum parametreler ve en yüksek çekme dayanımı değeri

Bütün faktörler birlikte değerlendirildiğinde, en yüksek çekme dayanımı elde etmek amacı ile program tarafından değişkenler için önerilen değerler Şekil 13'te gösterilmektedir. 19,50MPa'lık çekme dayanım değeri elde etmek amacı ile optimum deney koşullarında, kaynak sıcaklığı, 223°C, birleştirme basıncı 15 bar ve ısıtma süresi 120 sn olarak öngörülmüştür.

Ek olarak, program tarafından farklı parametrelerde toplam 100 deney tasarlanmıştır. Tasarlanan 100 deney arasından optimum ve optimuma yakın toplam 3 deney parametresi (deney no :1, 2 ve 3) belirlenmiştir. Belirlenen parametrelerde alın kaynak işlemi yapılmış olup, numuneler çekme ve hidrostatik iç basınç testine tabi tutulmuştur.

3.1.3. Optimum deney koşullarının belirlenmesi

Değişken parametrelerin maksimum çekme dayanımı üzerindeki etkileri incelendikten sonra, optimum parametre değerleri Design Expert 12 programında elde edilmiştir.

Elde edilen optimum parametre değerleri ve bu değerlere karşılık gelen maksimum çekme dayanımı Şekil 13'te verilmiştir.

4. Çekme Testi Sonuçları

İlk olarak, Design Expert programı tarafından belirlenmiş olan farklı değişken parametreler ile gerçekleştirilen (Tablo 6) alın kaynak işlemi yapılan 17 adet numunenin çekme testi sonrası görselleri Şekil 14 'de verilmiştir.



Şekil 14. Çekme testi sonrası kopan numune görselleri


Çekme testi aşamasında numunelerin kaynak birleşim bölgesinden gevrek veya sünek ayrılmalarına bakılarak kaynağın sağlıklı olup olmadığı gözlemlenmiştir. Sonuç olarak, yüksek kaynak sıcaklığı kullanılan numunelerde (deney 2, 15 gibi) daha gevrek bir kopma gözlemlenirken daha düşük kaynak sıcaklığının kullanıldığı numunelerde (deney 11) ise sünek bir kopma meydana gelmiştir. Uzun ve arkadaşının yapmış olduğu çalışmada, PE100 boruların üç farklı (200, 225 ve 250°C) kaynak sıcaklığındaki çekme testi sonucunda 250°C deki numunelerde kopma uzama değerlerini daha düşük tespit etmişlerdir. Bu sonuç çalışmamızı destekler niteliktedir (Uzun & Kocaman, 2018).

4.1. Optimum deney numunelerinin Çekme Testi

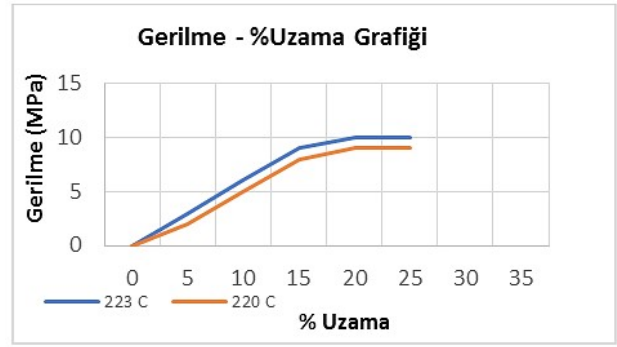
Deneysel parametreler sonucu analiz programının belirlemiş olduğu optimum ve optimuma yakın deney verileri (Tablo 9) ile ayrıca doğrulama deneyleri yapılmıştır. Bu veriler ışığında kaynak işlemi yapılmış olan numuneler çekme testine tabi tutulmuş (Şekil 15) ve çekme gerilme (N/mm²) değerlerine karşılık % uzama grafiği Şekil 16'da gösterilmiştir.

Tablo 9. Optimum ve optimuma yakın deneylerin alın kaynak işlemi parametreleri

Deney Numarası	Kaynak Sıcaklığı (°C)	Birleştirme Basıncı (bar)	Isıtma Süresi (sn)	Çekme Dayanımı (N/mm ²)
1	222,945	14,709	119,644	19,500
2	220,446	14,547	119,617	19,501
3	219,989	14,739	118,867	19,503



Şekil 15. Çekme testi öncesi (a) ve sonrası (b) numune görselleri



223°C optimum parametrelerin kullanıldığı deney numunesi, 220°C: Optimuma yakın parametrelerin kullanıldığı deney numuneleri ortalaması

Şekil 16. Optimum ve optimuma yakın deney numunelerinin Gerilme-% Uzama grafiği

Çekme testi grafik sonuçlarına göre optimum deneysel parametreler kullanılarak gerçekleştirilen alın kaynaklı numunelerin 223°C'de çekme dayanım değeri 21MPa olup diğer numunelere kıyasla (20 MPa) daha yüksek tespit edilmiştir. Ayrıca %kopma uzama değeri de diğer numunelere kıyasla daha yüksektir. Akkurt ve arkadaşlarının yapmış olduğu çalışmada ise, çekme dayanım değerleri, 21-27 MPa arasında bulunmaktadır (Akkurt & Saraç, 2015). Zhigiang ve arkadaşlarının yapmış olduğu diğer bir çalışmada ise en iyi kaynak kalitesinin 210-230°C aralığında olduğu belirtilmiştir (Cai ve diğerleri, 2018).

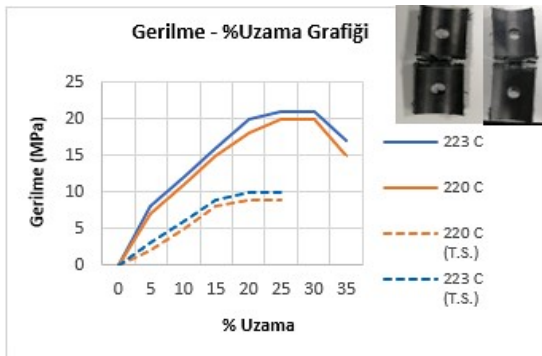
Sonuç olarak, program tarafından optimum deneysel parametreler için (223°C) hesaplanan (teorik) maksimum çekme dayanım değeri, 19,50 MPa iken, deneysel olarak bulunan maksimum çekme dayanım değeri, 21 MPa'dır. Bu değerler ile deneysel veriler ve teorik veriler arasındaki % hata payı aşağıdaki denklem yardımı ile hesaplanmıştır.

$$\% \text{ Hata} = \frac{[\text{deneysel değer} - \text{teorik değer}]}{\text{teorik değer}} \times 100$$

$\% \text{ Hata} = \frac{[21 - 19,50]}{19,50} \times 100 = \%7,69$ olarak bulunmuştur. Bu sonuç bize, deneysel veriler ile teorik veriler arasındaki tutarsızlığın %7,69; doğruluk oranının da %92,31 olduğunu göstermektedir.

4.2. Hidrostatik iç basınç testi ve Çekme testi

Optimum ve optimuma yakın toplamda üç adet deney parametreleri ile gerçekleştirilen alın kaynak işlemlerinden sonra numuneler hidrostatik iç basınç testine tabi tutulmuştur. Bu test sonrası standartlara uygun şekilde hazırlanan deney numunelerine çekme testi uygulanmıştır. Böylece numunelerin alın kaynak prosesinin kalitesi tahribatlı muayene testi sonrasında da analiz edilmiş ve kesit alana uygulanan maksimum çekme dayanımı (N/mm^2) gözlemlenmiştir. Hidrostatik iç basınç test süresi boyunca deney numunelerinde herhangi bir sızma ve patlama hasarı oluşmamıştır. Dolayısı ile test sonucu hasarsız olarak kaydedilmiştir. Hidrostatik iç basınç testi sonrası (T.S.) çekme deneyine tabi tutulan numunelerin, Gerilme-%Uzama grafiği ortalama değeri Şekil 17’de verilmiştir. 223°C kaynak sıcaklığı kullanılarak gerçekleştirilen deney numunelerinin çekme dayanımında %52 oranında azalma gözlemlenirken, 220°C kaynak sıcaklığında ise, %55 oranında azalma tespit edilmiştir. % Kopmada uzama değerlerine bakıldığında hidrostatik iç basınç testi öncesine kıyasla %31 oranında azalma göstermiştir. Beklenildiği üzere tahribatlı muayene sonrası numunelerin mekanik özelliklerinde azalmalar meydana gelmektedir. Fakat, Şekil 17’de deney numunelerinin çekme testindeki kopma davranışları sünektir. Ek olarak, deney numunelerinin alın kaynak bölgesinde ayrılma meydana gelmemiştir. Kopma daha çok boru bölgesinde (kaynak bölgesi dışında) gerçekleşmiştir. Bu sonuç bize kaynak kalitesinin ve kaynak parametrelerinin optimum olduğunu göstermektedir.



Şekil 17. Hidrostatik iç basınç öncesi ve sonrası Gerilme-% uzama grafiği ve numuneleri

5. Sonuçlar

PE100 boru malzemesiyle yapılan alın kaynağı işleminde aşağıdaki sonuçlar elde edilmiştir:

- RSM'nin optimum tavsiye edilen proses şartlarının proses sıcaklığı 223°C, birleştirme basıncı 15 bar ve ısıtma süresi 120 sn olduğu, kaynak sıcaklığı da en etkin faktör olarak öngörülmüştür. Bu parametreler kullanılarak gerçekleştirilen doğrulama deneyleri ile alın kaynaklı numunelerin deneysel sonuçlarda en yüksek çekme dayanım değerinin (21MPa) olduğu tespit edilmiştir.
- Yüzey Cevap Metodu ile deneysel veriler arasındaki doğruluk oranının da %92,31 olduğunu belirlenmiştir. Program tarafından analiz edilerek tahmin edilen veriler ile deney sonucu bulunan (gerçek) verilerin uyumlu olduğu görülmüştür.
- Sıcaklık arttıkça (250°C) çekme testi sonucunda numunelerde %kopma uzama değerlerinde %17 oranında azalma tespit edilmiştir.
- Hidrostatik iç basınç testi sonrası 223°C kaynak sıcaklığındaki numunelerde çekme dayanımı değerinde %52; 220°C kaynak sıcaklığında ise %55 oranında azalma tespit edilmiştir.
- Hidrostatik iç basınç testi sonrası 223°C kaynak sıcaklığındaki numunelerde %kopma uzama değerinde % 31.25, 220°C kaynak sıcaklığında ise %30.20 oranında azalma tespit edilmiştir.

6. Kaynaklar

- Akkurt, A, Saraç, E, 2015. Sıcak Alın Kaynak Yöntemi ile Farklı Sıcaklıklarında Birleştirilen Pe Doğalgaz Transfer Hatlarının Güvenirliklerinin Araştırılması. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, **21**(1), 15-23.
- Akkurt, A., 2013. An Analysis of Electro-Melting and Hot Element Welding Methods' Safety Used to Join PE Natural Gas Pipes. *International Journal of Mechanical Mechatronics Engineering*. **3**, 2493-504.

- Akkurt, A., Ertürk, İ., 2010. Sıcak Eleman Alın Kaynak Yöntemi ile Birleştirilen PE Doğalgaz Borularının Güvenirliklerinin Araştırılması. *Pamukkale Üniv. Mühendislik Bilimleri Dergisi*, **16**(2), 221-233.
- Benkreira, H., Shillitoe, S., Day, A.J., 1991. Modelling of the Butt Fusion Welding Process. *Chemical Engineering Science*, **46**(1), 135-142.
- Cai, Z., Dai, H., ve Fu, X., 2018. Investigation on the Hot Melting Temperature Field Simulation of HDPE Water Supply Pipeline in Gymnasium Pool, *Results in Physics*, **9**, 1050-1056.
- Chen, H., Scavuzzo, R.J, T.S, Srivatsan.,1997. Influence of Joining on The Fatigue And Fracture Behavior of High Density Polyethylene Pipe. *J. Mater. Eng. Perform.* **6** (4) 473–480.
- Cocard, M., Grozav, I., Iacob, M. ve Caneparu, A., 2009. Establishing the Optimum Welding Procedure for PE 100 Polyethylene Pipelines Using the Response Surface Design, *Materiale Plastice*, **46** (4), 452-457.
- Doaei, M., Tavallali, M.S., 2018. Intelligent Screening of Electro-Fusionpolyethylene Joints Based on a Thermal NDT Method. *Infrared Physics Technology*. **90**, 1–7.
- Ergül, E., Gezeğin, C. ve Yıldız, A., 2019. Yanıt yüzey yöntemi ve genetik algoritma kullanılarak transformatör sargı en sıcak nokta sıcaklığının modellenmesi ve optimizasyonu, *DÜMF Mühendislik Dergisi*, **10** (2), 467-480.
- Frederick, C., Porter, A., ve Zimmerman, D., 2009. High-Density Polyethylene Piping Butt-Fusion Joint Examination Using Ultrasonic Phased Array. *Material Sciences*, **132**(5), 8.
- Hilmioğlu, N., 2022. Optimization of Synthesis of Ethyl Acetate by Response Surface Method and Investigation of Reactive Sorption Effect of Hydrogel in Synthesis, *European Journal of Science and Technology*, (35), 94-101.
- Myers, R.H., ve Montgomery, D.C., 1995. Response surface methodology: process and product optimization using designed experiments, *4,Wiley*, 856.
- Nigiz, F.U, 2018.Yüzey Yanıt Metodu ile Optimize Edilen Metil Laurat Üretiminin Membran Reaktörde Uygulaması, *Mühendislik Bilimleri ve Tasarım Dergisi*, **6**(1), 47-55.
- Pathak, S., Pradhan, S., 2020. Experimentation and Optimization of HDPE Pipe Electro Fusion and Butt Fusion Welding Processes, *Materials Today: Proceedings*, **27**, 2925-2929.
- Shapheek, M., Shrivastava, N., 2020. Optimization of cooling time for polyethylene fusion joints, *Materials Today: Proceedings*, **28**, 1267-1272.
- Sheng, L. H., Ni, T. N., Bong Y. K. ve Hee, K. S., 2016. Effects of defects on failure of butt fusion welded polyethylene pipe, *International Journal of Pressure Vessels and Piping*, **139**, 117-122.
- Takehiko, W, & Hiyasa, S, 1998. Eutectic Bonding of Al Pipe to Cu Pipe. *Journal of The Japan Welding Society*, **16**(1), 35-44.
- Tarek, M.A.A., Sallam, H., ve Younan M, 2014. Effect of strain rate, thickness, welding on the J–R curve for polyethylene pipe materials, *Theoretical and Applied Fracture Mechanics*, **74**, 164-180.
- Uzun, H., Kocaman, A., HDPE 100 Boruların Sıcak Eleman Alın Kaynağıyla Birleştirilmesinde Kaynak Sıcaklığı Parametresinin Birleştirme Mukavemetine Etkisi, 6th International Symposium on Innovative Technologies in Engineering and Science, Alanya, Türkiye, 9-11 Aralık 2018.
- Uzunoğulları, P., 2010. Patates Atığında Aureobasidium Pullulans ile Pullulan Üretimi ve Cevap Yüzey Yöntemi ile Proses Koşullarının Optimizasyonu, Yüksek Lisans, Ege Üniversitesi Fen Bilimleri Enstitüsü, İzmir.
- Yılmaz, O, Ertürk, M, 2021.Etil Asetat Üretiminin Yanıt Yüzey Yöntemi ile Optimizasyonu, Yüksek Lisans Tezi, Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Kocaeli.

Araştırma Makalesi / Research Article

e-ISSN 2667-4165 (<https://dergipark.org.tr/akuumbd>)

Floroetilenpropilen (FEP)/Grafen Hidrofobik Kaplamaların Üretim Parametrelerinin Optimizasyonu

Batuhan ÖZAKIN¹, Mustafa PEHLİVAN^{1*}, Orhan Deniz ACER¹

¹Samsun University, Kavak Vocational School, Department of Motor Vehicles and Transportation Technologies, Samsun.

e-mail: ¹batuhan.ozakin@samsun.edu.tr ORCID: 0000-0003-1754-949X, ^{1*}mustafa.pehlivan@samsun.edu.tr ORCID: 0000-0002-7469-6528, ¹acerorhandeniz@gmail.com ORCID: 0009-0006-5416-9719

Received :29.06.2023; accepted:20.07.2023

Öz

Akışkan madde taşıyan yüzeylerin hidrofobik malzemelerle kaplanması sürtünme faktörünün azaltılmasında etkili sonuçlar göstermektedir. Bu çalışmada hidrofobik özellik sergileyen floroetilenpropilen (FEP) malzemenin hidrofobik davranışını artırmak için ilave edilen nano grafen katkısının üretim parametrelerinden katkı oranı, kürlenme sıcaklığı ve kürlenme süresi parametreleri optimize edilmiştir. Optimize edilen üç parametre için üç farklı seviye literatür kaynaklarından belirlenmiştir. Bu seviyeler grafen katkı oranları için ağırlıkça %1, %2, %3, kürlenme sıcaklıkları için 200 °C, 300 °C, 400 °C ve kürlenme süreleri için ise 30 dak, 40 dak, 50 dak olarak uygulanmıştır. L9 Taguchi dizisine uygun şekilde AISI 304 sac malzeme yüzeylerine floroetilenpropilen/grafen karışımı uygulanmış ve kürlenme işlemi fırında tamamlanmıştır. Optimizasyon işlemi yüzeylere bırakılan su damlasının temas açılımları yanıtlarına göre gerçekleştirilmiştir. Floroetilenpropilen içerisine ilave edilen grafenin optimum katkı oranı %1, kürlenme sıcaklığının optimum değeri 400 °C ve kürlenme süresinin optimum değerinin ise 40 dak olduğu tespit edilmiştir. Varyans analizinden temas açılımları üzerinde en etkili parametrenin %96.78 oranla kürlenme sıcaklığı olduğu belirlenmiştir. Floroetilenpropilen kaplama malzemesine ilave edilen katkılara optimum üretim parametrelerinin uygulanması pompa, türbin, tesisat vb. uygulamalarda enerji tasarrufuna katkıda bulunabileceği sonucuna varılmıştır.

Anahtar kelimeler

FEP; Kürlenme Şartları;
Taguchi Metodu; Yüzeysel Mühendisliği; Temas Açısı

Optimization of Manufacturing Parameters for Fluorinated Ethylene Propylene (FEP)/Graphene Hydrophobic Coatings

Abstract

The coating of surfaces carrying fluid with hydrophobic materials has shown effective results in reducing friction factors. In this study, the optimization of manufacturing parameters, including the additive ratio, curing temperature, and curing time was conducted to enhance the hydrophobic behavior of fluorinated ethylene propylene (FEP) material by incorporating nano graphene additives. Three different levels for the optimized parameters were determined based on the literature sources. These levels were set as 1% wt, 2% wt, and 3% wt for graphene additive ratios, 200 °C, 300 °C, and 400 °C for curing temperatures, and 30 min, 40 min, and 50 min for curing times. Following the L9 Taguchi design, the FEP/graphene mixture was applied to AISI 304 stainless steel surfaces, and the curing process was completed in an oven. The optimization process was performed based on the response of water droplet contact angles on the surfaces. The optimum graphene additive ratio was determined as 1%, the optimum curing temperature was 400 °C, and the optimum curing time was found to be 40 min. Variance analysis revealed that the curing temperature had the most significant effect on the contact angles with a contribution rate of 96.78%. Applying the optimal manufacturing parameters to the FEP coating material with added additives can contribute to energy savings in applications such as pumps, turbines, and pipelines.

Keywords

FEP; Curing Conditions;
Taguchi Method;
Surface Engineering;
Contact Angle

1. Introduction

In the majority of engineering applications, fluid substances are transported from one place to another to carry out processes (Yumurtacı and Sarigül, 2011). One way to achieve energy savings in the transportation of fluid substances is by reducing the friction losses occurring in pipelines. The decrease in the friction factor reduces pressure drop, thus enabling energy conservation. With the recent advancements in surface coating technologies, low surface energy materials can be produced, resulting in the creation of hydrophobic, or water-repellent, surfaces. These surfaces eliminate the no-slip condition at the fluid-solid interface, reducing the shear stress and consequently decreasing the frictional force (Voronov et al. 2007; Choo et al. 2007). It is applied in industrial sectors due to its stated properties. Therefore, surfaces are coated with hydrophobic materials. In line with this objective, the literature studies are as follows. Tanaka and Kawakami (1982) suggested the use of surface engineering technology to prepare hydrophobic and wear-resistant composite coatings by incorporating carbon fibers, graphene, or carbon nanotubes into pure hydrophobic polytetrafluoroethylene (PTFE) coatings. They aimed to enhance the hardness and wear resistance of the coatings (Tanaka and Kawakami, 1982). Takahashi et al. (2011) processed PTFE using reactive ion etching in a plasma reactor with Ar, CF₄, N₂, and O₂ gases, resulting in surfaces with different wetting properties. Particularly, they obtained a surface with a water contact angle higher than 150° after CF₄ plasma treatment, demonstrating reduced friction of water droplets (Takahashi et al. 2011). Wang et al. (2015) produced hydrophobic coatings by physically blending SiO₂ and PTFE nanoparticles. They found that the coating surface filled with hydrophobic SiO₂ exhibited better homogeneity compared to untreated SiO₂, and the maximum measured contact angle on the composite coating surface was 163.1° (Wang et al. 2015). Nemati et al. (2016) used a spin coating method to prepare PTFE/graphene oxide composite coatings on stainless steel substrates, showing that a volume

fraction of 15% graphene oxide could significantly reduce the friction coefficient and wear rate (Nemati et al. 2016). Wu et al. (2019) created a composite coating using carbon fiber-reinforced PTFE and reported that when the mass fraction of carbon fiber was 20%, the water contact angle reached $122.0 \pm 2.0^\circ$, indicating excellent hydrophobic properties (Wu et al. 2019). Chen et al. (2022) prepared PTFE/Al₂O₃ composites at 340 °C for 30 minutes. They observed that these composites formed a water contact angle of 135° (Chen et al. 2022). Furthermore, Wang et al. (2022) prepared carbon fiber-reinforced PTFE composite coatings on 35CrMo steel substrates using a one-step spray method, followed by laser surface modification. They investigated the effects of coatings with 10%, 20%, and 30% carbon fiber content on the contact angle, friction coefficient, and wear rate. They found that the 30% carbon fiber-reinforced coating exhibited the strongest hydrophobic characteristic (Wang et al. 2022).

It is commonly observed in the literature that fluorinated ethylene propylene (FEP) and PTFE materials are frequently used to impart hydrophobicity to surfaces. The addition of graphene, silica, alumina, carbon fiber, carbon nanotubes, and other materials to these mentioned polymers has been found to enhance the hydrophobicity of the resulting composite materials, thereby reducing the friction occurring on the surface. Furthermore, to achieve a hydrophobic surface, coatings are prepared with various manufacturing parameters such as particle size, reinforcement ratio, coating thickness, coating type, curing temperature, curing time, etc. The literature studies investigating the effects of these parameters are as follows. Lin et al. (2016) found that curing PTFE material at 230°C for 50 min resulted in a hierarchical structure characterized by microspheres with numerous nano-pores on the surface, providing excellent water repellency (Lin et al. 2016). Bansal et al. (2020) examined the influence of coating thickness on the hydrophobicity of PTFE coatings and concluded that the PTFE coating with the minimum thickness among the selected thickness parameters exhibited

superhydrophobic behavior with a contact angle of 159° (Bansal et al. 2020). Ayyagari et al. (2021) examined the influence of nanoparticle concentration, percentage of PTFE polymer, and rotational coating speed (rpm) on various properties of the coating such as contact angle, roll-off angle, scratch hardness, adhesion, and thickness. They also determined a coating formulation for achieving higher contact angles and mechanical properties (Ayyagari et al. 2021). Sun et al. (2021) demonstrated that the addition of graphene nanoparticle additives to PTFE coatings reduced the amount of wear, which rapidly decreased up to a 2% additive ratio, followed by a slower decrease. The minimum wear rate was achieved in the composite with at least a 10% nanoparticle addition (Sun et al. 2021). Overall, considering the literature, it is observed that hydrophobic coatings applied to material surfaces involve various variable parameters. In this regard, there are numerous studies in the literature. The most influential parameters in enhancing the hydrophobic behavior of FEP and PTFE materials are the type and ratio of additives, coating thickness, curing temperature, curing time, etc. Although there have been studies on the

optimization of these parameters, it can be stated that further contributions are still needed in this field.

In this study, the manufacturing parameters of FEP/graphene hydrophobic coatings were optimized using the Taguchi method. The graphene additive ratio, curing temperature, and curing time were considered as the three parameters, each with three levels. The optimum levels for these three parameters were determined based on the contact angles of water droplets deposited on the surface. Additionally, variance analysis was conducted to perform statistical evaluations.

2. Material and Methods

2.1 Material

AISI 304 stainless steel material was used extensively in applications such as pumps, turbines, and pipelines due to its high corrosion resistance performance (Akinlabi et al. 2019). The chemical composition of the AISI 304 sheet material used in this study is given in Table 1 (Özakin and Kurgan, 2022). Sheet material samples were cut into dimensions of 30 × 30 × 1 (mm³). The surfaces of the substrate material were cleaned with acetone and prepared for the coating process.

Table 1. Chemical composition of AISI 304 substrate (Özakin and Kurgan, 2022)

Chemical composition (%wt)													
Fe	C	Si	Mn	P	S	Cr	Ni	Cu	Al	V	Co	W	Mo
Balance	0.016	0.412	1.466	0.040	0.007	18.273	7.887	0.196	0.007	0.084	0.230	0.011	0.125

2.2 Methods

Within the scope of the study, it was decided to optimize the parameters of graphene content, curing temperature, and curing time for the manufacturing of FEP/graphene hydrophobic coatings. Based on the information in the literature, a L9 Taguchi experimental design was planned with three levels for each parameter (Sun et al., 2021; Pehlivan and Özbey, 2022). The experimental layout conforming to the Taguchi L9 orthogonal array is presented in Table 2.

Table 2. Taguchi experimental design

Experiment No	Control Factor		
	Graphene additive ratio (% wt)	Curing Temperature (°C)	Curing time (min)
1	1	200	30
2	1	300	40
3	1	400	50
4	2	200	40
5	2	300	50
6	2	400	30
7	3	200	50
8	3	300	30
9	3	400	40

Figure 1 presents the sequential methods used in the experimental study. In the first stage, nano-sized graphene (5 nm thickness, 30 µm diameter;

Nanografi Inc.) was added to the FEP material obtained from the market at 1% wt, 2% wt, and 3% wt ratios. The mixtures were prepared using a mechanical homogenizer. The obtained mixtures

were then sprayed onto the substrate surfaces using a spray gun to achieve a homogeneous distribution, following the experimental design.




Figure 1. Methods used in the experimental study

The curing process in the study was carried out using a Refsan RS400 furnace. The curing temperature and curing time parameters were linearly increased from room temperature to the curing temperatures to enhance the adhesion of the coating, and they were maintained at those temperatures for 10 min. After the 10 min period, the experimental samples were left to cool inside the furnace. For example, in experiment number 1, the FEP mixture with a 1% graphene additive reached 200°C within a linear temperature increase of 20 min and was kept at this temperature for 10 min. Subsequently, it cooled down in the furnace until it reached room temperature. The samples prepared according to the L9 orthogonal array used in the study are shown in Figure 2.




Figure 2. Samples prepared in accordance with the L9 orthogonal array

Contact angles were measured using a contact angle goniometer (Attention Theta Flex, Biolin Scientific, Sweden) at room temperature. A 5 µL water droplet was placed on the sample surfaces, and the image of the droplet was captured in a planar manner using a high-speed camera. The

contact angles were measured at two different points, one on the right side and one on the left side of each image obtained from the samples. The contact angle value was calculated as the average of these two measurements. The measured contact angles from the samples prepared according to the L9 orthogonal array are shown in Figure 3. The analyses of the Taguchi method and the analysis of variance (ANOVA) were conducted using Minitab 18 software.

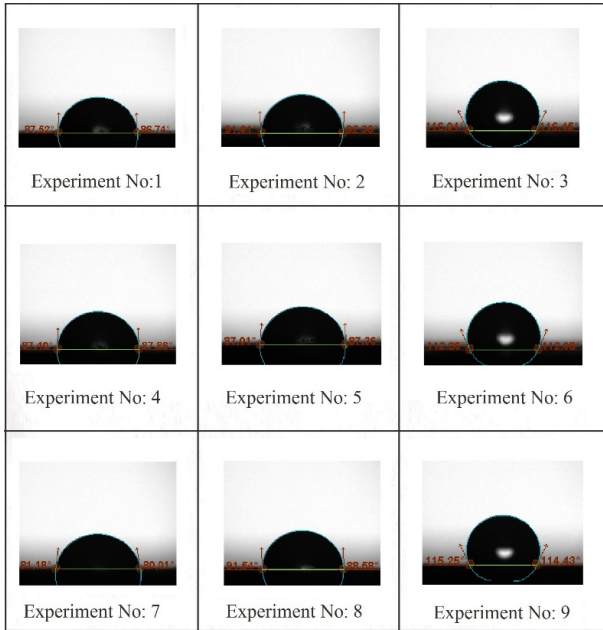


Figure 3. Measured contact angles

3. Results and Discussion

The Taguchi method was employed for the optimization of the manufacturing parameters of FEP/graphene hydrophobic coatings. Signal-to-noise ratios (S/N) were calculated based on the observed contact angles of water droplets placed on the test samples prepared according to the L9 orthogonal array. The contact angle of the water droplet on the material surface, being 90° or above, is an indication of the surface hydrophobicity (Ma et al., 2007). Therefore, the larger the contact angle, the more hydrophobic the surface is. Based on this principle, the S/N ratios were determined using the criterion of "larger is better." The S/N value was calculated according to Equation 1.

$$\frac{S}{N} = -10 \log\left(\frac{1}{n} \sum_{i=1}^n \frac{1}{Y_i^2}\right) \quad (1)$$

Table 3 presents the values of contact angles obtained from the experimental studies conducted according to the L9 orthogonal array, along with the signal-to-noise (S/N) ratios determined based on the criterion of "larger is better" for the contact angle responses. The results in Table 3 demonstrate that the FEP coating with 1% graphene addition, cured at 400°C for 50 min, exhibits the maximum contact angle. In contrast, the coating with 3% graphene addition, cured at 200°C for 50 min, shows the minimum contact angle. It was observed that the materials cured at 400°C exhibit significantly higher contact angles on their surfaces.

Table 3. Experimental contact angles and S/N ratios

Experiment No	Parameters			Results	S/N Ratios
	Graphene additive ratio (%)	Curing temperature (°C)	Curing time (min)	Contact angle (°)	Contact angle (dB)
1	1	200	30	87.13	38.8034
2	1	300	40	91.69	39.2464
3	1	400	50	116.25	41.3079
4	2	200	40	87.63	38.8531
5	2	300	50	87.19	38.8093
6	2	400	30	112.17	40.9975
7	3	200	50	80.60	38.1267
8	3	300	30	90.06	39.0906
9	3	400	40	114.84	41.2019

The optimal conditions for achieving a high contact angle are shown in Figure 4 through the main effect plots and in Table 4 through the contact angle responses in terms of the S/N ratios. The magnitude of the S/N ratio is the most important indicator for identifying the optimal values. In Figure 4, an increase in graphene addition leads to a decrease in the S/N ratio. Among the three addition levels of graphene (1-3%), the optimal addition ratio is 1%. Similarly, as the curing temperature increases, the S/N ratio also increases. Among the curing temperatures used in the study (200-400°C), the optimal temperature is 400°C. Additionally, the optimal curing time is observed to be 40 min, which corresponds to the higher S/N ratio.




Figure 4. Main effect plots for S/N ratios of contact angles

Table 4 shows the order used to determine the effect of parameters in the analysis of contact angles. From this analysis, it was determined that the curing temperature is the most influential parameter, followed by the curing time, and the least influential parameter is the graphene addition ratio. The optimal parameters were found to be 1% graphene addition ratio, 400°C curing temperature, and 40 min of curing time. As mentioned earlier, it was observed that materials cured at 400°C exhibited significantly higher contact angles on their surfaces. The use of a 1% graphene addition ratio contributed to achieving maximum contact angle on the surfaces. It was also observed that surfaces coated with a curing time of 40 min had the maximum contact angle.

Table 4. Signal-to-Noise (S/N) ratios derived from contact angles responses

Level	Graphene additive ratio (%)	Curing temperature (°C)	Curing time (min)
1	39.79	38.59	39.63
2	39.55	39.05	39.77
3	39.47	41.17	39.41
Delta	0.31	2.57	0.35
Rank	3	1	2

Analysis of variance (ANOVA) was conducted to determine the effect of coating parameters on the contact angles. ANOVA was applied with a 95% confidence level and a 5% significance level. Table 5 presents the results of variance analysis for the contact angles. According to the ANOVA results, it was found that the curing temperature is the most significant parameter with a contribution rate of 96.78% on the contact angles. This was followed by the graphene addition ratio with a contribution rate of 1.15%. The parameter with the least impact on the contact angles was determined to be the curing time with a contribution rate of 1.11%. One of the striking findings of the study was the significance of the curing temperature as the most important parameter, with an optimal point determined to be 400°C. This is believed to be

related to the better spreading of FEP on the substrate material at temperatures above its melting point (Barhoumi et al. 2022). This finding

indicates that it contributes to better hydrophobic properties.

Table 5. Analysis of variance for contact angles

Source	DF	Seq SS	Contribution	Adj SS	Adj MS	F-Value	P-Value
Graphene additive ratio (%)	2	17.68	1.15%	17.68	8.838	1.18	0.459
Curing temperature (°C)	2	1492.70	96.78%	1492.70	746.349	99.65	0.010
Curing time (min)	2	17.08	1.11%	17.08	8.542	1.14	0.467
Error	2	14.98	0.97%	14.98	7.489		
Total	8	1542.44	100.00%				

4. Conclusion

This study aimed to optimize the manufacturing parameters of nanographene added to FEP, a hydrophobic coating, in order to reduce energy requirements by minimizing the friction factor in fluid transportation. The Taguchi method was employed to optimize the additive ratios, curing temperatures, and curing times. The Taguchi optimization was based on the contact angle measurements of water droplets on the surface. The experimental results yielded the following outcomes.

- It was observed that the optimum graphene addition ratio in FEP was 1%. The optimum curing temperature was determined to be 400°C. Lastly, the optimum curing time was found to be 40 min.
- According to the variance analysis, the curing temperature was identified as the most influential parameter with a contribution of 96.78% on the contact angles. The graphene addition ratio and curing time had contributions of 1.15% and 1.11% respectively. Considering these ratios, it can be seen that the graphene addition ratio and curing time had similar effects.
- Among the parameters used in the optimization, it was determined that the curing temperature had the most significant impact on the contact angles.
- The FEP/graphene composite materials have shown promising results in reducing the friction factor in the transportation of

fluids. Therefore, applying the optimal manufacturing parameters to the FEP coating material with added additives can contribute to energy savings in applications such as pumps, turbines, and pipelines.

Acknowledgements

This study was supported by “TUBITAK 2209-A University Students Research Projects Support Program”.

5. References

- Akinlabi, E.T., Baruwa, A.D., Oladijo, O.P., Maledi, N. and Chinn, J., 2019. Characterization of Hydrophobic Silane Film Deposited on AISI 304 Stainless Steel for Corrosion Protection. *Journal of Materials Engineering and Performance*, **28**(10), 6330-6339.
- Ayyagari, S.V.G., Daware, S.V. and Rai, B., 2021. Data-driven approach to optimize composition and process parameters of hydrophobic coating formulation, *Surfaces and Interfaces*, **23**, 100972.
- Bansal, A., Singh, J. and Singh, H., 2020. Erosion behavior of hydrophobic polytetrafluoroethylene (PTFE) coatings with different thicknesses, *Wear*, **456**, 203340.
- Barhoumi, N., Khlifi, K., Maazouz, A. and Lamnawar, K., 2022. Fluorinated ethylene propylene coatings deposited by a spray process: mechanical properties, scratch and wear behavior. *Polymers*, **14**(2), 347.
- Chen, X., Dai, C., Zhang, T., Xu, P., Ke, W., Wu, J., Qui, M., Fu, K. and Fan, Y. 2022. Efficient construction of a robust PTFE/Al₂O₃ hydrophobic membrane for effective oil purification. *Chemical Engineering Journal*, **435**, 134972.

- Choo, J.H., Spikes, H.A., Ratoi, M., Glovnea, R. and Forrest, A. 2007. Friction reduction in low-load hydrodynamic lubrication with a hydrophobic surface. *Tribology International*, **40**(2), 154-159.
- Lin, K., Zang, D., Li, X. and Geng, X., 2016. Superhydrophobic polytetrafluoroethylene surfaces by spray coating on porous and continuous substrates, *RSC Advances*, **6**(52), 47096-47100.
- Ma, Y., Cao, X., Feng, X., Ma, Y. and Zou, H., 2007. Fabrication of super-hydrophobic film from PMMA with intrinsic water contact angle below 90. *Polymer*, **48**(26), 7455-7460.
- Nemati, N., Emamy, M., Yau, S., Kim, J.K. and Kim, D.E., 2016. High temperature friction and wear properties of graphene oxide/polytetrafluoroethylene composite coatings deposited on stainless steel, *RSC Advances*, **6**(7), 5977-5987.
- Özakin, B. and Kurgan, N., 2022. AISI 304 paslanmaz çelik sac malzemelere temper haddeleme ile pürüzlülük transferinde haddeleme parametrelerinin etkisinin incelenmesi. *Politeknik Dergisi*, **25**(3), 1201-1209.
- Pehlivan, M. and Özbey, M. 2022. Hidrofobik Yüzeylerin Türbülanslı Boru Akımlarında Sürtünme Kayıplarına Etkisinin Deneysel İncelenmesi. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, **10**(3), 1383-1397.
- Sun, W., Liu, X., Liu, K., Xu, J., Lu, Y. and Ye, J., 2021. Mechanochemical functionality of graphene additives in ultralow wear polytetrafluoroethylene composites, *Carbon*, **184**, 312-321.
- Takahashi, T., Hirano, Y., Takasawa, Y., Gowa, T., Fukutake, N., Oshima, A., Tagawa, S. and Washio, M., 2011. Change in surface morphology of polytetrafluoroethylene by reactive ion etching, *Radiation Physics and Chemistry*, **80**(2), 253-256.
- Tanaka, K. and Kawakami, S., 1982. Effect of various fillers on the friction and wear of polytetrafluoroethylene-based composites. *Wear*, **79**(2), 221-234.
- Voronov, R.S., Papavassiliou, D.V. and Lee, L.L., 2007. Slip length and contact angle over hydrophobic surfaces. *Chemical Physics Letters*, **441**(4-6), 273-276.
- Wang, H., Chen, E., Jia, X., Liang, L. and Wang, Q., 2015. Superhydrophobic coatings fabricated with polytetrafluoroethylene and SiO₂ nanoparticles by spraying process on carbon steel surfaces, *Applied Surface Science*, **349**, 724-732.
- Wang, L.T., Wang, R.Z., Zhu, L.N., Yue, W., Kang, J.J., Fu, Z.Q., She, D.S, Feng, M.G. and Wang, C.B., 2022. Hydrophobicity and wear resistance of textured carbon fiber/polytetrafluoroethylene composite coatings, *Journal of Materials Engineering and Performance*, **31**, 9200-9208.
- Wu, H., Zhu, L.N., Yue, W., Fu, Z.Q. and Kang, J.J., 2019. Wear-resistant and hydrophobic characteristics of PTFE/CF composite coatings, *Progress in Organic Coatings*, **128**, 90-98.
- Yumurtaci, Z. and Sarigul, A., 2011. Santrifüj pompalarda enerji verimliliği ve uygulamaları. *Makina Mühendisleri Odası Tesisat Mühendisliği Dergisi*, 49-58.

Araştırma Makalesi / Research Article

AA5754 Alüminyum Alaşımının Bilyeli Dövme Prosesi ile Mekanik Özelliklere Etkisi ve Dövme Üzerine Cr+6 Kaplamanın Korozyon Özelliklerine Bakış

Mesut BOZKURT¹, Ahmet DEMİRER¹

¹Sakarya Uygulamalı Bilimler Üniv., Teknoloji Fakültesi, Makine Müh. Turkey

e-posta: mesut.bozkuurt@gmail.com

ORCID: 0009-0006-0928-7142

e-posta: ademirer@subu.edu.tr

ORCID: 0000-0003-1252-9203

Geliş Tarihi:11.05.2023 ; Kabul Tarihi:13.09.2023

Öz

Bilyeli dövme prosesi, bir metalin yorulma ve stres korozyonuna karşı direncini artırmak için uygulanan mekanik bir yüzey işlemidir. Bu çalışmada, korozyon özelliklerinden dolayı havacılık endüstrisinde çeliğe alternatif olarak kullanılan AA5754 H111 Alüminyum alaşımının bilyeli dövme işlemi ile mekanik ve korozyon özelliklerinin artırılması amaçlanmıştır. Bu çalışmada %100 yüzey örtme oranında 3 farklı bilye çapı S110 (0,3 mm), S170 (0,4 mm), S230 (0,6 mm) ve 3 farklı Almen değerine sahip (8A-12A-15A) 3 çeşit çelik bilye ile dövme işlemi uygulanmıştır. Almen şiddeti (A); bilye çapı, bilye cinsi, püskürtme basıncı, dövme süresi ve yüzey örtme oranına bağlı olarak değişen bir ölçüm sistemidir. Elde edilen numuneler Cr+6 (Alodin) kaplama işlemine tabi tutulmuştur. Her numune çekme mukavemeti testi, pürüzlülük testi ve tuz püskürtme korozyon testine tabi tutulmuştur. Yapılan deneyler sonucu AA5754 H111 malzemesinde S170 (0,4mm) 15 Almen değerinde dövülen numunelerde malzemenin çekme mukavemeti değerinde %5,25 oranında artış meydana gelmiştir. Korozyon test sonucu ise S110 (0,3mm) bilyesininde 15 Almenlik dövülmüş numunede korozyon hasarı kısmen oluşmuştur. S170 (0,4mm) 15 Almenlik dövülmüş numune ise korozyon hasarı görülmemiştir. Sonuç olarak S170 bilyesi ve 15 Almen şiddetindeki prosese tabi tutulmuş numunelerde hem korozyon direncinin hem de çekme dayanımının arttığı tespit edilmiştir.

Anahtar kelimeler

AA 5754 H111;
Bilyeli Dövme;
Korozyon;
Cr+6 Kaplama;
Almen Şiddeti.

The Effect of Shot Peening Process on the Mechanical Properties of AA5754 Aluminum Alloy and a Perspective on Corrosion Characteristics with Cr+6 Coating on Shot Peened Surfaces

Abstract

The Shot peening process is a mechanical surface treatment applied to increase the resistance of a metal to fatigue and stress corrosion. In this study, it is aimed to increase the mechanical and corrosion properties of AA 5754 H111 Aluminum alloy, which is used as an alternative to steel in the aviation industry due to its corrosion properties, by shot peening process. In this study, 3 different steel ball diameters S110 (0.3 mm), S170 (0.4 mm), S230 (0.6 mm) and 3 different Almen values (8A-12A-15A) with 100% surface coverage ball forging was applied. The obtained samples were subjected to Cr+6 (alodyne) coating process. Each sample was subjected to tensile strength test, roughness test and salt spray corrosion test. As a result of the experiments, the tensile strength value of the material increased by 5.25% in the samples forged at S170 (0.4mm) 15 Almen in AA5754 H111 material. As a result of the corrosion test, the corrosion damage was partially formed in the 15 Almen forged sample in the S110 (0.3mm) ball. S170 (0.4mm) 15 Almen hammered sample showed no corrosion damage. As a result, it was determined that both the corrosion resistance and tensile strength increased in the S170 ball and the samples subjected to the process at 15 Almen intensity.

Keywords

AA5454 H111;
Shot Peening;
Corrosion;
Cr+6 Coating;
Almen Intensity.

1. Giriş

Bilyeli dövme (shot peening), küresel morfolojiye sahip metallerin ve alaşımların yüzey özelliklerinin iyileştirilmesine ve yüksek sertlikteki bilyelerin yüksek hızda tekrar tekrar malzeme yüzeyine vurulmasına dayanan mekanik bir yüzey işleme yöntemidir (Mhaede, 2012). Yüksek hızlarda fırlatılan küçük çaplı bilyelerin malzeme yüzeyine tekrarlı çarpması sonucu plastik deformasyon tabakası oluşturur (Alkan, 2016). Bu durum malzemenin tane yapılarını incelterek, çekme dayanımında artış, yüzeyde artık gerilme oluşumu, yüzey ve yüzey altı bölgelerinde sertlik artışı olarak gözlemlenir. Bilyeli dövme prosesinde bilyeler vasıtasıyla malzemeye kinetik enerji aktarımı sağlanmaktadır. Bu enerjinin ölçülmesi için Almen testi geliştirilmiştir. Almen şiddeti (A); bilye çapı, bilye cinsi, püskürtme basıncı, dövme süresi ve yüzey örtme oranına bağlı olarak değişen bir parametredir (Avcu,2018). Bilyeli dövme işlemi, metallerin ve alaşımların yüzey ve yüzey özelliklerini, bilhassa artık basınç gerilimi, sertlik ve yüzey topografyasını değiştirmeyi mümkün kılar. Metallerin ve alaşımların yüzey özelliklerinin, özellikle yorulma direnci, aşınma direnci ve korozyon direncinin önemli olduğu endüstriyel uygulamalar için uygulanması nispeten kolay ve ekonomik olması nedeniyle de yaygın olarak başvurulan bir yöntemdir.

Bilyeli dövme, metalik malzemelerin yüzey ve yüzey altı özelliklerini geliştirmek için kullanılan bir soğuk şekil verme yöntemidir. Malzemelerin yorulma ömrünü arttırmak için de uygulanır. Yüksek hızlarda fırlatılan küçük çaplı bilyelerin malzeme yüzeyine tekrarlı çarpması sonucu plastik deformasyon tabakası oluşturur. Uygulanan Almen şiddeti arttıkça plastik deformasyon kalınlığı da artmaktadır. Bilyeli dövme otomotiv ve havacılık sektörlerinde sıklıkla kullanılan ucuz ve erişilebilir bir yöntemdir (Kocaman ve Demirer, 2022).

Bilyeli dövme işlemi ile malzeme yüzeyinde belirli bir derinliğine kadar kalıcı basma gerilmesi oluşurken, yüzey altında ise çekme gerilmeleri oluşmaktadır. Yüzeyde oluşturulan basma gerilmeleri malzemenin yorulma dayanımını

arttırmakta ve dolayısıyla parçaların çalışma ömrünü de uzatmaktadır (Başaran, 2007). Araştırmalarda çatlak başlangıcını sınırlaması ve çatlağın yayılımını engellemesi, kalıcı basma gerilmelerinin yorulma ömrünü arttırıcı yönde davranış göstermesi, ince taneli yapıların mikro sertlik arttırışı göstermesi genel olarak karşılaşılan önemli sonuçlardır (Hongbin vd,1991; Tomlinson vd,1987; Zammit,2013; Appel,2013). Bilyeli dövme uygulaması sadece potansiyel malzeme dayanımı geliştirme tekniği olmayıp, malzeme yüzey karakteristiğini de geliştirmektedir Bu yüzey geliştirme tekniği parçaların yorulma ve korozyon dirençlerini, mekanik karakteristiklerini geliştirir (Nouguier,2013; Kocan,2005).

Alüminyum malzemeler yüksek korozyon direnci, yüksek özgül dayanım, kolay işlenebilirlik, hafiflik özellikleriyle çelikten sonra en yaygın kullanılan mühendislik malzemeleridir. Alüminyum çelik ile kıyaslandığında üç kat daha hafiftir enerji tasarrufunun önem kazandığı savunma sanayinde, trenler, uçaklar, gemiler ve otomobiller gibi pek çok alanda tercih edilmektedir (Başer, 2012). Son yıllardaki gelişmeler ile birlikte askeri araçlarda hız ve manevra kabiliyetinin arttırılması önemli bir konu olmuştur. Çelik malzemelerin yerini alacak alüminyum alaşımlarının mekanik özelliklerinin iyileştirilmesi yapılan çalışmaların başlıca amaçlarındandır (Coşkun, 2002).

Günümüz endüstrisinde önemli bir malzeme olan alüminyum ve alüminyum alaşımları; yüksek özgül mukavemeti, düşük yoğunluğu ve kolay kalıplanması nedeniyle elektronik, havacılık, savunma sanayi vb. birçok alanda kullanılmaktadır. Fakat düşük aşınma direnci, alüminyum ve alaşımlarının uygulamalarını sınırlar. Ayrıca kimyasal bileşimi nedeniyle alüminyum ve alaşımları korozyona karşı hassastır. Alaşımlama, ısıl işlem ve yüzey kaplama işlemleri, bu bahsedilen alüminyum alaşım kusurlarını en aza indirmek için kullanılır. Bu işlemler arasında alüminyum alaşımlarını çevresel etkilerden korumak ve yüzey özelliklerini iyileştirmek için yüzey kaplama işlemleri yaygın olarak kullanılmaktadır. Yüzey işlemleri malzemeye çok iyi aşınma direnci sağlar

(Varol, 1990). Alüminyum alaşımının yorulma ömrünün optimum parametrelerin altında uygulanan bilyeli dövme işlemi ile geliştirildiğini, ancak bilyeli dövme şiddetinin aşırı olması durumunda ise yorulma dayanımının azaldığını belirtmişlerdir (Trsko ve ark, 2014).

Havacılıkta kullanılan Alüminyum alaşımlarının bilyeli dövme ile yüzeyden itibaren belirli bir derinliğe kadar özelliklerinin geliştirilmesi çalışmaları yapılmıştır. Nozul mesafesi, bilye püskürtme basıncı, bilye çarpma açısı ve bilyeli dövme süresi gibi önemli işlem parametrelerinin alüminyum alaşımının mikro sertliğine ve artık basma gerilmesine olan etkileri araştırılmış ve araştırma sonucunda bu parametrelerin mikro sertliği ve artık basma gerilmesini önemli ölçüde etkilediği belirlenmiştir (Nam ve ark, 2015).

Bu deneysel çalışmada 5XXX serisi alüminyum alaşımı (AA5754 H111) malzemeye bilyeli dövme prosesi uygulanarak yüzeyde plastik deformasyon sertleşmesi ile yüzey sertliği artırılarak mekanik özelliklerinden çekme mukavemeti ve sertliğin bir miktar artırılması hedeflenmiştir. Bu durum aynı zamanda yorulma dayanımını da olumlu yönde arttıracığı bilinmektedir. Çalışmaya ayrıca ek olarak korozyon direncinin artırılması için elde edilen dövülmüş pürüzlü yüzeye Cr+6 (krom 6) kaplama uygulaması gerçekleştirilmiştir. Ek olarak yapılan

kimyasal kaplamanın genişletilmiş yüzey alanına daha fazla nüfuz ederek kaplamanın daha uzun süre tutunabilmesi de hedeflenmiş bu kaplamanın korozyon davranışı da çalışmada görsel olarak incelenmiştir.

Literatürden farklı olarak çalışmamızda Almen şiddetinin malzemenin mekanik özelliklerine etkisi araştırılmış ve ayrıca bilyeli dövme üzerine Cr+6 kaplamanın korozyon davranışı görsel olarak incelenmiştir. İleriki çalışmalarda korozyon etkisi daha detaylı incelenecektir.

2. Malzeme ve yöntem

2.1. Malzeme

AA5754 malzemesi mukavemetin yanında korozyon dayanımının da arandığı bölgelerde tercih edilmektedir. Yüksek kaynak kabiliyeti sebebiyle özellikle kaynaklı birleştirmelerde, yakıt tankı üretimi, gemi ve yat endüstrisi ve raylı taşıtlar, uçak kargo kompartımanları, nükleer endüstrisi ve otomotiv sanayisinde AA5754 alaşımının yoğun olarak kullanıldığı alanlardır. H111, malzemenin temper işlemine tabi tutulduğunu göstermekte ve bu malzemelerin yüzde uzama özelliğinin yüksek olması nedeniyle, soğuk şekillendirmelerde tercih edilmektedir. AA5754 H111 malzemesine ait kimyasal özellikler Tablo 1’de, mekanik özellikler ise Tablo 2’de verilmiştir.

Tablo 1. AA5754 H111 Alaşımının Kimyasal Özellikleri

Elementler	Si	Fe	Cu	Mn	Mg	Cr	Zn	Ti	Diğer	Al
Kütlece %	0,27	0,36	0,08	0,29	2,8	0,05	0,13	0,04	0,03	Kalan

Tablo 2. AA5754 H111 Malzemesinin Mekanik Özellikleri (Seykoç Alüminyum)


Temper	Akma Mukavemeti (MPa)	Çekme Mukavemeti (MPa)	Uzama %	Sertlik (HV)
H111	126	216	25	86

2.2. Yöntem

Bilyeli dövme işlemi SGM-1000G marka vakumlu tip bilyeli dövme makinesinde yapılmıştır. Manuel ayarlamalı olan ve makine için geliştirilen düzenele alüminyum numune plakalarına bilyeli

dövme işlemi uygulanmıştır (Şekil 1). Dövme prosesinde kullanılan bilyelerin kodlanmasında “S” bilyenin çelik olduğunu, ardından gelen numara ise bilyenin inç cinsinden çapını vermektedir. Örneğin

S230 bilyenin çapı, $230 \times (10^{-4})$ inç'dir (Başaran, (bilye çapı) Tablo 3'te verilmiştir. 2007). Bilyelere ait SAE standardı ve tane boyutu



Şekil 1. Deneysel çalışmanın bilyeli dövme düzeneği

Tablo 3. Çelik bilyelerin standardı ve çapları (Karahana ve İnce, 2015).

SAE	Tane Boyutu (mm)
S-70	0,20-0,40
S-110	0,30-0,60
S-170	0,40-0,70
S-230	0,60-0,90
S-280	0,70-1,00
S-330	0,90-1,20
S-390	1,00-1,40
S-460	1,20-1,70
S-550	1,40-2,00
S-660	1,70-2,40
S-780	2,00-2,40

Çalışmada işlem parametreleri 3 farklı bilye (tane) boyutuna sahip (S110, S170 ve S230) bilyelerle, üç farklı Almen şiddetinde (9A, 12A ve 15 A) ve %100 yüzey örtme oranında dövülmüştür. Tablo 4'te proses detaylı şekilde gösterilmiştir.


AA5754 H111 alüminyum numuneleri uygun ölçülerde kesilerek bilyeli dövme işlemine farklı Almen şiddeti ve farklı bilye çaplarına tabi tutulmuştur. Elde edilen numuneler Cr+6 (Krom-6) alüminyum kaplama proseslerinden geçirilerek korozitif dayanım özellikleri daha yüksek bir

kaplama elde edilmeye çalışılmıştır. Bilyeli dövme işlemi sonrası yüzey pürüzlüğü yüzey profilometresi ile ölçülmüştür. Kaplanmış numuneler tuz sisi testine tabi tutularak korozyona karşı dirençleri karşılaştırılmıştır. Nihai, mekanik davranışları incelemek için tahribatlı muayene yöntemlerinden olan çekme testleri yapılarak test aşaması sonuçlanmıştır. Elde edilen sonuçlar değerlendirilerek malzemelerin farklı proses şartlarına göre çekme dayanımları ve kaplamanın korozyon dirençleri karşılaştırılarak tablo halinde verilmiştir.

Tablo 4. Bilyeli dövme prosesi parametreleri

Malzeme	Bilye Ölçüsü	Yüzey Örtme Oranı	Almen Şiddeti
AA5754 H111	S110	100	8A
		100	12A
		100	15A
	S170	100	8A
		100	12A
		100	15A
S230	100	8A	
	100	12A	
	100	15A	

Bilyeli dövme (shot peening) prosesi ile malzemelerde oluşan çekme dayanımı özelliklerini incelemek için her numune proses öncesi ve sonrası çekme testine tabi tutulmuştur. Plaka şeklinde alınan malzeme üzerinden TRUMPF-82 CNC LAZER makinesi ile çekme numuneleri kesilmiştir. Çekme numunelerinin boyutları Şekil 2’de, hadde yönü ise Şekil 3’ de gösterilmiştir. Çekme deneyleri SHIMADZU AGIC çekme test cihazında gerçekleştirilmiştir. Bilyeli dövme işlemi öncesi ve sonrası yüzey pürüzlülüğünün ölçülmesi için ART300 cihazı (Şekil 4) kullanılmıştır. Yüzey özelliklerinin incelenmesi için bilye ile dövülen plaka formundaki malzemelerden 10x10mm boyutunda numuneler alınarak JEOL JSM-6060LV taramalı elektron mikroskobu (SEM) kullanılmıştır.


**Şekil 2.** Çekme numunesi boyutları (ISO 6892-1)

Çalışmada alüminyum üzerine uygulanan—Cr+6 (krom-6) kaplama malzemenin korozyon direncini artırması amaçlı uygulanmış olup endüstride ismi yaygın olarak “sarı kromat” olarak adlandırılmaktadır.


HADDE YÖNÜ

**Şekil 3.** Levhadan Çekme numunelerinin hazırlanması**Şekil 4.** Yüzey pürüzlük ölçüm cihazı

Cr+6 kaplama genelde askeri alanda ve havacılık sanayisinde kullanılmaktadır. Örneğin askeri alanda silahlar ve tüfek namlularında tercih edilmektedir. Cr+6 kaplama için numuneler 7 aşamadan geçirilmiştir. Şekil 5’te işlem aşamaları gösterilmiştir. Çalışmada bilyeli dövme prosesi öncesi ve sonrasında tüm numuneler krom kaplama işlemine tabi tutulmuştur.



Şekil 5. Cr+6 Kaplama Prosesi öncesi ve sonrası




Şekil 6. Tuz Sisi Korozyon Test Aşaması

“Tuz püskürtme testi” olarak da bilinen Tuz Sisi Testi, malzemeye üretim sonrası uygulanan koruyucu kaplamaların ya da yüzeylerin korozyon direncini tuz sisi altında gözleme ve kalitesel problemleri tespit etme imkanı vermektedir. Bu çalışmada bilyeli dövme parametreleri sonrası malzemeye yapılan Cr+6 kaplamanın Almen şiddetine göre korozitif özelliklerindeki değişimi gözlenmek istenmiştir. Şekil 6’da test düzeneği verilmiştir. Bilyeli dövme sonrası TS EN ISO 9227 standartına göre numuneler korozyon testine tabi tutulmuştur.


3. Deneysel Bulgular

3.1 Bilyeli Dövmenin Mekanik Özelliklere Etkisi


AA5754 H111 malzemedeki toplamda 60 numune hazırlanmıştır. Bu numuneler S110-S170-S230 bilye çaplarında ve 8A, 12A ve 15A olacak şekilde kombinasyonlanmıştır. Deneysel çalışmada bilye çapı ve Almen değeri arttıkça mekanik özelliklerdeki değişim incelenmiş ve bu proses sonrası yapılan kaplamanın ise korozyon direnci gözlemlenmiştir. Çalışma sonunda bilye çapı ve Almen şiddetinin mukavemet özelliklerinin artışı ile doğru orantılı olarak arttığı gözlemlenmiştir (Şekil 7-9). S110 bilyesinin mukavemet değerleri Şekil 7’de verilmiştir. Maksimum mukavemet özelliği S230-12A değerindeki numune de gerçekleşmiştir. S110 ve S170 bilyelerinde Almen değeri arttıkça mukavemet özellikleri de artış göstermiştir. S170 bilyesinin mukavemet değerleri Şekil 8’de verilmiştir. S230 bilyesinin ise 8A-12A değerlerinde mekanik artış gösterirken 15A değerinde düşüş yaşanmıştır. S230 bilyesinin mukavemet değerleri Şekil 9’da verilmiştir. Bunun sebebi bilye çapı ve almen değeri arttıkça malzemede oluşan proses stress artmış ve malzemelerde iç gerilmeler meydana gelmiştir. Bilye çapı arttıkça malzeme gevrekleşmiştir. S110 bilyede kopma uzaması %21,84 iken S230 bilyesinde kopma uzaması %14,97’ye düşmüştür. S110 bilyesinde malzemede sünek bir kırılma meydana gelirken, S230 bilyesinde gevrek kırılma meydana gelmiştir. Bu sonuçlar kıyasladığında bilye çapı ve Almen değeri arttıkça malzemenin daha sert bir yapı kazandığı gözlemlenmiştir. Bilyeli dövme süreci sonrası elde edilen mukavemet özellikleri Tablo 5’ de verilmiştir.



Şekil 7. S110 bilyesi ile 8A-12A-15A şiddetindeki numunelerin Gerilme-% Uzama grafiği



Şekil 8. S170 bilyesi ile 8A-12A-15A şiddetindeki numunelerin Gerilme-% Uzama grafiği



Şekil 9. S230 bilyesi ile 8A-12A-15A şiddetindeki numunelerin Gerilme-% Uzama grafiği

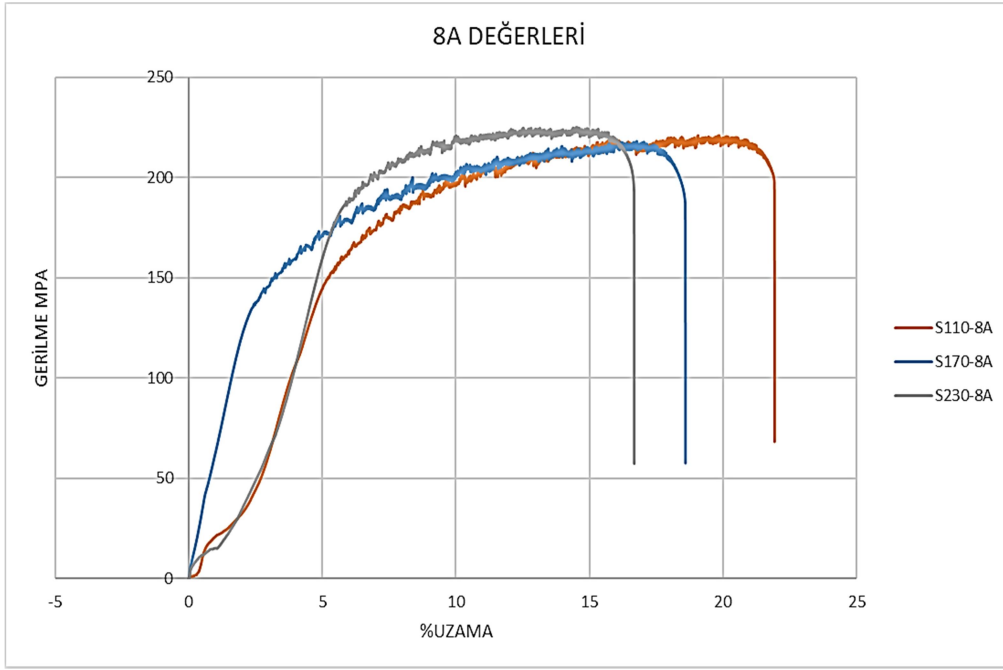
Tablo 5. Proses öncesi ve sonrası çekme mukavemeti değerleri

Malzeme ve Bilyeleri	Almen Şiddeti	Çekme Mukavemeti (MPa)
Dövülmemiş AA5754 H111	---	215,022
	8A	218,171
	S110	218,421
S170	12A	218,349
	15A	221,032
	8A	222,678
S230	12A	226,291
	15A	225,110
	8A	226,183
S230	12A	224,890
	15A	


3.2 Almen Şiddetinin Mekanik Özelliklere Etkisi

Bilyeli dövme uygulanmadan önce yani dövülmemiş olan numunelerde çekme dayanımı ortalama 215 MPa olup tüm numunelerin dövülme prosesi sonrasında çekme dayanımında artış belirlenmiştir. Bilye çapı arttıkça çekme dayanımı da artmıştır. S110 bilyesinde Almen değeri arttıkça çekme dayanımında (% 1,54'lük) artış gözlenmiştir (Tablo 5). S170 de Almen değeri arttıkça çekme

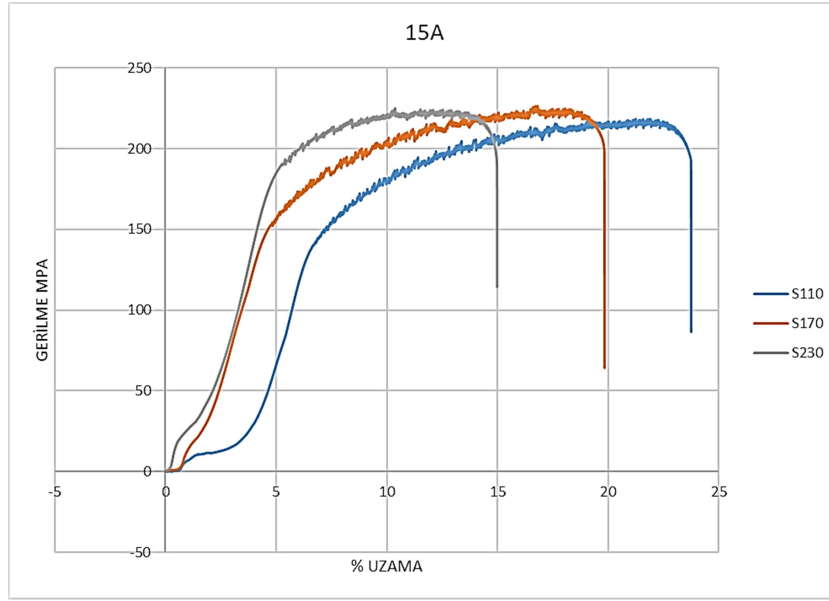
dayanımında artış gözlenirken S230 da diğer proseslerin dışında bir azalma gözlemlenmiştir. Çekme dayanımı 12A değerine kadar artış gösterirken 5A de ise bir miktar (%5) azalma meydana gelmiştir (Şekil 12, Tablo 5). Bunun sebebi ise bilye çapı ve Almen değeri arttıkça malzemede oluşan iç gerilmelerin ve stres artışının mekanik özelliklerde kısmi bir azalmaya neden olduğu düşünülmektedir.



Şekil 10. Farklı Bilye Türüne göre 8A şiddetindeki Gerilme-%Uzama değerleri



Şekil 11. Farklı Bilye Türüne göre 12A şiddetindeki Gerilme-%Uzama değerleri




Şekil 12. Farklı Bilye Türüne göre 15A şiddetindeki Gerilme-%Uzama değerleri

AA 5754 H111 numuneleri S110, S170 ve S230 çelik bilyeler kullanılarak 8-12-15 Almen şiddetinde işleme alınan numunelerin çekme test sonuçları Şekil 10-11-12 de detaylı olarak verilmiştir. Bilyelerin almen şiddeti ve bilye çapı ile deney parçasının yüzeyine uyguladıkları bombardımanın etkisi ile mekanik özellikleri doğrudan etkilemiştir. Çekme mukavemetindeki artış Almen şiddetiyle doğru orantılı bir şekilde artmıştır. Buradaki artış pekleşme sonucunda yüzeyde meydana gelen artık basma gerilmesi oluşumu ve tane yapılarındaki plastik deformasyonlar ile ilişkilendirilebilir (Kocaman ve Demirer, 2022). Tablolar incelendiğinde bilye çapı arttıkça malzeme de pekleşme meydana gelmiştir. Almen şiddeti arttıkça ise malzemenin mekanik özelliklerinde iyileşme meydana gelmiştir.

3.3 Bilyeli Dövme Prosesinde Malzeme Yüzey pürüzlülüğü

Bu çalışmada bilyeli dövme prosesi sonrası kaplama yapılacağı için yüzey pürüzlülüğü büyük önem arz etmektedir. Bilyeli dövme prosesi sonrası bilye çapı ve Almen şiddeti arttıkça malzeme yüzeyinde pürüzlülük değerlerinde artış meydana gelmiştir. S110 ve S170 çelik bilyelerinde bilyeli dövme prosesi sonrasında Ra (ortalama pürüzlülük) değerinde meydana gelen değişim Şekil 13'de verilmiştir. S110 bilyesinde 8A değerinde Ra=3,179 iken 15A değerinde 4,394'a yükselmiştir. Yüzey

pürüzlülüğündeki artış %38,2'dir. S170 bilyesinde 8A değerinde Ra=3,450 iken 15A değerinde Ra=5,852'ye yükselmiştir. Yüzey pürüzlülüğündeki artış %69,2'dir. S230 bilyesinde yüzey pürüzlülüğü, yüzey profilometresinin standartından büyük olduğu için ölçüm alınamamıştır. Bilye çapı ve Almen değeri arttıkça malzemenin yüzey pürüzlülüğünde doğrusal artış gözlenmiştir.



Şekil 13. S110-S170 Bilyelerin Almen değerlerine göre ortalama Ra pürüzlülük değerleri


3.4 Tuz sisi korozyon testi sonuçları

Bilyeli dövme işlemi ardından numunelere Cr+6 kaplama prosesi uygulanmıştır. Yapılan kaplama sonrasında numunelerin ilk görüntüleri fotoğraflanmıştır. Korozyon testi sonrasında kaplamanın yüzeyde tutunma kabiliyeti görsel olarak tespiti için tuz testi sonrasında da numune fotoğrafları karşılaştırma amaçlı alınmıştır. Korozyon testleri EN TS ISO 9227 standartına göre

gerçekleştirilmiştir. Çözeltinin Ph değeri 6,851'de sabit tutulmuştur (Şekil 14). Test sonrası bilyeli dövme prosesinin bazı parametreleri malzemeyi görsel olarak korozyona uğratmadığı gözlemlenmiştir. Bazı numunelerde ise korozyon testi sonrası korozyonun kaplamaya kısmen zarar verdiği görülmüştür. Korozyon testi öncesi ve sonrası numune resimleri Şekil 15'de verilmiştir.




Şekil 14. Çözeltinin Ph değeri ölçümü



(a) S110 Bilyesi 8A-12-15A korozyon testi öncesi



b) S110 Bilyesi 8A-12-15A korozyon testi sonrası



c) S170 Bilyesi 8A-12-15A korozyon testi öncesi



d) S170 Bilyesi 8A-12-15A korozyon testi sonrası



e) S230 Bilyesi 8A-12-15A korozyon testi öncesi



f) S230 Bilyesi 8A-12-15A korozyon testi sonrası

Şekil 15. Farklı bilye çapı ve Almen şiddetine göre korozyon testi öncesi ve sonrası görselleri


3.5 SEM incelenmesi

Bilyeli dövme ile birlikte yüzeyde plastik deformasyonlar meydana gelmiştir. Bilyelerin

mevcut kütlesi ve hızıyla oluşturduğu kinetik enerji yüzeye aktarılmıştır. Yüzeyde kırılan ve ezilen tane yapıları sonunda yeni bir yüzey formu oluşmuştur (Kocaman ve Demire, 2022).

Şekil 16'da bilyeli dövme işlemi uygulanan AA5754 H111 alüminyum alaşımının SEM görüntüleri verilmiştir. Numunelerin SEM görüntüleri JEOL marka JSM 6060LV model cihazda çekilmiştir. Bilye çapı ve Almen değeri arttıkça malzeme yüzeyindeki topografik yapıdaki tepe çukur farkı artmıştır. Bu sonuçlar pürüzlülük değeri ile karşılaştırdığında bilye çapı ve almen değeri arttıkça malzeme yüzeyinin pürüzlülük değerinde de artış gözlemlenmiştir.

Numunelerin SEM görüntüleri araştırıldığında bilye çapı arttıkça plastik deformasyon ve tepe-çukur oluşumunun arttığı gözlenmiştir. Almen şiddeti arttıkça yüzeydeki çukur oluşumları daha belirgin hale gelmiştir. Bu önceki yapılmış literatür çalışmaları ile tutarlılık göstermektedir.



Şekil 16. S110, S170, S230 bilye çaplarında, 8A-12A-15A şiddetindeki numunelerin SEM görüntüsü

4. Tartışma ve Sonuç

AA5754 H111 alüminyum alaşımına 3 farklı bilye çapında (S110-S170-S230) ve 3 farklı Almen şiddetinde (8A-12A-15A) bilyeli dövme prosesi uygulanmıştır. Bilyeli dövme prosesi sonrası numunelere Cr+6 kaplama uygulanmıştır. Numuneler tuz sisi tekniği ile korozyon testine sokulup sonrasında mekanik özellikleri (çekme testi ve yüzey pürüzlülük testi) incelenmiştir. Bilyeli dövme prosesi sonrası Cr+6 kaplamanın korozif özelliklerindeki etkisi incelenmiştir. Alüminyum alaşımlar ile yapılan bilyeli dövme işlemleri incelendiğinde Wanga ve arkadaşları (2011), farklı basınçlarda dövülen AA6061 T6 malzemesini incelemişler ve basınç arttıkça yüzey pürüzlülüğü, plastik deformasyon kalınlığı ve korozyon direncinde artış olduğunu tespit etmişlerdir (Alkan,2014). Korozyon testi sonrası elde edilen sonuçların literatüre uygun olduğu gözlemlenmiştir.

Bu çalışma sonunda aşağıdaki sonuçlar tespit edilmiştir:

- Bilye çapı arttıkça malzemenin pürüzlülük değerlerinde artış meydana gelmiştir.
- Almen değeri arttıkça pürüzlülük değerlerinde artış tespit edilmiştir. S110 ve S170 bilyelerinde sırasıyla %38,21 ve %69,62 pürüzlülük artışı tespit edilmiştir. Büyük bilye çapında pürüzlülük daha da artmış ve cihazın ölçüm skalasını aştığı için ölçülememiştir.
- Bilye çapı arttıkça malzemenin mekanik özelliklerinde de artış belirlenmiştir. S170 (0,4mm) bilyesinde 15 Almen şiddetinde dövülen numunede çekme testleri sonucu %5,25'lik mekanik artış

5. Kaynaklar

- Alkan, Z., Varol, R., & Server, R. 2016. Bilyeli dövme uygulanmış AA1050 alüminyum malzemenin metalografik incelenmesi. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, Vol.20 (3) 524-529.
- Alkan, Z., 2014. Alüminyum Alaşımlarında Bilyalı Dövmenin Fiziksel, Mekanik ve Yüzey Özelliklerine Etkisi, *Süleyman Demirel*

meydana gelmiştir. AA5754 H111 malzemesine yapılan çekme testlerinde buna en yakın değer ise S230 bilyesinde (0,6mm) ve 12 Almen değerinde %5,19 artış tespit edilmiştir. S110 bilyesinde (0,3mm) ise 15 Almen çekme dayanımında (%1,54) artış gerçekleşmiştir.

- Korozyon testi sonrası numuneler gözle muayene edilmiştir. S230 bilyesi ile uygulanan proseslerde numuneler korozyon testinde başarısız olmuştur. Bunun sebebi yüzeye fırlatılan bilye çaplarının büyük olması nedeni ile kaplamanın temas ettiği yüzey alanı diğer düşük bilye çaplarına göre küçülmüştür. Bu sebeple malzeme yüzeyinde kimyasal temasın az olması, yüzeyde daha az Cr+6 kaplanmasına neden olmuştur. Korozyon testi sonrası yüzeyde belirgin dökülmeler görülmüştür.
- Korozyon testi sonrası S170 ve S230 bilye ile dövülen numunelerde renk açılımı meydana gelmiştir. S110 -8A prosesi uygulanan numunelerde ise renk açması gözlemlenmemiştir.
- Korozyon testinde S170-12A prosesine tabi tutulan numuneler de ise renk açılımı çok düşük düzeyde gözlemlenmiştir.
- S170-15A prosesine tabi tutulan numuneler çekme dayanımı bakımından en yüksek dayanıma sahipken aynı zamanda korozyon testinde de en az renk kaybına yani en düşük aşınmaya uğramıştır.

Teşekkür

Bu çalışma TÜBİTAK 2209-A programı kapsamında (Proje No:1919B01220946) desteklenmiştir.

Üniversitesi Fen Bilimleri Enstitüsü, Doktora Tezi, 101s, Isparta.

- Appel, F. 2013. Atomic level observations of mechanical damage in shot peened TiAl, *Philosophical Magazine*, Vol.93 (1-3), 2-21.
- Avcu, E. 2018. Bilyalı dövme parametrelerinin AA7075 T6 alüminyum alaşımının yüzey altı özelliklerine etkisi, *GU J SCI*, Part C, Vol.6 (4), 741-752.

- Başaran, A. 2007. Toz Metal Parçalara Isıl ve Mekanik Yüzey İşlemlerin Birlikte Uygulanabilirliğinin Araştırılması, *Doktora tezi, Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü, Makina Mühendisliği Anabilim Dalı, Isparta*, s192.
- Başer, Z., T. 2012. Alüminyum alaşımlarını ve otomotiv endüstrisinde kullanımı. *Mühendis ve makina*, Vol.53 (635), 51-58.
- Çoşkun, K. 2002. Hadde alüminyum alaşımlarının uçaklarda kullanılması, *Yüksek lisans tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Üniversitesi*.
- Hongbin, X., Qing, C., ve Eryu, S., Dengzhen, W., Zhaohong, C., ve Zhengle, W. 1991. The effect of shot peening on rolling contact fatigue behaviour and its crack initiation and propagation in carburized steel, *Wear*, Vol.151 (1), 77-86.
- Karahan, B., İnce, U. 2015. Bilya Püskürtmenin (Shot Peening) Teknik-Teknolojideki Yolculuğu ve Soğuk Dövme Prosesine Adaptasyonu, <http://depark.com/derin/Ekim2015/Index/2.htm>, s74-90.
- Kocan, M., Rack, H. J., Wagner, L. 2005. Fatigue performance of metastable titanium alloys: Effects of microstructure and surface finish, *Journal of Materials Engineering and Performance*, Vol. 14 (6), Dec. JMEPEG 14,765-772.
- Kocaman, A., Demirer, A. 2021. AA6061 T6 Alüminyum Alaşımında Bilyeli Dövme İşleminin Mekanik Özelliklere Etkisinin İncelenmesi, *Afyon Kocatepe Üniversitesi Uluslararası Mühendislik Teknolojileri ve Uygulamalı* , Vol.4 (2), 49-58.
- Mhaede, M. 2012. Influence of surface treatments on surface layer properties, fatigue and corrosion fatigue performance of AA7075 T73 . *Materials & Design*, Vol. 41, 61-66.
- Nam, Y. S., Jeong, Y., Shin, B., & Byun, J. 2015. Enhancing surface layer properties of an aircraft aluminum alloy by shot peening using response surface methodology., *Materials & Design*, Vol.83 (4),566- 576.
- Nouguier-Lehon, C., Zarwel, M., Diviani, C., Hertz, D., Zahouani, H., Hoc, T. 2013. Surface impact analysis in shot peening process, *Wear*, Vol.302 (1-2) ,1058–1063.
- Seykoç Alüminyum. 2023. AA 5754 H111: <https://seykoc.com.tr/icerik/5754?dil=tr> adresinden.
- Tomlinson, W. J., Moule, R. T., Blount, G. N., 1987. The effect of shot peening on the cavitation erosion of pure iron and austenitic stainless steel in distilled and 1% salt waters, *Wear*, Vol.118, 233 - 242.
- Trsko, L., Guagliano, M., Bokuvka, O., Novy, F., Jambor, M., & Florkova, Z. 2017. Influence of Severe Shot Peening on the Surface State and Ultra-High-Cycle Fatigue Behavior of an AW 7075 Aluminum Alloy. *Journal of materials engineering and performance*, Vol.26, 2784 - 2797.
- Varol, R. 1990. 2024 Alüminyum alaşımının yorulma ömrü üzerine farklı bilyeli dövme işlem parametrelerinin etkisi. *Doktora Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya*.
- Wanga, Z., Jiang, C., Gan, X., Chen, Y., Ji, V. 2011. Influence of shot peening on the fatigue life of laser hardened 17-4PH steel, *International Journal of Fatigue*, Vol.33 (4), 549-556.
- Zammit, A., Abela, S., Wagner, L., Mhaede, M., Grech, M. 2013. Tribological behaviour of shot peened Cu-Ni austempered ductile iron, *Wear*, Vol.302 (1–2), 829-836.

Araştırma Makalesi / Research Article

Dirençli Punta Kaynağı Prosesinin KNN ve CART Makine Öğrenimi Teknikleri ile Değerlendirilmesi

Sena PEKŞİN¹, Soydan SERTTAŞ²

^{1,2} Kütahya Dumlupınar University, Faculty of Engineering, Department of Computer Engineering, Kütahya, Turkey.

¹e-mail: senapksnn@gmail.com, ORCID: 0000-0003-2537-890X

²e-mail: soydan.serttas@dpu.edu.tr, ORCID: 0000-0001-8887-8675

Received :25.05.2023; Accepted:20.10.2023

Öz

Bir çeşit direnç kaynağı olan punta kaynağı, metal sac birleştirme işleminde kullanılan ve üretim alanında yaygın olarak bulunan bir kaynak uygulamasıdır. Punta kaynak prosesi otomotiv endüstrisi başta olmak üzere, radyatör ve tel örgü üretimi gibi birçok üretim alanında yaygın olarak kullanılır. Araç üretim bantlarında punta kaynağı ağırlıklı olarak robotik uygulamalarla gerçekleştirilmektedir. Endüstri 4.0 ve dijital dönüşüm trendleri benzeri görülmemiş bir veri büyümesine yol açmıştır. Günümüz imalat sektöründe kalite, bakım ve üretim süreçlerinin izlenmesi, tahmini ve optimizasyonu konularında makine öğrenimi ve veri bilimi algoritmalarının gücünden yararlanılmaktadır. Makine öğrenimi algoritmalarının uygulanması deneylerin süresini kısaltmanın yanı sıra deneysel maliyeti de azaltmaktadır. Bu çalışma, gerçek üretim sahasında robotik kollarla uygulanan punta kaynağının izlenerek, kaynak argümanlarının ideal punta normları içerisinde olup olmadığının tespitini amaçlamaktadır. İdeal parametre normları değerlendirilirken KNN (K-En Yakın Komşu) ve CART (Sınıflandırma ve Regresyon Ağacı) makine öğrenimi algoritmaları kullanılmıştır. Çalışma üretimdeki gerçek verileri kullanabilmek için TOFAŞ fabrikasında yapılmıştır ve pilot hat olarak gövde üretim montaj hattı seçilmiştir. Araştırmada kullanılan veri seti 2023 yılı güncel kaynak parametrelerinden oluşmaktadır. Veri kümesi üzerinde makine öğrenimi algoritmaları çalıştırılarak her bir algoritmanın başarımlarını değerlendirmesine bakılmış ve en uygun tahminleme yöntemi belirlenmiştir. Yapılan deneylerde en iyi F1-Skor değeri %93 ile CART modeli tarafından elde edilmiştir.

Anahtar kelimeler

Dirençli Punta Kaynağı;
Kaynak Parametreleri,
Makine Öğrenimi;
Otomotiv Endüstrisi.

Evaluation Of The Resistance Spot Welding Process With KNN and CART Machine Learning Techniques

Abstract

Spot welding, a type of resistance welding, is a welding application widely used in the production area and it is a common method for joining metal sheets. The spot-welding process is widely used in many production areas, especially in the automotive industry, radiator, and wire mesh production. Spot welding in car production lines is mainly performed by robotic applications. Industry 4.0 and digital transformation trends have led to unprecedented data growth. Nowadays, the manufacturing industry benefits from the power of machine learning and data science algorithms to monitor production processes and make predictions for quality, maintenance, and production optimization. Applying machine learning algorithms reduces the duration and cost of experiments. This study aims to confirm whether the spot welding, applied by robotic arms, is within the ideal spot-welding norms, in real production area. The ideal parameter norms were evaluated by using KNN and CART machine learning algorithms. To use real production data, this study was executed in the body production assembly line, which is selected as the pilot area, at TOFAŞ factory. The data set used in this research consists of the welding parameters of the current year, 2023. By running machine learning algorithms on the dataset, the performance evaluation of each algorithm was examined and the most appropriate estimation method was determined. In the experiments, the best F1-Score value was obtained by the CART model with 93%.

Keywords

Resistance Spot
Welding; Welding
Parameters; Machine
Learning; Automotive
Industry.

1. Introduction

One of the primary objectives of the digitization process is the automation of activities within production domains. Digital transformation may be defined as a system that permits the rapid analysis and more efficient utilization of information within business processes employing information technologies (Küçükvardar and Aslan 2021).

Through digitization in manufacturing processes, errors caused by workers can be minimized, and processes can be made autonomous. While various error modes occur in the automotive sector during the production stage, measures are taken to minimize these errors. However, sometimes errors cannot be detected and result in high costs. Digital systems can instantly detect any issues during the production process and necessary interventions can be made. When quality issues arise, information can be quickly shared with informed personnel, and production processes can be halted to make adjustments for quality production. In this way, an increase in quality and efficiency can be achieved in the production process (IntRes. 1).

Spot welding machines can benefit from digital transformation processes to make production processes more efficient. For example, spot welding machines can automatically weld materials together using pre-defined welding parameters that can be adjusted automatically. This eliminates the need for manual adjustments and makes welding processes more precise and repeatable, eliminating the trial-and-error approach to learning efficiency.

In the automotive industry, resistance spot welding machines serve as crucial welding tools. These machines perform the welding process by applying an electrical current to the metal pieces between two electrodes. Electrodes are the instruments used to join the metal parts and are brought into contact with the workpiece to ensure connectivity between the metal plates. At this stage, the applied pressure is slightly increased to initiate the passage

of electrical current. The current flows in accordance with the predetermined current intensity and duration, heating the workpiece. The melting process commences, initiated by the pressure exerted by the electrodes on the workpiece. The molten region is allowed to cool for a few seconds without relieving the pressure applied by the electrodes. Subsequently, the pressure on the electrodes is released, and they move apart. The welding process is completed during this phase (IntRes. 2). The utilization of resistance spot welding machines in the automotive industry contributes to reducing welding costs during the manufacturing process. These machines operate swiftly and precisely, reducing production time and enhancing production efficiency (Dai et al. 2022).




Figure 1. Spot Welding Principle. (IntRes. 3).

In the automotive industry, weld quality holds paramount significance as the safety and performance of manufactured vehicles are directly correlated with the quality of welding. A critical step in enhancing weld quality is the accurate determination of welding parameters. Through a review of literature and assistance from the expert system employed in the study (comprising two welding experts working in the factory and welding documentation), the parameters influencing weld quality have been identified as follows: welding current, welding duration, welding pressure, and electrode life.

These parameters are adjusted based on the properties of the material to be welded. Achieving this balance is possible through trial and error

methods. Standards set by factories are also crucial in maintaining this balance in welding processes. Factories develop specific standards for welding parameters based on their experience. These standards aim to enhance the quality and reliability of the welding process. It is important that the parameters obtained through trial and error methods are in compliance with factory standards, and adjustments are made as necessary. This ensures that the welding connection can be executed according to desired standards and expectations.

Finding the correct welding parameters is often a challenging and costly process. Each resistance welding machine has a controller that oversees parameter settings, and all adjustments are made through this system. Adaptive welding control systems like BOS 6000 are used to monitor, analyze, and automatically adjust welding parameters in real-time. These systems track welding errors within predefined tolerances throughout the welding process (Akgül 2017).

For instance, parameters such as welding current, voltage, and duration can be monitored and automatically adjusted in real-time by adaptive welding control systems. This minimizes welding errors during the welding process and maintains a high level of welding connection quality (Kas and Das 2019).

Proper adjustment of these parameters affecting quality can lead to energy savings, prevention of excessive nugget formation, reduction in cycle times, and improvement in product quality during the manufacturing process. Incorrectly set parameters can lead to various issues during the production process and even result in low-quality products (Selova and Aydin 2019).

The objective of this study is to present machine learning approaches using digital solutions to reduce errors in resistance spot welding (RSW) processes, one of the primary welding applications utilized in the automotive industry.

To achieve this goal, data analyses were conducted using real field data and various process parameters obtained by sensors in a specific industrial Resistance Spot Welding (RSW) scenario and applications at TOFAŞ, one of the leading manufacturing companies in the automotive industry. In this study, different process parameters acquired through sensors were analyzed using K-Nearest Neighbors (KNN) and Classification and Regression Trees (CART) machine learning models, and insights were gained regarding the status of the welding process conducted using real field data.

2. Literature Review

In recent years, machine learning has garnered substantial significance within the realm of industrial applications, with spot-welding machines representing a notable sector of interest. The integration of machine learning methods into spot welding machinery holds the promise of enhancing production processes, elevating operational efficiency, and mitigating expenditure. The academic literature encompasses a plethora of studies dedicated to the analysis of factors influencing welding quality. Furthermore, there has been a surge in research endeavors specifically focusing on the application of machine learning techniques in this domain.

In a study conducted by Zhou et al. (2018), a comprehensive comparison of diverse machine learning approaches was conducted for quality monitoring, primarily relying on time series data derived from resistance spot welding processes. The research encompassed critical phases of data preprocessing and feature engineering. The study harnessed datasets generated through a simulation model. Furthermore, an iterative methodology was introduced within the research to amalgamate data collection and analysis seamlessly.

In the practical application segment, rudimentary features were extracted from the data acquired through simulations. Subsequent to a meticulous feature selection process, three distinct machine learning techniques were employed to construct

various data-driven models. These models were implemented using the MATLAB tool, SciXMiner. The study embarked on modeling endeavors by conducting hyperparameter selection. The findings from this investigation illuminated the superiority of the Multi-Layer Perceptron algorithm over the K-Nearest Neighbor (KNN) algorithm.

Xing et al. (2018) proposed an approach for real-time quality monitoring of resistance spot welding (RSW) processes. In their research, they conducted modeling utilizing dynamic resistance signals gathered and processed from actual production scenarios, employing the Random Forest classification algorithm. The study classified welding quality into three distinct levels: cold welding, satisfactory welding, and expulsion cases. Cross-validation techniques were employed, and a rigorous 10-fold cross-validation procedure was executed to compare test prediction errors and misclassifications. The outcomes demonstrated that the Random Forest algorithm achieved an impressive performance level of 98.8%.

In accordance with the findings of Gavidel et al. (2019), they conducted an exhaustive analysis of prediction models' performance using RSW data derived from an American automotive manufacturer. A comparative assessment was carried out among commonly utilized prediction algorithms. The dataset underwent rigorous training, validation, and testing for modeling purposes. The research incorporated bootstrapping and statistical hypothesis tests for a comprehensive performance evaluation. The Deep Neural Network (DNN) model, employed for predicting nugget (weld size) width, exhibited the highest accuracy and exhibited lower variability. Consequently, the DNN model was recommended for processing highly nonlinear and intricate data, such as that encountered in RSW processes. Additionally, the K-Nearest Neighbors (KNN) and KStar models were also scrutinized and were noted for their commendable performance. The study suggested that future research endeavors might explore scenarios where welding does not occur within the dataset.

Literature review reveals significant progress in predicting welding quality. The methods employed in these studies have shown promising potential in accurately identifying faulty welding points in the RSW process, as well as the ability to generalize with a small number of samples. This highlights their significance in improving the overall quality of spot welding.

3. Materials and Methods

Spot welding represents a widely employed technique within the automotive industry (Liu et al. 2020). In this procedure, variables including the welding type, material characteristics, and welding parameters collectively dictate the welding quality. Given the myriad permutations of these variables, visual assessment of welding quality becomes a formidable challenge. Consequently, machine learning emerges as a viable approach for modeling spot welding data. Machine learning augments the learning capability of computer systems through the capacity to glean insights from data. Within the realm of spot welding machines, machine learning techniques encompass classification, clustering, and regression analysis. These methodologies offer valuable insights into the current state of resources and contribute to enhancing the efficiency of production processes.

3.1 Data Set

In the manufacturing facility, each robot arm is equipped with a timer controller. Real-time, vehicle-specific welding parameters are obtained through communication between the timers/controllers in the body production line section of Tofaş factory models and the PLC (Programmable Logic Controller). This enables the collection of customized welding data for each vehicle, which is then stored in a database. This dataset comprises two distinct classes of welding data: good welds (OK) and defective welds (Not OK). It is known that a modern vehicle body undergoes approximately 4,000 to 6,000 spot welds on average. Therefore, the dataset to be modeled is quite extensive. In machine learning, the significance of data cannot be overstated. If the data quality is low, one should not expect favorable

results. Hence, regardless of the task at hand, having high-quality data is crucial.

One of the most pivotal facets of this study pertains to the data collection phase, given the pivotal role of obtaining precise data to ensure accurate outcomes. The process of solely collecting data from the factory was conducted through a project that combines welding parameters with chassis codes, which resulted in a valuable and unique dataset. This process involved data collection from 14 machines located on the body assembly line where the study was conducted. The data obtained from the actual field is 7 GB per day. Processing all of the data and performing model training through machine learning algorithms is very difficult and costly. It necessitates access to technical equipment furnished with high GPU capabilities. Consequently, our study constrained data processing to a selected timeframe, leading to a dataset comprising 16,397 observation units (rows) and 174 variables. The memory footprint for this dataset approximates 21 MB.


Among the 174 variables within the dataset, 137 can be categorized as categorical, 35 as numerical, and 2 as cardinal variables. These variables primarily represent scalar magnitudes. Our independent variable is categorical, specifically categorized as "Okay" and "Not Okay" thereby framing our research problem as a classification task.

The category "Good Weld" signifies a successful and dependable welding process that aligns with the desired quality standards. Conversely, the "Bad Weld" category denotes a welding process falling short of the required quality criteria, indicative of a flawed or unreliable weld. The visual representation of both "Good" and "Bad" sources can be found in Figure 2.

The first step in this process is to determine whether the welding process parameters fall within the ideal range of parameter values. This is accomplished through the use of KNN and CART models.

In accordance with existing literature, it is advisable to treat our independent variable as categorical. Consequently, the independent variable featuring categorical options, namely "Okay" and "Not okay" was converted into numerical format via Label Encoding techniques. This encoding operation streamlines subsequent transactions during the application of machine learning or data analysis techniques on our dataset (IntRes. 4).

Metallographic picture



Good spot-weld



Incomplete fused joint

Figure 2. Results of spot-weld inspection. (Ambroziak 2015).

In the subsequent phase of the study, feature extraction procedures were executed. Feature selection, aimed at diminishing the number of features in the dataset to enhance model efficiency, contrasts with feature extraction, which entails the transformation of existing dataset features into novel features. Employing appropriate techniques for feature selection and extraction holds the potential to ameliorate the model's performance and render the dataset more comprehensible and manageable (IntRes. 5).

Achieving an optimal welding connection necessitates a delicate equilibrium between current intensity and welding duration. This equilibrium is contingent upon the material properties of the workpiece and the specific welding requisites. The material type and thickness play pivotal roles in ensuring an adequate heat supply for the welding connection. Moreover, the correct welding duration should align with the material's capacity to melt and coalesce

seamlessly. The attainment of this equilibrium is typically realized through iterative trial and error methods.

Conversely, the standards established by manufacturing facilities hold significant importance in achieving the requisite balance within welding processes. Factories formulate specific standards and guidelines for welding parameters, drawing upon their accumulated experience and expertise. These standards are formulated with the overarching goal of elevating the quality and dependability of the welding process. It is imperative that parameters derived through trial and error methods align consistently with these factory-established norms, necessitating adjustments whenever discrepancies arise. This practice ensures that welding connections are executed in accordance with the envisioned standards and anticipated outcomes.

Throughout the process of feature selection and extraction from the dataset, variables were judiciously reduced based on insights provided by welding experts at the manufacturing facility. Drawing from insights offered by welding experts at the manufacturing facility and referencing the pertinent literature, novel variables were introduced, encompassing pivotal welding parameters exerting influence on weld quality. An exemplary parameter is Joule's Law, characterized as a scalar quantity.

Spot welding machines operate in alignment with Joule's Law, which elucidates the conversion of electrical energy into thermal energy. As electric current traverses the workpieces, it generates heat by virtue of encountering resistance.

The resistance between the two parts causes the electrons to lose energy due to friction and collisions during their passage. This energy loss leads to heat concentration at the junction and melting of the parts.

$$Q = (I^2 * R * t)$$

Formula 1. Joule Law.

As the formula indicates, a high current is required to achieve sufficient heat in the welding process. When the current intensity and welding time are properly adjusted, the necessary heat for the welding joint is generated. Joule's law is crucial for an efficient welding process.

In spot welding, it is imperative to execute the process at specific values of current, resistance, and time. Within the dataset, prescribed tolerance values for current, resistance, and time are provided. Guided by this information, feature extraction was carried out by categorizing observed values as either erroneous or accurate, contingent upon their alignment with the prescribed tolerance ranges. Values falling outside these tolerance ranges are categorized as erroneous, as they have the potential to detrimentally impact weld quality. Conversely, values falling within the tolerance ranges signify that the weld aligns with the desired standards and can be classified as accurate.

Through this feature extraction, the difference between the realized scalar values and the required scalar values is calculated, allowing for the classification of erroneous and accurate instances. As a result, the adherence of crucial parameters such as current, resistance, and time to the specified tolerance values can be evaluated, thereby assessing the compliance of the weld with the desired standards.

Subsequently, these variables were incorporated into the dataset. Fundamental statistical attributes, such as mean, standard deviation, median, minimum, and maximum, were scrutinized for numerical variables within the dataset. Correlation analysis was conducted to gauge the interrelationships between variables and the target variable. Furthermore, new variables were generated using the Binary Features method, leveraging existing variables in the "true-false" or "yes-no" format.

As a result of the pre-processing stage, our initial set of 174 variables has been notably reduced to 53 variables. This feature selection method has had a

substantial impact on streamlining our training time.

Subsequently, the next phase involved the implementation of One Hot Encoding (OHE). OHE is a widely adopted technique for numerically representing categorical variables, as machine learning models tend to perform optimally with numerical data. Under OHE, each distinct category within a categorical variable is transformed into an individual column, assuming binary values of 0 or 1. The advantages of OHE encompass its simplicity, versatility, and compatibility with a broad spectrum of machine learning algorithms. However, it is essential to acknowledge its disadvantages, which encompass an expansion in the number of categorical variables and the overall dataset size due to the creation of additional columns. This expansion may entail elevated computational costs and a heightened risk of overfitting (IntRes. 6).

In the next stage, the study has advanced to the modeling phase, wherein the dataset was subjected to two distinct machine learning algorithms.

3.2 Methodology

Within the scope of this investigation, spot-welding data specific to vehicles was acquired through integration with Programmable Logic Controllers (PLCs) embedded within the production line. Subsequently, this spot-welding data was systematically stored within a PostgreSQL database. Throughout the entire study, the Python programming language served as the predominant tool of choice.

Following the culmination of data collection, a series of essential data preprocessing steps were meticulously executed. These steps encompassed rectifying variable names within the dataset, conducting exploratory data analysis, and generating summary statistics.

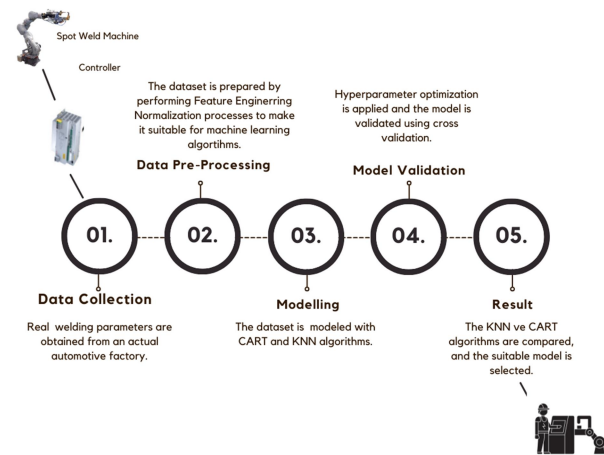


Figure 3. The architecture used in comparing different models for spot welding quality detection with machine learning techniques.

Concurrently, the data underwent a thorough scrutiny to detect missing observations and outliers, while novel variables were introduced, and variables exhibiting low information content were expunged from the dataset. Subsequently, the variables were distinctly categorized based on their types, including the identification and classification of categorical and numerical variables. To facilitate subsequent analysis, categorical variables were converted into a numerical format, and standardization procedures were implemented.

Model performance assessment was carried out using the cross-validation method. In addition, the most suitable hyperparameter combination of the used machine learning algorithm was found according to the determined success metric with hyperparameter optimization. The model complexity was balanced, and overfitting and underfitting were attempted to be avoided. Machine learning algorithms were selected as a result of a literature review and modeling was performed.

In this study, K-Nearest Neighbor (KNN) and CART (Classification and Regression Trees) techniques were used to determine whether the welding parameters are within the ideal norm range.




Figure 4. Distribution of Categorical and Numerical Variables.

3.2.1 K-Nearest Neighbors (KNN) Model

K-Nearest Neighbors (KNN) is a machine learning algorithm used in classification or regression problems. Essentially, it finds the K nearest neighbours for a sample and uses the class labels or output values of these neighbours to make a prediction. KNN is a non-parametric algorithm, meaning there is no predefined model structure and it makes predictions based solely on the features of the training data (IntRes. 7).

In the context of this study, the optimal hyperparameter values for the KNN algorithm were determined utilizing the GridSearchCV method. GridSearchCV systematically explores various hyperparameter combinations, ultimately selecting the configuration that yields the best performance. Key hyperparameters for the KNN algorithm encompass elements such as "n_neighbors," "weights," "algorithm," "p," "metric," "metric_params," and "n_jobs." Notably, "n_neighbors" specifies the number of neighbors considered in proximity. The term "n_neighbors" elucidates its role as the "number of neighbors" or "numeric neighbors." The "weights" hyperparameter enables the weighting of neighbor influence, with "uniform" signifying equal influence for all neighbors, while "distance" implies an inverse effect based on their proximity to the sample. The "metric" hyperparameter dictates the distance measure employed for neighbor identification. For instance, the "euclidean" metric

adopts the Euclidean distance, while the "manhattan" metric relies on the Manhattan distance. The "p" hyperparameter defines the power value within the chosen metric for neighbor calculation, with "p=1" employing the Manhattan distance and "p=2" employing the Euclidean distance.

Following the optimization process, the hyperparameters were configured as follows: "n_neighbors" was set to 3, "weights" to 'uniform,' "algorithm" to 'auto,' "p" to 2, "metric" to 'minkowski,' "metric_params" to None, and "n_jobs" to None. These meticulously tuned hyperparameters have markedly contributed to the superior performance achieved by the KNN model in this study.

3.2.2 CART (Classification and Regression Trees

When examining the modeling and classification of spot-welding data, the CART (Classification and Regression Trees) algorithm is frequently used as one of the methods (Zhang et al. 2014). CART is a decision tree algorithm that represents data in a tree structure and performs classification operations. The CART algorithm tries to create the most homogeneous subgroups by dividing the data and performs the classification process in this way (IntRes. 8).

Entropy and Gini are the criterias used in classification methods such as decision tree algorithm. The algorithm in Formula 2 uses Gini impurity and Entropy impurity criteria for classification problems. Gini impurity can be expressed as the "Gini Principle" or "Gini Purity". The Gini impurity criterion is the probability of misclassifying any randomly selected example.

$$G = 1 - \sum(pi^2)$$

Formula 2. Gini impurity formula, which measures the homogeneity of classes (Smith 2015).

Entropy, alternatively referred to as "Entropy" or "Confusion" in Turkish, represents a metric applied in the context of classification problems to assess the node's purity. Formula 3 elucidates the

operational principle of the Entropy algorithm. When a dataset comprises instances associated with diverse classes, it exhibits increased disorder and consequently registers a higher entropy value. In essence, the entropy metric quantifies the degree of disorder within a dataset, with elevated entropy values signifying datasets characterized by a more pronounced intermixing of example classes (IntRes. 9).

$$E = -\sum p_i * \log_2(p_i)$$

Formula 3. Formula for entropy, which is a measure of the homogeneity of classes.

In the context of the CART algorithm, various hyperparameters were employed to fine-tune its performance. The optimal hyperparameter combination for the CART algorithm is delineated as follows: The 'gini' criterion was utilized in conjunction with the Gini impurity measure, CCP alpha was configured at 0.0, a maximum tree depth was imposed at 3 levels, leaf nodes mandated a minimum of 1 sample, node splitting necessitated a minimum of 2 samples, 'random_state' was set to 17 to ensure reproducibility, and the 'best' strategy was adopted for node splitting.

To enhance the model's performance, a 5-fold cross-validation approach and hyperparameter optimization through the GridSearchCV method were implemented. Cross-validation served as a means to assess the model's capacity for generalization. This methodology entails the partitioning of the dataset into training and test sets, a process repeated multiple times with varying datasets to provide comprehensive insights into the model's generalizability (IntRes. 10).

4. Results

In this study, the performance of various machine learning techniques was assessed using various evaluation metrics. The key metrics used in this evaluation include precision, recall, F1 score, and accuracy. These four performance criteria were used to evaluate the accuracy of the model. The study examined the differences in model

performance outcomes between the Holdout and Cross Validation methods. Furthermore, hyperparameter optimization was leveraged to identify the most suitable combination of hyperparameters for the machine learning algorithm, guided by the specified performance metric.

The KNN model, constructed employing the Holdout method, underwent performance assessment by partitioning the dataset into training and test subsets. Initially, the dataset was randomly bifurcated into these two segments.

To evaluate model performance in classification problems, the classification report function was employed. This function furnishes a range of metrics including accuracy, precision, recall, and F1 score, which are instrumental in the assessment of model performance. The outcomes of this evaluation are presented in Table 1.

Table 1. Classification Report Results for Haldout Method Training Error

	Precision	Recall	F1-Score
0 (Okay)	0.99	0.86	0.92
1 (Not Okay)	0.97	0.73	0.83

Table 2. Classification Report Results for Haldout Method Test Error

	Precision	Recall	F1-Score
0 (Okay)	0.96	0.82	0.88
1 (Not Okay)	0.93	0.65	0.76

Analyzing the outcomes, high precision values are achieved for both the training and test errors of the "Okay" class. This indicates that a significant portion of the samples predicted as "Okay" by the model is indeed correct. However, there is a slight difference in the recall values between the training and test errors. The training error shows a higher recall value, while the test error demonstrates a slightly lower recall value. This suggests that the model fits better to the training data and may miss some "Okay" examples in general.

In the case of the "Not Okay" class, both the training and test errors manifest elevated precision values. Nevertheless, the recall values are higher in

the training error in contrast to the test error. This indicates that the model adeptly identifies the majority of samples predicted as "Not Okay" but encounters challenges in capturing certain genuine "Not Okay" samples.

These findings imply that the model may benefit from further refinement or hyperparameter optimization. Consequently, to enhance performance, hyperparameter optimization was executed through the GridSearchCV method, and the results of a 5-fold cross-validation utilizing the Cross Validation technique are presented in Table 3.

Table 3. 5-fold cross-validation model results for KNN algorithm.

	Accuracy (%)	F1- Score (%)	Roc AUC (%)
Mean	99.58	68.57	90.21

Following hyperparameter optimization, the pivotal parameter of the algorithm, namely the number of neighbors, has been ascertained to be 3. The results derived from the 5-fold cross-validation utilizing the optimal parameters are delineated in Table 4.

Table 4. With hyperparameter optimization 5-fold cross-validation model results for the KNN algorithm.

	Accuracy (%)	F1- Score (%)	Roc AUC (%)
Mean	99.70	80.86	90.23

When comparing the outcomes presented in Table 3 and Table 4, it becomes evident that hyperparameter optimization has yielded a substantial enhancement in the model's performance. The "Mean" values in Table 3 were obtained with default parameter settings, devoid of any hyperparameter optimization. Under these circumstances, the model attained an accuracy of 99.58%, an F1 score of 68.57%, and a Roc AUC of 90.21%.

However, subsequent to the execution of hyperparameter optimization, the outcomes illustrated in Table 4 were achieved. These findings manifest a significant upswing in model

performance as a result of judicious parameter tuning. The accuracy (99.70%), F1 score (80.86%), and Roc AUC (90.23%) values in Table 4 underscore the substantial and superior performance gains realized through hyperparameter optimization.

This underscores the pivotal role of selecting appropriate parameters in machine learning models, as hyperparameters wield significant influence over the model's performance. Hyperparameter optimization facilitates enhanced model generalization, more effective pattern recognition within the dataset, and ultimately elevates overall performance.

In our model, we harnessed the Validation Curve function. This function orchestrates a cross-validation procedure to scrutinize the model's performance across various hyperparameter values and elucidates how alterations in hyperparameters impact the model's efficacy on the training set.

The function generates multiple training sets with varying sizes while maintaining consistent hyperparameter values. Subsequently, it computes the performance metrics for both the training and validation sets for each configuration. This process culminates in a graphical representation illustrating the relationship between hyperparameter adjustments and performance. This iterative analysis aids in discerning which hyperparameter values yield optimal model performance.

In our study, we focused on the KNN model, with the hyperparameter "n_neighbors" under scrutiny. "n_neighbors" represents a crucial hyperparameter in the KNN algorithm as it determines the number of neighbors considered for classification. We systematically calculated and compared the training set accuracy (train_score) and test set accuracy (test_score) across various values of "n_neighbors" ranging from 1 to 10.

In Figures 5, there are two lines representing the scores on the training set (usually higher) and the test set. Generally, increasing the value of k is a good choice for improving model performance and

achieving better generalization. However, very high k values can also affect model performance, and it is important to choose an optimal value to reduce overfitting.

Therefore, a delicate equilibrium must be struck when selecting the optimal "k" value. Lower "k" values tend to imbue the model with increased complexity, while higher "k" values can adversely affect generalization performance. Finding the ideal "k" value necessitates a process of experimentation with different values, closely followed by meticulous evaluation of the model's performance. Achieving this balance is pivotal in attaining the finest results.

Upon scrutinizing the accuracy scores of both the training and test sets, a discernible pattern emerges: as the "k" value ascends, the accuracy score for the training set experiences a gradual descent. This phenomenon is attributed to the model's diminishing complexity as a higher "k" leads to a more generalized approach. However, it is noteworthy that the accuracy score for the test set exhibits an upswing when "k" equals 3. This pivotal point signifies that an increment in the "k" value enhances the model's capacity for generalization, effectively optimizing its performance.

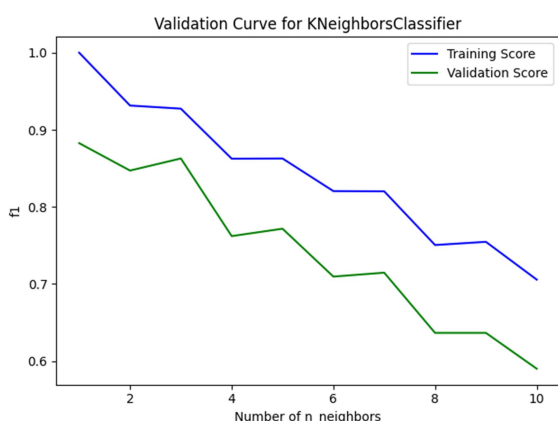


Figure 5. F1-Score Performance of the KNN model for different values of n_neighbors.

In summary, the optimal "k" value for our model was found to be "k = 3," delivering the highest performance. Conversely, elevating the "k" value

excessively can detrimentally impact the model's performance. Hence, it is of paramount importance to meticulously select an appropriate "k" value, striking a balance to mitigate overfitting and attain optimal results.




Figure 6. Roc AUC Performance of the KNN model for different values of n_neighbors.

Similar procedures were executed for the CART algorithm. Table 5 exhibits the outcomes of 5-fold cross-validation for the CART model.

Table 5. 5-fold cross-validation model results for the CART algorithm.

	Accuracy (%)	F1 Score (%)	Roc AUC c
Mean	92.00	78.73	94.63

The optimal parameter values for the CART algorithm were determined through GridSearchCV, resulting in 'max_depth' being set to 1 and 'min_samples_split' set to 2. These parameter selections were made to enhance the model's overall performance.

Following this, a cross-validation procedure was executed on the 'cart_final' model. Employing the cross_validate function, a 5-fold cross-validation was carried out, and the model's performance was assessed utilizing metrics such as 'accuracy,' 'f1,' and 'roc_auc.'

This iterative process encompassed the identification of optimal parameter values for the CART algorithm via GridSearchCV and the subsequent execution of cross-validation on the

resultant 'cart_final' model. These steps play a pivotal role in optimizing the performance of the CART algorithm, ensuring superior generalization.

Table 6 presents the results of 5-fold cross-validation following hyperparameter optimization for the CART model.

Table 6. With hyperparameter optimization 5-fold cross-validation model results for the CART algorithm.

	Accuracy (%)	F1- Score (%)	Roc AUC (%)
Mean	99.87	92.49	93.41




Figure 7. Performance of CART model for different values of 'max_depth' hyperparameter.



Figure 8. Roc AUC Performance of the CART model for different values of max_depth.

4.1. KNN and CART Comparison

Table 7 displays the performance metrics obtained from 5-fold cross-validation after the appropriate hyperparameters were selected for both the KNN and CART models within the same dataset.

Table 7. Comparison of KNN and CART algorithms.

	Accuracy (%)	F1 Score (%)	Roc AUC (%)
KNN	0.99	0.80	0.90
CART	0.99	0.92	0.93

The graph depicted in Figure 9 illustrates the Roc AUC values for both of the algorithms.




Figure 9. ROC AUC values of KNN and CART models.

In this study, a comparative analysis was conducted between the KNN and CART algorithms. Table 7 presents the performance metrics, including Accuracy, F1 Score, and ROC AUC, derived from the 5-fold cross-validation results for both models. Upon scrutinizing the outcomes, it becomes evident that both models exhibit notably high accuracy values. While the CART model attains an F1 Score of 0.92, the KNN model obtains a slightly lower F1 Score of 0.80. Additionally, concerning the ROC AUC score, the CART model outperforms the KNN model, displaying a higher value. These findings collectively suggest that, for the dataset employed in this study, the CART model outperforms the KNN model. Nevertheless, it's essential to recognize that results may vary when applied to different datasets, and various other factors should be taken into consideration when selecting an appropriate model.

The study conducted by Zhou et al. (2018) involved a comparison of diverse machine learning approaches for quality monitoring in resistance spot welding (RSW) based on time-series data. Their research revealed that artificial neural

networks outperformed K-nearest neighbors in terms of the "Error Within 5%" performance metric. This metric assesses the percentage of predictions with relative errors smaller than 5% of the reference value, and the study reported a success rate of 90% for this criterion.

In our study, we utilized ROC AUC as the performance metric. We achieved a success rate of 90% for ROC AUC. It is important to note that these two studies employed different performance metrics, each focusing on a different aspect. Error Within 5% emphasizes the relative errors of predictions, while ROC AUC evaluates the model's ability to accurately distinguish between classes in a classification problem.

Hence, directly comparing these two studies can be challenging due to the application of dissimilar performance metrics and potential disparities in datasets, methodologies, and research objectives. It is imperative to consider various factors when interpreting these results. Discrepancies in datasets, data dimensions, feature sets, and other experimental conditions may exist. Furthermore, aspects such as data partitioning, feature selection strategies, and hyperparameter tuning can exert a notable influence on the final outcomes. In conclusion, each study pursued its own unique objectives and employed specific performance metrics, and both studies attained significant success by harnessing machine learning techniques.

5. Discussion and Conclusion

Upon a comprehensive review of the existing literature, it becomes evident that the predominant focus of prior studies primarily revolves around the optimization of welding parameters. These studies have traditionally been conducted within controlled laboratory environments, often constrained by limited datasets. However, the extent to which models developed based on such laboratory data can be reliably applied to genuine industrial production conditions remains a subject of ongoing discourse.

Consequently, our study makes a substantial contribution to the automotive sector by harnessing authentic production data and delivering results under real-world operational settings. Moreover, in contrast to numerous existing studies that compare the performance of various machine learning algorithms, our research augments the literature by evaluating these algorithms within the context of genuine production data, thereby determining which algorithm demonstrates superior efficacy.

The results obtained using real data demonstrate the capability to successfully predict whether the quality of an occurring resource falls within the ideal norm range. These findings emphasize the potential effectiveness of managing resource quality processes and optimizing resource parameters. As a continuation of this study, further tests can be conducted with larger datasets, and techniques to address challenges such as class imbalance can be explored. To further enhance our findings, it is necessary to employ different machine learning algorithms and conduct model training under appropriate conditions. Our results make a significant contribution to the literature by demonstrating the effective prediction of resource parameters in the automotive sector.

Thanks

We extend our sincere appreciation to the management team of End Solution software company, namely Adem Şener, Cüneyt Eğrilmez and Asude Merey Arslan, for their invaluable support during the data acquisition process and their assistance in facilitating machine communication.

We would like to thank our valuable colleague Mücahit Genç for her help and support throughout the study.

Our profound gratitude is extended to Tofaş Turkish Automobile Factory Inc. for generously granting permission to access their invaluable data sources.

Furthermore, we wish to convey our heartfelt thanks to our families for their unwavering support and understanding throughout the course of this research endeavor.

6. References

- Ahmed, F., Jannat, N.-E., Schmidt, D. and Kim, K.-Y., 2021. Data-driven cyber-physical system framework for connected resistance spot welding weldability certification. *Robotics and Computer Integrated Manufacturing*, **67**.
- Akgül, K., 2017. Modeling the Relationship Between Welding Electrode Types, Sheet Thicknesses, and Welding Force in the Automotive Sector. Master's Thesis, Gebze Technical University, Institute of Natural Sciences, Gebze.
- Ambroziak, A., Korzeniowski, M. and Kustroń, P. Investigations of spot welds quality based on ultrasonic techniques. Institute of Production Engineering and Automation, *Wroclaw University of Technology*, Wrocław.
- Gavidel, S.Z., Lu, S. and Rickli, J.L., 2019. Performance analysis and comparison of machine learning algorithms for predicting nugget width of resistance spot welding joints. *The International Journal of Advanced Manufacturing Technology*, **105**(9), 3779–3796.
- Kas, Z. and Das, M., 2019. Adaptive Control of Resistance Spot Welding Based on a Dynamic Resistance Model. *Mathematical and Computational Applications*, **24**(4), 86.
- Küçükvardar, M. and Aslan, A., 2021. Analysis of the Economic, Technological, Social, and Ethical Effects of Digitalization via International Reports. *Intermedia International e-journal*, **8**(14), 21-38.
- Selova, L. and Aydın, H., 2019. Investigation of Welding Parameters in Triple Sheet Resistance Spot Welding. Master's thesis, Uludağ University, Institute of Science, Bursa, 72.
- Smith, J., 2015. Gini Coefficient and Income Inequality. *Journal of Economics*, **30**(2), 45-60.
- Wei, D., Li, D., Zheng, Y. and Wang, D., 2022. Online quality inspection of resistance spot welding for automotive production lines. *Journal of Manufacturing Systems*, **63**(7), 354-369.
- Xing, B., Xiao, Y., Qin, Q. and Cui, H., 2018. Quality assessment of resistance spot welding process based *The International Journal of Advanced Manufacturing Technology*, **94**, 327–339.
- Zhang, H., Hou, Y., Zhang, J. and Qi, X., 2014. A new method for nondestructive quality evaluation of the resistance spot welding based on the radar chart method and the decision tree classifier. *The International Journal of Advanced Manufacturing Technology*, **78**(5-8).
- Zhou, B., 2021. Machine Learning Methods for Product Quality Monitoring in Electric Resistance Welding ,Dissertation. Karlsruhe Institute of Technology (KIT), Faculty of Mechanical Engineering, 218.
- Zhou, B., Pychynski, T., Reischl, M. and Mikut, R., 2018. Comparison of Machine Learning Approaches for Time-series-based Quality Monitoring of Resistance Spot Welding (RSW).

Internet Resources

1-<https://www.snotradigital.com/uretimde-dijital-donusum-nasil-yapilir/> , (02.03.2023)

2-<https://silo.tips/download/otomotv-sektrnde-kaynak-teknolojler> , (02.03.2023)

3-
https://www.dahching.com/blog/spot_welding_machin
e (16.07.2023)

4-<https://towardsdatascience.com/understanding-feature-engineering-part-2-categorical-data-f54324193e63> , (02.03.2023)

5-<https://vitalflux.com/machine-learning-feature-selection-feature-extraction/> , (01.02.2023)

6-<https://towardsdatascience.com/what-is-one-hot-encoding-and-how-to-use-pandas-get-dummies-function-922eb9bd4970> , (14.03.2023)

7-<https://towardsdatascience.com/knn-k-nearest-neighbors-1-a4707b24bd1d> , (18.04.2023)

8-<https://machinelearningmastery.com/classification-and-regression-trees-for-machine-learning/> , (20.04.2023)

9-<https://medium.com/machine-learning-t%C3%BCrkiye/cart-algori%C8%7Bmasi-bfdf1c6f740c> , (08.05.2023)

10-<https://towardsdatascience.com/what-is-cross-validation-60c01f9d9e75> , (10.05.2023)

**AFYON KOCATEPE ÜNİVERSİTESİ
ULUSLARARASI MÜHENDİSLİK
TEKNOLOJİLERİ ve UYGULAMALI
BİLİMLER DERGİSİ**

Afyon Kocatepe Üniversitesi
Ahmet Necdet Sezer Kampüsü
Teknoloji Fakültesi
AFYONKARAHİSAR
Tel: +90 272 228 14 46
Belgegeçer: +90 272 228 14 49
E-posta: ijetas@aku.edu.tr

www.ijetas.aku.edu.tr