

Araştırma Makalesi / Research Article

Makine Öğrenmesi ile 6082 Alüminyum Alaşımının Yorulma Ömrü Tahmini

Resul ÜNAL^{1*}, Recai KUŞ², Mustafa ACARER³

^{1*} Kilis 7 Aralık Üniversitesi, Makine ve Metal Teknolojileri Bölümü, Kilis, Türkiye,
ORCID ID: <https://orcid.org/0000-0002-7597-9490>, resulunal@kilis.edu.tr

² Selçuk Üniversitesi, Teknoloji Fakültesi, Makine Mühendisliği Bölümü, Konya, Türkiye,
ORCID ID: <https://orcid.org/0000-0002-7705-7924>, recaikus@gmail.com

³ Selçuk Üniversitesi, Teknoloji Fakültesi, Metalurji ve Malzeme Mühendisliği Bölümü, Konya, Türkiye,
ORCID ID: <https://orcid.org/0000-0003-2876-4881>, macarer@selcuk.edu.tr

Geliş/ Received: 24.12.2024;

Revize/Revised: 02.01.2025

Kabul / Accepted: 13.01.2025

ÖZET: Alüminyum alaşımlar endüstride oldukça sık tercih edilen malzemelerdendir. Alüminyumun en önemli özelliklerinden biri yoğunluklarının düşük olmasıdır. Bu sayede otomotiv sektörü de dahil olmak üzere birçok sektörde önemli bir mühendislik malzemesi olarak yerini almıştır. Otomotiv sektöründe kullanılan alüminyum alaşımlardan bir tanesi de 6082 serisi alüminyum alaşımıdır. Tekrarlı yüklere maruz kalan makine parçalarında zamanla mikro çatlaklar oluşarak birikir ve bu çatlaklar ani kırılmalara sebep olur. Malzemelerde yorulma olarak bilinen bu olgunun anlaşılması ve yorulma deneylerinin yapılarak kırılma çevrim sayılarının belirlenmesi büyük önem taşır. Bu çalışmada 6082 alüminyum alaşımının yorulma testleri sırasında DCPD (Direct Current Potential Drop) tekniğiyle numune üzerinden akım ve gerilim değerleri toplanırken, uygulanan kuvvet ve meydana gelen deplasman verileri de eş zamanlı olarak kaydedilmiştir. Daha sonra bu veriler karar ağacı, ekstra ağaçlar, rastgele orman, XGBoost (Aşırı Gradyan Arttırma) ve KNN (K-En Yakın Komşu) olmak üzere 5 farklı makine öğrenmesi algoritmasına girdi olarak verilmiş ve çevrim sayıları tahmin edilmiştir. Test edilen modeller arasında R-kare (R^2) ve ortalama mutlak yüzde hata (MAPE) değerleri baz alındığında en iyi performansı karar ağacı ve ekstra ağaçlar makine öğrenmesi modelleri göstermiştir.

Anahtar Kelimeler: Yorulma, DCPD, 6082 Alüminyum alaşımı, Makine öğrenmesi, Tahmin

*Sorumlu yazar / Corresponding author: resulunal@kilis.edu.tr

Bu makaleye atıf yapmak için /To cite this article

Fatigue Life Prediction of 6082 Aluminum Alloy with Machine Learning

ABSTRACT: Aluminum alloys are one of the most preferred materials in industry. One of the most important properties of aluminum is its low density. In this way, it has taken its place as an important engineering material in many sectors, including the automotive sector. One of the aluminum alloys used in the automotive industry is the 6082 series aluminum alloy. Machine parts subjected to repetitive loads develop and accumulate micro cracks over time and these cracks cause sudden breakage. It is of great importance to understand this phenomenon known as fatigue in materials and to determine the number of fracture cycles by performing fatigue tests. In this study, during the fatigue tests of 6082 aluminum alloy, current and voltage values were collected from the specimen using DCPD (Direct Current Potential Drop) technique, while the applied force and displacement data were recorded simultaneously. These data were then given as input to 5 different machine learning algorithms: decision tree, extra trees, random forest, XGBoost (eXtreme Gradient Boosting) and KNN (K-Nearest Neighbor) and the number of cycles were estimated. Among the tested models, the decision tree and extra trees machine learning model performed the best based on R-square (R^2) and mean absolute percentage error (MAPE) values.

Keywords: Fatigue, DCPD, 6082 Aluminum alloy, Machine learning, Prediction

1. GİRİŞ

Alüminyum alaşımlar gelişmiş mekanik özelliklerinden dolayı çeşitli sektörlerde yaygın kullanıma sahiptirler (Sagar ve ark., 2023). Örneğin, havacılık sektöründe alüminyum alaşımlar büyük ölçüde kullanılırlar (Malek ve ark., 2020). Bununla birlikte Avrupa'daki otomobillerde kullanılan alüminyum içeriğinin 2022'de 205 kg iken, 2026'da 237 kg'a (+%15.6) ve 2030'da araç başına 256 kg'a (+%24.9) çıkacağı öngörülmektedir (European Aluminium, 2023).

Al-Si-Mg-Mn alaşımları, 200 MPa'nın üzerinde yüksek bir akma dayanımına sahiptir (Cai ve ark., 2020). 6xxx serisi alaşımlar, sahip oldukları ekstrüde edilebilirlik özelliği ile metal tasarım şekillerinin, karmaşık mimari formların ve tek şekillerin üretilmesine olanak tanırırlar. 6082 Al alaışımının ana uygulamaları açısından otomotiv sektörü benzersiz bir sektördür (Kumar ve ark., 2024). Alüminyumun tasarım ve boyutlandırma süreçleri çelik için kullanılanlara benzer olsa da önemli fiziksel farklılıklar vardır (Gitter, 2006). Alüminyum gibi bazı metallerin tek eksenli gerilim altında sınırlı uzamalara sahip olduğu ve kırılmadan önce düşük uzama nedeniyle çekme testlerinin doğruluğunu olumsuz etkilediği bildirilmiştir (Olguner ve Bozdana, 2020).

Metallerin yorulma kırılması endüstride sık karşılaşılr ve bu sebeple, tasarım yorulma ömrü ilgi çeken bir araştırma konusu olmuştur (He ve ark., 2021). Genelde, alüminyum malzemelerin yorulma ömürleri, güvenilirliğini değerlendirmek için farklı üretim ortamlarında ölçülür (Lian ve ark., 2022). Çeliklerde gözlemlenen çatlak büyüme hızı ile çatlak uzunluğu arasındaki doğrusallığın, alüminyum 6082-T6 alaışımında da geçerli olduğu doğrulanmıştır (Jíša ve ark., 2010). Bu alaışımının yorulma ömrü tahmini için literatürdeki bir çalışmada önerilen yaklaşımın, değişken genlikli yüklemelerde, yorulma ömrü tahminine uygulanabilir olduğu ifade edilmiştir (Guo ve ark., 2022). 6082 alaışımının farklı varyantlarıyla yapılan bir çalışmada saflık arttıkça yorulma özelliklerinin iyileştiği de bildirilmiştir (Sarkar ve ark., 2024).

Maliyetleri azaltma çabası tasarım sürecine de uygulanmalı ve güvenilir malzeme verileri elde etmek, pahalı deneysel çalışmalar gerektirmemelidir (Karolczuk ve ark., 2022). Ayrıca, bazı fiziksel

temeller kullanılmasına rağmen seçilen gerilme/gerinim büyüklükleri ve malzeme parametreleri, deneysel sonuçlara en iyi uyumu elde etmek için keyfi şekilde formüle edilmiş parametrik fonksiyonlarla ilişkilendirilir (Karolczuk ve ark., 2022). Bu sebeplerle farklı yapay zekâ modellerinin, örneğin sinir ağı modellerinin, çekme dayanımının modellenmesi gibi (Yılmaz ve ark., 2016), malzemelerin mekanik özelliklerinin tahmin edilmesinde kullanmak oldukça elverişlidir. Sinir ağı modelleri, yorulma ile ilgili yapılan çalışmalarda da önemli bir etki oluşturmuş ve bu etkinin yapay zekâ alanındaki son gelişmelerle birlikte hızla artması beklenmektedir (Chen ve Liu, 2022). Alüminyum alaşımlarda korozyona bağlı yorulma çatlak büyüme oranının artırımı öğrenme stratejine dayalı tahmini (Peng ve ark., 2024), yapay sinir ağı modelinin lamine kompozitlerin yorulma ömrünün tahmini (Mirzaei ve ark., 2024), yapay sinir ağları ve destek vektör regresyon modelleri uygulanarak yorulma ömrü tahmini (Li ve ark., 2024) gibi literatürde yorulma ömrünün tahminiyle ilgili birçok çalışma mevcuttur. Karmaşık bir doğaya sahip olan yorulma olgusunun tahmini için makine öğrenmesi modellerinin iyi performans göstermesi beklendiğinden, bu çalışmada yorulma deneylerinden elde edilen verilerle yapılacak tahminlerde makine öğrenmesi modelleri kullanıldı.

Literatürdeki bazı çalışmalarda da (Silva ve Pinho, 2002; Doré ve Maddox, 2013; Arunachalam ve Fawaz, 2016; Funk ve Bär, 2019;) olduğu gibi, çatlak yayılımı ve büyümesini ölçmek için kullanılan yöntemlerden biri de DCPD yöntemidir. DCPD yöntemi bir numunenin tüm kesitinden geçen homojen bir doğru akımın, numunedeki çatlakların neden olduğu potansiyel düşüşün meydana gelmesini temel alarak çalışır (Černý, 2004). DCPD yönteminde, yorulma çatlağının bulunduğu numuneden sabit bir elektrik akımı geçirilir ve elektrik potansiyel düşüşü ölçülür (Vecchiato ve ark., 2021). İki potansiyel arasındaki fark ve oran, çatlak ilerleme davranışındaki farklılıkları tanımlamak için yararlı parametrelerdir (Funk ve Bär, 2019). Yapılan bir çalışmada araştırmacılar, 6082-T6 alüminyum alaşımından üretilen tek kenarlı çentik gerilimi (SENT) numunesi ile yorulma deneylerinde özel bir DCPD yöntemi kullanmışlar ve bu tekniğin çok kısa çatlaklara sahip alüminyum alaşımlarına uygulanabilir olduğunu kanıtlamışlardır (Mann ve ark., 2007).

Literatürde T6 ısıtıl işlemi görmüş 6082 alüminyum alaşımı için DCPD yöntemiyle toplanan verilerin yanında, aksiyal deplasman ve aksiyal kuvvet verilerinin de kullanıldığı ve bu veriler kullanılarak geliştirilen makine öğrenmesi modelleri ile çevrim sayılarının tahmin edildiği bir çalışmaya rastlamadık. Bu çalışmada, T6 ısıtıl işlemi görmüş 6082 alüminyum alaşımı için, DCPD yöntemi ile topladığımız verilerle birlikte eş zamanlı toplanan kuvvet ve deplasman verileri, veri ön işleme yapılarak birleştirilip, makine öğrenmesi algoritmalarına girdi olarak verildi. Geliştirilen 5 farklı makine öğrenmesi modeliyle numunelerin çevrim sayıları tahmin edildi. Bu modellerin 6082 serisi alüminyum alaşımlarının yorulma testlerindeki çevrim sayılarını tahmin etme performansı gösterildi.


2. MATERYAL VE YÖNTEM

Yaptığımız yorulma deneylerinde, kimyasal bileşim sınırları Çizelge 1.'de verilen 6082 serisi alüminyum alaşımı kullanıldı.


Çizelge 1. 6082 Alüminyum alaşımının kimyasal bileşimi (Ağırlıkça %) (ASTM, 2021).

Si	Fe	Cu	Mn	Mg	Cr	Zn	Ti	Diğer Elementler		Alüminyum
								Herbiri	Toplam	
0.7-1.3	0.5	0.1	0.40-1	0.6-1.2	0.25	0.2	0.1	0.05	0.15	Kalan

Deney numuneleri ASTM E466 standardına göre hazırlandı. Hazırlanan numune şekli ve ölçüleri Şekil 1.'de verilmiştir. Numunenin en ince kesiti 6 mm'dir.




Şekil 1. a) Test numunesi şekli (ASTM, 2002) b) Üretilen test numunesi ölçüleri



Şekil 2. a) Üretilen test numunesi b) Deney sonrası kırılmış test numunesi

Şekil 2a.'da üretilen test numunesi ve Şekil 2b'de yapılan deneyler sonucunda kırılan numune görülmektedir.

DCPD yöntemiyle akım ve gerilim değerlerinin ölçülebilmesi için, test probleminin numune üzerinde durmasını kolaylaştıracak bir aparat tasarımı yapıldı. Tasarlanan aparatta numuneye uygun şekilde yerleştirilebilen 4 adet prob bulunmaktadır. Aparat tasarımında, literatürde bulunan bir çalışmada (Vecchiato ve ark., 2021) kullanılan aparattan esinlenildi. İletkenliğin yüksek olması için bakır çubuklar kullanılarak aparata yerleştirildi. Elektriksel ölçümler için Şekil 4.'de görülen Keithley 2634B cihazı kullanıldı.



Şekil 3. a) Tasarlanan aparat b) Deney düzeneğine montajı yapılan aparat

Şekil 3a’da numuneye bağlı aparat, Şekil 3b’de ise yorulma deney cihazına bağlı numune görülmektedir. Yorulma deneyleri MTS Landmark masaüstü yorulma test cihazı kullanılarak yapıldı. Bu test cihazı maksimum 100 Hz ve 15 kN yükte çalışabilir. Bazı deneysel çalışmalarda 6082 serisi alüminyum alaşımın akma dayanımı yaklaşık olarak 300 MPa bulunmuştur. (Biro ve ark., 2016).



Şekil 4. Keithley 2634B Sourcemeter cihazı.

Deneyler sabit kuvvet uygulanarak gerilme aralığı $R=-1$ yükleme durumunda yapıldı. Uygulanan kuvvet ve gerilim değerleri Çizelge 2’de verilmiştir.

Çizelge 2. Numunelere uygulanan kuvvet, gerilim ve yorulma kırılmasının gerçekleştiği çevrim değerleri

Numune	Kuvvet (N)	Gerilim (MPa)	Çevrim
Numune 1	5500	195	38035
Numune 2	6000	212	45828
Numune 3	6500	230	9547

Çizelge 2 incelenecek olursa Numune 2’ye uygulanan kuvvet Numune 1’e uygulanan kuvvetten fazla olmasına karşı yorulma kırılmasının gerçekleştiği çevrim sayısının daha fazla olduğu görülmektedir. Bu iki değer birbirine oldukça yakındır. Numune 1’in kırılma çevrim sayısı yaklaşık

olarak 4×10^4 iken, Numune 2'nin kırılma çevrim sayısı 4.5×10^4 çevrimdir. Numune 3 ise yaklaşık 10^4 çevrimde kırılmıştır. Çizelge 3 incelenirse, numunelere uygulanan gerilim değerlerinin hepsi akma dayanımına yakındır.

Çizelge 3. 6082-T6 Alüminyum alaşımının mekanik özellikleri (ASTM, 2021)

Malzeme	Minimum Çekme Dayanımı (Mpa)	Minimum Akma Dayanımı (Mpa)	Uzama (%)
6082-T6	310	260	6 - 8

Paris-Erdoğan modelinden (Paris ve Erdogan, 1963) de bilindiği üzere, çatlak gelişimi çevrim başına çatlak büyümesi üzerinden düşünülecek olursa, minimum ve maksimum gerilim yığılma faktörleri arasındaki farkla ilişkilendirildiğinde, yorulma kırılmasının 3 temel aşamadan gerçekleştiği söylenebilir. İkinci aşama lineer bir davranış sergilese de ilk ve son aşama daha belirsizdir. Özellikle son aşamada çatlak hızla ilerleyerek kırılma gerçekleşir. Bu aşamalar dikkate alındığında yorulma ömrü, malzemelerin mikroyapılarına oldukça bağlıdır. Literatürde bulunan bir çalışmada (Winter ve ark., 2020), ortalama gerilim duyarlılığının, kabul görmüş bir görüşe göre, yalnızca çekme dayanımından değil, aynı zamanda malzemenin mikro yapısal ve mekanik özelliklerinin yanında işleme geçmişinden de etkilendiği ve basınç yüklemesinin yüksek çevrimli yorulma rejiminde, çekme kadar önemli olduğu bildirilmiştir. İfade edildiği gibi mikroyapı kusurları yorulma ömrü üzerinde önemli bir etkiye sahiptir ve çatlakların ilerleme hızını etkiler. Malzemeler aynı olsa dahi mikro yapıdaki farklılıklar, kullanılan makine elemanlarının yorulma ömrünün tahmin edilmesi güçleştirmektedir. Buradaki mikroyapı farklılıklarından kasıt, mikroyapıda bulunan kusurların türü ve sayısı, yeni oluşan veya daha önceden mevcut olan mikro çatlakların büyüklüğü, sayısı ve ilerleme doğrultusu gibi her numuneye özel farklı parametrelerdir. Yaptığımız deneylerde de buna benzer sonuçlar elde edilmiştir. Numune 1'e göre Numune 2'ye uygulanan kuvvetin artmasına karşı çevrim sayısı da bir miktar artmıştır. Bu durumun sebebinin, her numune için bahsedilen mikroyapı farklılıklarının olduğu düşünülmektedir.

DCPD yöntemi yorulma için tercih edilen yaygın deneysel yöntemlerden biridir (Pokharel ve ark., 2023). DCPD yönteminin temel çalışma prensibinde, numuneye sabit bir akım verilerek çatlak boyunca potansiyel farkın ölçülmesi yatar, uzayan çatlak boyu numunedeki elektriksel direnci artırarak ölçülen potansiyel düşüşün artmasına neden olur (Doremus ve ark., 2015).

Hazırlanan numunelere Şekil 5'te gösterilen 3-4 noktaları arasından, Şekil 4'te görülen Keithley 2634B Sourcemeter cihazı kullanılarak sabit 1 amper akım verildi. Deneyler yapılırken 1-2 ve 3-4 noktaları arasındaki akım ve gerilim değerleri DCPD yöntemiyle anlık olarak saniyede 30 veri kaydedildi. Ayrıca deney sırasında uygulanan kuvvet ve deplasman verileri de eş zamanlı olarak saniyede 30 veri alınarak toplandı. Toplanan bu veriler daha sonra birleştirilerek makine öğrenmesi algoritmalarıyla çevrim sayılarının tahmini için kullanıldı.

Verilerin ön işleme için Python programından faydalanıldı. Ham veriler programda farklı veri setleri olarak alındı ve daha sonra tek veri setindeki sütunlar yan yana gelecek şekilde birleştirildi. Eksik değerler bir sonraki satırda bulunan değerler kullanılarak dolduruldu. Oluşan yeni veri seti makine öğrenmesi algoritmalarında kullanıldı.


Toplamda 3 numune için 92895 satır ve 5 özellik bulunan veri seti, makine öğrenmesi modellerini eğitmek için kullanıldı. Bağımlı değişken olarak yorulma deneylerinden elde edilen çevrim sayıları seçildi. Bu değişken sıfırdan kırılmanın gerçekleştiği çevrim sayısına kadar artmaktadır. Bağımsız değişkenler ise aksiyal deplasman, aksiyal kuvvet ve numunelerden ölçülen

elektriksel gerilim değerleridir. Veri setinde bulunan değişkenlerin minimum ve maksimum değerleri Çizelge 4’te verilmektedir.

Çizelge 4. Veri setindeki bağımlı ve bağımsız değişkenlerin minimum ve maksimum değerleri

	Deplasman (mm)		Kuvvet (N)		1-2 Arası Gerilim (V)		3-4 Arası Gerilim (V)		Çevrim Sayısı	
	Min.	Mak.	Min.	Mak.	Min.	Mak.	Min.	Mak.	Min.	Mak.
Numune 1	-0.17	8.51	-5536	5539	0.001931	0.000098	0.34964	0.384992	0	38035
Numune 2	-0.16	6.7	-6036	6048	0.001888	0.000226	0.35045	0.355692	0	45828
Numune 3	-0.19	3.43	-6526	6532	0.001888	0.000184	0.34967	0.352607	0	9547

Deneyler sırasında numune üzerine probların temas ettiği noktalar ve bu noktalar arası mesafeler Şekil 5’ te gösterilmektedir.



Şekil 5. Propların numune üzerindeki temas noktalarının mesafeleri

Her bir numune için toplanan veriler %80 ve %20 oranında eğitim ve test verisi olmak üzere rastgele ayrıldı. Eğitim verileri kullanılarak eğitilen farklı makine öğrenmesi modelleriyle, numunelerin eğitim ve test verileri üzerinde çevrim sayılarının tahminleri yapıldı. Karar ağacı, ekstra ağaçlar, rastgele orman, XGBoost (Aşırı Gradyan Arttırma) ve KNN (K-En Yakın Komşu) olmak üzere 5 farklı makine öğrenmesi algoritması kullanıldı ve eğitilen modeller test verileri kullanılarak test edildi. Hiperparametrelerin en iyi kombinasyonunu bulmak için ızgara arama tekniğiyle her bir model için belirlenen en iyi parametreler kullanılarak modeller eğitildi ve numunelerin çevrim sayıları tahmin edildi. Izgara arama yöntemiyle belirlenen en iyi hiperparametreler Çizelge 5’de verilmiştir.

Çizelge 5. Sırasıyla tüm numuneler için ızgara arama yöntemiyle belirlenerek makine öğrenmesi modellerinde kullanılan en iyi hiperparametreler

Karar	max_depth	min_samples_leaf	min_samples_split		
Ağacı	None-None-20	1	5-2-2		
Ekstra	max_depth	max_features	min_samples_leaf	min_samples_split	n_estimators
Ağaçlar	None-None-30	sqrt - sqrt - log2	1	2	200-200-100
Rastgele	max_depth	max_features	min_samples_leaf	min_samples_split	n_estimators
Orman	None-None-30	sqrt-log2-sqrt	1	2	200
	algorithm	leaf_size	n_neighbors	p	weights
KNN	auto	10	9-7-5	1	distance
	colsample_bytree	learning_rate	max_depth	n_estimators	subsample
XGBoost	1	0.2	7	200	0.6-0.8-1.0

Model performansları R-kare (R^2) ve ortalama mutlak yüzde hata (MAPE) metrikleriyle ölçülmüştür.

R^2 değeri Denklem 1. (Elmoualami, 2020) ile hesaplanabilir.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (1)$$

Burada;

y_i : Gerçek değeri,

$\hat{y}_i$: Tahmin edilen değeri,

$\bar{y}$: Gerçek değerlerin ortalamasını ifade etmektedir.

MAPE değerini hesaplamak için Denklem 2. (Elmoualami, 2020) kullanılabilir.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{\hat{y}_i} \times 100 \quad (2)$$

Burada;

y_i : Gerçek değeri,

$\hat{y}_i$: Tahmin edilen değeri


n : veri kümesindeki toplam örnek sayısını, ifade etmektedir

Elde edilen bulgular çizelge ve grafiklerle sunulmuştur.

3. BULGULAR VE TARTIŞMA

3.1 Bulgular

Numunelerin Şekil 5'te gösterilen 1-2 noktaları arasından alınan gerilim değerlerinin 1. dereceden eğilim grafiği Şekil 6'da verilmiştir. Bütün numunelerdeki ölçülen elektriksel gerilim değerleri çevrim sayısı arttıkça artmaktadır. Numune içindeki çatlak miktarı arttığından, numuneden akımın geçmesi zorlaşmış ve ölçülen gerilim değeri de akımın sabit tutulması sebebiyle artma eğilimi göstermiştir.



Şekil 6. Numune üzerindeki 1-2 noktaları arasından ölçülen gerilim değerlerinin 1. dereceden eğilim grafiği

Her numunenin eğitim verilerindeki tahminlerine bağlı olarak hesaplanan R^2 hata ve MAPE değerleri Çizelge 6’da sunulmuştur.

Çizelge 6. Makine öğrenmesi modellerinin eğitim verileri üzerindeki performansları


Numune	Karar Ağacı		Ekstra Ağaçlar		Rastgele Orman		XGBoost		KNN	
	R^2	MAPE	R^2	MAPE	R^2	MAPE	R^2	MAPE	R^2	MAPE
Numune 1	1.00	0.00	1.00	0.00	1.00	0.06	1.00	1.64	1.00	0.00
Numune 2	1.00	0.00	1.00	0.00	1.00	0.06	0.99	0.38	1.00	0.00
Numune 3	1.00	0.01	1.00	0.00	1.00	0.07	1.00	0.26	1.00	0.00

Test verilerindeki tahminler sonucunda hesaplanan R^2 hata ve MAPE ise Çizelge 7’de gösterilmektedir.

Çizelge 7. Makine öğrenmesi modellerinin test verileri üzerindeki performansları


Numune	Karar Ağacı		Ekstra Ağaçlar		Rastgele Orman		XGBoost		KNN	
	R^2	MAPE	R^2	MAPE	R^2	MAPE	R^2	MAPE	R^2	MAPE
Numune 1	0.99	0.05	0.99	0.04	0.99	0.08	0.99	0.55	0.95	1.10
Numune 2	0.99	0.08	0.99	0.07	0.99	0.17	0.99	0.66	0.85	1.61
Numune 3	0.98	0.06	0.99	0.04	0.99	0.08	0.99	0.17	0.51	1.55

Çizelge 7’de bulunan değerler tüm numuneler için değerlendirildiğinde KNN modeli hariç tüm modellerin yüksek bir R^2 değerine sahip olduğu görülebilir. R^2 değerinin 1’e yakın olması modellerin veri seti üzerinde iyi uyum sağladığını göstermektedir. Hata değerlendirmeleri için kullanılan MAPE değerleri ise tüm numuneler için karar ağacı ve ekstra ağaçlar modellerinde 0.1’in altındadır. En iyi MAPE değerlerine sahip olan bu iki model için eğitim ve test verileri kullanılarak elde edilen tahmin ve gerçek değer nokta grafikleri Şekil 7 ve Şekil 8’de verilmiştir.



Şekil 7. Sıralanmış gerçek ve tahmin edilen değerler için karar ağacı modelinin nokta grafiği

Şekil 7’de gerçek ve karar ağacı modeli ile tahmin edilen değerler görülmektedir. Model daha önce görmediği test verilerinde bazı büyük hatalar yapmasına karşılık, modelin genel performansı oldukça iyidir. Nitekim Çizelge 7’deki R^2 ve MAPE değerleri bunu desteklemektedir. Ayrıca eğitim verisi üzerinde de Numune 1 ve Numune 2 için bazı değerleri hatalı tahmin ettiği de görülmektedir. Eğitim verileri üzerindeki performansı test verilerine göre daha başarılıdır.



Şekil 8. Sıralanmış gerçek ve tahmin edilen değerler için ekstra ağaçlar modelinin nokta grafiği

Şekil 8’de ise gerçek ve ekstra ağaçlar modeli ile tahmin edilen değerler görülmektedir. Ekstra ağaçlar modeli test veri setinde, karar ağacı modeline göre daha küçük hatalar yapsa da hata sayısı karar ağacı modeline göre biraz daha fazladır. Eğitim veri setinde ise karar ağacı modeline göre daha başarılıdır.

Karar ağacı ve ekstra ağaçlar makine öğrenmesi modelleri, numunelerin çevrim sayılarını tahmin etmede R^2 ve MAPE metrikleriyle değerlendirildiğinde, birbirlerine yakın performans gösterdiler. MAPE değerleri tüm numuneler için 0.1 değerinden daha küçüktür. Bu ise her iki modelin de yüksek bir doğruluk oranı yakaladığını ve yapılan hataların kabul edilebilir aralıkta olduğunu göstermektedir. MAPE değerleriyle birlikte değerlendirildiğinde, her iki modelin de R^2 değerlerinin 0,97’nin üzerinde olması modellerin iyi performans sergilediklerinin göstergesidir. Rastgele orman algoritması kullanılarak geliştirilen model ise Numune 2 için yapılan tahminde MAPE değeri 0.1’in üzerine çıkmıştır. Bu değer biraz büyük görünse de kabul edilebilir hata sınırları içerisindedir. Rastgele orman modeli de karar ağacı ve ekstra ağaçlar modeline yakın performans sergilemiştir. Diğer makine öğrenmesi modellerinde de R^2 değerleri yüksektir. Bu sonuçlar modelin veriye iyi uyum sağladığını gösterse de MAPE değerlerinin karar ağacı, ekstra ağaçlar ve rastgele orman modellerine göre yüksek olması, modelin tahminlerde yaptığı hata sayılarının veya değerlerinin yüksek olmasının bir sonucudur. Veri ölçeklemesi yaparak ya da ızgara arama parametreleri genişletilerek diğer modellerden de daha iyi sonuçlar elde edilebilir.

3.2 Tartışma

Yapılan bir araştırmada (Doré ve Maddox, 2013), 6082 T651 alüminyum alaşımında çatlak büyümesi hızlanmasının temel olarak, düşük yükün ardından etkin çatlak ucu ortalama gerilimindeki artıştan kaynaklandığı ileri sürülmektedir. Yorulma çatlak büyüme davranışı genellikle mikro

yapının içsel morfolojisi ve malzemede bulunan faz sayısından etkilendiği gösterilen başka bir çalışmada (Ojo ve ark., 2022) ise, enerji biriktirme eklemeli üretim yöntemiyle üretilen Ti-6Al-4V alaşımları için, iki farklı yönelimli yorulma çatlak büyüme özelliklerinde önemli anizotropi gösterdiği ve kıvrımlı çatlak yollarına sahip numunelerin, pürüzsüz çatlak yolları gösteren numunelere kıyasla daha düşük yorulma çatlak büyüme oranlarına sahip olduğu ifade edilmiştir.

Laboratuvar ortamında yaygın olarak kullanılan çatlak büyümesi izleme tekniklerinden biride, doğru akım potansiyel düşüşü (DCPD) tekniğidir (Ni ve ark., 2024). Yüksek çözünürlüklü bir DC potansiyel düşüşü ölçümüyle, bir çatlakın çok erken tespit edilebileceği, ancak ilk çatlakın gerçek şeklini ve yerini görüntülemenin mümkün olmadığı söylenen bir çalışmada (Funk ve Bär, 2019), tek kenarı çentikli (SEN) numuneleri üzerinde iki bağımsız potansiyel probu ile yapılan yorulma çatlak yayılma deneylerinin, ölçülen potansiyel değerlerinde belirgin farklılıklar gösterdiği belirtilmiştir. Ayrıca literatürdeki bir diğer çalışmada (Vavouliotis ve ark., 2011) ise, yorulma yüklemesine maruz izotropik karbon elyaf takviyeli laminatların elektrik direnci tepkisinin doğrudan hasar birikimiyle bağlantılı olduğu söylenmiştir. Biz de yaptığımız çalışmada yorulma tahmini için makine öğrenmesi modeline girdi olarak kullanılacak verileri DCPD yöntemi ile topladık. Literatürdeki tüm bu çalışmaları destekleyici nitelikte, yaptığımız çalışmada numunelerin gerilim değerlerinin, Şekil 6'da bulunan eğilim çizgilerinden de görüleceği üzere, çevrim sayısına paralel bir değişim içinde olduğunu gösterdik.

Yapılan bir çalışmada (Pokharel ve ark., 2023) araştırmacılar DCPD yöntemiyle topladıkları verileri, LSTM (uzun kısa süreli bellekli) mimarisinde kullanarak ve Inconel 718 (IN718) süper alaşımının düşük çevrimli yorulma yüklemelerindeki önceki çatlak sıçramalarına dayanarak gelecekteki çatlak olaylarını tahmin edebildiklerini, modelin daha fazla deney yapılmadan tüm ara koşulları üretebileceğini ve bunun da daha iyi hasar modelleri üretmek için bir araç sağlayacağını ifade etmişlerdir. Diğer bir çalışmada (Lian ve ark., 2022) da sadece bileşim ve temperleme girdileri kullanarak Al alaşımlarının yorulma dayanımının tahmini için güvenilir bir model sunulmuştur. Farklı bir çalışmada (Abdullatef ve ark., 2023) ise çeşitli makine öğrenmesi teknikleriyle saf burulma yüklemesi altında yüksek mukavemetli 2090-T83 alüminyum alaşımının yorulma ömrü tahmininde, geleneksel yaklaşımlara kıyasla, sinir ağı ve nöro-bulanık modellerin daha iyi sonuçlar ürettiği, güçlendirme yinelemeleri tekniği kullanılarak eğitilen sinir ağı modellerinin en iyi performansı sağladığı ifade edilmiştir. Yapay sinir ağının (ANN) Monte-Carlo yöntemi (MCM) ile ilişkilendirildiği diğer bir çalışmada (Song ve ark., 2022) araştırmacılar, kalıntı yorulma ömrü tahmin modeli oluşturmuşlar ve oluşturulan modelin kullanılarak kalıntı yorulma ömrünü %3,264 bağıl hata oranıyla tahmin ettiklerini belirtmişlerdir. Farklı bir çalışmada (Guo ve ark., 2023) demir alaşımlarının yorulma ömürlerinin tahmini için Bayes optimizasyon algoritması ile optimize edilmiş rastgele orman regresyonu kullanımının, doğrusal regresyon, yapay sinir ağı, karar ağacı regresyonu ve destek vektör regresyonu ile karşılaştırıldığında üstün performans ve doğruluk gösterdiğini belirtilmiştir. 17-4 PH paslanmaz çeliklerin yorulma ömrü ve çatlak büyüme oranını analiz etmek için, KNN, karar ağacı, rastgele ormanlar ve aşırı gradyan artırma algoritmaları kullanılan diğer bir çalışmada (Kalita ve ark., 2024) ise hiper parametreleri optimize ettikten sonra eğitilen modellerin, görülmemiş verileri, eğitilen veriler kadar iyi tahmin ettiği ve en iyi performansı XGB modelinin gösterdiği söylenmiştir. Östenitik paslanmaz çeliklerin yorulma ömrü tahminleri için 4 makine öğrenmesi ve 1 yapay sinir ağı modeli geliştirilen literatürdeki farklı bir çalışmada (Bhardwaj ve Shukla, 2024), yapay sinir ağı modelinin klasik modellere ve makine öğrenimi modellerine göre tahmin doğruluğunu artırdığı ifade edilmiştir. Yapılan diğer bir çalışmada (Çavdar ve ark., 2024) ise AISI H11 sıcak iş takım çeliğinin kutu borlama tekniğiyle borlanmasında işlem sıcaklığı ve süresinin

kaplama kalınlığı, yüzey pürüzlülüğü, sertliği ve korozyon oranına etkisini makine öğrenmesi yöntemleriyle modelleyerek, kaplama kalınlığı ve korozyon oranı için SVR, yüzey pürüzlülüğü ve mikrosertlik için RF algoritmalarının en iyi sonuçları verdiği ifade edilmiştir.

Yaptığımız çalışmada en iyi performansı karar ağacı ve ekstra ağaçlar modelleri gösterirken, en kötü performansı KNN modeli gösterdi. Literatürde bulunan çalışmalarda modellerin performanslarıyla ilgili temel farklılık, yapılan çalışmalarda toplanan veri yapılarının farklı olması ve modellerin farklı verilerde, farklı doğruluk oranlarını vermesinden kaynaklandığı düşünülmektedir. Deney verilerinin ve seçilen hiperparametrelerin optimizasyonu yapılarak geliştirilen diğer makine öğrenmesi algoritmalarının da yüksek doğruluk ve düşük MAPE değerlerine sahip tahminler yapması sağlanabilir. Yaptığımız çalışma, bahsedilen çalışmalarda da gösterildiği gibi, geliştirilen makine öğrenmesi modellerinin yorulma çevrim sayılarının tahmin edilmesinde başarılı araçlar olarak kullanılabileceğini desteklemektedir.

Makine öğrenmesi algoritmalarının iyi bir genelleme yaparak, doğru performans göstermesinin en önemli etkenlerinden biri de hiperparametre ayarlarının iyi seçilmiş olmasıdır. Hiperparametre ayarları her problem ve veri setine göre değişkenlik gösterir. Karar ağaçlarında bulunan bir karar ağacı, karar düğümleri, dallar ve ağacın daha fazla ayıramayacağı yaprak düğümlerinden oluşur (Efeoğlu, 2022). Ekstra Ağaçlar algoritması, klasik yukarıdan aşağıya prosedüre göre budanmamış karar veya regresyon ağaçlarından oluşan bir topluluk oluşturur. Diğer ağaç tabanlı topluluk yöntemleriyle arasındaki iki ana fark, düğümleri tamamen rastgele seçerek düğümleri bölmesi ve ağaçları büyütmek için tüm öğrenme örneğini kullanmasıdır (Geurts ve ark., 2006). Karar ağacı ve ekstra ağaçlar algoritmaları doğrusal olmayan ilişkilerde daha iyi sonuç verebilirler. Rastgele ormanlar, her ağacın ormandaki tüm ağaçlar için bağımsız olarak ve aynı dağılımla örneklenen rastgele bir vektörün değerlerine bağlı olduğu ağaç öngörücülerinin bir kombinasyonudur ve ağaç sınıflandırıcılarından oluşan bir ormanın genelleme hatası, ormandaki bireysel ağaçların gücüne ve bunlar arasındaki korelasyona bağlıdır (Breiman, 2001). Rastgele ormanda rastgele seçime bağlı olarak model çeşitliliği artarken, aşırı uyumun azaltılması hedeflenir. Çok fazla çeşitlilik olması ise bazı veri yapılarında çeşitliliğin birbirini dengelemesi ile doğruluk oranının azalmasına neden olur. Yaptığımız çalışmada rastgele orman modeli, karar ağacı ve ekstra ağaçlar modellerine yakın performans sergilese de Numune 2 için MAPE değeri 0.1'in üzerine çıkmıştır. XGBoost (eXtreme Gradient Boosting), esnek ve taşınabilir, optimum dağıtılmış karar gradyan artırma kitaplığıdır (Chen ve ark., 2020). Birçok zayıf öğreniciyi bir araya getirerek güçlü bir tahmin modeli oluşturmaya ve her adımda modelin hatalarını düzeltmeye çalışır. Bu durum modelin daha karmaşık hale gelmesine sebep olarak doğruluk oranını düşürebilir. KNN algoritması, sınıflandırma ve regresyon için parametrik olmayan bir yöntemdir. Giriş, her alandaki en yakın k örnekten oluşur. Verilen N eğitim vektörü için, k-en yakın komşu algoritması k sayıda en yakın komşuyu tanımlar (Pandey ve Jain, 2017). Bu çalışma kapsamında en kötü tahmini KNN modeli yapmıştır. Bunun sebebinin, bahsedildiği gibi KNN algoritmasının komşu verileri dikkate almasına bağlı olarak, veri setinin büyüklüğü nedeni ile kötü performans gösterdiği düşünülmektedir.

4. SONUÇ

Bu çalışmada 6082 alüminyum alaşımının yorulma deneyleri yapıldı. Deneyler sırasında DCPD yöntemi kullanılarak değişen potansiyel fark verileri toplandı. Ayrıca gerçek zamanlı olarak, deneyler sırasında deplasman ve kuvvet verileri de eş zamanlı olarak kaydedildi. Daha sonra karar ağacı, ekstra ağaçlar, rastgele orman, XGBoost (eXtreme Gradient Boosting) ve KNN (K-En Yakın Komşu) olmak

üzere 5 farklı makine öğrenmesi algoritmasına bu veriler girdi olarak verildi ve eğitilen modellerle numunelerin çevrim sayıları tahmin edildi.

Tahminlerde karar ağacı ve ekstra ağaçlar algoritmaları ile geliştirilen modeller, tüm numuneler için MAPE değerleri 0.1'in altında kalarak en iyi performansı gösterdi. Rastgele orman algoritması kullanılarak geliştirilen model ise Numune 2 için hesaplanan MAPE değerinin 0.1'in üzerinde olmasına rağmen karar ağacı ve ekstra ağaçlar modellerine benzer performans gösterdi. Çizelge 7'de verilen değerler incelendiğinde, XGBoost modeli kullanılarak yapılan tahminlerde R^2 değerleri istenildiği gibi 1'e yakındır. Fakat, MAPE değerlerinin beklenenden yüksek olduğu görülmektedir. Bu sonuçlar, XGBoost modelinin verilere iyi uyum sağladığını gösterebilir, bazı değerler için gerçek ve tahmin edilen değerler arasındaki farkın, dolayısıyla da hata oranının yüksek olduğunu ifade eder. KNN algoritması kullanılarak geliştirilen model en kötü performansı gösterdi. Numune 1 için MAPE değeri istenen gibi 1'e yakın olsa da diğer numuneler 0.9 değerinden küçüktür. Ayrıca MAPE değerleri de 1'in üzerindedir. KNN modeli diğer modellere göre en çok hata yapan modeldir.

5. TEŞEKKÜR

Yazarlar Selçuk Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğüne maddi desteklerinden dolayı teşekkür ederler. Ayrıca yazarlar bu çalışmada gerçekleştirilen yorulma deneylerindeki katkılarından ve yardımlarından dolayı AYD ARGE ekibine teşekkür ederler.

6. ÇIKAR ÇATIŞMASI

Yazarlar, bilinen herhangi bir çıkar çatışması veya herhangi bir kurum/kuruluş ya da kişi ile ortak çıkar bulunmadığını onaylamaktadırlar.

7. YAZAR KATKISI

Resul ÜNAL çalışmanın kavramsal ve tasarım süreçlerinin belirlenmesi, veri toplama, veri analizi ve yorumlama, makale taslağının oluşturulması, fıkırsel içeriğin eleştirel incelemesi, son onay ve tam sorumluluk kısımlarında katkıda bulunmuştur. Recai KUŞ çalışmanın kavramsal ve tasarım süreçlerinin yönetimi, makale taslağının oluşturulması, son onay ve tam sorumluluk kısımlarında katkıda bulunmuştur. Mustafa ACARER çalışmanın kavramsal ve tasarım süreçlerinin belirlenmesi, fıkırsel içeriğin eleştirel incelemesi, son onay ve tam sorumluluk kısımlarında katkıda bulunmuştur.

8. KAYNAKLAR

- Abdullatef M. S., Alzubaidi F. N., Al-Tamimi A., Mahmood Y. A., Fatigue Life Estimation of High Strength 2090-T83 Aluminum Alloy Under Pure Torsion Loading Using Various Machine Learning Techniques, *Fluid Dynamics and Materials Processing*, 19(8), 2083–2107, 2023.
- Arunachalam S., Fawaz S., Test Method for Corrosion Pit-To-Fatigue Crack Transition From A Corner of Hole in 7075-T651 Aluminum Alloy, *International Journal of Fatigue*, 91, 50–58, 2016.
- ASTM, Specification for Aluminum and Aluminum-Alloy Extruded Bars, Rods, Wire, Profiles, and Tubes, Test, 2021.
- ASTM, Standard Practice for Conducting Force Controlled Constant Amplitude Axial Fatigue Tests of Metallic Materials, Test, 03, 4–8, 2002.

- Bhardwaj H. K., Shukla M., Low-Cycle Fatigue Life Prediction of Austenitic Stainless Steel Alloys: A Data-Driven Approach with Identification of Key Features, *International Journal of Fatigue*, 187, 108454, 2024.
- Birol Y., Gokcil E., Ali M., Akdi S., A Processing of High Strength EN AW 6082 Forgings Without a Solution Heat Treatment, *Materials Science & Engineering:A*, 674, 25–32, 2016.
- Breiman L., Random forests, *Machine Learning*, 45(1), 5–32, 2001.
- Cai Q., Mendis C. L., Chang I. T. H., Fan Z., Microstructure Evolution and Mechanical Properties of New Die-Cast Al-Si-Mg-Mn Alloys, *Materials & Design*, 187, 108394, 2020.
- Černý I., The use of DCPD Method for Measurement of Growth of Cracks in Large Components at Normal and Elevated Temperatures, *Engineering Fracture Mechanics*, 71(4–6), 837–848, 2004.
- Chen J., Liu Y., Fatigue Modeling Using Neural Networks: A Comprehensive Review, *Fatigue and Fracture of Engineering Materials and Structures*, 45(4), 945–979, 2022.
- Chen J., Zhao F., Sun Y., Yin Y., Improved XGBoost Model Based On Genetic Algorithm, *International Journal of Computer Applications in Technology*, 62(3), 240, 2020.
- Çavdar F., Günen A., Sert M., Borlanmış AISI H11 Takım Çeliğinin Kaplama Özellikleri ve Korozyon Oranının Makine Öğrenmesi Temelli Modellenmesi, *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi*, 39(3), 625–638, 2024.
- Doré M. J., Maddox S. J., Accelerated Fatigue Crack Growth in 6082 T651 Aluminium Alloy Subjected to Periodic Underloads, *Procedia Engineering*, 66, 313–322, 2013.
- Doremus L., Nadot Y., Henaff G., Mary C., Pierret S., Calibration of The Potential Drop Method for Monitoring Small Crack Growth from Surface Anomalies - Crack Front Marking Technique and Finite Element Simulations, *International Journal of Fatigue*, 70, 178–185, 2015.
- Efeoğlu E., Kablosuz Sinyal Gücünü Kullanarak İç Mekan Kullanıcı Lokalizasyonu için Karar Ağacı Algoritmalarının Karşılaştırılması, *Acta Infologica*, 163 - 173, 2022.
- Elmousalami H. H., Artificial Intelligence and Parametric Construction Cost Estimate Modeling: State-of-the-Art Review, *Journal of Construction Engineering and Management*, 146(1) 2020.
- European Aluminium, Aluminium Usage in Cars Surges As Automotive Industry Shifts Towards Electrification, (May) www.european-aluminium.eu.
- Funk M., Bär J., DCPD Based Detection of the Transition from Short to Long Crack Propagation in Fatigue Experiments on The Aluminum Alloy 7475 T761, *Procedia Structural Integrity*, 17, 183–189, 2019.
- Geurts P., Ernst D., Wehenkel L., Extremely Randomized Trees. *Machine Learning*, 63(1), 3–42, 2006.
- Gitter R., Aluminium Materials for Structural Engineering – Essential Properties and Selection of Materials, *Structural Engineering International*, 16(4), 294–300, 2006.
- Guo J., Zan X., Wang L., Lei L., Ou C., Bai S., A Random Forest Regression with Bayesian Optimization-Based Method for Fatigue Strength Prediction of Ferrous Alloys, *Engineering Fracture Mechanics*, 293, 109714, 2023.
- Guo Y. B., Liu K. G., Lan Z. Y., Du X. K., Fatigue Life Prediction and System Development for 6082-T6 Aluminum Alloy Under Variable Amplitude Loading, *International Conference on Advanced Sensing and Smart Manufacturing (ASSM 2022)*, SPIE 2022.
- He L., Wang Z. L., Akebono H., Sugeta A., Machine Learning-Based Predictions of Fatigue Life and Fatigue Limit for Steels, *Journal of Materials Science & Technology*, 90, 9–19, 2021.
- Jíša D., Liškutín P., Kruml T., Polák J., Small Fatigue Crack Growth in Aluminium Alloy EN-AW 6082/T6, *International Journal of Fatigue*, 32(12), 1913–1920, 2010.

- Kalita B., Abhiraaj R. C., Jayaganthan R., Fatigue Life and Crack Growth Rate Prediction of Additively Manufactured 17-4 PH Stainless Steel Using Machine Learning, *Procedia Structural Integrity*, 56, 105–110, 2024.
- Karolczuk A., Skibicki D., Pejkowski Ł., Gaussian Process for Machine Learning-Based Fatigue Life Prediction Model Under Multiaxial Stress–Strain Conditions, *Materials*, 15(21) 2022.
- Kumar V., Singh I. V., Mishra B. K., Jayaganthan R., Crack Growth Behavior of 6082 Al Alloys Under Mixed Mode-I Loading, In: Kumar A., Kumar Singla Y., Maughan M.R. (Ed.), *Fracture Behavior of Nanocomposites and Reinforced Laminate Structures* (pp. 207–237), Springer Nature Switzerland: Cham 2024.
- Li S., Zhu Q., Lu Z., Yan H., Zhu C., Li P., Fatigue Life Prediction of AA2524 Thin Plate Strengthened using Compound Laser Heating and Laser Shot Peening Method. *Theoretical and Applied Fracture Mechanics*, 129, 104178, 2024.
- Lian Z., Li M., Lu W., Fatigue Life Prediction of Aluminum Alloy Via Knowledge-Based Machine Learning, *International Journal of Fatigue*, 157, 106716, 2022.
- Malek B., Mabru C., Chaussumier M., Fatigue Behavior of 2618-T851 Aluminum Alloy under Uniaxial And Multiaxial Loadings, *International Journal of Fatigue*, 131, 105322, 2020.
- Mann T., Härkegård G., Stärk K., Short Fatigue Crack Growth in Aluminium Alloy 6082-T6, *International Journal of Fatigue*, 29(9–11), 1820–1826, 2007.
- Mirzaei A. H., Haghi P., Shokrieh M. M., Prediction of Fatigue Life of Laminated Composites by Integrating Artificial Neural Network Model and Non-Dominated Sorting Genetic Algorithm, *International Journal of Fatigue*, 188, 108528, 2024.
- Ni C., Xue H., Wang S., Yang F., Zhao K., Effect of Deformation on Crack Extension Measurement for Compact Tension Specimen with the DCPD Technique, *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*, 238(5), 1618–1628, 2024.
- Ojo S. A., Shrestha S., Manigandan K., Morscher G. N., Gyekenyesi A. L., Scott-Emuakpor O. E., Application of Small Geometry Specimens to Determine the Fatigue Crack Growth Anisotropy of Ti–6Al–4V Additively Manufactured for Repair, *Results in Materials*, 15 2022.
- Olguner S., Bozdana A. T., Prediction of Lankford Coefficients for AA1050 and AA5754 Aluminum Sheets Using Uniaxial Tensile Tests and Cup Drawing Experiments, *Lecture Notes in Mechanical Engineering*, 438–446, 2020.
- Pandey A., Jain A., Comparative Analysis of KNN Algorithm using Various Normalization Techniques, *International Journal of Computer Network and Information Security*, 9(11), 36–42, 2017.
- Paris P., Erdogan F., A Critical Analysis of Crack Propagation Laws, *Journal of Basic Engineering*, 85(4), 528–533, 1963.
- Peng Y., Zhang Y., Zhang L., Yao L., Guo X., Prediction of Corrosion Fatigue Crack Growth Rate in Aluminum Alloys Based on Incremental Learning Strategy, *International Journal of Fatigue*, 187, 108481, 2024.
- Pokharel A., Keesler-Evans J., Tempke R., Musho T., A Machine Learning Model for Predicting Progressive Crack Extension Based on Experimental Data Obtained Using DCPD Measurement Technique, *Journal of Materials Research and Technology*, 24, 5687–5701, 2023.
- Sagar S., Singh N. K., Maurya N. S., Compression, Flexure and Wear Behaviours of Aluminium 6082-T6 Alloy, *U.P.B. Scientific Bulletin, Series D: Mechanical Engineering*, 85(3), 193–204, 2023.

- Sarkar A., Aktunali M., Marthe Arbo S., Holmestad J., Mario Viespoli L., Nyhus B., Ringen G., Razavi N., A Study on the Influence Of Impurity Content on Fatigue Endurance In A 6082 Al-Alloy, *International Journal of Fatigue*, 186, 108406, 2024.
- Silva F. S., Pinho A. C. M., The Effect of Temperature on Crack Behavior In An 7175 Aluminum Alloy Under Mode I + Steady Mode III, *European Structural Integrity Society*, 29(C), 247–256, 2002.
- Song M., Liu J., Chen H., Hu Y., Shi Z., Yin H., Xia J., Berto F., Li R., Effects and Optimization of Biomimetic Laser Shock Peening on Residual Fatigue Life Improvement of Aluminum Alloy Used In Aircraft Skin. *Theoretical and Applied Fracture Mechanics*, 117, 103155, 2022.
- Vavouliotis A., Paipetis A., Kostopoulos V., On the Fatigue Life Prediction of CFRP Laminates using The Electrical Resistance Change Method, *Composites Science and Technology*, 71(5), 630–642, 2011.
- Vecchiato L., Campagnolo A., Meneghetti G., Numerical Calibration and Experimental Validation of The Direct Current Potential Drop (DCPD) Method for Fracture Mechanics Fatigue Testing of Single-Edge-Crack Round Bars, *International Journal of Fatigue*, 150(February) 2021.
- Winter L., Hockauf K., Winter S., Lampke T., Equal-Channel Angular Pressing Influencing the Mean Stress Sensitivity In The High Cycle Fatigue Regime of the 6082 Aluminum Alloy, *Materials Science and Engineering: A*, 795, 140014, 2020.
- Yılmaz N. F., Çakır M. V., Yılmaz M., Saplama Kaynak Bağlantılarının Çekme Dayanımının ANFIS ile Modellenmesi, *Çukurova Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 31(ÖS1), 79–88, 2016.