



Makine Öğrenmesi ile Kompozit Malzemelerin Yük Altındaki Yer Değiştirme ve Gerilme Değerlerinin Tahmini

Kajs Feratı^{1*}, Nurettin Gökhan Adar^{2*}

¹Mekatronik Mühendisliği / Mühendislik ve Doğa Bilimleri Fakültesi, Bursa Teknik Üniversitesi, Türkiye, (ORCID: 0000-0001-5223-1976), kaysferati@gmail.com
²Mekatronik Mühendisliği / Mühendislik ve Doğa Bilimleri Fakültesi, Bursa Teknik Üniversitesi, Türkiye, (ORCID: 0000-0001-6888-5755), gokhan.adar@btu.edu.tr

(2nd International Conference on Engineering and Applied Natural Sciences ICEANS 2022, October 15 - 18, 2022)

(DOI: 10.31590/ejosat.1188744)

ATIF/REFERENCE: Feratı, K. & Adar, N. G. (2022). Makine Öğrenmesi ile Kompozit Malzemelerin Yük Altındaki Yer Değiştirme ve Gerilme Değerlerinin Tahmini. *European Journal of Science and Technology*, (42), 66-70.

Öz

Bu çalışmada, makine öğrenmesi modelleri kullanılarak cam elyaf ve epoksi reçine takviyeli lamine kompozit malzemelerin yer değiştirme ve gerilme değerlerinin tahmin edilebilmesi hedeflenmiştir. Çalışma kapsamında, kesiti belirlenen numune farklı laminasyonlar için malzeme özellikleri değiştirilerek modellenmiş ve Ansys yazılımı ile uygulanan çekme kuvveti altında toplam yer değiştirme ve Von Misses gerilmeleri ile veri seti oluşturulmuştur. Oluşturulan veri seti ile makine öğrenmesi modelleri olan Sağlam regresyon ve Gauss işlemci regresyonu modelleri kullanılarak toplam yer değiştirme ve Von Misses gerilmelerinin tahmin edilmesi sağlanmıştır. Sonuç olarak, Ansys yazılımı ile elde edilen ve eğitim ve test amacıyla kullanılan veri seti değerleri ile her iki modelden elde edilen aynı değerlerin kıyaslaması yapılmıştır. Ayrıca, iki modele ait modellerin çalışma parametreleri göz önünde bulundurularak doğruluk oranı açısından değerlendirmesi gerçekleştirilmiştir. Sonuçlara göre, Gauss işlemci regresyon modelinin ilgili çalışma açısında daha uygun olduğu belirlenmiştir.

Anahtar Kelimeler: Kompozit Malzeme, Makine Öğrenmesi, Mekanik Özellik.

Prediction of Displacement and Stress Values of Composite Materials Under Load with Machine Learning Models

Abstract

In this study, the determination of displacement and stress values under certain load of glass fiber and epoxy resin laminated reinforced composite materials by using machine learning models is targeted. In the scope of study, the modelling is done by changing the material properties of varied laminations of composite samples via Ansys software and a tensile force is implemented in order to receive the total deformation and Von Misses stresses under the implemented tensile force and creation of the dataset is completed. The robust linear regression and Gaussian process regression models from machine learning algorithms are used to predict and determine the total deformation and Von Misses stresses by training and testing the models with the dataset created. As result, the predicted values obtained from trained and tested regression models and the real values obtained by modelling in Ansys are compared. Additionally, in consideration of model parameters for both regression models, the evaluation of true responses and correct prediction/determination is done. According to the results, Gaussian process regression model is determined as a better model for related study.

Keywords: Composite Material, Machine Learning, Mechanical Properties

1. Giriş

Kompozit malzemeler taşıdığı karakteristik özellikleri sebebiyle diğer malzemelere göre pek çok avantajı bulunmaktadır. Takviye ve matris malzemelerin özelliklerinin birleşimi bu malzemeleri mekanik özellikler bakımından kullanımını çok avantajlı hale getirmektedir. Ancak mekanik özellikleri net olarak bilinmemektedir. Malzeme seçiminde değişik şartlar altında (yük, darbe vs.) nasıl davranışlar göstereceğini bilmek çok büyük bir öneme sahiptir. Bu sebeple, kompozit malzemeler üretildikten sonra istenilen mekanik özellikleri taşıdığını doğrulamak amacıyla farklı yöntemler kullanılarak özelliklerin belirlenmesi gerekmektedir.

Tespit edilmesi istenen özelliğe bağlı olarak testler veya sonlu elemanlar analizi yapılması kompozit malzemelerin özelliklerini tespit etmekte kullanılan yöntemlerdir. Ancak her iki yöntem de zaman ve maliyet bakımından her zaman avantajlı değildir.

Makine öğrenmesi, kompozit malzemelerin özelliklerini tespit etmekte son birkaç yıl içerisinde kullanılmaya başlanmış farklı bir uygulamadır. Son yıllarda literatürde mekanik özelliklerin tahmini için pek çok çalışma yapıldığı görülmektedir.

Kondo, R. Ve arkadaşları bir çalışmada (2017), seramik bazlı kompozit malzemelerin mikro yapısını ele alarak, iyonik iletkenlik özelliklerinin tespiti için bir yapay sinir ağı modeli çalışması gerçekleştirmişler [1].

Fatih Buyrul ve arkadaşları (2022) bir çalışmada, aramid takviyeli malzemelerin mekanik özelliklerini deneyler sonu tespit ederek bir yapay sinir ağı geliştirmiş ve deney sonucu elde edilen değerlerin tahmini için eğitmişlerdir [2].

Nateghi A. ve M. H. Ahmad (2019) tarafından yapılan bir çalışmada da inşaat sektöründe kullanılan beton bazlı kompozit malzemelerdeki karışma oranının mekanik özellikler üzerindeki etkisine dikkat çekilmiş ve yapıların güçlendirilmesi amacıyla kullanılan beton bazlı kompozit malzemelerde 36 farklı karışım oranına göre test yapılmıştır. Bu testlerde elde edilen veriler ile farklı karışım oranlarına göre gerilme kuvvetini ve gerilme dayanımını tahmin eden bir yapay sinir ağı modeli tasarlanmıştır [3].

Pathan, M. ve arkadaşları bir çalışmada (2017), kompozit lamine tabakaların viskoelastik özellikleri ve frekans ve sıcaklığa karşı duyarlılıklarının tahmini için bir model çalışması gerçekleştirmişler [4].

Z. Kaya ve arkadaşları (2020) yaptıkları bir çalışmada, cam elyaf/epoksi takviyeli kompozit malzemelerdeki kırılma davranışlarını bir makine öğrenmesi modeli analiz etmişlerdir [5].

Bu çalışmadaki amaç, üretilmesi planlanan kompozit malzemelerin mekanik özelliklerini tahmin edebilen bir makine öğrenmesi modeli oluşturmak ve maliyet ile zaman bakımından dezavantajlı olan yöntemleri kullanmadan ya da ilgili yöntemlerin kullanılmasından önce çalışma yapılması planlanan kompozit malzemelerin özelliklerini öngörebilmektir. Makine öğrenmesi modelinde elyaf ve reçinenin temel özellikleri olan yoğunluk, elastisite modülü, kayma modülü, poisson oranı, kalınlık, çekme mukavemeti, basma mukavemeti ve kayma mukavemeti girdi verisi olarak, yük altında numunede oluşan toplam yer değiştirme ve Von Misses gerilmesi de çıktı olarak kullanılmıştır.

2. Materyal Ve Yöntem

Yapılan çalışma kapsamında, cam elyaf takviye malzemesi ve epoksi reçine matris malzemesinin birleşimiyle oluşturulabilen farklı laminasyon yapılarındaki kompozit malzemelerin üretilmeden önce belirli mekanik özelliklerinin makine öğrenmesi modeli ile öngörülmesi amaçlanmıştır.

Öncelikli olarak makine öğrenmesi modelinde kullanılmak üzere bir veri seti oluşturulmuştur. Veri seti için her laminasyon yapısının belli bir yük altında gösterdiği mekanik özelliklerin saptanabilmesi ve belirlenebilmesi amacıyla Ansys yazılımı kullanılarak belirlenen kesite yük uygulaması yapılmış ve bu yük altında her laminasyonun gösterdiği tepki kaydedilmiştir. Daha sonrasında belirlenen özellikler liste olarak hazırlanmış ve girdi ve çıktı olarak modelde kullanılması planlanan özellikler belirlenmiştir. Elde edilen veri seti ile 2 farklı makine öğrenmesi modeli geliştirilmiş ve modellerin verdiği sonuçlara istinaden hangi yöntemin ve modelin daha doğru tahmin yaptığı kıyaslanmıştır.

2.1. Veri Setinin Oluşturulması

Veri setinin oluşturulması kapsamında öncelikle kullanılması planlanan 5 tip cam elyaf belirlenmiş ve ilgili cam elyaf tiplerinin mekanik özellikleri Ansys yazılımında malzeme olarak tanımlanmıştır. Aynı şekilde takviye malzemesi olarak kullanılması amaçlanan epoksi reçine özellikleri de malzeme tanımı olarak gerçekleştirilmiştir.

Tablo 1’de, çalışma kapsamında kullanılan 5 tip cam elyaf ve epoksi reçine malzeme özellikleri gösterilmiştir.

Veri setinin oluşturulması amacıyla Ansys ACP modülü kullanılmıştır.

Tablo 1. Cam elyaf ve epoksi reçine malzeme özellikleri

Parametre	Cam elyaf Tip 1	Cam elyaf Tip 2	Cam elyaf Tip 3	Cam elyaf Tip 4	Cam elyaf Tip 5	Epoksi reçine
Yoğunluk (kg/m ³)	1350	450	300	300	800	1450
Elastisite modülü (Mpa)	23990	10110	9900	15660	13340	5330
Kayma modülü (Mpa)	9680	4150	3900	6230	5300	1910
Poisson oranı	0,24	0,22	0,37	0,26	0,35	0,4
Kalınlık (mm)	1,2	1	0,7	0,4	1,4	0,1
Çekme muk. (Mpa)	254,38	76,58	74,37	188,9	142,13	30,62
Basma muk. (Mpa)	211,27	141,19	320,25	431,87	296,76	139,42
Kayma muk. (Mpa)	123,7	77,73	42,96	112,49	84,76	16,44

Laminasyon tanımı yapıldıktan sonra modele yük tanımlanması yapılmıştır. Geometri bir kenardan sabit varsayılmış, x yönünden de çekme kuvveti maruz bırakılmıştır.

Belirtildiği şekilde yük uygulandıktan sonra sonlu elemanlar analizi çözdürülmüş ve çekme yüküne karşılık malzemenin bu yük altındaki toplam yer değiştirmesi ve Von Misses gerilmesi tespit edilmiştir.

Bu şekilde farklı kombinasyonlardaki kompozit malzeme laminasyonları modellenerek çekme kuvveti etkisi altında gösterdikleri toplam yer değiştirme ve Von Misses gerilmesi kaydedilerek eğitim ve test amacıyla veri seti oluşturulmuştur.

Eğitim amacıyla oluşturulan veri setinde 33 farklı laminasyon tipi mevcuttur. Test amacıyla kullanılacak olan veri setinde 11 farklı laminasyon kullanılmıştır.

2.2. Makine öğrenmesi modellerinin oluşturulması

Regresyon, bir bağımlı değişken ile diğer bağımsız değişkenler arasındaki ilişkinin gücünü belirlemeye çalışan, bu güce göre tahminler ortaya koyan istatistiksel bir ölçümdür ve makine öğrenmesi algoritmaları arasında önemli bir algoritmadır. Bu nedenle, bu çalışma kapsamında oluşturulan veri seti 2 farklı regresyon modeli çalıştırılarak, regresyon modelleri arasında ilgili veri setine en uygun olan modelin tespiti için kıyaslama yapılmıştır.

3. Bulgular ve Tartışma

Bu çalışmada 2 farklı regresyon algoritması kullanılarak sonlu elemanlar analizi ile elde edilen toplam yer değiştirme ve Von Misses gerilmesinin tahmi edilmesi amaçlanmıştır.

Çalışmada kullanılan 2 regresyon algoritması, sağlam lineer regresyon ve Gauss işlemci regresyonu modelleridir.

Belirtilen modeller Matlab yazılımı Regression App modülü kullanılarak oluşturulmuştur. Regression App modülü ile modeller çalıştırıldıktan sonra sonuçların değerlendirilmesi ve modeller arasında kıyaslama yapılabilmesi için doğrulama RMSE, test RMSE ve doğrulama R-Square, model parametreleri ile yanıt grafiği, eğitim verisi artık değer grafiği ve test verisi artık değer grafiği elde edilmiştir.

RMSE (Kök Ortalama Kare Hata), bir makine öğrenmesi modelinin, tahminleyicinin tahmin ettiği değerler ile gerçek değerleri arasındaki uzaklığın bulunmasında sıklıkla kullanılan, hatanın büyüklüğünü ölçen kuadratik bir metriktir. İyi eğitilmiş bir modelde bu değer mümkün olduğunca düşük olması beklenir.

R-Square, determinasyon katsayısıdır. R-square her zaman 1'den küçüktür ve genellikle 0'dan büyüktür. Eğitilmiş modeli yanıtın sabit olduğu modelle karşılaştırır ve eğitim yanıtının ortalamasına eşittir. Model bu sabit modelden daha kötüyse, R-square negatiftir. İyi eğitilmiş bir modelde bu değer mümkün olduğunca 1'e yakın olması beklenir.


Yanıt grafiği, veri setinde yer alan gerçek çıktılar ile modelin tahmin ettiği çıktı değerlerinin gösterildiği grafiklerdir.

Artık değer grafiği, tahmin edilen ve gerçek yanıtlar arasındaki farkı göstermektedir.


3.1. Sağlam lineer regresyon modeli

Bu modelin diğer regresyon modellerine göre farkı ve avantajı, aykırı değerlere karşı algoritmanın daha az duyarlı olması ve lineer yapısını koruma amacıyla küçük ağırlık değerlerine sahip olmasıdır.

Sağlam lineer regresyon modelinde yer değiştirme verisine karşılık doğrulama RMSE 19.542, doğrulama RMSE 11.624 ve doğrulama R-square 0,56 olarak elde edilmiştir. Bu model ile elde edilen yanıt grafiği Şekil.1 ve test verisi artık değer grafiği Şekil.2'de verilmiştir.

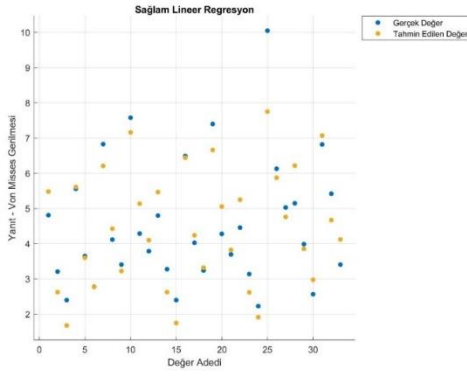


Şekil 1. Sağlam Lineer Regresyon – Eğitim Veri Seti – Toplam yer değiştirme – Yanıt Grafiği

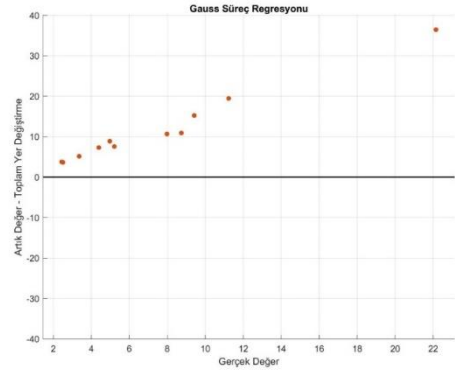


Şekil 2. Sağlam Lineer Regresyon – Test Veri Seti – Toplam yer değiştirme – Test Verisi Artık Değer Doğrulama Grafiği

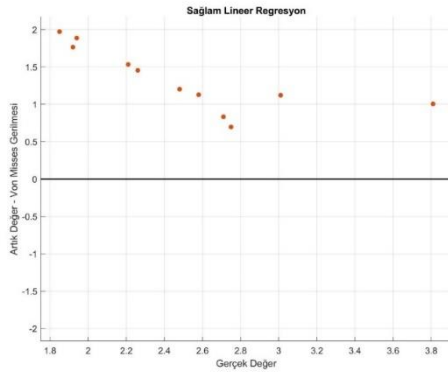
Sağlam Lineer Regresyon modelinde gerilme verisine karşılık doğrulama RMSE 0,74, doğrulama RMSE 1.38 ve doğrulama R-square 0,84 olarak elde edilmiştir. Bu model ile elde edilen yanıt grafiği Şekil.3 ve test verisi artık değer grafiği Şekil.4'te verilmiştir.



Şekil 3. Sağlam Lineer Regresyon – Eğitim Veri Seti – Von Misses Gerilmesi – Yanıt Grafiği

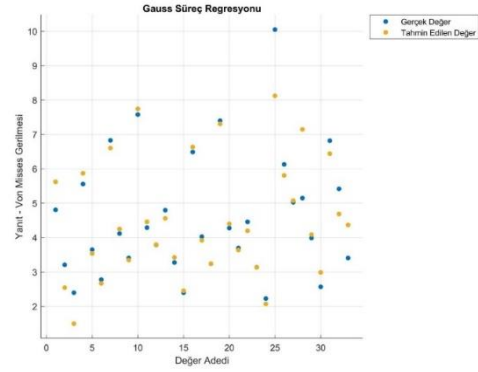


Şekil 6. Gauss İşlemci Regresyonu – Test Veri Seti – Toplam yer değiştirme – Test Verisi Artık Değer Doğrulama Grafiği



Şekil 4. Sağlam Lineer Regresyon – Test Veri Seti – Von Misses Gerilmesi – Test Verisi Artık Değer Doğrulama Grafiği

Gauss işlemci regresyon modelinde gerilme verisine karşılık doğrulama RMSE 0.362, doğrulama RMSE 1.40 ve doğrulama R-square 0,96 olarak elde edilmiştir. Bu model ile elde edilen yanıt grafiği Şekil.7 test verisi artık değer grafiği Şekil.8’de verilmiştir.

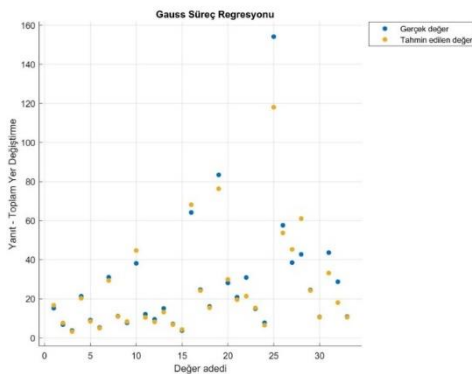


Şekil 7. Gauss İşlemci Regresyonu – Eğitim Veri Seti – Von Misses Gerilmesi – Yanıt Grafiği

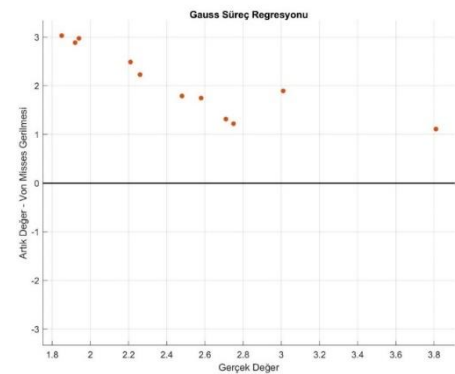
3.2. Gauss işlemci regresyon modeli

Gauss işlemci regresyon modeli yapı itibariyle bir fonksiyon uzayı üzerinde olasılık dağılımı kullanan, yorumlaması nispeten zor ancak doğruluk oranı yüksek bir modeldir. Bu modelin diğer regresyon modellerine göre farkı ve avantajı olasılık dağılımı sayesinde doğruluk oranının nispeten yüksek olmasıdır.

Gauss işlemci regresyon modelinde yer değiştirme verisine karşılık doğrulama RMSE 10.565, doğrulama RMSE: 15.821 ve doğrulama R-square 0,87 olarak elde edilmiştir. Bu model ile elde edilen yanıt grafiği Şeki.5 ve test verisi artık değer grafiği Şekil.6’da verilmiştir.



Şekil 5. Gauss İşlemci Regresyonu – Eğitim Veri Seti – Toplam yer değiştirme – Yanıt Grafiği



Şekil 8. Gauss İşlemci Regresyonu – Test Veri Seti – Von Misses – Test Verisi Artık Değer Doğrulama Grafiği

3.3. Model kıyaslaması

Sonuçlara istinaden, aşağıdaki tabloda her iki model olan sağlam lineer regresyon modeli ve Gauss işlemci regresyonu modeline ait parametrelerin yer aldığı bilgiler Tablo 2’de yer almaktadır.

Tablo 2. Test veri seti laminasyon ve sonuçları

Model	Sağlam lineer regresyon		Gauss işlemci regresyonu	
	Toplam yer değiştirme	Von Misses gerilmesi	Toplam yer değiştirme	Von Misses gerilmesi
Doğrulama RMSE	19.542	0.74	10.565	0.362
Test RMSE	11.624	1.38	15.821	1.4
Doğrulama R-square	0.56	0.84	0.87	0.96

Test veri setindeki laminasyon yapıları için iki modelin de tahmin değerleri Tablo 3'te yer almaktadır.

Tablo 3. Test veri seti tahmin değerleri

Sağlam lineer regresyon		Gauss işlemci regresyonu		Gerçek çıktı değeri	
Yer değ. (mm)	Gerlime (Mpa)	Yer değ. (mm)	Gerlime (Mpa)	Yer değ. (mm)	Gerlime (Mpa)
35.40	6.21	29.17	6.60	31.02	6.83
15.58	4.42	10.91	4.25	11.13	4.12
6.74	3.22	8.34	3.35	7.76	3.41
42.15	7.16	49.35	7.74	38.18	7.58
11.28	4.10	9.07	3.79	9.54	3.79
15.78	3.32	15.46	3.24	16.05	3.24
23.46	3.82	20.46	3.64	20.86	3.70
15.39	2.61	15.36	3.13	14.95	3.14
6.06	1.92	6.47	2.07	7.73	2.23
43.41	6.22	67.88	7.14	42.77	5.15
26.14	3.38	25.81	4.08	24.54	3.99

4. Sonuçlar

Çalışma kapsamında öncelikle Ansys yazılımı kullanılarak çekme kuvveti etkisi altında farklı laminasyon yapılarındaki kompozit malzemelerin yer değiştirme ve Von Misses gerilme değerleri ile 33 farklı laminasyondan oluşan eğitim veri seti ve 11 laminasyondan oluşan test veri seti oluşturulmuş ve veri setleri regresyon algoritmalarından oluşan sağlam lineer regresyon ve Gauss işlemci regresyonu modellerini eğitmek ve test etmek üzere oluşturulmuştur.

Her iki model de belirli bir doğruluk oranında yük altındaki kompozit malzemelerin yer değiştirme ve gerilme değerlerini tahmin eden sonuçları grafikleri ile beraber çıktı olarak vermiştir. Ancak Gauss işlemci regresyonu modeli ile sağlam lineer regresyon modeline nispeten daha doğru sonuçlar elde edilmiştir.

Regresyon modellerinden R-square değeri 1'e yakın olan model 0.86 ile Gauss işlemci regresyonu modelidir. Aynı zamanda Tablo 3'te belirtilen değerler de incelendiğinde sonlu elemanlar analizi ile elde edilen sonuçlara daha yakın değerler elde edildiği görülmektedir.

Aynı zamanda, her iki model de Von Misses gerilme değerlerini tahmin etme sürecinde daha doğru değerler vermiştir. Bunun sebebi, toplam yer değiştirme veri setinde Von Misses gerilme veri setine nispetle daha fazla aykırı değerler bulunmaktadır. Bu sebeple, her iki model de aykırı değerler sebebiyle daha yanlış tahmin etme eğilimindedirler.

Elde edilen sonuçlara göre, daha başarılı sonuç veren model Gauss işlemci regresyonu modelidir. Buna ek olarak, veri setinde yer alan aykırı değerler elimine edilip daha yakın değerlere sahip bir veri seti oluşturulur ise, aynı yöntem daha da doğru sonuçlar verecektir.

Yapılan çalışma ile, ilk defa üretimi planlanan kompozit malzemelerin yük altında gösterdiği yer değiştirme ve gerilme değerleri herhangi bir test ya da analiz gerçekleştirilmeden tahmin edilebilmektedir. Bu sayede, ilk defa üretilecek olan kompozit malzemelerin özellikleri üretim, test ve analiz öncesi bilinebilmektedir. Elde edilen bu tahminler ile üretim, test ve analiz işlemlerine başlandıktan sonra başarısız ya da beklentileri karşılamayacak olan bir kompozit malzeme çalışması önlenmektedir. Bu sayede, üretim, test ve analiz maliyet ve iş yükü önlenmektedir. Ayrıca, yeni kompozit malzeme keşfi için referans alınabilecek bir veri elde edilebilecek ve çalışması planlanan yeni kompozit malzeme özellikleri için ışık tutabilecektir.

Kaynaklar

- [1] Kondo, R., Yamakawa, S., Masuoka, Y., Tajima, S. & Asahi, R. (2017), Microstructure recognition using convolutional neural networks for prediction of ionic conductivity in ceramics, *Acta Materialia* 141, 29–38, <https://doi.org/10.1016/j.actamat.2017.09.004>, Nagakute
- [2] F. Buyrul, V. Ateş, A. Tunçel, A.H.M. Ariff, R. Çalın (2022), Predictions and Statistical Analysis of Mechanical Experiment Results of Aramid Fiber Reinforced Polymer Matrix Composites with Artificial Neural Networks, *Dergipark, Bursa*
- [3] Nateghi-A, F., Ahmadi, M.H. and Dehghani, A (2019)., Experimental study on improved engineered cementitious composite using local material, *Materials Sciences and Applications*, Vol. 9, No. 03, 315-329, Tehran
- [4] Ozkaya, U., Melgani, F., Bejiga, M. B., Seyfi, L., & Donelli, M. (2020). GPR B scan image analysis with deep learning methods. *Measurement*, 165, 107770.
- [5] Z. Kaya, H. Ersen Balçoğlu, H. Gün, A.Ç. Seçkin (2020), Machine learning approach to determine fracture behaviour in laminated composite, *Researchgate, Uşak*
- [6] Ö. Eyecioğlu (2021), Bazalt/PANI Kompozitlerinin Dielektrik Özelliklerinin Tahmini için Makine Öğrenmesi Modellerinin Karşılaştırılması, *Dergipark, Bursa*
- [7] <https://azure.microsoft.com/tr-tr/overview/machine-learning-algorithms/#overview>
- [8] W. Xie, W. Zhang, (2016), Experimental investigation of normal and oblique impacts on CFRPs by high velocity steel sphere, *Composites Part B* 99 483–493, Harbin