



Serkan Islak, Mehmet Akkaş, Ünal Kaya, Hacı Güzel Güleç
Kastamonu University, Kastamonu-Turkey
serkan@kastamonu.edu.tr; mehmetakkas@kastamonu.edu.tr;
ukaya@kastamonu.edu.tr; hgulec@kastamonu.edu.tr

<http://dx.doi.org/10.12739/NWSA.2017.12.3.2A0119>

Cu-TiC KOMPOZİTLERİN MEKANİK VE FİZİKSEL ÖZELLİKLERİNİN YAPAY SİNİR AĞLARI (YSA) MODELİ İLE TAHMİNİ

ÖZ

Bu çalışma, sıcak presleme tekniği ile üretilen Cu-TiC kompozitlerin mekanik ve fiziksel özelliklerinin yapay sinir ağları (YSA) modeli ile tahmin etmeyi amaçlamaktadır. Giriş parametresi olarak, bakır matrise ilave edilen titanyum karbürün miktarı seçilirken, çıkış değerleri olarak bağıl yoğunluk, sertlik, elektriksel iletkenlik, çapraz kırılma dayanımı, sürtünme katsayısı ve aşınma oranı değerleri seçilmiştir. Eğitim veri girişlerinde TiC miktarı ağı. %0, 1, 3, 5, 10 ve 15 olarak çalışılmıştır. Bu değerler eğitildikten sonra ağı. %2, 4, 6, 8, 12 ve 14 TiC katkılı bakır kompozitlerin çıkış değerleri tahmin edilmiştir. Tüm tahminlerde regresyon değerlerinin 1'e çok yakın olduğu görülmektedir. Bu sonuç YSA model çıkışının gerçek verilere çok yakın değerler olduğunu göstermektedir.

Anahtar Kelimeler: YSA, Cu-TiC Kompozitler, Sıcak Presleme, Mekanik Özellikler, Fiziksel Özellikler

ESTIMATION OF MECHANICAL AND PHYSICAL PROPERTIES OF Cu-TiC COMPOSITES BY ARTIFICIAL NEURAL NETWORKS (ANN) MODEL

ABSTRACT

This study aims to estimate the mechanical and physical properties of Cu-TiC composites produced by hot pressing technique using artificial neural networks (ANN) model. The values of relative density, hardness, electrical conductivity, transverse rupture strength, and friction coefficient and wear rate were selected as the output values while the amount of titanium carbide added to copper matrix was selected as the input parameter. The amount of TiC in training data entries is 0, 1, 3, 5, 10 and 15 wt. %. After these values were trained, the output values of copper composites with 2, 4, 6, 8, 12 and 14 wt. % TiC contents were estimated. All estimates show that the regression values are very close to 1. This shows that the ANN model output is very close to the actual data.

Keywords: ANN, Cu-TiC Composites, Mechanical Properties, Physical Properties, Hot Pressing

How to Cite:

Islak, S., Akkaş, M., Kaya, Ü. ve Güzel Güleç, H., (2017). Cu-TiC Kompozitlerin Mekanik ve Fiziksel Özelliklerinin Yapay Sinir Ağları (YSA) Modeli İle Tahmini, **Technological Applied Sciences (NWSATAS)**, 12(3):122-129,
DOI: 10.12739/NWSA.2017.12.3.2A0119.



1. GİRİŞ (INTRODUCTION)

Son yıllarda, bakır matrisine oksitler, karbürler ve borür parçacıkların eklenmesi ile bakır matrisli kompozitler üretilmektedir. Bakır kompozitlerin üretilmesinin amacı, bakırın mükemmel termal ve elektrik iletkenliği, muhteşem korozyon ve oksidasyon direncine sahip olmasına karşın, zayıf aşınma direncine sahip olmasındandır [1 ve 2]. Bakır kompozitler, hem mükemmel termal ve elektriksel özelliklerinden hem de mükemmel mekanik özelliklerinden dolayı mühendislik uygulamalarının vazgeçilmez malzemeleridir. Bu kompozitler, matrisin elektrik iletkenliğini kaybetmeden iyi aşınma direncinin istendiği uygulamalar için düşünülür [3 ve 4]. Bakır kompozitlerde, kompozitin aşınma özellikleri açısından matris ile partiküller arasındaki bağın kalitesi önemlidir. Matris ve takviye parçacıkları arasında iyi bir bağ olmazsa, kompozitin aşınma oranı artar. Matris takviyesi, takviye parçacıkları içindeki zayıf bağlanma, aşınma sırasında üç cismin aşınmasına neden olur [5]. Literatür araştırıldığında bakır esaslı kompozitlerdeki takviye parçacıkları olarak genellikle Al_2O_3 , SiC, TiB_2 ve WC parçacıkları kullanılmıştır. Zhu ve diğ. [6] basınçlı infiltrasyon yöntemi ile üretilen Cu/SiC_p aşınma özelliklerini araştırmışlardır. Çalışmada bakıra yüksek miktarda (%61 vol.) SiC eklenmiştir. Sonuçlar, uygulanan yük arttıkça, kayma hızı ve kayma mesafesi ile hacimsel kayıpların arttığını göstermiştir. Buna ek olarak, takviye parçacıklarının tane boyutu arttıkça aşınma oranı da artmıştır. Fathy ve diğ. [7] ağırlıkça %2,5, 7.5 ve 12.5 Al_2O_3 takviyeli bakır matrisli kompozitlerinin aşınma davranışlarını araştırmışlardır. Al_2O_3 ilavesi arttıkça, kompozitin aşınma oranını ve elektrik iletkenliği azaltmıştır.

Metal matrisli kompozitlerde optimum değerleri yakalamak oldukça zordur. Bu zorluklar bilim insanlarını, optimum kompozit özelliklerini tahmin etmek için farklı yöntemler geliştirmeye yönlendirmiştir. Çoklu regresyon analizi, matematiksel modelleme ve bulanık küme teknikleri, genetik algoritmalar ve yapay sinir ağları bu amaçla kullanılan yöntemlerdir. Bu yöntemler içinde YSA, geleneksel yöntemlerle karşılaştırıldığında hızı, basitliği, örneklerden öğrenmedeki başarısı ve çok fazla deneysel veriye ihtiyaç duyulmaması nedeniyle öne çıkmaktadır. İnsanlığın doğayı araştırma ve taklit etme çabalarının en son ürünlerinden biri olan YSA'lar, insan beynindeki hücrelerin çalışma prensibini modelleyen bir teknik olarak kullanılmaktadır [8].

YSA'ları basit biyolojik sinir sisteminin çalışma şeklini simülasyonu yapılarak modelleme, tahmin, denetim ve buna benzer birçok amaç için kullanılan bir algoritmadır. Simülasyonu yapılan sinir hücreleri nöronlar içerirler ve bu nöronlar çeşitli şekillerde birbirlerine bağlanarak ağı oluştururlar. Bu ağlar öğrenme, hafızaya alma ve veriler arasındaki ilişkiyi ortaya çıkarma kapasitesine sahiptirler [9]. YSA'ların ilgi çekici ve yararlı birçok özellikleri vardır. Bunlardan en önemli olanı ise öğrenme yeteneğidir. Öğrenme kabiliyetlerinin olması ve farklı öğrenme algoritmaları kullanabilmesi YSA'ların üstün özellikleri olarak kabul edilmektedir. Bunun yanı sıra en sık belirtilen sakıncaları ise sistemin çalışmasının analiz edilememesi ve öğrenme işleminde başarısız olma riskidir. Literatürde 100'den fazla YSA modeli vardır. Bazı bilim adamları, beynimizin güçlü düşünme, hatırlama ve problem çözme yeteneklerini bilgisayara aktarmaya çalışmışlardır. Bazı araştırmacılar ise, beynin fonksiyonlarını kısmen yerine getiren birçok modelleri oluşturmaya çalışmışlardır [10]. YSA'lar eksik, belirsiz, karmaşık ve bulanık bilgileri işlemekteki başarıları nedeniyle, birçok endüstriyel probleme uygulanabilmektedir. Yapılardaki paralellikten dolayı çok hızlı çalışabilmeleri, onların özellikle gerçek zamanlı olaylarda



çalışmalarını sağlamaktadır [11]. Sinir hücreleri bir grup halinde işlem gördüklerinde ağ (network) olarak adlandırılırlar ve böyle bir grupta binlerce nöron bulunur. Yapay nöronların birbirleriyle bağlantılar aracılığıyla bir araya gelmeleri YSA' yı oluşturmaktadır. YSA ile aslında biyolojik sinir ağının bir modelini oluşturmak istenmektedir [12].

Literatürde metal matrisli kompozitlerin özelliklerinin YSA modeliyle tahmin edilmesi üzerine çalışmalar mevcuttur. Taşkın ve diğ. [13] Al/SiC_p kompozit malzemelerin difüzyon kaynağı ile birleştirilebilirliğini YSA modeli ile tahmin etmişlerdir. Elde edilen sonuçlar, gerçek verilerle tahmin edilen verilerin birbirine çok yakın olduğunu göstermiştir. Yine Taşkın ve diğ. [14] AlSiMg/SiC_p kompozitlerin adhesiv aşınma davranışını YSA ile tahmin etmişler ve bu çalışmada SiC miktarı, aşınma yükü ve aşınma mesafesini giriş verisi, aşınma kayıplarını ise çıkış verisi olarak seçmişlerdir. Test ve tahmin sonuçlarının birbirine yakın değerler olması, YSA modeli ile zaman ve malzeme kaybı olmadan sonuçların elde edilebileceğini göstermiştir. Durmuş ve diğ. [15], AA 6351 alaşımının aşınma kayıpları ve yüzey pürüzlülüğü üzerine yaşlandırma sıcaklıklarının etkisini YSA ile modellemişlerdir. Aşınma kayıplarında %1.73 hata payıyla tahmin yapılırken, yüzey pürüzlülüğünde ise %2.11 hata payıyla tahmin yapılmıştır. Çanakçı ve diğ. [16], AA2014/B₄C_p metal matrisli kompozitlerin aşınma davranışları üzerine B₄C katkısının ve tane boyutunun etkisini YSA ile modellemişlerdir. Yine aynı yazarlar farklı bir çalışmada [17], AlCuMg-B₄C kompozitinin mekanik özelliklerine, ısıl işlem, takviye miktarı ve takviye boyutunun etkisi modellenmiştir. Her iki çalışmada da gerçekçi sonuçlara ulaşılmıştır. Bakır matrisli kompozitlerin YSA modellenmesiyle ilgili çalışma sınırlıdır. Prakash ve diğ. [18], Cu-cNT kompozitlerin aşınma kayıplarını YSA ile optimize etmişlerdir. Gerçek ve tahmin değerleri arasında %99.5'lik bir R değeri elde edilmiş olup; bu, tahminin başarılı olduğunu göstermektedir. Yapılan birçok çalışmada Cu-TiC kompozitlerin YSA ile modellenmesi üzerine herhangi bir çalışma mevcut değildir.

2. ÇALIŞMANIN ÖNEMİ (RESEARCH SIGNIFICANCE)

Bu çalışmada, toz metalurjisi yöntemlerinden sıcak presleme tekniği ile üretilen Cu-TiC kompozitlerinin mekanik ve fiziksel özelliklerinin değişimi yapay sinir ağları ile tahmin edilmiştir. Ağırlıkça %2, 4, 6, 8, 12, 14 oranlarında TiC ilave edilen Cu-TiC kompozitlerin bağlı yoğunluk, sertlik, elektrik iletkenliği, çapraz kırılma dayanımı, sürtünme katsayısı ve aşınma oranlarında değişimleri deneysel olarak araştırılmıştır.

3. DENEYSEL ÇALIŞMA (EXPERIMENTAL STUDY)

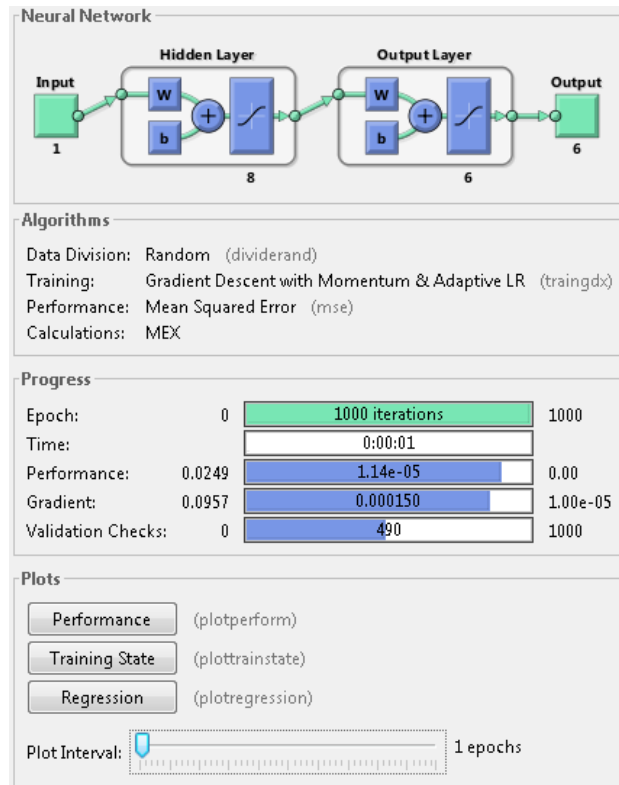
Bu çalışmada TiC içeriğine göre bağlı yoğunluk, sertlik, elektrik iletkenliği, çapraz kırılma dayanımı, sürtünme katsayısı ve aşınma oranlarındaki değişimler görülmek istenmiştir. Toz metalurjisi yöntemlerinden sıcak presleme tekniği ile üretilen 0, 1, 3, 5, 10 ve 15 TiC katkılı Cu-TiC kompozitlerin yukarıda bahsedilen özellikleri deneysel olarak incelenmiştir. Buna göre TiC içeriği YSA modelinin eğitim giriş verisi diğerleri ise eğitim çıkış verileri olarak eğitim süreci tamamlanmıştır. Eğitim giriş ve eğitim çıkış verileri Tablo 1'de görülmektedir.

Tablo 1. Yapay sinir ağlarının eğitim verileri
(Table 1. Training data of artificial neural networks)

Giriş	Çıkış					
TiC İçeriği (%ağ)	Bağıl Yoğunluk (%)	Sertlik (HV _{0,1})	Elektrik İletkenliği (% IACS)	Çapraz Kırılma Dayanımı (TRS) (MPa)	Sürtünme Katsayısı (COF)	Aşınma Oranı (mm ³ /N/m)
0	98.6	47.5	88.7	307	0.745	0.00959
1	98.1	58.6	81.3	289	0.678	0.00457
3	96	62.2	78.4	235	0.621	0.00412
5	93.3	76.3	72.2	195	0.41	0.00308
10	84.3	83.4	64.9	188	0.631	0.00458
15	78.8	87.8	58.2	168	0.346	0.00141


4. BULGULAR VE TARTIŞMALAR (FINDINGS AND DISCUSSION)

Yapılan eğitimde durma kriteri olarak "1000" iterasyon, "0" hata 1e-5 gradient değeri ve "1000" doğrulama (validation) hata sayısı kullanılmıştır. Eğitimi 4 s sürede 1000 iterasyona ulaşılarak durmuştur. Dividerand fonksiyonu ise eğitim verilerini randomize şekilde %70, %15 ve %15 olarak kendi içinde eğitim doğrulama ve test olarak ayırmıştır. Performans fonksiyonu olarak ortalama karesel hata "mse" kullanılmıştır. Kullanılan Matlab YSA arayüzü ve eğitim verileri toplu olarak Şekil 1'de gösterilmiştir.




Şekil 1. Kullanılan Matlab YSA arayüzü ve eğitim verileri
(Figure 1. Used Matlab YSA interface and training data)

Eğitim, doğrulama ve test verilerine ait eğitim aşamasındaki performans fonksiyonunun değişimleri Şekil 2'de görülmektedir. Şekil 3'te ise, gradyent değeri, doğrulama hatası ve öğrenme oranı değişimleri verilmiştir. Doğrulama hatasının yüksek seçilmesi modelde ezberlemeye yol açmasına neden olmaktadır.

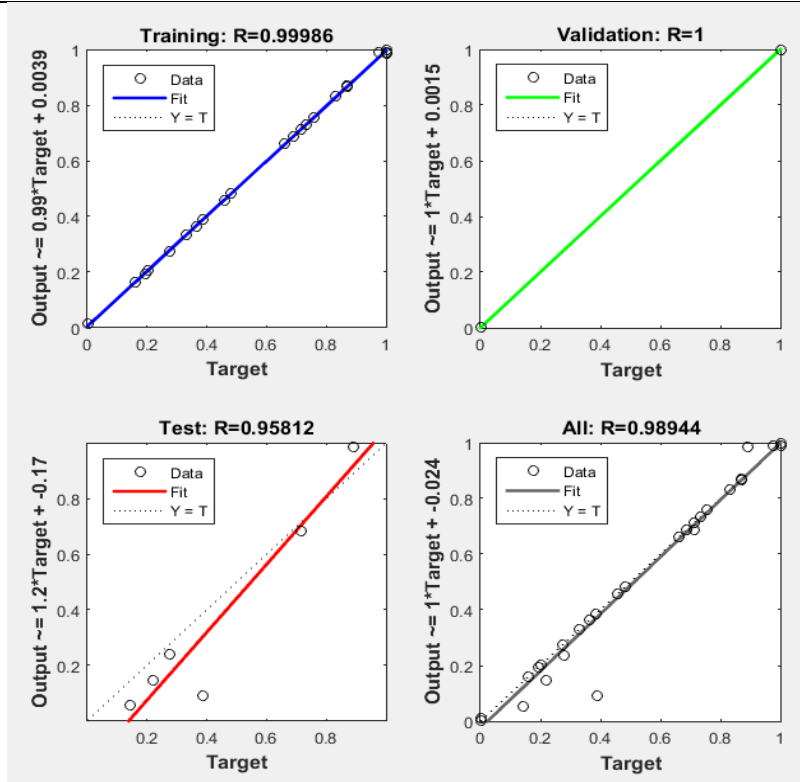


Şekil 2. Eğitim, doğrulama ve test verilerine ait eğitim aşamasındaki performans fonksiyonunun değişimleri
(Figure 2. Changes of training stage in the performance function of training, validation, and test data)



Şekil 3. Gradyent değeri, doğrulama hatası ve öğrenme oranı değişimleri
(Figure 3. Gradient value, validation error and learning ratio changes)

Modelleme performansının gösterilmesi için gerçekte olması gereken çıkış ile YSA'nın çıkışının karşılaştırması ise eğitim, doğrulama ve test verilerinin ve tüm datanın sonuçlarına ait regresyon eğrileri ise Şekil 4'te verilmiştir. Bu eğriler 0 ile 1 arasında ölçeklendirilmiştir. Eğrilerden de görüldüğü gibi tüm veriler için regresyon 1'e yakın çıkmıştır. Yani YSA model çıkışı gerçek verilere çok yakın değerler almıştır.



Şekil 4. Eğitim, doğrulama ve test verilerinin ve tüm datanın sonuçlarına ait regresyon eğrileri
(Figure 4. Regression curves for the results of training, validation and test data and for all data)

Tablo 2. Yapay sinir ağları modelinin çıkış verileri (Tahmin sonuçları)
(Table 2. Output data of artificial neural networks model (Prediction results))

TiC İçeriği (%ağ)	Bağıl Yoğunluk (%)	Sertlik (HV _{0,1})	Elektrik İletkenliği (% IACS)	Çapraz Kırılma Dayanımı (TRS) (MPa)	Sürtünme Katsayısı (COF)	Aşınma Oranı (mm ³ /N/m)
2	97.2	58.8	80.1	264.7	0.6	0.00867
4	94.9	68.2	75.8	215.3	0.5	0.00341
6	93.9	75.5	73.2	191.7	0.4	0.00378
8	95.6	70.6	77.1	188.3	0.7	0.00725
12	79.3	84.2	70.5	170.2	0.5	0.00152
14	78.8	87.6	58.2	168.6	0.3	0.00144

5. SONUÇ VE ÖNERİLER (CONCLUSION AND RECOMMENDATIONS)

Bu çalışmada, toz metalurjisi yöntemlerinden sıcak presleme tekniği ile üretilen Cu-TiC kompozitlerinin mekanik ve fiziksel özelliklerinin değişimi yapay sinir ağları ile tahmin edilmiştir. Ağırlıkça %2, 4, 6, 8, 12, 14 oranlarında TiC ilave edilen Cu-TiC kompozitlerin bağıl yoğunluk, sertlik, elektrik iletkenliği, çapraz kırılma dayanımı, sürtünme katsayısı ve aşınma oranlarında değişimleri deneysel olarak YSA yöntemiyle araştırılmıştır. Eğitim verilerinde kullanılan değerlere göre YSA'da gerçekçi sonuçlar çıkmış ve YSA'nın bu alanda başarılı sonuçlar çıkardığı sonucuna varılmıştır. Aynı zamanda bu sonuçlara göre malzemeden ve zamandan tasarruf yapılmaktadır.



KAYNAKLAR (REFERENCES)

1. Lu, J., Shu, S., Qiu, F., Wang, Y., and Jiang, Q., (2012). Compression Properties and Abrasive Wear Behavior Of High Volume Fraction TiC_x-TiB_2/Cu Composites Fabricated by Combustion Synthesis and Hot Press Consolidation. *Materials & Design*, Vol:40, pp:157-162.
2. Eslami, M., Golestani-fard, F., Saghafian, H., and Robin, A., (2013). Study on Tribological Behavior of Electrodeposited $Cu-Si_3N_4$ Composite Coatings. *Materials & Design*: Vol:58, pp:557-569.
3. Selvakumar, N. and Vettivel, S.C., (2013). Thermal, Electrical and Wear Behavior of Sintered $Cu-W$ Nanocomposite. *Materials & Design*: Vol:46, pp:16-25.
4. Vettivel, S.C., Selvakumar, N., Leema, N., and Lenin, A.H., (2014). Electrical Resistivity, Wear Map and Modelling of Extruded Tungsten Reinforced Copper Composite. *Materials & Design*: Vol:56, pp:791-806.
5. Çelikyürek, İ., Körpe, N.Ö., Ölçer, T., and Gürler, R., (2011). Microstructure, Properties and Wear Behaviors of $(Ni_3Al)_p$ Reinforced Cu Matrix Composites. *Journal of Materials Science & Technology*: Vol:27(10), pp:937-943.
6. Zhang, L. He, X.B., Qu, X.H., Duan, B.H., Lu, X., and Qin, M.L., (2008). Dry Sliding Wear Properties of High Volume Fraction Sic_p/Cu Composites Produced By Pressureless Infiltration, *Wear*: Vol:265(11-12), pp:1848-1856.
7. Fathy, A., Shehata, F., Abdelhameed, M., and Elmahdy, M., (2012). Compressive and Wear Resistance of Nanometric Alumina Reinforced Copper Matrix Composites. *Materials & Design*: Vol:36, pp:100-107.
8. Allahverdi, N., (2012). *Uzman Sistemler Bir Yapay Zeka Uygulaması*. İstanbul: Atlas Yayın Dağıtım.
9. Sağıroğlu, Ş., (2011). *Yapay Sinir Ağları ve Mühendislik Uygulamaları Semineri*. Erciyes: Erciyes Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği.
10. Elmas, Ç., (2011). *Yapay Zeka Uygulamaları*, Ankara: Seçkin Yayıncılık.
11. Bayır, R., (2008). *Yapay Zeka Teknikleri Dersi Ders Notları*. Karabük: Karabük Üniversitesi Elektronik ve Bilgisayar Eğitimi Bölümü.
12. Saraç, T., (2004). *Yapay Sinir Ağları Seminer Projesi*. Ankara: Gazi Üniversitesi Endüstri Mühendisliği Bölümü.
13. Taşkın, M. and Çalığülü, U., (2006). Modelling of Microhardness Values By Means of Artificial Neural Networks of Al/Sic_p Metal Matrix Composite Material Couples Processed With Diffusion Method. *Mathematical and Computational Applications*: Vol:11(3), pp:163-172.
14. Taşkın, M., Çalığülü, U., and Gur, A.K., (2008). Modeling Adhesive Wear Resistance of $Al-Si-Mg-/Sic_p$ PM Compacts Fabricated By Hot Pressing Process, By Means Of ANN. *The International Journal of Advanced Manufacturing Technology*: Vol:37(7), pp:715-721.
15. Durmuş, H.K., Özkaya, E., and Meriç, C., (2006). The Use of Neural Networks For The Prediction of Wear Loss and Surface Roughness of AA 6351 Aluminum Alloy. *Materials & Design*, Vol:27(2), pp:156-159.



-
16. Canakci, A., Ozsahin, S., and Varol, T., (2014). Prediction of Effect of Reinforcement Size and Volume Fraction on the Abrasive Wear Behavior of AA2014/B₄C MMC Using Artificial Neural Network. *Arabian Journal for Science & Engineering*: Vol:39(8), pp:6351-6361.
 17. Canakci, A., Varol, T., and Ozsahin, S., (2015). Artificial Neural Network To Predict The Effect Of Heat Treatment, Reinforcement Size, And Volume Fraction On Alcumg Alloy Matrix Composite Properties Fabricated By Stir Casting Method. *The International Journal of Advanced Manufacturing Technology*: Vol:78(1-4), pp:305-317.
 18. Prakash, K.S., Thankachan, T., and Radhakrishnan, R., (2017). Parametric Optimization of Dry Sliding Wear Loss of Copper-MWCNT Composites. *Transactions of Nonferrous Metals Society of China*: Vol:27(3), pp:627-637.