

PAPER DETAILS

TITLE: AI Matrisli Kompozitlere ANFIS, ANN ve Taguchi Yaklasimlari Uygulanarak Ozelliklerin Karsilastirilmasi

AUTHORS: Engin ERGÜL, Halil KURT

PAGES: 406-416

ORIGINAL PDF URL: <https://dergipark.org.tr/tr/download/article-file/1422077>



Al Matrisli Kompozitlere ANFIS, ANN ve Taguchi Yaklaşımları Uygulanarak Özelliklerin Karşılaştırılması

Comparison of Properties by Applying ANFIS, ANN and Taguchi Approaches to Al Matrix Composites

Engin Ergül¹ , Halil İbrahim Kurt²

¹Dokuz Eylül Üniversitesi, İzmir Meslek Yüksekokulu, Makine ve Metal Teknolojileri Bölümü, 35380 İzmir, TÜRKİYE

²Gaziantep Üniversitesi, Mühendislik Fakültesi, Metallürji ve Malzeme Mühendisliği Bölümü, 27310 Gaziantep, TÜRKİYE

Başvuru/Received: 30/11/2020

Kabul/Accepted: 07/02/2021

Çevrimiçi Basım/Published Online: 15/02/2021

Son Versiyon/Final Version: 18/06/2021

Öz

Metal matris kompozitler havacılık, savunma sanayii, otomobiller ve diğer önemli yapısal uygulamalar gibi çeşitli alanlarda yaygın olarak kullanılmaktadır. Alüminyum ve alaşımıları hafifliği yanı sıra sağlamlığı ve kolay şekillendirilebilme özellikleri sayesinde endüstride giderek artan kullanım alanına sahip olmuştur. Alüminyum matrisli kompozitlerde takviye elamanı olarak Al_2O_3 , SiC, TiC, MgO, CNT ve B_4C yaygın olarak kullanılır. Bu çalışmada, Al-bazlı metal matris kompozitlerin mekanik özelliklerini incelemek için matematiksel ve sonlu eleman modellemesi kullanılmıştır. Basınç, sinterleme sıcaklığı ve sinterleme süresine bağlı kalarak porozite içeriği uyarlanabilir nöro-bulanık çıkarım sistemi (ANFIS) yöntemi kullanılarak relatif yoğunluklar ise yapay sinir ağları (ANN) yöntemi ile başarılı bir şekilde analiz edilmiştir. ANFIS yaklaşımında, dört giriş parametresi, ağırlıkça %SiC oranı, kullanılan basınç (MPa), sinterleme sıcaklığı ($^{\circ}\text{C}$), sinterleme zamanı (dk) ve bir çıkış parametresi porozite (%) oranı kullanılmıştır. Analizlerin korelasyon katsayılarının ve istatiksel hata oranlarının iyi olduğu görülmüştür. Toz metalürjisi yöntemiyle üretilen Al-Mg-Al₂O₃ kompozitlerin relatif yoğunluk değerleri ANN yöntemiyle incelenmiştir. Sistemin oranın %81 ve kabul edilebilir sınırlar içerisinde olduğu söylenebilir. Ayrıca, Taguchi yaklaşımı ile Al_2O_3 ve SiC içeren kompozitlerin relatif yoğunlukları analiz edilmiş ve sonuçlar karşılaştırılmıştır.

Anahtar Kelimeler

"Alüminyum matris kompozit, SiC, Al_2O_3 , ANFIS, ANN"

Abstract

Metal matrix composites are widely used in various fields such as aerospace, defense industry, automobiles and other important structural applications. Aluminum and its alloys have been increasingly used in the industry thanks to their lightness, strength and easy formability. Al_2O_3 , SiC, TiC, MgO, CNT and B_4C are widely used as reinforcing elements in aluminum matrix composites. In this study, mathematical and finite element modeling was used to examine the mechanical properties of Al-based metal matrix composites. Based on the pressure, sintering temperature and sintering time, the relative densities were successfully analyzed using the adaptive neuro-fuzzy inference system (ANFIS) method and the artificial neural networks (ANN) method. In the ANFIS approach, four input parameters, weight %SiC ratio, used pressure (MPa), sintering temperature ($^{\circ}\text{C}$), sintering time (min) and one output parameter porosity (%) ratio were used. Correlation coefficients and statistical error rates of the analyzed dataset were found to be good. The relative density values of Al-Mg-Al₂O₃ composites produced by powder metallurgy method were examined by ANN method. It can be said that the estimation rate of the system is 81% and that it is within acceptable limits. Besides, the relative density of composites with Al_2O_3 and SiC was examined using Taguchi method and the results were compared.

Key Words

"Aluminum matrix composite, SiC, Al_2O_3 , ANFIS, ANN"

1. Giriş

En az iki farklı malzemenin belirli bir amaç için bir araya getirilmesiyle oluşan yapıya kompozit malzemeler adı verilir ve matris malzemesi olarak metal ve alaşımının kullanılmasıyla metal matris kompozitler (MMC) oluşur (Kurt vd. 2018). Metal matris kompozitler havacılık, savunma sanayii, otomobiller ve diğer önemli yapisal uygulamalar gibi çeşitli alanlarda yaygın olarak kullanılmaktadır (Şimşek 2019, Başyigit 2020). Metal matris kompozitler, lif gibi takviye ediciler ile doldurulmuş bir malzeme türüdür. Al matris kompozitler, yüzey merkezli kübik kafes yapıdadır, iyi bir plastiklik özelliğe ve topluğa sahiptir. Buna ek olarak, işlenebilirlik, dayanım ve düşük fiyat avantajları nedeniyle mühendislik uygulamalarında sıkılıkla kullanılır. Hafif malzemenin yanı sıra yüksek sertlik ve mukavemet gerektiren havacılık sektöründe Mg matris kompozitler tercih edilir (Zhao vd. 2020, Baksan vd. 2020).

Metal matris kompozit üretiminde döküm, toz metalürjisi, in-situ ve infiltrasyon gibi farklı metodlar kullanılmaktadır. İnfiltasyon metodu içerisinde birkaç farklı uygulama tekniği barındırır. Bunlar; basıncı, basınsız ve vakum infiltrasyon teknikleridir. Basıncı infiltrasyon yöntemi; ön şekil verilmiş gözenekli takviyeye sıvı metalin nüfuz etmesi için, sıvı metale mekanik basınç yerine inert gaz basıncı uygulayan bir sıvı infiltrasyon tekniğidir. Basıncı infiltrasyon tekniğinde; sıvı metal sıcaklığı, takviye tane büyütüğü, infiltrasyon süresi ve basıncı en önemli infiltrasyon parametrelerini teşkil ederler ve sıvı metal sıcaklığı bu parametrelerin en önemlilerinden birisidir (Ateş ve Kızılık 2011).

Alüminyum ve alaşımıları hafifliği yanı sıra sağlamlığı ve kolay şekillendirilebilme özellikleri sayesinde endüstride giderek artan kullanım alanına sahip olmuştur (Pul 2017, Uludağ 2018, Hekimoğlu ve Haciosmanoğlu 2019, Kurt vd. 2019). Alüminyum alaşımının zayıf olan mekanik özelliklerini geliştirmek için alüminyum matrise makro boyutta dayanımı yüksek takviye elemanları değişik üretim yöntemleri ile ilave edilerek çok üstün özelliklere sahip alüminyum esaslı kompozit malzemeler üretilmektedir (Karabulut vd. 2019). Alüminyum matrisli kompozitlerde takviye elamanı olarak Al₂O₃, SiC, TiC, MgO, CNT ve B4C yaygın olarak kullanılır (Gosavi ve Jaybhaye 2020, Kaya vd. 2020). MMC'ler yumuşak alaşımı matris üzerine sert ve kırılgan takviyenin birleşik etkisiyle elde edilen gelişmiş fiziksel ve mekanik özelliklere sahip alaşındır. Kullanılan takviye türüne ve metal matris içindeki hacim oranına bağlı olarak, alüminyum metal matris kompozitler daha büyük mukavemet, sertlik, aşınma direnci, yorulma, korozyon ve sürünme direnci değerleri elde edilebilir.

Kompozit malzemelerin karakterizasyonu, güvenilir kullanımları için esastır. En güçlü modelleme tekniklerinden biri olan Yapay Sinir Ağları (ANN) ve Uyarlanabilir Nöro-bulanık Çıkarım Sistemi (ANFIS) kullanımı, gerekli deneyel olcumülerin zamanını ve maliyetini düşürür (Fazılat vd. 2012). Bu bağlamda kompozit malzemelerin karakterizasyonu ile ilgili literatür çalışmalarına bakıldığından; Jalham (2005), Al bazlı kompozitlerde takviye içeriğinin sıcak mukavemeti üzerindeki etkisini tahmin etmek için karşılaştırmalı ağ yaklaşımları üzerine bir çalışma gerçekleştirilmiştir. Yapılan incelemeler sonunda nöro-bulanık ağın, ortalama parçacık boyutu 25µm olan Al₂O₃ parçacıklarının farklı takviye içeriğine (%5, 10, 15 ve 20) sahip Al-bazlı kompozitlerin sıcak deformasyon davranışını tahmin etmek için en iyi araç olduğunu vurgulamıştır. Çalışmasında Al₂O₃'ün içeriği arttıkça akma dayanımının azaldığını ifade etmektedir. Azmi (2015) frezelemene cam elyaf takviyeli polimer (GFRP) kompozitleri işlemenin zor ve aşırı takım aşınmasına neden olduğunu vurgulamaktadır. Çalışmasında işleme kuvvetinin ve takım aşınmasının büyümесini sürekli olarak izlemiştir. İki farklı ANFIS modeli geliştirilmiştir. (Al-Ghamdi ve Taylan 2015) Ti – 6Al – 4V alaşımı üzerinde EDM (elektro-erozyon) deneyinin sonuçları üzerinde ANFIS modellemesi gerçekleştirilmiştir. Geri yayılım sinir ağları eğitim algoritması ile birinci dereceden Sugeno bulanık yaklaşımı kullanılarak 6, 9, 19, 21 ve 51 kurallı beş ANFIS modeli geliştirilmiştir. Bunlardan 21 kurallı ANFIS modelinin en iyisini olduğunu vurgulamaktadır. Bu model ayrıca, tahmin hatası, kalıntı aralığı, deneyel ve öngörülen MRR değerleri arasındaki korelasyon katsayısı açısından polinom modelinden önemli ölçüde daha iyi performans gösterdiğini ifade etmektedirler. Çalışma, karmaşık doğrusal olmayan işleme süreçlerinin modellenmesi açısından ANFIS modellerinin güçlü öğrenme kapasitesine ve geleneksel polinom modellerine göre üstünlüğe ışık tutduğunu söylemektedirler. Kumarasamy vd. (2017) çalışmalarda, iki aşamalı birleştirme yoluyla geliştirilen yeni bir hibrit Alüminyum Metal Matris Kompozitin (AMMC) karakterizasyonuna odaklanılmışlardır. Geliştirilen hibrit kompozitin işlenebilirlik (tornalama) özellikleri, Yapay Sinir Ağı (YSA) teknigi kullanılarak işleme parametrelerinin optimize edilmesinin yanı sıra ayrıntılı olarak incelemiştir. ANOVA sonuçlarına göre, kesme hızının ve grafit ilavesinin %'sinin, geliştirilen kompozitin yüzey pürüzlüğünü en aza indirmede büyük katkısı olduğunu bulmuşlardır.

Bu çalışmada, Al-bazlı metal matris kompozitlerin mekanik özelliklerini incelemek için matematiksel ve sonlu eleman modellemesi kullanılmıştır. Basıncı, sinterleme sıcaklığı ve sinterleme süresine bağlı kalarak porozite içeriği ANFIS yöntemi kullanılarak relatif yoğunluklar ise ANN yöntemi ile başarılı bir şekilde analiz edilmiştir.

2. Malzeme ve Yöntem

2.1. Yapay sinir ağları (ANN)

Yapay sinir ağları (ANN), genellikle bu tür sistemleri tanımlamak için matematiksel modeller bulmanın zor veya imkânsız olduğu sistemlerin veya süreçlerin girdi çıktı ilişkilerini modellemeye kullanılan hesaplama modelleme araçlarıdır. ANN, canlı organizmaların beyinlerindeki akıllıca hareket etmelerini sağlayan nöron ağından esinlenmiştir. Yapay sinir ağları yapay nöronlardan yararlanır. Yapay sinir ağları (ANN), insan vücudundaki doğal nöronların çalışma şéklini simüle eder. Çoğu ANN, ileri beslemeli çok katmanlı algılayıcı

ağılardır. İleri beslemeli ağlar, öğrenme için geriye doğru yayılma algoritmaları kullanır. Bazı öğrenme algoritmaları arasında Levenberg – Marquardt algoritması, gradyan iniş algoritması, genetik algoritma veya diğer doğal optimizasyon algoritmaları bulunur. ANN, nöronları temsil eden birkaç düğümden oluşur. Giriş düğümleri bağımsız değişkenleri temsil ederken, çıkış düğümleri bağımlı değişkenleri temsil eder (Nwobi-Okoye vd. 2019).

Bu çalışmada SiC ile güçlendirilen ve toz metalürjisi yöntemiyle üretilen alüminyum-magnezyum matrisli kompozitlerin relatif yoğunluk değerlerini doğru bir şekilde modellemek için ANN kullanıldı. Herhangi bir sürecin parametrelerinin doğru tahmin edilmesi, sürecin kalitesi, ekonomisi ve optimum performansı için kritiktir. Tatmin edici bir ANN modeli geliştirildikten sonra, model, relatif yoğunluk parametrelerinin çok amaçlı optimizasyonu için uygunluk işlevi olarak genetik algoritma olarak bilinen bir optimizasyon prosedürüne entegre edildi. ANN, Matlab ile geliştirildi. ANN girdileri basınç, sinterleme sıcaklığı ve sinterleme süresinden oluşur.

2.2. Uyarlanabilir nöro-bulanık çıkarım sistemi (ANFIS)

ANFIS, bir sinir ağının öğrenme yeteneklerini ve bulanık mantığın akıl yürütme yeteneklerini birleştiren düğümler ve yönlü bağlantılardan oluşan çok katmanlı ileri beslemeli bir ağdır. Ağın bu hibrit yapısı, ANFIS'in tahmin yeteneklerini ANN'nin ve tek başına kullanıldıklarında bulanık mantık tekniklerinin ötesine genişletme olasılığna sahiptir. ANFIS, girdi ve çıktı verileri arasındaki eşleştirme ilişkisini analiz ederek, ortalama mutlak hatayı en aza indirecek işlevlerinin optimal dağılımını, tek başına bir geri yayılım gradyan iniş algoritması veya en küçük kareler yöntemiyle kombinasyon halinde belirleyebilir (Nwobi-Okoye vd. 2019, Said vd. 2020). Bu araştırmada kullanılan ANFIS MATLAB ile geliştirilmiştir.

2.3. Porozite ve relatif yoğunluk ölçümü

Bu çalışmada SiC ile güçlendirilen ve toz metalürjisi yöntemiyle üretilen alüminyum-magnezyum matrisli kompozitlerin porozite içeriği incelenmiştir ve ANFIS yöntemi kullanılarak analiz edilmiştir. Ayrıca Al₂O₃ ile güçlendirilen alüminyum-magnezyum matrisli kompozitlerin relatif yoğunluk değerleri incelenerek yapay sinir ağları yöntemiyle analiz edilmiştir. Kompozitlerin teorik yoğunlukları, Arşimet prensibine göre değerlendirilmiştir.

$$d_{\text{ölçülen}} = \frac{W_k}{W_k - W_a} \cdot 0,998$$

W_k = havadaki ağırlık

W_a = sudaki ağırlık

d_{teorik} = karışım kanunu

Teorik yoğunluklar ve ölçülen yoğunluklar kullanılarak porozite değerleri hesaplanmıştır.

$$\% \text{Porozite} = \left(1 - \frac{d_{\text{ölçülen}}}{d_{\text{teorik}}} \right) \cdot 100$$

Ölçülen yoğunluklar ve hesaplanan yoğunluklar kullanılarak relatif yoğunluk değerleri hesaplanmıştır.

$$d_{\text{relatif}} = \frac{d_{\text{ölçülen}}}{d_{\text{teorik}}}$$

SiC ile güçlendirilen ve toz metalürjisi yöntemiyle üretilen alüminyum-magnezyum matrisli kompozitlerin porozite içeriği ANFIS yöntemi kullanılarak relatif yoğunluklar ise ANN yöntemi ile analiz edilmiştir. Porozite içeriğinin analizinde kullanılan ANFIS giriş ve çıkış parametreleri Tablo 1'de verilmiştir.

Tablo 1. Porozite içeriğinin analizinde kullanılan ANFIS parametreleri

SiC Oranı (%)	Basınç (MPa)	Sinterleme Sıcaklığı (°C)	Sinterleme Süresi (dk)	Porozite (%)
Min	15	260	300	22,87
Maks	30	520	500	44,51

SiC ile güçlendirilen ve toz metalürjisi yöntemiyle üretilen alüminyum-magnezyum matrisli kompozitlerin relatif yoğunluklarının analizinde kullanılan ANN giriş ve çıkış parametreleri Tablo 2'de verilmiştir.

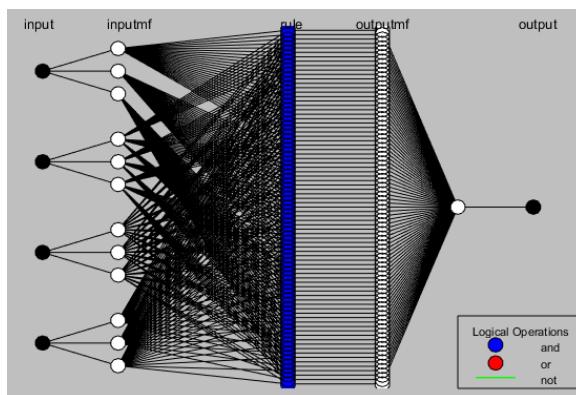
Tablo 2. Relatif yoğunlukların analizinde kullanılan ANN parametreleri

	Al ₂ O ₃ Oranı (%)	Basınç (MPa)	Sinterleme Sıcaklığı (°C)	Sinterleme Süresi (dk)	Relatif Yoğunluk
Min	15	260	300	30	0,85
Maks	30	520	500	90	0,93

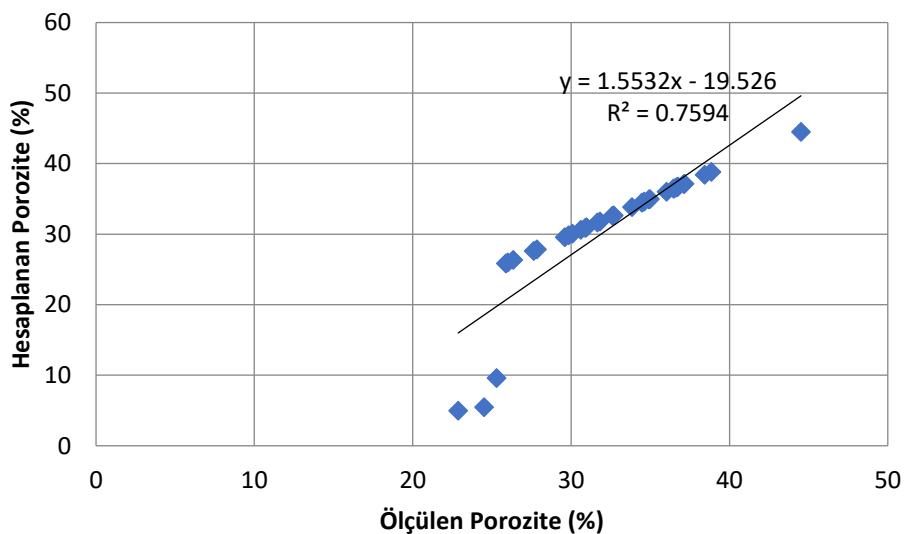
3. Bulgular ve Tartışma

3.1. ANFIS Sonuçları

ANFIS programında, 4 giriş değişkeni, 1 çıkış değişkeni, giriş fonksiyon tipi (mf) gaussmf, fonksiyon numarası 3 3 3 3, çıkış fonksiyon tipi sabit, öğrenme algoritması (FIS) hibrit, epoch 1000, hata toleransı 0 olarak ayarlanmıştır. Sistem sonuçları, ortalama karesel hata (MSE), ortalama mutlak hata (MAE), ortalama mutlak hata yüzdesi (MAPE) ve korelasyon katsayısı (R) ve tahmin oranı (R^2) kullanılarak değerlendirilmiştir.

**Şekil 1.** Sistem yapısı

Şekil 1'de sistem yapısı gösterilmiştir. Burada 4 giriş parametresi, ağırlıkça %SiC oranını, kullanılan basıncı (MPa), sinterleme sıcaklığını (°C), sinterleme zamanını (dk) ve bir çıkış parametresi porozite (%) oranını temsил etmektedir.

**Şekil 2.** Porozite içeriğinin karşılaştırılması ve uyumu

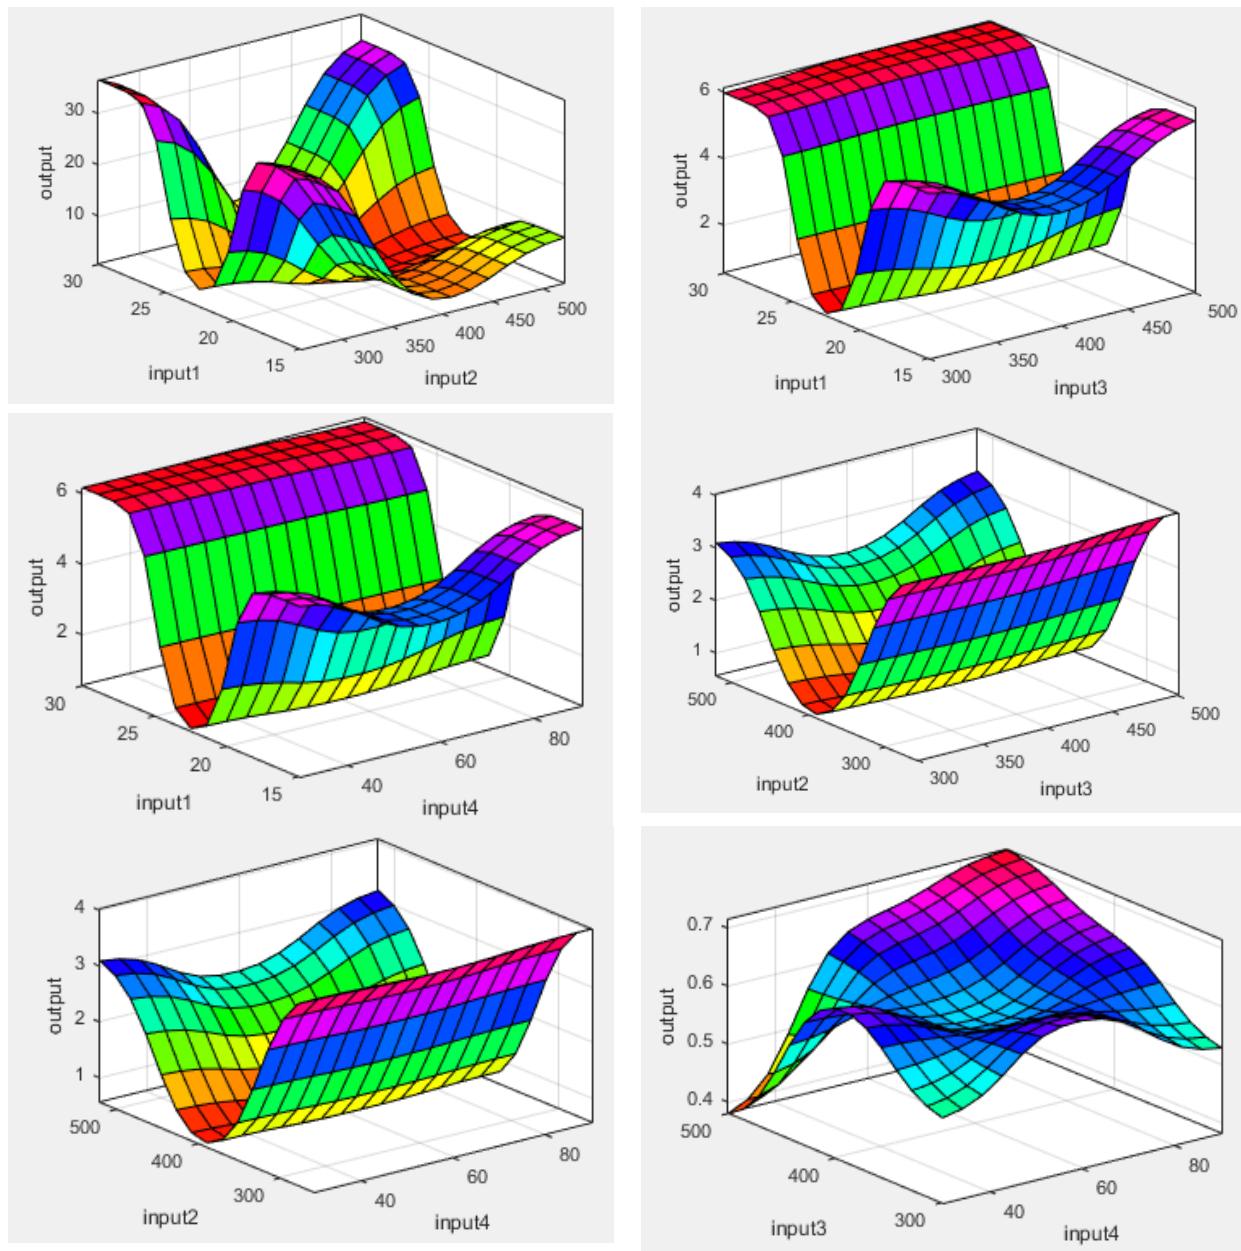
Şekil 2'de ölçülen ve hesaplanan porozitelere ait uyum gösterilmiştir. Ölçülen ve hesaplanan porozitelere ait korelasyon katsayısı $R=0,87$ ve R^2 değeri 0,7594 olarak meydana gelmiştir. Bir başka ifadeyle sistemin tahmin oranı yaklaşık olarak %75 olduğu görülmektedir.

Tablo 3'te sisteme ait istatistiksel ortalama hatalara ait veriler görülmektedir. Elde edilen istatistik sonuçlarının oldukça iyi olduğu saptanmıştır. Sistem parametreleri değiştirilerek daha düşük hata değerleri elde edilebilir ve dolayısıyla tahmin oranı arttırılabilir. Buna rağmen, üretim esnasındaki bütün değişimleri kontrol etmek mümkün olmadığı için sıfır hatayla bir sonuç elde etmek çok zordur.

Tablo 3. İstatistik analiz sonuçları

MSE	MAE	MAPE
27,28	1,55	6,41

ANFIS yüzey modelleme ile parametreler arasındaki ilişkiler grafik olarak incelenebilmektedir. Yüzey grafikleri bu ilişkileri net bir şekilde ifade edebilmektedir.



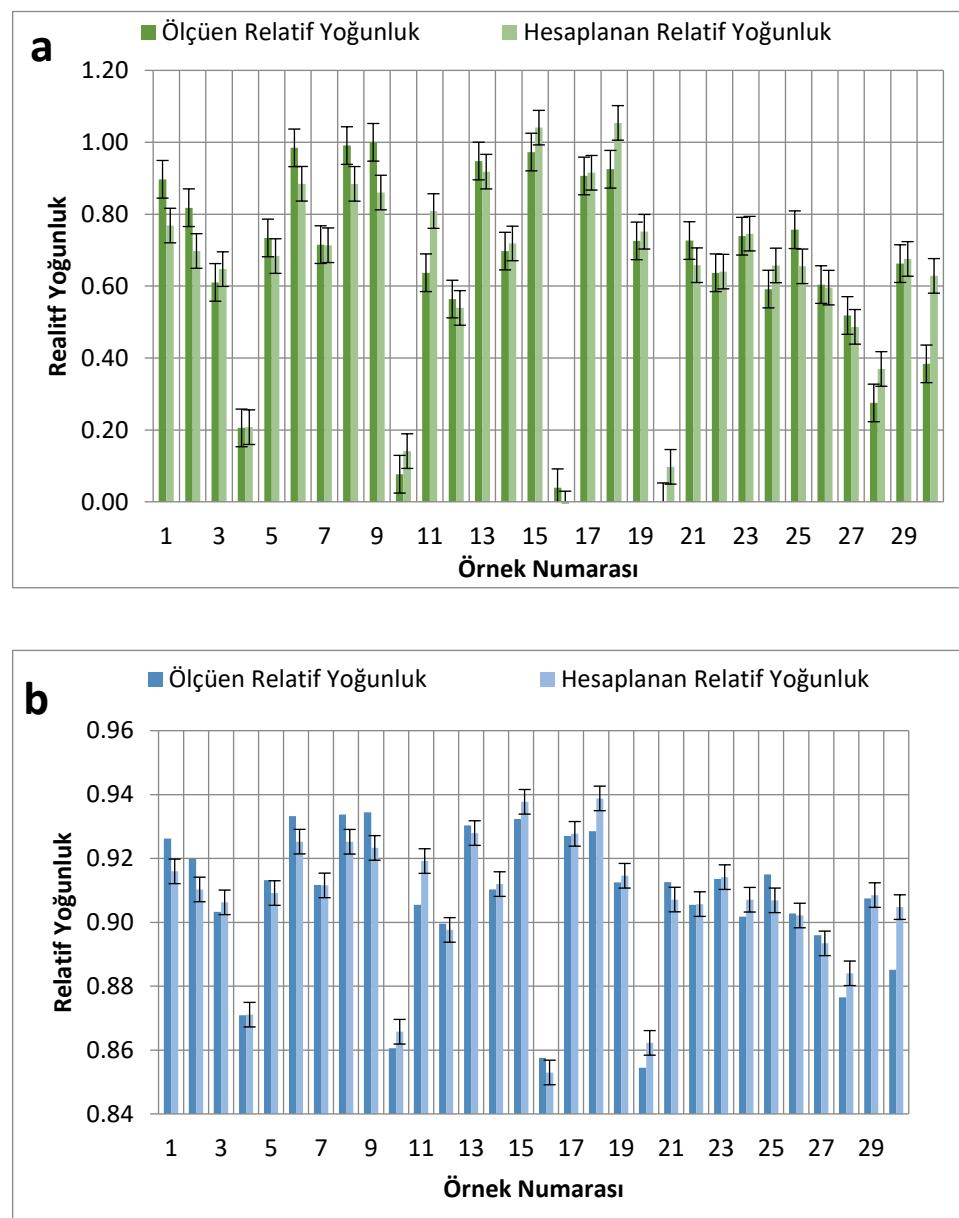
Şekil 3. Değişkenlere ait yüzey grafiği

Şekil 3'te ANFIS programı kullanılarak elde edilen yüzey grafikleri verilmiştir. Bu grafikler ile giriş değişkenlerinin birbiri üzerindeki etkileri ve sonuç üzerindeki etkileri değerlendirilebilir. Burada input 1 ağırlıkça %SiC oranını, input 2 kullanılan basıncı (MPa), input 3 sinterleme sıcaklığını (°C), input 4 sinterleme süresini (dk) ve output porozite (%) oranını temsil etmektedir. Genelde lineer bir görüntü elde edilmemekte birlikte farklı değişkenlerin birbiri üzerine etkileri farklı karakteristikler sergilemektedir. Sinterleme sıcaklığı, süresi ve basınç artışı bir dereceye kadar porozite içeriğini azalttığı sonucuna varılabilceği kanaati olmaktadır.

3.2. ANN Sonuçları

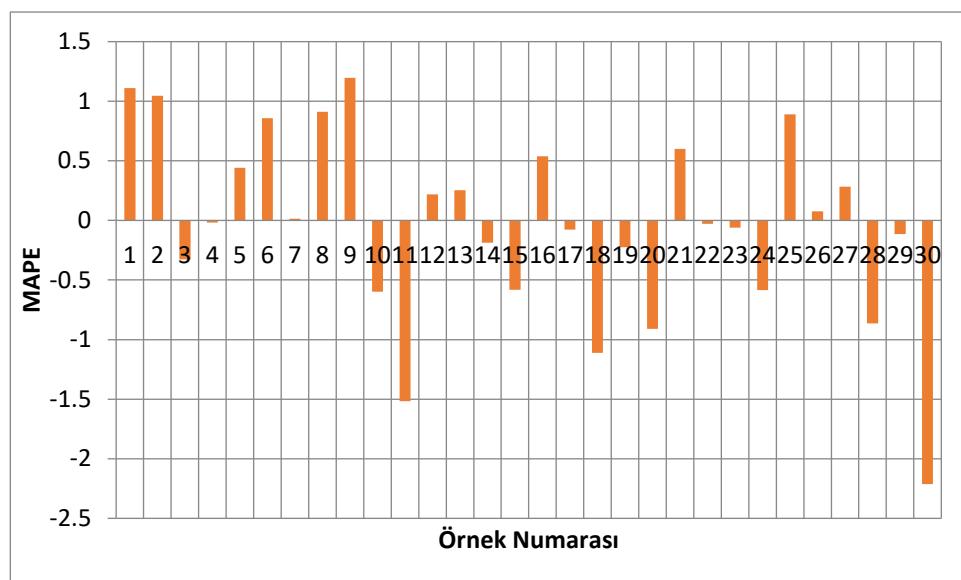
Yapay sinir ağları (YSA), sistemlerin parametrelerin değişikliklere nasıl tepki vereceğini tahmin edebilecekleri için karmaşık sistemleri modellemede yararlı araçlardır. Ayrıca, değişkenler arasındaki ilişkileri keşfetmek için YSA'lar kullanılır ve bu da sistem işlevinin anlaşılmasına yardımcı olur. YSA'lar insan sinir sistemini simüle eder ve giriş verileri hata içerdiginde veya eksik olduğunda bile anlamlı çözümler üretmek için örneklerden öğrenip genelleme yapabilir. YSA'nın hesaplanması, işlemlerin giriş katmanına bir dizi eklenmesiyle başlar. Bu sinyaller daha sonra bitişik katmandaki nöronların her birine bağlantılar boyunca bağlantıya özgü ağırlıklar ile hareket eder. Bitişik katman nöronlar, gelen sinyaller için toplama ağıdır. Gelen sinyal daha sonra bir çıkış sinyaline dönüştürülür. Bu çıkış sinyali daha sonra ağırlıklı bağlantılar boyunca aşağıdaki nöron katmanına taşınır. İşlem, sinyal çıkış katmanına ulaşana kadar tekrarlanır. Çıkış sinyali daha sonra YSA'nın verilen giriş uyarısına tepkisi olarak yorumlanabilir.

Tablo2'de kullanılan değerler 0-1 aralığında =(maks-min)/fark ile normalize edilmiştir. Yapay sinir ağları yaklaşımında verilerin %80 eğitim geri kalanı test verisi olarak ayarlanmıştır. Yapay sinir ağlarında 4 giriş ve 1 sonuç verileri, 1 gizli tabaka içinde 10 nöron yapısı ile Sigmoid LM aktivasyon fonksiyonu ileri beslemeli geri yayılım kullanılmıştır.



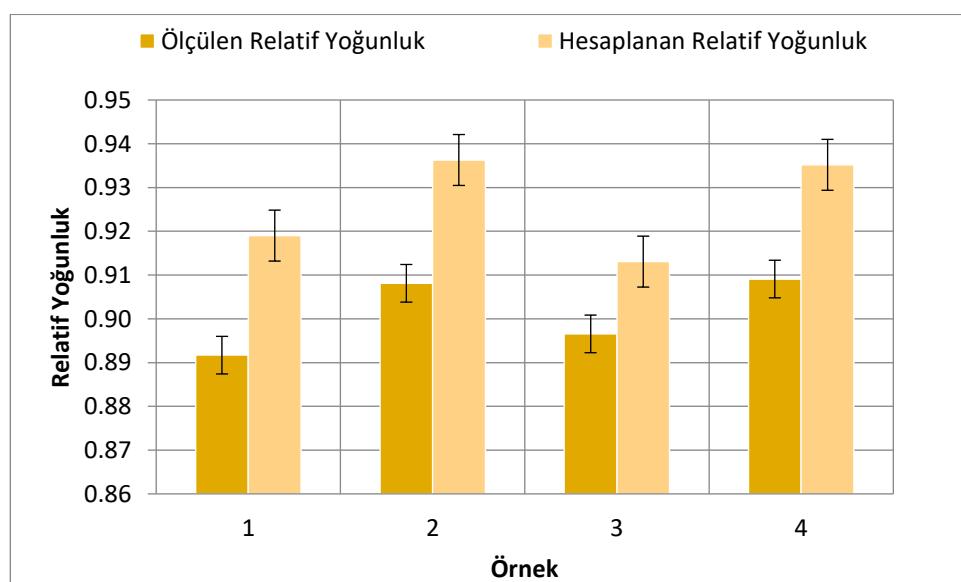
Şekil 4. Eğitim setine ait uyum a) Normalize edilmiş b) Normalize edilmemiş

Yapay sinir ağları yaklaşımında eğitim setine ait ölçülen ve hesaplanan yoğunluk değerlerinin uyumu Şekil 4'te gösterilmiştir. Normalize edilmiş sonuçların uyumu ile normalize edilmemiş örneğe ait uyumun her ikisinin de yüksek olduğu saptanmıştır. Her iki sonucun korelasyon değerlerinin $R = 0,95$ olması bu varsayıımı doğrulamaktadır (Jajarmi vd. 2019).



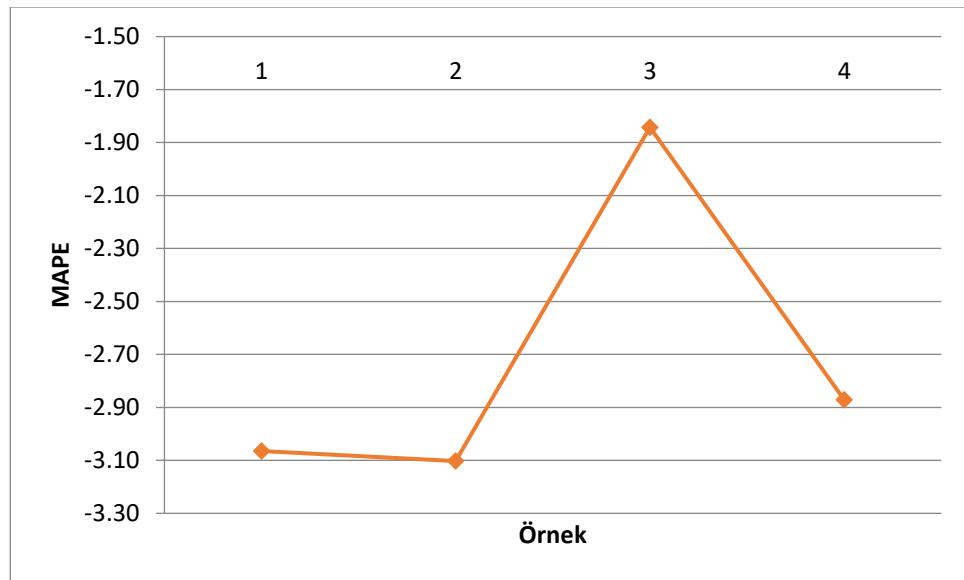
Şekil 5. Eğitim setine ait yüzde hata değişimi

Yapay sinir ağları yaklaşımında sistemin analizi ortalama karesel hata (MSE), ortalama mutlak hata (MAE) ve ortalama mutlak hata yüzdesi (MAPE) kullanılarak değerlendirilmiştir. Eğitim testine ait normalize edilmemiş sonuçların; ortalama karesel hata (MSE) 0,00005, ortalama mutlak hata (MAE) 0,0054 ve ortalama mutlak hata yüzdesi (MAPE) ise -0,0325 olarak tespit edilmiştir. Şekil 5'te yüzde hata değişimi verilmiştir. Maksimum yüzde hata %2,5'i geçmemiştir. Buda analiz sonuçlarının doğruluğunu ve güvenirliliğini göstermektedir.



Şekil 6. Normalize edilmemiş test setine ait uyum

Normalize edilmemiş test setine ait ölçülen ve hesaplanan yoğunluk değerlerinin uyumu Şekil 6'da gösterilmiştir. Test setine ait korelasyon değerinin $R = 0,899$ olması sisteme ait uyumun yüksek olduğunu göstermektedir. Test testine ait normalize edilmemiş sonuçların ortalama karesel hata (MSE) 0,0006 ortalama mutlak hata (MAE) 0,025 ortalama mutlak hata yüzdesi (MAPE) ise -2,72 olarak tespit edilmiştir.



Şekil 7. Test setine ait yüzde hata değişimi

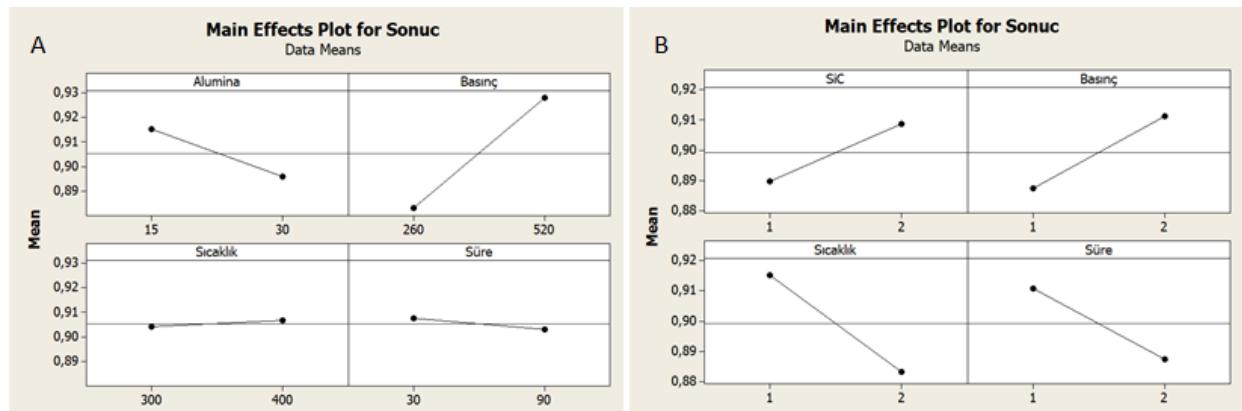
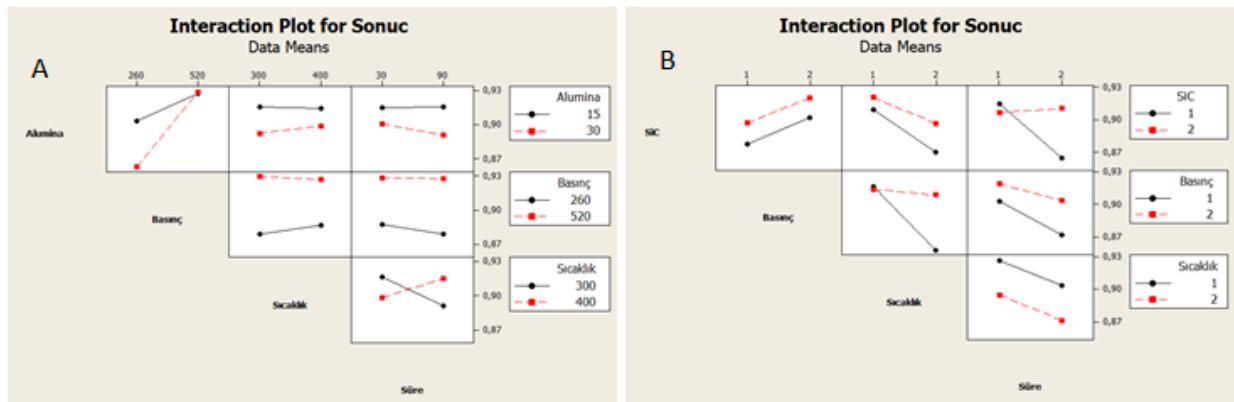
Şekil 7'de yüzde hata değişimi verilmiştir. Maksimum yüzde hata %3,5'i geçmemiştir. Buda analiz sonuçlarının doğruluğunu ve güvenirliliğini göstermektedir. Bütün yapılan sonuçlar değerlendirildiğinde yapay sinir ağları yaklaşımının verilen parametreler ışığında tahmin oranın (R^2) yaklaşık %81 ve yüksek olduğu sonucuna varılmıştır.

3.3. Taguchi Sonuçları

Bu bölümde, üretilen kompozitlerin relatif yoğunluk değerleri verilen parametreler ışığında Taguchi yaklaşımı kullanılarak incelenmiştir. Taguchi metodunda, 2 seviye, 4 faktör ve L8 ortogonal ara yüzü kullanılmıştır. Tablo 4'te, SiC ve alümina içeren kompozitlerin Taguchi deney parametreleri ve relatif yoğunluk değerleri verilmiştir. Farklı deney sonuçlarına bağlı olarak farklı yoğunluk değerleri elde edilmiştir. Relatif yoğunluk değerleri, porozite içeriğini değiştirdiğinden kompozitlerin mekanik özelliklerini de etkilemektedirler (Kurt 2016).

Tablo 4. Taguchi yaklaşım parametreleri ve relatif yoğunluk değerleri

$\text{Al}_2\text{O}_3/\text{SiC}$ (%)	Basınç (MPa)	Sinterleme Sıcaklığı (°C)	Sinterleme Süresi (dk)	Relatif Yoğunluk (Al_2O_3)	Relatif Yoğunluk (SiC)
15	260	300	30	0,903294947	0,922541754
15	260	400	90	0,902808696	0,832260820
15	520	300	90	0,928479906	0,896632786
15	520	400	30	0,926243810	0,907185257
30	260	300	90	0,854465266	0,910912861
30	260	400	30	0,870908400	0,883018508
30	520	300	30	0,930306451	0,930828293
30	520	400	90	0,926982137	0,910266966

Şekil 8. Giriş parametrelerinin relatif yoğunluğu ortalama etkisi a) Al_2O_3 b) SiCŞekil 9. Relatif yoğunluğun deney parametreleri ile etkileşimi a) Al_2O_3 b) SiC

Şekil 8 ve 9'da giriş parametrelerinin relatif yoğunluk üzerine etkileri ve etkileşimi yarı ayrı verilmiştir. Alümina içeriğinde artışa bağlı olarak kompozitlerin relatif yoğunluk değerleri azalırken SiC içeriğindeki artışa bağlı olarak relatif yoğunlıklar artmıştır. Basınç değerindeki artış hem alümina hem de SiC içeren kompozitlerin relatif yoğunluk değerini arttırmıştır. Bu daha iyi sıkıştırılabilirlik etkisine dayandırılabilir. Bununla beraber, giriş parametrelerinin “Delta ve Rank” istatistikleri verilmiş ve Regresyon analizi yapılmıştır. Tablo 5 ve 6'da bu değerler sunulmuştur.

Tablo 5. Alümina içeren kompozitlerin Taguchi istatistikleri

Level	Al_2O_3	Basınç	Sıcaklık	Süre
1	0,9152	0,8829	0,9041	0,9077
2	0,8957	0,9280	0,9067	0,9032
Delta	0,0195	0,0451	0,0026	0,0045
Rank	2	1	4	3
P	0,219	0,037	0,850	0,745

Tablo 6. SiC içeren kompozitlerin Taguchi istatistikleri

Level	SiC	Basınç	Sıcaklık	Süre
1	0,8897	0,8872	0,9152	0,9109
2	0,9088	0,9112	0,8832	0,8875
Delta	0,0191	0,0240	0,0320	0,0234
Rank	4	2	1	3
P	0,325	0,236	0,143	0,246

Delta, her faktör için en yüksek ve en düşük ortalama yanıt değerleri arasındaki farktır ve bir faktör için en yüksek ve en düşük karakteristik ortalama arasındaki farkı alarak etkinin boyutunu kullanır. Rank, hangi faktörün en büyük etkiye sahip olduğunu belirlemek için kullanılır (Yılmaz vd. 2019). Delta ve Rank değerleri birbirinin etkileşimi olduğu açıklanır. Alümina içeren kompozitlerde

Basınç en yüksek etkiye sahipken SiC içeren kompozitlerde Sıcaklık en yüksek etkiye sahiptir. Başka bir ifade ile basınç ve sıcaklığındaki herhangi bir değişim kompozitlerin relatif yoğunluk değerlerini diğer parametrelere göre daha fazla etkilemektedirler. Regresyon eşitliği alümina ve SiC içeren kompozitler için sırayla verilmiştir.

$$\text{Relatif Yoğunluk (Alümina)} = 0,862 - 0,00130 \text{ Alümina} + 0,000174 \text{ Basınç} + 0,000026 \text{ Sıcaklık} - 0,000075 \text{ Süre}$$

$$\text{Relatif Yoğunluk (SiC)} = 0,918 + 0,0191 \text{ SiC} + 0,0240 \text{ Basınç} - 0,0320 \text{ Sıcaklık} - 0,0234 \text{ Süre}$$

Tablo 5 ve 6'da verilen P değerleri sonuçları ölçen bir olasılık hipotezini göstermektedir. Düşük P değerleri daha güçlü bir olasılık kanıtı sağlamaktadır. Yani, P değerleri ile Rank değerleri birbirini doğrulamakta olduğunu söyleyebilir ve en küçük P değerleri daha yüksek etki oranına sahip olduğunu belirtebiliriz. Regresyon analizinde alümina içeren kompozitlerde P değeri 0,149 olarak gerçekleşirken SiC içeren kompozitleri için P değeri 0,251 olarak gerçekleşmiştir. Alümina içeren kompozitlerin Regresyon analizi SiC içeren kompozitlere göre daha yüksek uyumluluk göstermiştir.

4. Sonuçlar

Bu çalışmada toz metalürjisi yöntemiyle üretilen ve SiC ile güçlendirilmiş alüminyum-magnezyum matrisli kompozitlerin porozite içeriği ANFIS yöntemi kullanılarak incelenmiştir. ANFIS yaklaşımında, dört giriş parametresi, ağırlıkça %SiC oranını, kullanılan basıncı (MPa), sinterleme sıcaklığını (°C), sinterleme zamanını (dk) ve bir çıkış parametresi porozite (%) oranını kullanılmıştır. Analizlerin korelasyon katsayılarının ve istatiksel hata oranlarının iyi olduğu görülmüştür. Her bir değişkenin birbiri üzerinde etkisinin olduğu ve bu değişkenlerin porozite içeriğini etkilediği görülmektedir.

Toz metalürjisi yöntemiyle üretilen Al-Mg-Al₂O₃ kompozitlerin relatif yoğunluk değerleri yapay sinir ağları yöntemiyle incelenmiştir. Ölçülen yoğunluklar ve teorik yoğunluklar kullanılarak relatif yoğunluk değerleri hesaplanmıştır. Eğitim ve test setlerine ait istatiksel hata oranlarının çok düşük olduğu görülmüştür. Bununla birlikte setlere ait korelasyon değerlerinin yüksek olduğu belirlenmiştir. Maksimum hata test setinde görülmüş olup bu değer %3,5'i aşmamıştır. Sistemin tahmin oranın %81 olduğu ve kabul edilebilir sınırlar içerisinde bulunduğu görülmektedir.

Teşekkür / Bilgilendirme

Bu çalışma, TÜBİTAK (Türkiye Bilimsel ve Teknolojik Araştırma Kurumu) tarafından 217M084 numaralı proje kapsamında desteklenmiş olup, TÜBİTAK'a teşekkür ederiz.

Referanslar

- Al-Ghamdi, Khalid, and Osman Taylan. (2015). "A Comparative Study on Modelling Material Removal Rate by ANFIS and Polynomial Methods in Electrical Discharge Machining Process." *Computers & Industrial Engineering*, 79, 27–41. doi: <https://doi.org/10.1016/j.cie.2014.10.023>.
- Ateş, Serkan, and Emel Kızılık. (2011). "Basınçlı İnfiltasyon İle Üretilen SiC/Al2014 Kompozitlerin Özelliklerine İnfiltasyon Sıcaklığının Etkisinin Tek Yönlü Varyans Analizi İle İncelenmesi." *Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi*, 3(1), 50–54.
- Azmi, A. I. (2015). "Monitoring of Tool Wear Using Measured Machining Forces and Neuro-Fuzzy Modelling Approaches during Machining of GFRP Composites." *Advances in Engineering Software*, 82, 53–64. doi: <https://doi.org/10.1016/j.advengsoft.2014.12.010>.
- Baksan, Bedri, İbrahim Çelikyürek, and Yusuf Kılıç. (2020). "Effect of Secondary Aging of EN AC 43200 Aluminum Alloy to Mechanical Properties." *The International Journal of Materials and Engineering Technology*, 3(1), 16–20.
- Başyigit, Aziz Barış. (2020). "Investigating the Mechanical and Microstructural Properties of Aluminium Based Alloy Wheel Rims after TIG Welding." *Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi*, 12(2), 388–95. doi: 10.29137/umagd.686466.
- Fazilat, H., M. Ghatarband, S. Mazinani, Z. A. Asadi, M. E. Shiri, and M. R. Kalaee. (2012). "Predicting the Mechanical Properties of Glass Fiber Reinforced Polymers via Artificial Neural Network and Adaptive Neuro-Fuzzy Inference System." *Computational Materials Science*, 58, 31–37. doi: <https://doi.org/10.1016/j.commatsci.2012.01.012>.
- Gosavi, Swapnil V, and M. D. Jaybhaye. (2020). "Microstructural Studies on Aluminium Metal Matrix Composite (Al7075-SiC) Fabricated through Stir Casting Process." *Materials Today: Proceedings*, doi: 10.1016/j.matpr.2020.05.094.
- Hekimoğlu, Ali Paşa, and Murat Hacıosmanoğlu. (2019). "Effect of Copper and Magnesium Additions on the Structural, Mechanical

and Tribological Properties of the Al-17Si Alloy.” Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi, 11(2), 685–94. doi: 10.29137/umagd.546562.

Jajarmi, E., S. A. Sajjadi, and J. Mohebbi. (2019). “Predicting the Relative Density and Hardness of 3YPSZ/316L Composites Using Adaptive Neuro-Fuzzy Inference System and Support Vector Regression Models.” Measurement, 145, 472–79. doi: <https://doi.org/10.1016/j.measurement.2019.05.108>.

Jalham, Issam S. (2005). “A Comparative Study of Some Network Approaches to Predict the Effect of the Reinforcement Content on the Hot Strength of Al–Base Composites.” Journal of Materials Processing Technology, 166(3), 392–97. doi: <https://doi.org/10.1016/j.jmatprotec.2004.08.028>.

Karacif, Kubilay, Hasan Karabulut, and Ramazan Çitak. (2019). “Al₂O₃ Takviyeli Alüminyum Esası Kompozit Malzemelerde Mekanik Alaşımlama Süresinin Korozyon Davranışına Etkilerinin İncelenmesi.” Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi, 11(2), 576–83. doi: 10.29137/umagd.507023.

Kaya, Abdulaziz, Mikail Aslan, Necip Fazıl Yılmaz, and Halil Kurt. (2020). “Al-Mg-SiC Kompozitlerin Görünür Yoğunlıklarının Taguchi Analizi.” El-Cezeri Fen ve Mühendislik Dergisi, 7(2), 773–80. doi: 10.31202/ecjse.695249.

Kumarasamy, Soorya Prakash, Kavimani Vijayananth, Titus Thankachan, and Gopal Pudhupalayam Muthukutti. (2017). “Investigations on Mechanical and Machinability Behavior of Aluminum/Flyash Cenosphere/Gr Hybrid Composites Processed through Compocasting.” Journal of Applied Research and Technology, 15(5), 430–41. doi: <https://doi.org/10.1016/j.jart.2017.05.005>.

Kurt, Halil Ibrahim. (2016). “Influence of Hybrid Ratio and Friction Stir Processing Parameters on Ultimate Tensile Strength of 5083 Aluminum Matrix Hybrid Composites.” Composites Part B: Engineering, 93, 26–34. doi: 10.1016/j.compositesb.2016.02.056.

Kurt, Halil İbrahim, Yahya Bozkurt, Serdar Salman, and Hüseyin Uzun. (2019). “Application of FSW Technique to AA2124/%25SiCp-T4 Aluminium Matrix Composites.” The International Journal of Materials and Engineering Technology, 2(1), 16–24.

Kurt, Halil İbrahim, Necip Fazıl Yılmaz, and Murat Oduncuoğlu. (2018). “ANN in Estimation Shear Modulus of Laminate Composite.” The International Journal of Materials and Engineering Technology, 1(1), 1–5.

Nwobi-Okoye, Chidozie Chukwuemeka, Basil Quent Ochieze, and Stanley Okiy. (2019). “Multi-Objective Optimization and Modeling of Age Hardening Process Using ANN, ANFIS and Genetic Algorithm: Results from Aluminum Alloy A356/Cow Horn Particulate Composite.” Journal of Materials Research and Technology, 8(3), 3054–75. doi: <https://doi.org/10.1016/j.jmrt.2019.01.031>.

Pul, Muhamrem. (2017). “Comparison of Surface Roughness and Tool Wear in Turning of 7075, 6061 and 2024 Aluminum Alloys.” Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi, 9(2), 65–75. doi: 10.29137/umagd.351746.

Said, Zafar, L. Syam Sundar, Hegazy Rezk, Ahmed M. Nassef, Hafiz Muhammad Ali, and Mohsen Sheikholeslami. (2020). “Optimizing Density, Dynamic Viscosity, Thermal Conductivity and Specific Heat of a Hybrid Nanofluid Obtained Experimentally via ANFIS-Based Model and Modern Optimization.” Journal of Molecular Liquids. doi: <https://doi.org/10.1016/j.molliq.2020.114287>.

Şimşek, İjlal. (2019). “Mekanik Alaşımlama Yöntemi İle Üretilen Farklı Miktarlarda ZrO₂ Takviyeli Al-2Gr Matrisli Kompozit Malzemelerin Aşınma Performanslarının İncelenmesi.” El-Cezeri Fen ve Mühendislik Dergisi, 6(3), 594–605. doi: 10.31202/ecjse.560741.

Uludağ, Muhammet. (2018). “Investigation of the Relationship Between Casting Quality, Microstructure and Mechanical Properties in Al-18Si Alloy.” Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi, 10(1), 30–41. doi: 10.29137/umagd.419659.

Yilmaz, Necip Fazil, Halil Ibrahim Kurt, Murat Oduncuoglu, and Engin Ergul. (2019). “Experimental and Theoretical Analysis of the Welding Process Parameters for UTS with Different Methods.” Materials Research Express, 6(1). doi: 10.1088/2053-1591/aae348.

Zhao, Zhanyong, Peikang Bai, Wenbo Du, Bin Liu, Duo Pan, Rajib Das, Chuntai Liu, and Zhanhu Guo. (2020). “An Overview of Graphene and Its Derivatives Reinforced Metal Matrix Composites: Preparation, Properties and Applications.” Carbon, 170, 302–26. doi: <https://doi.org/10.1016/j.carbon.2020.08.040>.