

AKÜ FEMÜBİD 22 (2022) 065901 (1469-1482)
DOI: 10.35414/akufemubid.1099381

AKU J. Sci. Eng. 22 (2022) 065901 065901 (1469-1482)

Araştırma Makalesi / Research Article

ANFİS Model ile Mg Alaşımlarının Sıkıştırılabilirliğinin Tahminleme Performansının İncelenmesi

Pınar KARAKUŞ¹, Demet ZALAOĞLU²

¹ Osmaniye Korkut Ata Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Osmaniye.

² Osmaniye Korkut Ata Üniversitesi, Mühendislik Fakültesi, Makine Mühendisliği Bölümü, Osmaniye.

Sorumlu yazar e-posta: pinarkarakus@osmaniye.edu.tr
demetkayretli@osmaniye.edu.tr

O RCID ID: <https://orcid.org/0000-0003-3727-7233>
O RCID ID: <https://orcid.org/0000-0002-1116-6327>

Geliş Tarihi: 06.04.2022

Kabul Tarihi: 09.11.2022

Öz

Anahtar kelimeler

ANFİS; Toz Metalurjisi;
Mg Alaşımı;
Sıkıştırılabilirlik

Bu çalışmada, farklı Zn (ağırlıkça %5 ve 10 Zn) oranlarına sahip Mg alaşımlarına ait toz karışımları hazırlanmış ve farklı sıkıştırma basınçlarında sıkıştırılarak hesaplanan ham yoğunluklar ile ANFİS model için test ve eğitim verileri elde edilmiştir. ANFİS çoklu girdi ve çıktılarla doğrusal olmayan ilişkinin tahmininde iyi performans göstermektedir. Bu sebepten dolayı elde edilen test ve eğitim verileri, Matlab programında ANFİS ile eğitilmiş ve sonuçlar incelenmiştir. Yapılan eğitimlerde, ANFİS model de giriş üyelik fonksiyon tipi olarak trimf, üyelik fonksiyonu sayıları olarak ise 2 2, 3 3, 4 4, 5 5 kullanılmış, çıkış üyelik fonksiyonu constant olarak seçilmiştir. Tüm deneyler için kullanılan MAPE, MSE, RMSE istatistiksel eşitliklerine göre seçilen üyelik fonksiyonlarının tahminleme performansları karşılaştırılmıştır. Elde edilen sonuçlar, ANFİS modelinin Mg-Zn toz karışımlarının sıkıştırılabilirliğinde kullanılabilirliğini göstermiştir.

Investigation of Prediction Performance of Compressibility of Mg Alloys with ANFIS Model

Abstract

Keywords

ANFIS; Powder
Metallurgy;
Mg Alloy;
Compressibility

In this study, powder mixtures of Mg alloys with different Zn (5% and 10% by weight) ratios are attained, and the test and training data for the ANFIS model with the aid of the raw densities, which is calculated by compressing at different compression pressures, are determined. ANFIS performs well in estimating the nonlinear relationship with multiple inputs and outputs. For this reason, the test and training data obtained is handled with ANFIS in the Matlab program, and the results are analyzed. In the pieces of training performed, trimf is selected as the input membership function type, 2 2, 3 3, 4 4, 5 5 is selected as the membership function numbers, and the output membership function is selected as constant in the ANFIS model. The estimation performances of the membership functions chosen regarding MAPE, MSE, and RMSE statistical equations used for all experiments are checked. The results obtained showed the usability of the ANFIS model in the compressibility of Mg-Zn powder mixtures.

© Afyon Kocatepe Üniversitesi

1. Giriş

1774 yılında keşfedilen ve adını antik kent Magnesia'dan alan, yer kabuğunun toplam kütlelerinin %2'sini oluşturan magnezyum alaşımı doğada en çok bulunan 6. Elementtir (Norsk 1996). Magnezyum, kullanımı en yaygın metal olan çeliğe (~ ¼) ve alüminyuma (~ ½) göre oldukça düşük

yoğunluğa (1,738 g/cm³) sahiptir. Hafif bir metal olmasının yanı sıra; iyi dökülebilirlik, geri dönüşebilirlik ve atmosfer kontrollünde iyi kaynaklanabilirlik gibi özellikleri olan magnezyumun kullanımı günümüzde yaklaşık olarak 10 kat artmıştır (Mordike and Ebert 2001, Gupta and Ling 2011, Polmear *et al.* 2017). Bunun yanı sıra magnezyumun

düşük dayanımı gibi bazı dezavantajları vardır. Dayanımını arttırmak amacıyla alaşım elementleri ile Mg alaşımları elde edilmeye çalışılmaktadır (Moreno *et al.* 2001, Özarslan vd. 2019). AZ31, AZ61 ve AZ91 gibi AZ alaşımları olarak adlandırılan Mg alaşımları endüstrilerde yaygın olarak kullanılmaktadır (Marya *et al.* 2006). Magnezyum alaşımları bahsedebilen avantajlarından dolayı otomotiv, elektronik, biyomedikal ve havacılık gibi endüstriler için en uygun aday malzeme olarak kabul edilmektedir (Mordike and Ebert 2001, Wang *et al.* 2011, Jiang *et al.* 2012, Zhang *et al.* 2012, Chen *et al.* 2015).

Döküm ve geleneksel imalat yöntemlerine alternatif olarak belirtilen toz metalurjisi; neredeyse her malzemeye uygulanabilen, hassas, karmaşık ve net şekilli parçaların elde edilmesini hatta seri üretimini sağlayan bir üretim yöntemidir (German 2007). Bu üretim yönteminin önemli aşamalarından biri olan tozların sıkıştırılmasında amaç tozların belirli bir ham yoğunluğa ulaşmasını sağlamaktır (Upadhyaya 1999). Tozların sıkıştırılabilirliğinin belirlenmesinde, sıkıştırma aşamada soğuk sıkıştırma olarak farklı sıkıştırma basınçlarında tozlar sıkıştırılarak ham yoğunluğun değişimi ve sıkıştırma aşamaları ile basınç yoğunluk değişim eğrisi elde edilmeye çalışılmaktadır. Ancak bu aşamada çok fazla metal tozu kaybı yaşanacağından dolayı sıkıştırma basıncına karşılık gelen yoğunluğun tahminlenmesi için farklı yöntemlerin kullanması önem arz etmektedir.

Adaptive Neuro-Fuzzy Inference System (ANFİS), sinir ağlarının geriye yayımlı öğrenme yeteneği ile bulanık mantığın sonuç çıkarma özelliklerinin entegre edildiği bir hibrit öğrenme algoritmasını kullanan birinci dereceden Takagi Sugeno bulanık modeline dayanmaktadır (Jang 1993, Piero 2002, Yazdi *et al.* 2010). Çıkış verileri, giriş verilerinin üyelik fonksiyonları ile bulanıklaştırılması ile elde edilen bulanık kurallar ağ üzerinde dağıtılarak hesaplanmaktadır. Bu nedenle ANFİS çoklu girdi ve çıktılarla doğrusal olmayan ilişkinin tahmininde iyi performans göstermektedir (Erdirencelebi and Yalpir 2011, Haznedar vd. 2017).

ANFİS yönteminin mühendislik uygulamalarında geniş bir kullanım alanı bulunmaktadır. Bunlar arasında Harita mühendisliğinde (Yılmaz 2010, Yalpir and Ozkan 2018) biyomedikal bilimlerde (Buyukbingol *et al.* 2007), inşaat mühendisliğinde (Yılmaz 2010, Yalpir and Ozkan 2018), vb. gibi çalışmalar bulunmaktadır.

Makine mühendisliği alanında ise işlenebilirlik, aşınma ve yüzey pürüzlülüğü gibi alanlarda Taguchi yöntemi ile tahmin yaygın bir şekilde kullanılmaktadır (Gaitonde *et al.* 2008, Ghose *et al.* 2011, Kayır vd. 2013, Çelik ve Kıvak 2016, Kara *et al.* 2017, Basmacı 2018, Yıldırım 2019, Jeyaprakash *et al.* 2020, Kechagias *et al.* 2020). Ancak literatür incelendiğinde benzer alanlarda tahminleme için ANFİS kullanımının da arttığı gözlemlenmiştir (Hossain and Ahmad 2014, Maher *et al.* 2014, Shivakoti *et al.* 2019, Ergül ve Kurt 2021). Shivakoti ve arkadaşları yaptıkları çalışmada; 202 paslanmaz çeliğinin işlenmesinde yüzey pürüzlülüğü ve talaş kaldırma oranının tahmini için L16 ortogonal dizine göre ANFİS modelleri geliştirmişlerdir. Ayrıca, kesme parametrelerinin etki oranlarını tespit etmek amacıyla ANOVA uygulamışlardır. Elde ettikleri sonuçlarda ise ANFİS modellerinin yüksek tahmin yeteneğine sahip olduğunu belirtmişlerdir (Shivakoti *et al.* 2019). Maher ve arkadaşları da; prınç alaşımının CNC parmak frezelemede, mil ve ilerleme hızı ile kesme derinliği değişkenlerine göre yüzey pürüzlülüğünün tahmin edilebilirliğini gözlemlemek için ANFİS kullanmışlardır. Çalışmalarında ölçülen ve tahmin edilen yüzey pürüzlülüğü verilerini karşılaştırmışlar, yüzey pürüzlülüğü için en büyük tahmin hatasının %6,25 ve ortalama tahmin hatasının ise %2,75 olduğunu belirtmişlerdir (Maher *et al.* 2014). Hossain ve Ahmad ise alüminyumun frezelemede, 49 eğitim verisi ile kesme parametrelerinin yüzey pürüzlülüğüne etkisi için tahmin modelleri geliştirmek amacı ile ANN, RSM, ANFİS ve teorik denklemler kullanmışlardır. 25 test verisi ile de tüm tahmin modellerinin doğruluğunu test etmişlerdir. Elde ettikleri sonuçlarda ise ANFİS modelinin, eğitim ve test verileri için ortalama karekök hatası (RMSE) ve ortalama mutlak yüzde

hatasının (MAPE) en küçük değeri verdiği için daha iyi tahmin modeli olarak seçildiğini ifade etmişlerdir (Hossain and Ahmad 2014). Yapılan çalışmalardan farklı olarak Ergül ve Kurt ise seramik parçacık takviyeli metal esaslı kompozitlerin mekanik özelliklerinin incelemesinde ANFİS ve ANN yöntemlerini kullanmışlardır. ANFİS modelde, SiC parçacık takviyesi, sıkıştırma basıncı, sinterleme sıcaklığı ve sürelerini giriş parametresi olarak kullanarak % gözenek oranını tahminlemeye çalışmışlardır. Elde ettikleri sonuçlarda, yaklaşımların korelasyon katsayılarının ve istatistiksel hata oranlarının iyi olduğu belirtmişlerdir. Ayrıca Al-Mg-Al₂O₃ kompozitlerin bağıl sinter yoğunluklarını ANN yöntemiyle tahmin etmeye çalışmışlar ve tahmin oranın %81 olduğunu ifade etmişlerdir. Bu doğruluk oranın ise kabul edilebilir sınırlar içerisinde olduğunu söylemişlerdir. Bu çalışmalara ek olarak ise Taguchi yaklaşımı ile Al₂O₃ ve SiC parçacık takviyeli kompozit malzemelerin bağıl sinter yoğunluklarını incelemişler ve sonuçları karşılaştırmışlardır (Ergül ve Kurt 2021).


Yapılan çalışmada, incelenen literatürde numunelerin yoğunluğuna, toz metalurjisi üretim parametrelerinin etkisini ANFİS model tahminlemesi ile inceleyen sınırlı sayıda çalışma bulunmaktadır. Buna karşın doğrudan toz karışımlarının sıkıştırılabilirliğinin araştırılması ile ilgili çalışmaya ulaşamamıştır. Bundan dolayı Mg-Zn alaşımlarının sıkıştırılabilirliğinin ANFİS model ile tahmin edilebilirliğinin incelenmesi amaçlanmıştır. Bu kapsamda farklı Zn (ağırlıkça %5 ve 10 Zn) oranlarına sahip Mg alaşımlarına ait toz karışımları hazırlanmış ve farklı sıkıştırma basınçlarında sıkıştırılarak hesaplanan ham yoğunluklar ile ANFİS model için test ve eğitim verileri elde edilmiştir. Elde edilen test ve eğitim verileri, Matlab programında ANFİS ile eğitilmiş ve sonuçlar incelenmiştir.

2. Materyal ve Metot

2.1 Malzeme ve Örneklerin Hazırlanması

Sigma Aldrich firmasından temin edilen Mg ve Zn toz parçacıkları ile iki farklı (ağırlıkça %5 ve 10 Zn) Mg-

Zn alaşımı hazırlanmıştır. Hazırlık aşamasında belirlenen oranlarda metal karışımlarının tartımı Şekil 1a'da verilen hassas terazi ile gerçekleştirilmiştir. Sonraki aşamada ise hazırlanan toz karışımları, 4 saat boyunca 3D karıştırıcı (Şekil 2b) ile homojen bir dağılıma sahip olabilmeleri için karıştırılmıştır.



Şekil 1. a) Hassas terazi, b) Soğuk pres, c) Karıştırıcı



Şekil 2. Sıkıştırmada kullanılan kalıplar

En son aşamada ise toz karışımları farklı sıkıştırma basınçlarında soğuk pres (Şekil 1c) ile preslenmiştir. Sıkıştırma esnasında farklı basınç değerlerine ulaşabilmek için üç farklı (2cmx2cm, 1,3cmx1,3 cm ve Ø 1,3 cm) boyutta kalıp kullanılmıştır (Şekil 2).

Elde edilen ham örneklerin yoğunluklarının belirlenmesi aşamasında ise öncelikle hassas terazi (Şekil 1a) ile kütleleri belirlenmiştir. Sonrasında ise boyutsal olarak hacim hesabı yapılarak, ham yoğunlukları hesaplanmıştır. Hacim hesabında boyut ölçümleri, dijital kumpas ile gerçekleştirilmiştir. Gerçekleştirilen ölçümler sonucunda hesaplanan deneysel ham yoğunlukları ile hesaplanan teorik ve bağıl ham yoğunlukları ağırlıkça % Zn miktarı ve sıkıştırma basıncına göre Çizelge 1'de verilmiştir. Elde edilen sonuçlar incelendiğinde artan sıkıştırma basıncı ile iki alaşım için bağıl ham yoğunluk değerlerinin arttığı ve en yüksek ham yoğunluğa ise 600 MPa sıkıştırma

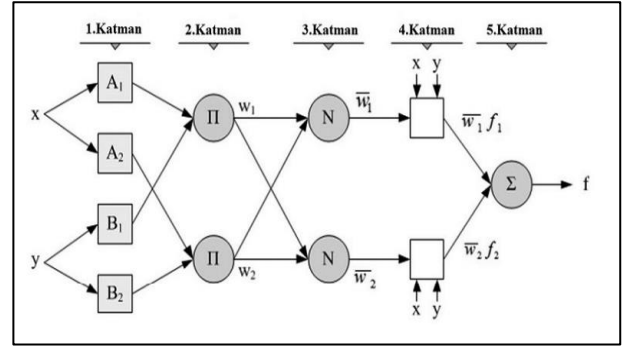
basıncında ulaştıkları gözlemlenmiştir. Buna ek olarak alaşımda artan Zn miktarı ile ulaşılan bağıl ham yoğunluk değerlerinin ve sıkıştırılabilirliğin daha düşük olduğu sonuçları elde edilmiştir.

Çizelge 1. Ağırlıkça % Zn ve sıkıştırma basıncına göre teorik, ham ve bağıl ham yoğunluk değerleri

Ağırlıkça %Zn	Sıkıştırma Basıncı (MPa)	Teorik Yoğunluk (g/cm ³)	Ham Yoğunluk (g/cm ³)	Bağıl Ham Yoğunluk
5	100	1,8063	1,4693	0,8135
5	150	1,8063	1,6060	0,8891
5	200	1,8063	1,6423	0,9092
5	350	1,8063	1,7353	0,9607
5	400	1,8063	1,7405	0,9636
5	450	1,8063	1,7577	0,9731
5	500	1,8063	1,7606	0,9747
5	550	1,8063	1,7842	0,9878
5	600	1,8063	1,7860	0,9888
10	100	1,8803	1,5010	0,7983
10	150	1,8803	1,6505	0,8778
10	200	1,8803	1,6884	0,8979
10	250	1,8803	1,7650	0,9387
10	400	1,8803	1,7824	0,9479
10	450	1,8803	1,7883	0,9511
10	500	1,8803	1,7911	0,9526
10	550	1,8803	1,7958	0,9551
10	600	1,8803	1,8073	0,9612

2.2 Yöntemler

Bulanık kuralları birbirine bağlayan giriş ve çıkış parametrelerinin optimizasyonu ile modelin eğitimi yapılmaktadır. Şekil 3'te iki giriş ve bir çıkıştan oluşan temel bir ANFİS yapısı verilmiştir. ANFİS 5 tane katmandan oluşmaktadır (Karaboga and Kaya 2014, Haznedar vd. 2017)



Şekil 3. Temel ANFİS yapısı (Uzundurukan 2006)

Bu katmanlar sırası ile;

1. Katman

Bulanıklaştırma katmanı olarak bilinen bu katmanda A_i ve B_i gibi bulanık kümeler her bir düğümü belirtmektedir. Her bir düğüm noktasından alınan sinyaller bir diğer katmana aktarılmaktadır. Bu sinyal, kullanılan üyelik fonksiyon türüne ve giriş verisine göre elde edilmektedir. x ve y değerleri düğümün giriş değişkenlerini göstermektedir (Jang and Sun 1995).

2. Katman

Bulanıklaştırma katmanından elde edilen üyelik dereceleri çarpılarak bir sonraki katmana aktarılmaktadır. Bu katmanda her bir düğüm sabittir. Her bir düğüm bir kural ile temsil edilmektedir. Bu nedenle bu katmana kural katmanı denilmektedir (Kassa *et al.* 2016). Her bir düğüm çıkışı için ateşleme kuvveti hesaplanmaktadır.

3. Katman

Bu katmanda, kural katmanından ateşleme kuvveti normalize edildiği için normalizasyon katmanı denilmektedir (Jang *et al.* 1997).

4. Katman

Normalizasyon katmanından gelen normalize edilmiş ateşleme kuvveti değerinin birinci dereceden polinom ile çarpılmasıyla her bir kuralın çıkış değeri hesaplanmaktadır. Bu katmana durulaştırma katmanı da denilmektedir. Bu

katmanda her bir düğümün model çıktısı üzerindeki katkısı hesaplanmaktadır (Jang *et al.* 1997, Haznedar vd. 2017).

5. Katman

Durulaştırma katmanından elde edilen her kurala ait çıkış verileri toplanıp ANFİS'in çıkış verisi elde edilmektedir. Bu nedenle bu katmana çıkış katmanı denilmektedir (Haznedar vd. 2017).

ANFİS sinirsel ve bulanık bir ağ modelidir. ANFİS modelinin bulanık yapısı adaptasyon ve öğrenme kısmının da, sinirsel ağ yapısı ise kontrol elemanlarını ağ yapı etrafında yayararak doğrusal olmayan problemlerin çözümünde kolaylıklar sağlamaktadır (Haznedar vd. 2017). Giriş ve çıkış parametreleri ANFİS yapısının parametreleridir. Öncelikle eğitim verileri yapay sinir ağına girilir, seçilen eğitime algoritması ile ağ eğitim verileri ile girdi ve çıktı fonksiyonel model ilişkisini öğrenir. Başka bir ifade ile verilere optimizasyon işlemi uygulanmaktadır. ANFİS modelinden elde edilen sonuçlar ile eğitim seti arasındaki farkın kareler toplamının minimum olduğu durumun bulunması temel amaçtır (Perez 2001, Caner ve Akarşlan 2009).

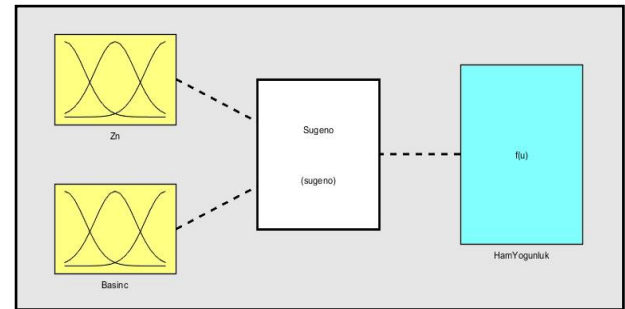
MATLAB'da Fuzzy araç kutusunun ANFİS (Adaptive Neuro-Fuzzy Inference System) editörü ile Sugeno yapısında bir model oluşturulmuştur. Yapılan çalışmada deneysel olarak elde edilen veriler, ANFİS modeli için giriş verileri olarak girilmiştir. Elde edilen veriler eğitim (training) ve test (testing) olmak üzere iki kısma ayrılmıştır (Çizelge 2). Buradaki amaç girilen eğitim verileri sonucunda test (testing) verilerinin ne kadar doğru bir şekilde belirlenebildiğini gözlemlemektir. Ayrıca ANFİS yapısındaki üyelik fonksiyonunun etkisini gözlemleyebilmek için, farklı üyelik fonksiyonu (2 2, 3 3, 4 4, 5 5) değerleri girilerek incelemeler yapılmıştır. Kurulan ANFİS modeli ile alaşımda bulunan ağırlıkça % Zn miktarı ve sıkıştırma basıncının ham yoğunluğa etkisi tahmin edilmeye çalışılmıştır. Bu amaçla oluşturulan ANFİS modeline ait yapı Şekil 4'te verilmiştir. Literatürde görüldüğü gibi, verilerin yaklaşık üçte ikisi (11 veri) ile verilerin eğitilmesi ve

kalan üçte biri (7 veri) ile test edilmesi gerekmektedir (Brondino and Silva 1999, Lokshina *et al.* 2003).

Giriş ve çıkış parametrelerinin ANFİS model yapısı oluşturulma aşamasından sonra, Eğitim ve test verilerinin ANFİS modele aktarılması Şekil 5'te gösterildiği gibi gerçekleştirilmiştir.

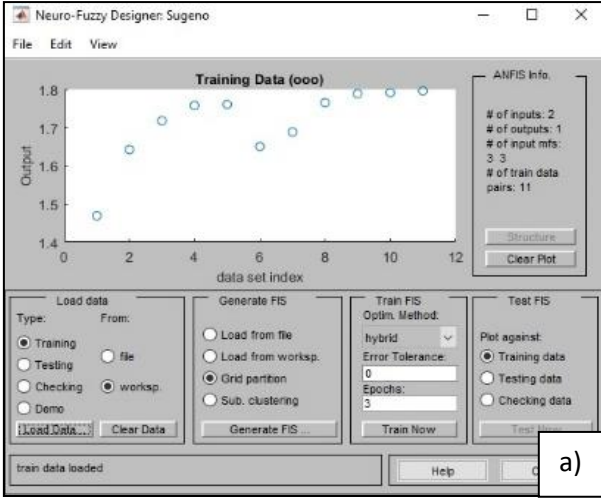
Çizelge 2. ANFİS model için eğitim ve test verileri

	Deney No	w.% Zn	Sıkıştırma Basıncı (MPa)	Ham Yoğunluk (g/cm ³)
Eğitim Verisi	1	5	100	1,4693
	2	5	200	1,6423
	3	5	250	1,7175
	4	5	450	1,7577
	5	5	500	1,7606
	6	10	150	1,6505
	7	10	200	1,6884
	8	10	250	1,7650
	9	10	450	1,7883
	10	10	500	1,7911
	11	10	550	1,7958
Test Verisi	1	5	150	1,6060
	2	5	400	1,7405
	3	5	550	1,7842
	4	5	600	1,7860
	5	10	100	1,5010
	6	10	400	1,7824
	7	10	600	1,8073

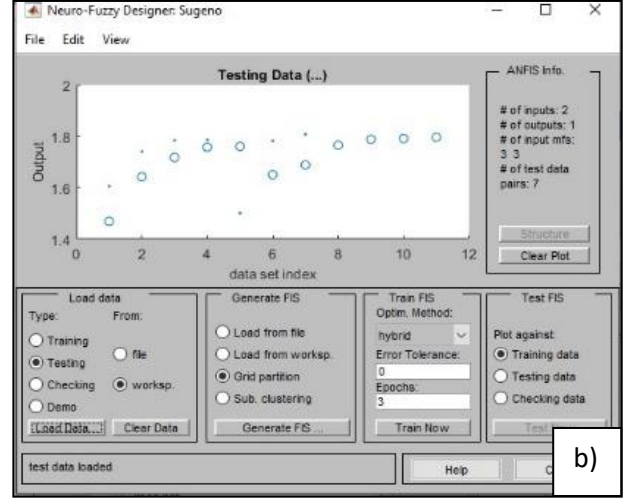


Şekil 4. ANFİS modelinde giriş ve çıkış parametrelerinin gösterimi

Bir sonraki aşamada ise üyelik fonksiyon tipi ve sayıları belirlenmiştir. Giriş üyelik fonksiyon tipi olarak trimf kullanılmış, üyelik fonksiyonu sayıları olarak ise 2 2, 3 3, 4 4, 5 5 belirlenirken, çıkış üyelik fonksiyonu constant olarak seçilmiştir (Şekil 6).



a)



b)

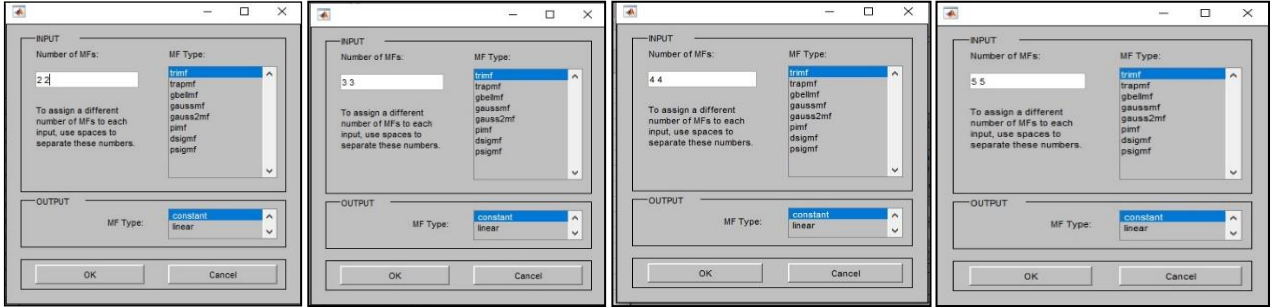
Şekil 5. a) Eğitim verilerinin ANFİS modele aktarımı,

b) Test verilerinin ANFİS modele aktarımı

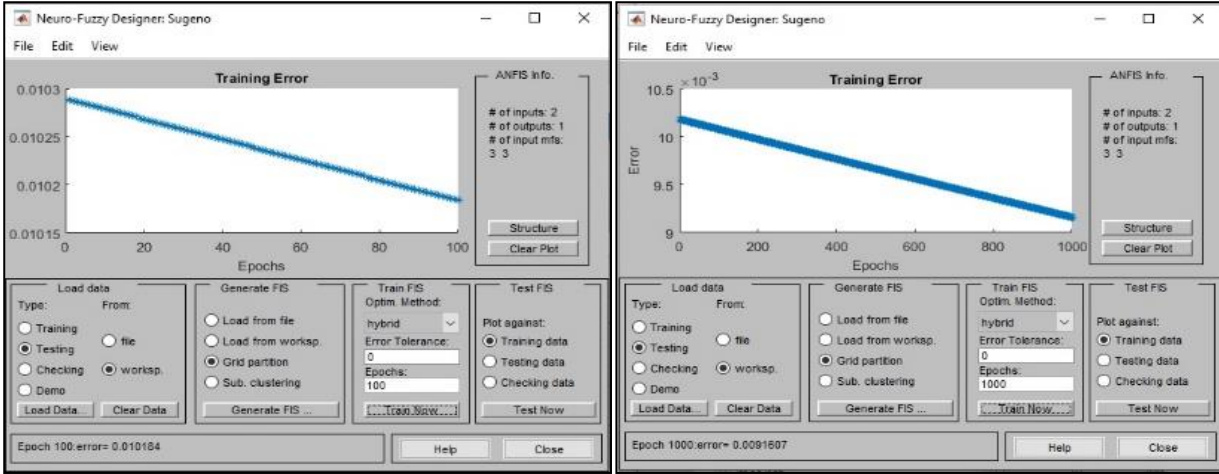
Üyelik fonksiyon tipi ve sayılarının belirlenmesi aşamasından sonra sıfır hata toleransı ile hybrid öğrenme optimizasyon yöntemi kullanılarak 100 ve 1000 epochta eğitim verileri ayrı ayrı eğitilmiştir. Bu eğitimde en düşük karesel ortalama hata sonucuna ulaşmak amaçlanmıştır. Eğitim sonucunda ise 1000 epoch için karesel ortalama hata değerinin $\sim 0,0092$ olduğu sonucuna ulaşılırken 100 epoch için ise hata değeri $\sim 0,0102$ olarak belirlenmiştir. Elde edilen sonuçlara göre 1000 epoch için karesel ortalama hata değerinin daha düşük olduğu gözlemlenmiştir.

Bu nedenle çalışmada kullanılan tüm üyelik fonksiyon sayıları için 1000 epoch kullanılmıştır (Şekil 7).

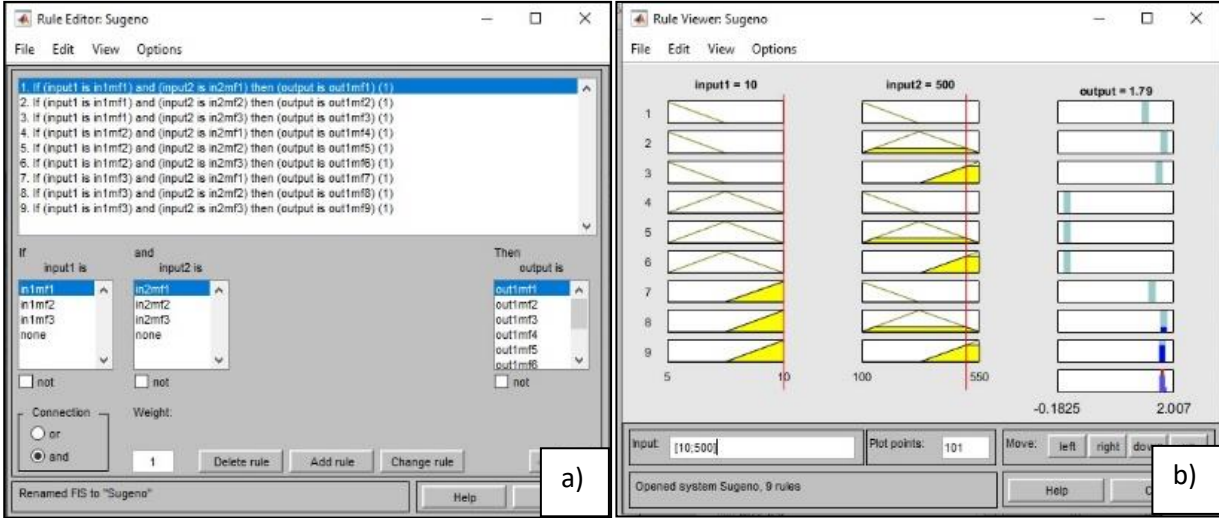
En son aşamada ise ANFİS sistemi bulanık kural tabanlı çalıştığı için Şekil 8a'da bulunan kurallar kullanılarak çıktılar tahmin edilmiştir. Kurulan ANFİS sistemine göre iki giriş değerleri (ağırlıkça %5 ve 10 %Zn oranı, farklı sıkıştırma basıncı) kullanılarak çıkış değişkeninin değeri belirlenmiştir (Şekil 8b).



Şekil 6. Giriş ve çıkış üyelik fonksiyonu değişkenleri



Şekil 7. 100 ve 1000 epoch için karesel ortalama hata değerleri



Şekil 8 a. ANFIS modele ait kurallar, b. Kurallara bağlı elde edilen sonuç tahmini

Tahminlemede kurulan modelin performansı, tahminleme hatası ile ilgili çeşitli istatistik eşitlikler ile ölçülür. Elde edilen hata değerleri ne kadar yüksek ise tahminlemede ulaşılan sonucun doğruluğu o kadar az anlamına gelir. Bu amaçla kurulan ANFIS model ve seçilen üyelik fonksiyonlara ait tahminlemenin doğruluğunu ölçmek için yaygın olarak kullanılan bazı istatistiksel eşitlikler belirlenmiştir. Kullanılan istatistiklere ait eşitlikler, ortalama mutlak yüzde hata (MAPE), ortalama karesel hata (MSE) ve ortalama karekök hata (RMSE) olarak seçilmiş ve bu istatistiklerin eşitliklerine ait denklemler sırasıyla Denklem (1)-(3)'te verilmiştir (Chatfield 2000, Demirel *et al.* 2010, Ghofrani and Alolayan 2018, Gujarati 2021).

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{a_i - b_i}{a_i} \right| * 100\% \quad (1)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (a_i - b_i)^2 \quad (2)$$

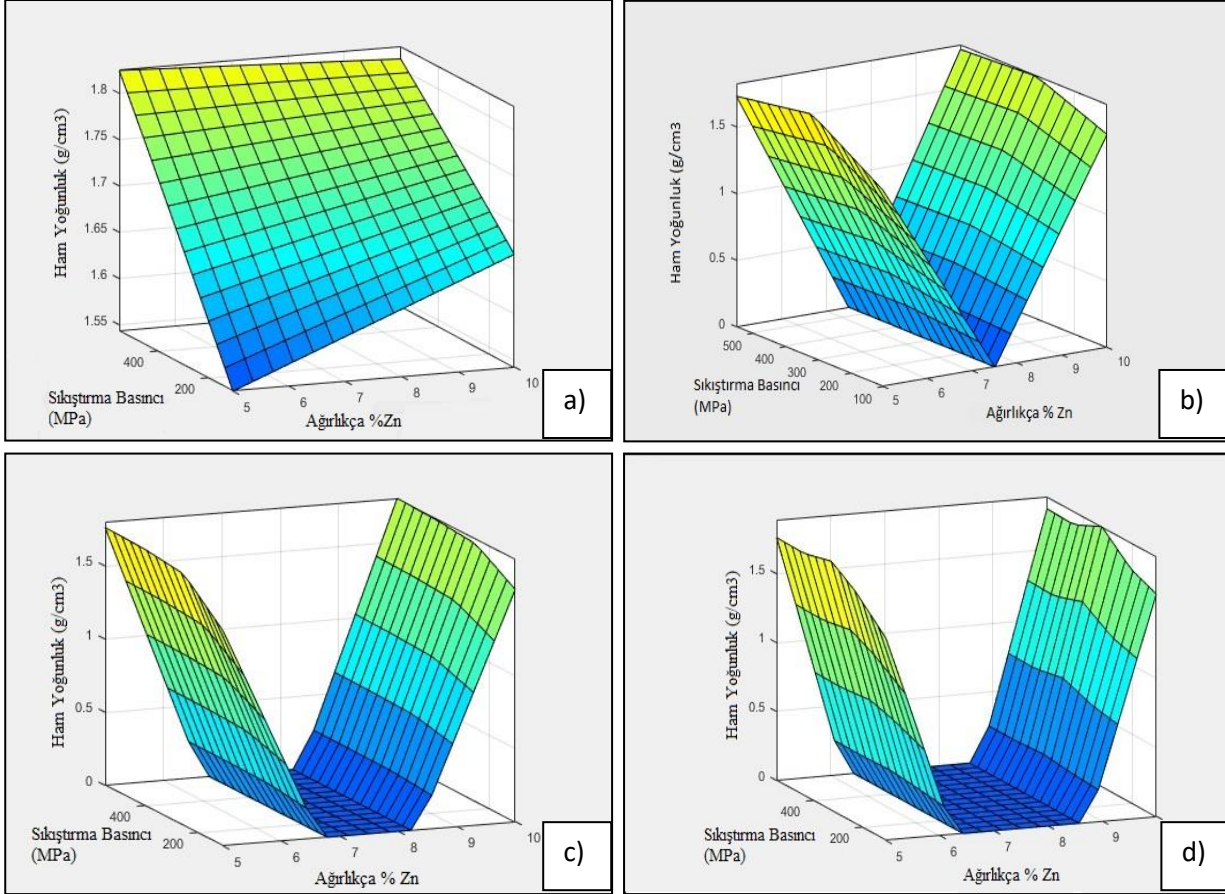
$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (a_i - b_i)^2} \quad (3)$$

Verilen eşitliklerde, a_i deneysel olarak belirlenen ham yoğunluğu verirken, b_i ise kurulan modele sonucu tahmin edilen ham yoğunluk değerini vermektedir. n ise yapılan toplam deney sayısını vermektedir. Hesaplar eğitim ve test verileri için ayrı ayrı yapılmış ve tüm hata eşitliklerinin eğitim ve test verilerinin ortalama değerleri verilmiştir. Son olarak ise tüm deneyler için (eğitim ve test ayrı olacak şekilde) MAPE için değerleri hesaplanarak her deney için % hataları belirlenmiştir.

3. Bulgular ve Tartışma

Kurulun ANFİS modelin eğitilmesi ile sıkıştırma basıncı, ağırlıkça %Zn ve ham yoğunluk arasındaki ilişkileri gösteren üç boyutlu grafikler her bir üyelik fonksiyonu için Şekil 9'da gösterilmektedir. Elde edilen grafikler incelendiğinde artan sıkıştırma basıncı ile her iki Zn miktarında da alaşıma ait ham yoğunluk değerinin arttığı gözlemlenmiştir. Ayrıca grafiklerden, Zn miktarının artması ile de ham

yoğunluk değerlerinin arttığı sonucu elde edilmiştir. Literatürde de elde edilen grafiklerle ile benzer şekilde artan sıkıştırma basıncı ile toz karışımlarının ham yoğunluk değerlerinin arttığı bilinmektedir (Lund 1982, Bouvard 2000, Wu *et al.* 2000, Denny 2002, Hafizpour *et al.* 2009, Mahdavi and Akhlaghi 2011). Elde edilen sonuçların, incelenen literatür ile benzerlik gösterdiği belirlenmiştir.



Şekil 9. Farklı Üyelik fonksiyonların ait parametreler arasındaki ilişkiyi veren üç boyutlu grafikler a. m22, b. m33, c. m44 ve d. m55

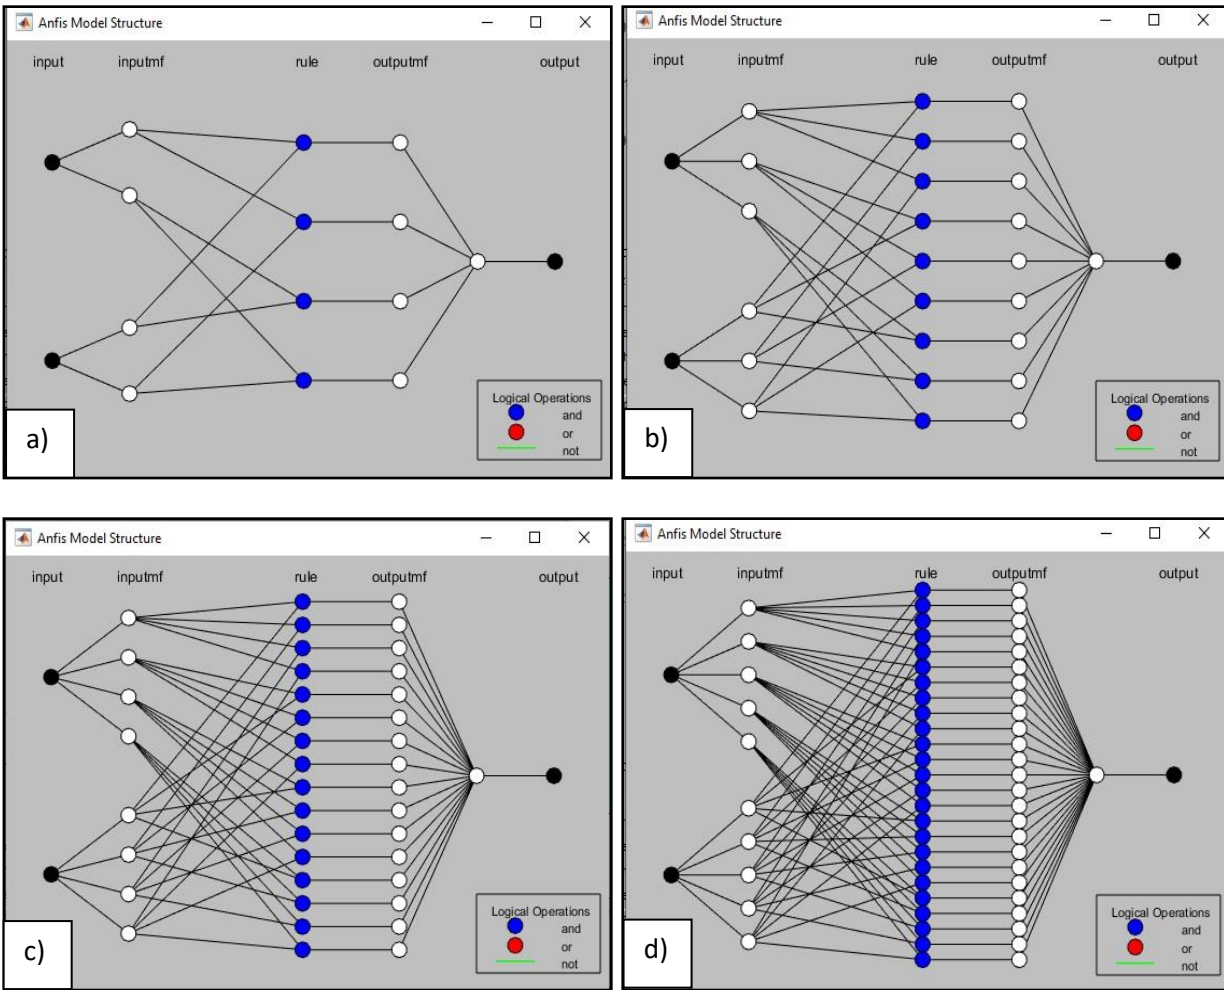
Toz metalürjisinde ham yoğunluğun belirlenmesi amacı ile kurulan ANFİS modeli için farklı üyelik fonksiyonlarına (m22, m33, m44 ve m55) ait ANFİS yapıları Şekil 10'da verilmiştir. Uygulanan ANFİS modeli, ağırlıkça %Zn ve sıkıştırma basıncı olmak üzere iki giriş ve bir çıkış (ham yoğunluk) parametrelerinden oluşmaktadır. Elde edilen ANFİS yapılarının sol tarafında bulunan siyah düğümler (input) ağırlıkça %Zn oranı ve sıkıştırma basıncını verirken hemen sonrasında gelen beyaz düğümler (inputmf) ise oluşturulan üyelik fonksiyonlarını (m22, m33, m44 ve m55) göstermektedir. Mavi renkli düğümler (rule) ise ikinci katmanı

oluşturmakta ve girdi, üyelik fonksiyonlarına göre elde edilen kuralları (sırası ile 4, 9, 16, 25) vermektedir. Üçüncü katmanda ise sırası ile 4, 9, 16 ve 25 adet kural için normalizasyon işlemi uygulanmıştır. Dördüncü katmanda her bir kuralın çıkış değeri hesaplanmıştır. Son katmanda ise her bir kural için hesaplanan değerler toplanmış ve ANFİS'in çıkış verisi elde edilmiştir.

Oluşturulan ANFİS yapılarının sonrasında ise deneysel olarak elde edilen eğitim ve test verilerine ait gerçek ve üyelik fonksiyonlarına göre tahmini ham yoğunluk değerleri Çizelge 3'te verilmiştir. Elde edilen ham yoğunluk değerleri incelendiğinde

eğitim veriler için m55 üyelik fonksiyonunun tüm deney numuneleri için deneysel ham yoğunluklara yakın değerler verdiği gözlemlenmiştir. Ayrıca m44 üyelik sonuçları için de aynı şekilde tahminlenen ham yoğunluk değerlerinin de m55 üyelik fonksiyonuna çok benzer olduğu ve tüm deney numunelerinde eğitim verileri için benzer eğilimde olduğu belirlenmiştir. Eğitim verileri için elde edilen bu sonuçların yanı sıra m33 ve m22 üyelik fonksiyonları için de tahminlenen ham yoğunluk değerlerinin deneyselden çok uzaklaşmadığı söylenebilir. Ancak benzer eğilim test verilerinde gözlemlenememiştir. Test verilerinde ise deneysel sonuçlara en yakın sonucu veren üyelik fonksiyonları

deney numaraları için değişkenlik göstermiş ve incelenen çizelgede test verisinde 2 numaralı deney numunesi için en yakın ham yoğunluk değerini m22 üyelik fonksiyonu verirken 5 numaralı deney numunesi için ise m44 üyelik fonksiyonu vermiştir. Bu farklılıklardan dolayı sonuçları daha iyi yorumlayabilmek amacı ile eğitim ve test verilerine ait ham yoğunluk değerlerinin, tahmini sonuçlarının gerçek sonuçlardan ne kadar saptığını gözlemleyebilmek için eğitim ve test verilerine ait grafikler oluşturulmuştur (Şekil 11 ve 12).



Şekil 10. Üyelik Fonksiyonlarına göre ANFİS yapıları a. m22, b. m33, c. m44 ve d. m55


İncelenen Şekil 11’de eğitim verileri için verilen grafikte daha önce bahsedildiği gibi m33, m44 ve m55 üyelik fonksiyonları için tahminlenen yoğunluklara ait değerlere ait eğrilerin, deneysel veriler ile neredeyse üst üste geldiği özellikle m55’in tam çakıştığı gözlemlenmektedir. Ancak m22 üyelik fonksiyonuna ait eğri incelendiğinde ise sonuçların

m33, m44 ve m55 göre deneysel sonuçlardan uzaklaşmanın bir miktar daha fazla olduğu ve bu farkın 1 ve 3 numaralı deney numunelerinde belirginleştiği söylenebilir. Test verilerinin ise eğitim verileri için elde edilen sonuçlardan farklı bir eğilim sergilediği Şekil 12’de verilen grafik ile belirlenmiştir. Grafik incelendiğinde test verilerinin üyelik

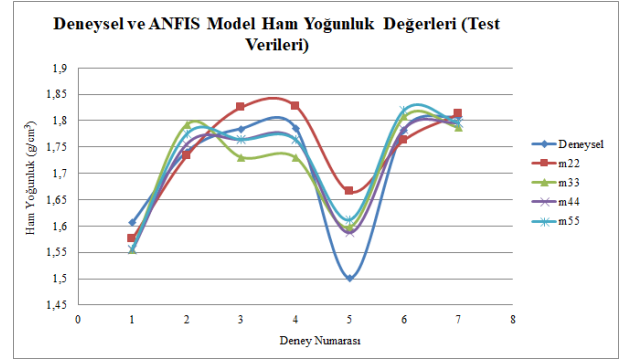
fonksiyonlarına ait sonuçların tahminleme performansının deney numaralarına göre farklılık gösterdiği gözlemlenmiştir. Tüm üyelik fonksiyonları gözlemlendiğinde 2 numaralı deney için m22 üyelik fonksiyonunun ulaştığı $1,7327 \text{ g/cm}^3$ değeri ile en iyi sonucu verdiği söylenirken, 3 numaralı deney için ise m44 ve m55 üyelik fonksiyonlarının sırası ile $1,7635$ ve $1,7638 \text{ g/cm}^3$ değerleri ile en uygun üyelik fonksiyonları olduğu belirtilebilir. Bunun yanı sıra tüm üyelik fonksiyonlarında, 5 numaralı örnek için tahminlenen ham yoğunluk değerlerinin (özellikle m22) gerçek değerden en belgin şekilde uzaklaştığı gözlemlenmiştir. Bu durumdan dolayı test verilerinde en iyi tahminleme sonucunu hangi üyelik fonksiyonunun verdiğini net bir şekilde ifade etmek mümkün olmamıştır. Ayrıca grafik incelendiğinde test verilerinin deneysel ham yoğunluk değerlerinden, eğitim verilerine göre daha fazla uzaklaştığı sonucu elde edilmiştir. Test verileri için bahsedilen sebeplerden dolayı ve tahminlenen tüm ham yoğunluk değerlerinin kabul edilebilirliğinin tartışılabilmesi için istatistiksel hata eşitlikleri değerleri ile net bir yoruma ulaşılmaya çalışılmıştır.

Çizelge 3. Eğitim ve test verileri için deneysel ve tahminlenen ham yoğunluk değerleri

Deney No	Deneysel Ham Yoğunluk (g/cm^3)	ANFIS Model Sonucu Yaklaşık Ham Yoğunluk Değerleri				
		m22	m33	m44	m55	
Eğitim Verisi	1	1,4693	1,5433	1,4732	1,4709	1,4693
	2	1,6423	1,6073	1,6356	1,6375	1,6423
	3	1,7175	1,6389	1,7165	1,7207	1,7175
	4	1,7577	1,7636	1,7714	1,7577	1,7577
	5	1,7606	1,7943	1,7507	1,7606	1,7606
	6	1,6505	1,6815	1,6488	1,6440	1,6505
	7	1,6884	1,6980	1,6994	1,7013	1,6884
	8	1,765	1,7145	1,7499	1,7585	1,7650
	9	1,7883	1,7792	1,8003	1,7880	1,7880
	10	1,7911	1,7951	1,7936	1,7917	1,7916
	11	1,7958	1,8109	1,7871	1,7955	1,7955
Test Verisi	1	1,606	1,5754	1,5545	1,5542	1,5565
	2	1,7405	1,7327	1,7922	1,7548	1,7745
	3	1,7842	1,8247	1,7304	1,7635	1,7638
	4	1,786	1,8274	1,7299	1,7635	1,7638
	5	1,501	1,6648	1,5981	1,5868	1,6119
	6	1,7824	1,7631	1,8070	1,7842	1,8199
	7	1,8073	1,8123	1,7869	1,7955	1,7956



Şekil 11. Eğitim verilerine ait gerçek ve tahmini ham yoğunluk değerleri



Şekil 12. Test verilerine ait gerçek ve tahmini ham yoğunluk değerleri

Kurulan ANFİS modeli ve uygulanan üyelik fonksiyonlarının doğruluğunu ölçmek için hesaplanan yüzde (%) RMSE, MSE, MAPE değerleri Çizelge 4’de verilmiştir


Çizelge 4. Hesaplanan yüzde (%) MAPE ve RMSE, MSE değeri

Performans Hata Eşitlikleri	Eğitim Verisi				Test Verisi			
	m22	m33	m44	m55	m22	m33	m44	m55
MAPE (%)	1,8978	0,4525	0,1985	0,0054	2,7443	3,0446	1,8487	2,1503
MSE	0,0016	0,0001	0,00	0,00	0,0045	0,0031	0,0016	0,0026
RMSE	0,0404	0,0092	0,0051	0,0002	0,0672	0,0558	0,0402	0,0512

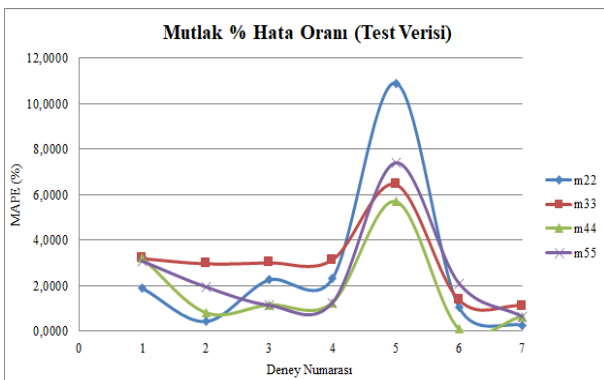
Eğitim ve test verileri için hesaplanan ortalama hata değerleri (Çizelge 4) incelendiğinde değerlerin özellikle eğitim verileri için sıfıra çok yakın olduğu gözlemlenmiştir. Kullanılan hata eşitlikleri için beklenen amaç elde edilen sonucun en küçük değere sahip olmasıdır (Karabıçak *et al.* 2018). MSE ve RMSE hata eşitlikleri için sonucun sıfır ya da yakın çıkması kullanılan model için performans sonucunun yüksek olduğunu göstermektedir (Özcan 2021). Ayrıca MAPE (%) değeri için Witt ve Witt; Lewis tarafından yapılan çalışmalarda, kullanılan model için hesaplanan hata değerlerine göre modelin tahminleme performansını; %10’un altında çok iyi, %10-%20 arasında iyi, %20-%50 arasında kabul edilebilir ve %50’nin üzerinde ise yanlış veya hatalı olarak belirtmişlerdir (Lewis 1982, Witt and Witt 1992). Bu ifadelerle göre eğitim ve test verilerinin tamamı için MSE ve RMSE değerlerinin sıfıra çok yakın hatta bazı üyelik fonksiyonları için sıfır olmasından dolayı oluşturulan ANFİS model ve üyelik fonksiyonlarının yüksek tahminleme performansına sahip olduğu gözlemlenmiştir. Elde edilen bu sonuçlara ek olarak MAPE (%) değerleri incelendiğinde, sonuçların %10’un altında olmasından dolayı oluşturulan ANFİS modelin ve

kullanılan tüm üyelik fonksiyonlarının performansını yüksek olarak sınıflandırılabilceğini söylemek mümkündür. Karşılaştırılan tüm üyelik fonksiyonları için tahminlemenin çok iyi sonuçlar verdiği Çizelge 4’te verilen ortalama hata değerleri için net bir şekilde görülmüştür. Ancak bu sonuçlara göre kendi aralarında karşılaştırıldığında ise eğitim ve test verileri için tüm hata eşitlikleri için hesaplanan ortalama hata sonuçlarında en iyi sonucu eğitim için m55 ve test için m44 üyelik fonksiyonunun verdiği sonucuna ulaşılmıştır.

Kurulan ANFİS modele ve seçilen tüm üyelik fonksiyonları için literatüre uygun olarak, incelenen ortalama MAPE (%) değerlerinin %10'dan daha düşük olmasından dolayı kabul edilebilir olduğu sonucuna ulaşılmıştı ancak Şekil 12'de test verileri için verilen grafik incelendiğinde her bir deney için sonucun farklılık göstermesinden dolayı tüm deneyler için MAPE (%) değerleri hesaplanmıştır. Tüm deney numuneleri için hesaplanan MAPE (%) değerleri Şekil 13 ve 14'te sırası ile eğitim ve test verileri için verilmiştir. Elde edilen sonuçlar incelendiğinde eğitim verileri ait tüm deneyler için sonuçların %10 altında olmasından dolayı tahminleme performanslarının çok yüksek olduğunu ifade edebiliriz. Eğitim verileri içinde benzer bir sonuç elde edilmiştir. Ancak m22 üyelik fonksiyonu için 5 numaralı deneyde sonucun %10,9159 çıkmasından dolayı bu deney için tahminleme performansı iyi olarak sınıflandırılabilir. Ulaşılan bu sonuçla birlikte kurulmuş ANFİS model ve seçilen üyelik fonksiyonlarının ham yoğunluklarının tahminlemesinde kullanılabileceği ifade edilebilir.



Şekil 13. Eğitim verilerinin üyelik fonksiyonlarına göre % MAPE değerleri



Şekil 14. Test verilerinin üyelik fonksiyonlarına göre % MAPE değerleri

4. Sonuçlar

Yapılan çalışmada deneysel olarak hazırlanan örnekler ile belirlenen ham yoğunluk değerleri kullanılarak kurulan ANFİS modeli ve seçilen üyelik fonksiyonlarının tahminleme performansları incelenmiştir. Çalışmalar sonucunda;

- Eğitim verileri için tahminlenen ham yoğunluk değerinin tüm üyelik fonksiyonları için iyi sonuç verdiği belirlenmiştir. İncelenen sonuçlarda m33, m44 ve m55 (özellikle m44 ve m55) çok yakın sonuçlar verdiği gözlemlenmiştir.

- Test verileri için belirlenen ham yoğunluk değerlerinin ise eğitim verileri kadar deneysel sonuçlara yakın olmadığı ve en iyi sonucu veren üyelik fonksiyonun deney numaralarına göre farklılık gösterdiği sonucuna ulaşılmıştır.

- Eğitim verileri için hesaplanan MSE RMSE ve MAPE (%) için ortalama hata değerleri için ulaşılan en büyük değerler sırasıyla 0,0016, 0,0404 ve 1,8978 değerleri ile m22 üyelik fonksiyonu olmuştur. Ancak ulaşılan bu değer ile de kullanılan model ve üyelik fonksiyonun, tahminlemede çok iyi performans gösterdiği söylenebilir.

- Eğitim verileri için ulaşılan MSE RMSE ve MAPE (%) için ortalama hata değerleri için ulaşılan en küçük değerler sırasıyla 0,00, 0,0002 ve 0,0054 ile m55 üyelik fonksiyonu vermiştir. Hesaplanan değerlerin sıfıra çok yakın olmasından dolayı tahminlenen yoğunluk değerlerinin neredeyse deneysel sonuçlar ile benzer olduğu söylenebilir.

- Test verilerinde ortalama hata değerinde en küçük değerlere m44 üyelik fonksiyonu ile ulaşılmıştır. En büyük ortalama hata değerleri ise m22 üyelik fonksiyonunda elde edilmiştir. m22 üyelik fonksiyonu için belirlenen bu değerlerinde MSE, RMSE için sıfıra çok yakın olmaları ve MAPE (%) değerinin %10'nun altında olmasından dolayı test verileri içinde seçilen üyelik fonksiyonlarının

tahminleme performansının yüksek olduğu ifade edilebilir.

- Her bir deney için belirlenen MAPE (%) değerleri için en yüksek değere; eğitim verileri için 5,0367 MAPE (%) 1 numaralı deney ile m22 üyelik fonksiyonunda ulaşılrken, test verileri için ise 10,9159 MAPE (%) değeri ile 5 numaralı deney için m22 üyelik fonksiyonunda elde edilmiştir. Elde edilen sonuçlar bize eğitim veri için tüm deneylerin çok iyi başarımlar gösterdiğini ifade ederken, test verileri için ise sadece 5 numaralı deney için m22 fonksiyonun da iyi başarımlar verdiğini söyleyebiliriz. Çalışmada deneysel veriler ile ANFİS sonucu elde edilen değerler arasında iyi tahminleme yeteğine ulaşılmıştır. Çalışmanın doğruluğu açısından kullanılan ortalama RMSE, MSE, MAPE (%) değerlerinin de gösterdiği gibi toz karışımlarının sıkıştırılabilirliği sonucu ulaşılan ham yoğunluk değerlerinin ANFİS model ile başarılı bir şekilde tahmin edilebildiği görülmüştür. Ayrıca eğitim ve test verileri için tüm deneylere ait ortalama değerlerinin de yüksek tahminleme performansına sahip olduğu söylenebilir.

5. Kaynaklar

Basmacı, G., 2018. Optimization of machining parameters for the turning process of AISI 316 L stainless steel and Taguchi design. *Acta Physica Polonica A*, **134**, 1, 260-264.

Bouvard, D., 2000. Densification behaviour of mixtures of hard and soft powders under pressure. *Powder technology*, **111**, 3, 231-239.

Brondino, N. C. M. and Silva, A., 1999. Combining artificial neural networks and GIS for land valuation purposes. *Proceedings of the Computers in Urban Planning and Urban Management, India*, **10**.

Buyukbingol, E. et al., 2007. Adaptive neuro-fuzzy inference system (ANFİS): a new approach to predictive modeling in QSAR applications: a study of neuro-fuzzy modeling of PCP-based NMDA receptor antagonists. *Bioorganic & medicinal chemistry*, **15**, 12, 4265-4282.

Caner, M. and Akarşlan, E., 2009. Mermer Kesme İşleminde Spesifik Enerji Faktörünün ANFİS ve YSA Yöntemleri ile Tahmini. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, **15**, 2, 221-226.

Chatfield, C., (2000). Time-series forecasting, Chapman and Hall/CRC.

Chen, X. et al., 2015. Microstructure, electromagnetic shielding effectiveness and mechanical properties of Mg–Zn–Cu–Zr alloys. *Materials Science and Engineering: B*, **197**, 67-74.

Çelik, E. and Kıvık, T., 2016. 17-4 PH Paslanmaz çeliğin tornalanmasında minimum miktarda yağlamanın yüzey pürüzlülüğü üzerindeki etkileri. *7th International Symposium On Machining*, İstanbul. 214-221.

Demirel, O. et al., 2010. Electric energy load forecasting using ANFİS and ARMA methods. *Journal of the Faculty of Engineering and Architecture of Gazi University*, **25**, 3.

Denny, P., 2002. Compaction equations: a comparison of the Heckel and Kawakita equations. *Powder technology*, **127**, 2, 162-172.

Erdirencelebi, D. and Yalpir, S., 2011. Adaptive network fuzzy inference system modeling for the input selection and prediction of anaerobic digestion effluent quality. *Applied mathematical modelling*, **35**, 8, 3821-3832.

Ergül, E. and Kurt, H., 2021. AI Matrisli Kompozitlere ANFİS, ANN ve Taguchi Yaklaşımları Uygulanarak Özelliklerin Karşılaştırılması. *International Journal of Engineering Research and Development*, **13**, 2, 406-416.

Gaitonde, V. et al., 2008. Taguchi approach for achieving better machinability in unreinforced and reinforced polyamides. *Journal of Reinforced Plastics and Composites*, **27**, 9, 909-924.

German, R. M., 2007. Toz metalurjisi ve parçacıklı malzeme işlemleri. *Çeviri Editörleri, Sarıtaş, S., Türker, M., Durlu N., Türk Toz Metalurjisi Derneği Yayınları, Ankara*, 60-80.

Ghofrani, M. and Alolayan, M., (2018). Time series and renewable energy forecasting, IntechOpen.

Ghose, J. et al., 2011. Taguchi-fuzzy based mapping of EDM-machinability of aluminium foam. *Technical Gazette*, **18**, 4, 595-600.

Gujarati, D. N., (2021). Essentials of econometrics, SAGE Publications.

Gupta, M. and Ling, S. N. M., (2011). Magnesium, magnesium alloys, and magnesium composites, John Wiley & Sons.

- Hafizpour, H. et al., 2009. Analysis of the effect of reinforcement particles on the compressibility of Al–SiC composite powders using a neural network model. *Materials & Design*, **30**, 5, 1518-1523.
- Haznedar, B. et al., 2017. Karaciğer mikrodizi kanser verisinin sınıflandırılması için genetik algoritma kullanarak ANFIS'in eğitilmesi. *Sakarya Üniversitesi Fen bilimleri Enstitüsü Dergisi*, **10**.
- Hossain, M. S. J. and Ahmad, N., 2014. A neuro-fuzzy approach to select cutting parameters for commercial die manufacturing. *Procedia Engineering*, **90**, 753-759.
- Jang, J. S. and Sun, C.-T., 1995. Neuro-fuzzy modeling and control. *Proceedings of the IEEE*, **83**, 3, 378-406.
- Jang, J. S. R., 1993. Anfis - Adaptive-Network-Based Fuzzy Inference System. *Ieee Transactions on Systems Man and Cybernetics*, **23**, 3, 665-685.
- Jang, J. S. R. et al., 1997. Neuro-fuzzy and soft computing- a computational approach to learning and machine intelligence [Book Review]. *IEEE Transactions on automatic control*, **42**, 10, 1482-1484.
- Jeyapragash, N. et al., 2020. Machinability study on CFRP composite using Taguchi based grey relational analysis. *Materials Today: Proceedings*, **21**, 1425-1431.
- Jiang, J. et al., 2012. Microstructure and mechanical properties of the motorcycle cylinder body of AM60B magnesium alloy formed by combining die casting and forging. *Materials & Design*, **37**, 202-210.
- Kara, F. et al. (2017). Optimization by Taguchi method of surface roughness and vibration in turning of AISI 4140 steel. II. International Academic Research Congress-(INES 2017), Antalya, Türkiye.
- Karabıçak, Ç. et al., 2018. Determination of demand estimation methods by values and variability measures for stock items in a cleaning paper company. *Journal of Current Researches on Engineering Science and Technology*, **4**, 1, 47-68.
- Karaboga, D. and Kaya, E. (2014). Training ANFIS using artificial bee colony algorithm for nonlinear dynamic systems identification. 2014 22nd Signal Processing and Communications Applications Conference (SIU), IEEE.
- Kassa, Y. et al. (2016). Short term wind power prediction using ANFIS. 2016 IEEE international conference on power and renewable energy (ICPRE), IEEE.
- Kayır, Y. et al., 2013. AISI 316Ti paslanmaz çeliğin tornalanmasında kesici uç etkisinin Taguchi yöntemi ile analizi. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, **28**, 2.
- Kechagias, J. D. et al., 2020. A comparative investigation of Taguchi and full factorial design for machinability prediction in turning of a titanium alloy. *Measurement*, **151**, 107213.
- Lewis, C., 1982. International and Business Forecasting Methods Butterworths: London.
- Lokshina, I. et al. (2003). Applications of artificial intelligence methods for real estate valuation and decision support. Hawaii International Conference on Business.
- Lund, J., 1982. Origins of green strength in iron P/M compacts. *Int. J. Powder Metall. Powder Technol.*, **18**, 2, 117-127.
- Mahdavi, S. and Akhlaghi, F., 2011. Effect of SiC content on the processing, compaction behavior, and properties of Al6061/SiC/Gr hybrid composites. *Journal of Materials Science*, **46**, 5, 1502-1511.
- Maher, I. et al., 2014. Investigation of the effect of machining parameters on the surface quality of machined brass (60/40) in CNC end milling—ANFIS modeling. *The International Journal of Advanced Manufacturing Technology*, **74**, 1, 531-537.
- Marya, M. et al., 2006. Microstructural effects of AZ31 magnesium alloy on its tensile deformation and failure behaviors. *Materials science and engineering: A*, **418**, 1-2, 341-356.
- Mordike, B. and Ebert, T., 2001. Magnesium: properties—applications—potential. *Materials Science and Engineering: A*, **302**, 1, 37-45.
- Moreno, I. et al., 2001. Microstructural characterization of a die-cast magnesium-rare earth alloy. *Scripta Materialia*, **45**, 12, 1423-1429.
- Norsk, H. D., 1996. NHMg.db (ext.).
- Özarlan, S. et al., 2019. Microstructure, mechanical and corrosion properties of novel Mg-Sn-Ce alloys produced by high pressure die casting. *Materials Science and Engineering: C*, **105**, 110064.
- Özcan, E., 2021. Kükürt Giderme İşlemi İçin Kullanılan Malzeme Miktarının Makine Öğrenme Yöntemleri İle Tahmini.
- Perez, P., 2001. Prediction of sulfur dioxide concentrations at a site near downtown Santiago, Chile. *Atmospheric Environment*, **35**, 29, 4929-4935.

- Piero, P., 2002. Bonissone adaptive neural fuzzy inference systems (ANFIS): analysis and applications.
- Polmear, I. et al., (2017). Light alloys: metallurgy of the light metals, Butterworth-Heinemann.
- Shivakoti, I. et al., 2019. ANFIS based prediction and parametric analysis during turning operation of stainless steel 202. *Materials and Manufacturing Processes*, **34**, 1, 112-121.
- Upadhyaya, G. S., (1999). Sintered metallic and ceramic materials: preparation, properties, and applications, Wiley.
- Uzundurukan, S., 2006. Determining and modelling of principal parameters affecting swelling properties of soils. *Suleyman Demirel*.
- Wang, J. et al., 2011. A study of the effect of antimony content on damping capacity of ZA84 magnesium alloy. *Materials & Design*, **32**, 8-9, 4567-4572.
- Witt, S. F. and Witt, C. A., (1992). Modeling and forecasting demand in tourism, Academic Press.
- Wu, W. et al., 2000. Experimental and numerical investigation of idealized consolidation: Part 1: Static compaction. *Acta materialia*, **48**, 17, 4323-4330.
- Yalpir, S. and Ozkan, G., 2018. Knowledge-based FIS and ANFIS models development and comparison for residential real estate valuation. *International journal of strategic property management*, **22**, 2, 110-118.
- Yazdi, H. S. et al., 2010. Neuro-fuzzy based constraint programming. *Applied mathematical modelling*, **34**, 11, 3547-3559.
- Yıldırım, Ç. V., 2019. Grafit parçacık takviyeli nano akışkan kullanılarak AISI 316'nın frezelenmesinde yüzey pürüzlülüğü ve kesme sıcaklığının optimizasyonu. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, **7**, 1, 326-341.
- Yılmaz, M., 2010. Adaptive network based on fuzzy inference system estimates of geoid heights interpolation. *Scientific research and essays*, **5**, 16, 2148-2154.
- Zhang, W. et al., 2012. Effects of Sr and Sn on microstructure and corrosion resistance of Mg–Zr–Ca magnesium alloy for biomedical applications. *Materials & Design*, **39**, 379-383.