

**TEPKİ YÜZEYLERİ TASARIMI VE
YAPAY SINIR AĞLARI
YÖNTEMLERİYLE EPOKSİ
KOMPOZİTLERİN AŞINMA
ÖZELLİKLERİNİN
OPTİMİZASYONU**

NECİP FAZIL KARAKURT

**Yüksek Lisans Tezi
Endüstri Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. AYSUN SAĞBAŞ
2019**

T.C.
TEKİRDAĞ NAMIK KEMAL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

TEPKİ YÜZEYLERİ TASARIMI VE YAPAY SINIR AĞLARI
YÖNTEMLERİYLE EPOKSİ KOMPOZİTLERİN AŞINMA
ÖZELLİKLERİNİN OPTİMİZASYONU

Necip Fazıl KARAKURT

ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI

DANIŞMAN: Prof. Dr. Aysun SAĞBAŞ

TEKİRDAĞ-2019

Her hakkı saklıdır.

Prof. Dr. Aysun SAĞBAŞ danışmanlığında Necip Fazıl KARAKURT tarafından hazırlanan “Tepki Yüzeyleri Tasarımı ve Yapay Sinir Ağları Yöntemleriyle Epoksi Kompozitlerin Aşınma Özelliklerinin Optimizasyonu” isimli bu çalışma aşağıdaki jüri tarafından Endüstri Mühendisliği Anabilim Dalı’nda Yüksek Lisans tezi olarak oy birliği ile kabul edilmiştir.

Jüri Başkanı:

İmza:

Üye:

İmza:

Üye:

İmza:

Fen Bilimleri Enstitüsü Yönetim Kurulu adına

Doç. Dr. Bahar UYMAZ
Enstitü Müdürü

ÖZET

Yüksek Lisans Tezi

TEPKİ YÜZEYLERİ TASARIMI VE YAPAY SİNİR AĞLARI YÖNTEMLERİYLE EPOKSİ KOMPOZİTLERİN AŞINMA ÖZELLİKLERİNİN OPTİMİZASYONU

Necip Fazıl KARAKURT

Tekirdağ Namık Kemal Üniversitesi
Fen Bilimleri Enstitüsü
Endüstri Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Aysun SAĞBAŞ

Yapılan tez çalışmasında; inşaat sanayii başta olmak üzere tekstil ve otomotiv gibi çok geniş bir alanda yaygın bir kullanıma sahip olan epoksi (reçine) bazlı kompozitlerin aşınma davranışına etki eden faktörler incelenmiş olup, süreç optimizasyonu gerçekleştirilmiştir. Epoksi malzemenin aşınma dayanımının artırılması için ferrokrom ve cam katkıları kullanılmıştır. Merkezi birleşik tasarım (Central Composite Design-CCD) uygulanarak toplam 18 deney noktasında 54 adet deney numunesi üretilmiştir. Üretilen numunelerin abrasif aşınma testleri yapılarak aşınma tepki değerleri ölçülmüştür. Elde edilen veriler tepki yüzeyleri tasarımı ve yapay sinir ağları yaklaşımı ile değerlendirilmiştir. Elde edilen sonuçlara göre; cam katkı oranının artmasının aşınma oranını büyük ölçüde azalttığı görülmüş ve minimum aşınma oranı; cam katkı oranının en yüksek seviyesinde (%17,07) elde edilmiştir. Ferrokrom katkının aşınma oranı üzerindeki etkisi ise küçük parçacıklar (0-50 mikron) için negatif olurken, minimum aşınma oranı en düşük düzeyli ferrokrom katkı oranı (%2,93) ile elde edilmiştir. Sertlik ve maliyet tepki değişkenlerinde tahmin modelleri geliştirilmiş olup, çoklu tepki optimizasyonu gerçekleştirilmiştir. Aşınma tepki değişkeninin tahmini için oluşturulan yapay sinir ağı ve tepki yüzeyleri modellerinin performansları karşılaştırılmıştır. Alınan sonuçlara göre; yapay sinir ağı (Artificial Neural Network-ANN), sınama setinin aşınma tepki değişkenini %8,18 ortalama yüzde hata (MAPE) değeri ile tahmin ederken; Tepki Yüzeyleri Tasarımı (Response Surface Methodology-RSM) modelinin MAPE değeri %9,42 olarak bulunmuştur. Tepki değişkenindeki değişkenliğin açıklanmasında R^2 ve MSE (ortalama kare hata) tanımlayıcı istatistikleri için tepki yüzeyleri tasarımı modeli daha başarılı bulunmuştur.

Anahtar kelimeler: Tepki yüzeyleri tasarımı, aşınma, optimizasyon, epoksi kompozit, yapay sinir ağları.

2019, 97 Sayfa

ABSTRACT

MSc. Thesis

OPTIMIZATION OF WEAR CHARACTERISTIC OF EPOXY COMPOSITES BY RESPONSE SURFACE AND ARTIFICIAL NEURAL NETWORK METHODOLOGIES

Necip Fazıl KARAKURT

Tekirdağ Namık Kemal University
Graduate School of Natural and Applied Sciences
Department of Industrial Engineering

Supervisor: Prof. Dr. Aysun SAĞBAŞ

Epoxy is widely used in many industries including automotive and construction. In thesis work, ferrochrome carbide and glass reinforcements have been used to enhance wear resistance of epoxy material. Total number of 54 specimen is produced on 18 different experimental points determined by employing Central Composite Design (CCD) approach. For each specimen, abrasive wear test is performed in laboratory environment. Findings are interpreted and certain conclusions have been drawn from the results via response surface and neural network approach. Glass reinforcement is found to have a negative correlation with wear rate of epoxy which means that the more glass is added to epoxy, the more wear resistance epoxy gets. Minimum wear rate is obtained when glass reinforcement is at its maximum level (17,07%). Ferrochromium reinforcement increases wear rate when small sized particles (0-50 microns) is concerned whereas it decreases wear rate for large sized particles (50-75 microns). Compare to large sized particles, small sized particles have a significant effect on wear resistance in a positive way. Hardness and production cost of samples are included to the work as additional response variables. Optimization with multiple response is conducted to find out optimum design points for different scenarios predetermined. Many artificial neural network alternatives are trained and tested. Among all the alternatives, the best predictive network is selected and compared with response surface model (RSM) prediction in terms of prediction accuracy. According to mean absolute percentage error (MAPE), neural network outperforms RSM model. When it comes to R^2 and mean square error (MSE) performance indicators, RSM model achieves better results.

Key words: Response surface design, wear, optimization, epoxy composite, artificial neural networks.

2019, 97 Pages

İÇİNDEKİLER

ÖZET	i
ABSTRACT	ii
İÇİNDEKİLER	iii
ÇİZELGE DİZİNİ	v
ŞEKİL DİZİNİ	vi
SİMGELER DİZİNİ	vii
ÖNSÖZ	viii
1. GİRİŞ	1
2. LİTERATÜR ÖZETİ	6
3. MATERYAL ve YÖNTEM	12
3.1. Kullanılan Malzemeler	12
3.2. Tepki Yüzeyleri Tasarımı	15
3.2.1. Model yeterlilik testleri	19
3.2.2. Tahmin modeli seçimi	21
3.3. Yapay Sinir Ağları.....	22
3.3.1. Toplama fonksiyonu	23
3.3.2. Öğrenme fonksiyonu	24
3.3.3. Aktivasyon fonksiyonları	27
3.3.4. İleri beslemeli ağlar	29
3.3.5. Radyal tabanlı yapay sinir ağları	30
3.3.6. Genelleştirilmiş regresyon ağı	30
3.3.7. Geri beslemeli ağlar	31
3.4. ANN-RSM Modellerinin Karşılaştırılması	31
3.5. Uygulanan Deney Tasarımı	32
3.6. Numunelerin Hazırlanması ve Uygulanan Testler	35
3.6.1. Aşınma testleri.....	35
3.6.2. Sertlik testleri.....	36
3.6.3. Maliyet hesaplamaları.....	38
4. BULGULAR ve TARTIŞMA	39
4.1. Test Sonuçları	39
4.2. Uygulanan İstatistiksel Analiz.....	41
4.3. Aşınma Tahmin Modeli.....	43
4.4. Sertlik Tahmin Modeli	56

4.5. Maliyet Tahmin Modeli.....	67
4.6. Aşınma Sertlik Korelasyonu.....	69
4.7. Çoklu Tepki Optimizasyonu.....	70
4.8. ANN ile Aşınma Oranı Tahmini	72
4.8.1. Genelleştirilmiş regresyon ANN modeli	75
4.8.2. Radyal tabanlı ANN modeli	77
4.8.3. İleri beslemeli geri yayımlı ANN modeli.....	80
4.8.4. ANN tahmin modelleri performans karşılaştırması	87
4.8.5. RSM-ANN tahmin performanslarının karşılaştırılması	87
5. SONUÇLAR ve DEĞERLENDİRME.....	89
6. KAYNAKLAR.....	92

ÇİZELGE DİZİNİ

Çizelge 2.1: Literatür Matrisi.....	11
Çizelge 3.1: MGS L285 Epoksi Malzeme Sertifikası ve Özellikleri.....	13
Çizelge 3.2: H285 Sertleştirici Özellikleri.....	13
Çizelge 3.3: Karbür İçeriği	14
Çizelge 3.4: Öğrenme Algoritmaları (Jain ve Mao 1996)	26
Çizelge 3.5: Katkı Büyüklüğü İçin Kodlanmış ve Gerçek Değişken Seviyeleri	33
Çizelge 3.6: Katkı Oranı İçin Kodlanmış ve Gerçek Değişken Seviyeleri.....	33
Çizelge 3.7: CCD Deneysel Tasarım Noktaları.....	34
Çizelge 3.8: Karışım Malzemeleri İçin Birim Maliyetler	38
Çizelge 4.1: Aşınma Test Sonuçları	39
Çizelge 4.2: Sertlik Test Sonuçları	39
Çizelge 4.3: Numunelerin Toplam Maliyetleri.....	40
Çizelge 4.4: Tepki Değişkenlerinin Normallik Testi Sonuçları.....	41
Çizelge 4.5: Tepki Değişkenlerinin Hata Varyanslarının Eşitliği Testi Sonuçları	42
Çizelge 4.6: Tepki Değişkenlerinin Grubbs' Testi Sonuçları	42
Çizelge 4.7: Aşınma Tepki Değişkeni ANOVA Tablosu.....	43
Çizelge 4.8: Aşınma Tepki Değişkeni Model İstatistikleri.....	44
Çizelge 4.9: Aşınma Tepki Değişkeni Model Uyum İstatistikleri.....	44
Çizelge 4.10: Aşınma Tepki Değişkeni Regresyon Katsayıları.....	45
Çizelge 4.11: Sertlik Tepki Değişkeni ANOVA Tablosu.....	56
Çizelge 4.12: Sertlik Tepki Değişkeni Model İstatistikleri	57
Çizelge 4.13: Sertlik Tepki Değişkeni Model Uyum İstatistikleri.....	57
Çizelge 4.14: Sertlik Tepki Değişkeni Regresyon Katsayıları	58
Çizelge 4.15: Sertlik Tepki Değişkeni Artıklarının Grubb's Testi Sonuçları.....	61
Çizelge 4.16: Maliyet Tepki Değişkeni ANOVA Tablosu	68
Çizelge 4.17: Maliyet Tepki Değişkeni Model Uyum İstatistikleri.....	68
Çizelge 4.18: Sertlik-Aşınma Değişkenleri Arasındaki Korelasyon	69
Çizelge 4.19: Çoklu Tepki Optimizasyonu İçin Oluşturulan Senaryolar	71
Çizelge 4.20: Tepki Değişkenleri İçin Oluşturulan Senaryoların Çözümü.....	71
Çizelge 4.21: Üretilen Numuneler İçin Sınama Veri Seti.....	74
Çizelge 4.22: Sınama Veri Setinin Aşınma Test Sonuçları	74
Çizelge 4.23: GRNN Eğitim Verisi Sonuç İstatistikleri	76
Çizelge 4.24: GRNN Sınama Verisi Sonuç İstatistikleri.....	76
Çizelge 4.25: En Başarılı GRNN Ağının Aşınma Tahmin Sonuçları.....	77
Çizelge 4.26: RBF Eğitim Verisi Sonuç İstatistikleri	78
Çizelge 4.27: RBF Sınama Verisi Sonuç İstatistikleri.....	78
Çizelge 4.28: En Başarılı RBF'nin Tahmin Sonuçları.....	79
Çizelge 4.29: FFBP'nin Eğitim Verisi Sonuç İstatistikleri.....	81
Çizelge 4.30: FFBP'nin Sınama Verisi Sonuç İstatistikleri.....	82
Çizelge 4.31: Nöron Sayılarına Göre FFBP Ağının Performansı.....	83
Çizelge 4.32: Eğitim Algoritmasına Göre FFBP Ağının Performansı.....	83
Çizelge 4.33: Transfer Fonksiyonlarına Göre FFBP Ağının Performansı.....	83
Çizelge 4.34: En Başarılı Beş FFBP Ağı	84
Çizelge 4.35: A3 Ağının Tahmin Sonuçları	85
Çizelge 4.36: A3'ün Yanlılık ve Ağırlıkları	86
Çizelge 4.37: Çapraz Doğrulama Sonuçları.....	86
Çizelge 4.38: Yapay Sinir Ağlarının Performans Ortalamaları	87
Çizelge 4.39: Sınama Setinin RSM Tahmini Sonuçları.....	87
Çizelge 4.40: Tahmin Modellerinin Sonuç İstatistikleri.....	88

ŞEKİL DİZİNİ

Şekil 1.1: Tez Çalışması İş Akış Diyagramı	5
Şekil 3.1: Tasarımların Geometrik Gösterimleri (Anonim 2018).....	18
Şekil 3.2: CCD'nin Kübik Gösterimi (Montgomery 2001)	18
Şekil 3.3: Sinir Nöronlarının Yapısı (Basheer ve Hajmeer 2000)	23
Şekil 3.4: İleri ve Geri Beslemeli Ağ Yapılarının Sınıflandırılması (Jain ve Mao 1996)	28
Şekil 3.5: Aşınma Testinde Kullanılan Cihaz	36
Şekil 3.6: Sertlik Testinde Kullanılan Cihaz.....	37
Şekil 4.1: Aşınma Tepki Değişkeni Artıklarının Normallik Testi	47
Şekil 4.2: Aşınma Tepki Değişkeni Artıklarının Histogram Dağılımı	47
Şekil 4.3: Aşınma Tepki Değişkeni Artıklarının Saçılma Diyagramı.....	48
Şekil 4.4: Aşınma Tepki Değişkeninin Ana Etkiler Grafiği (Küçük Parçacıklar).....	49
Şekil 4.5: Aşınma Tepki Değişkeninin Ana Etkiler Grafiği (Büyük Parçacıklar).....	50
Şekil 4.6: Aşınma Tepki Değişkeninin Etkileşim Grafiği (Küçük Parçacıklar)	51
Şekil 4.7: Aşınma Tepki Değişkeninin Etkileşim Grafiği (Büyük Parçacıklar)	52
Şekil 4.8: Aşınma Tepki Değişkeninin İzdüşüm Grafiği (Küçük Parçacıklar).....	53
Şekil 4.9: Aşınma Tepki Değişkeninin İzdüşüm Grafiği (Büyük Parçacıklar).....	53
Şekil 4.10: Aşınma Tepki Değişkeninin Üç Boyutlu Tepki Grafiği (Küçük Parçacıklar).....	54
Şekil 4.11: Aşınma Tepki Değişkeninin Üç Boyutlu Tepki Grafiği (Büyük Parçacıklar).....	55
Şekil 4.12: Sertlik Tepki Değişkeni Artıklarının Normallik Testi	59
Şekil 4.13: Sertlik Tepki Değişkeni Artıklarının Histogram Dağılımı	60
Şekil 4.14: Sertlik Tepki Değişkeni Artıklarının Saçılma Diyagramı	60
Şekil 4.15: Sertlik Tepki Değişkeninin Ana Etkiler Grafiği (Küçük Parçacıklar).....	61
Şekil 4.16: Sertlik Tepki Değişkeninin Ana Etkiler Grafiği (Büyük Parçacıklar).....	62
Şekil 4.17: Sertlik Tepki Değişkeninin Etkileşim Grafiği (Küçük Parçacıklar)	63
Şekil 4.18: Sertlik Tepki Değişkeninin Etkileşim Grafiği (Büyük Parçacıklar).....	64
Şekil 4.19: Sertlik Tepki Değişkeni İzdüşüm Grafiği (Küçük Parçacıklar).....	65
Şekil 4.20: Sertlik Tepki Değişkeni İzdüşüm Grafiği (Büyük Parçacıklar).....	65
Şekil 4.21: Sertlik Tepki Değişkeninin Üç Boyutlu Tepki Grafiği (Küçük Parçacıklar)	66
Şekil 4.22: Sertlik Tepki Değişkeninin Üç Boyutlu Tepki Grafiği (Büyük Parçacıklar)	67
Şekil 4.23: Maliyet Tepki Değişkeni İzdüşüm Grafiği	69
Şekil 4.24: Çoklu Tepki Optimizasyonu İstenirlik Oranı İzdüşüm Grafiği	72
Şekil 4.25: En Başarılı GRNN Ağınnın Sınama Verisi Performans Grafiği	76
Şekil 4.26: En Başarılı RBF'nin Eğitim Performansı	78
Şekil 4.27: En Başarılı RBF'nin Sınama Verisi Performans Grafiği.....	79
Şekil 4.28: Dört Katmanlı İleri Beslemeli Geri Yayımlı Ağ Yapısı.....	80
Şekil 4.29: A3 Ağınnın Sınama Verisi Performans Grafiği.....	84

SİMGELER DİZİNİ

AIC _c	: Düzeltilmiş Akaike Bilgi Kriteri
ANN	: Yapay Sinir Ağları
ANOVA	: Varyans Analizi
BIC	: Bayezyen Bilgi Kriteri
CCD	: Merkezi Birleşik Tasarım
FFBP	: İleri Beslemeli Geri Yayılımlı Yapay Sinir Ağı
GDX	: Değişken Hızlı Gradyan İnceleme Algoritması
GRNN	: Genelleştirilmiş Regresyon Yapay Sinir Ağı
LM	: Levenberg Marquardt Algoritması
Logsig	: Log-Sigmoid Transfer Fonksiyonu
MAE	: Ortalama Mutlak Hata
MLP	: Çok Katmanlı Algılayıcı
MRE	: Ortalama Göreli Hata
MSE	: Ortalama Kare Hata
PRESS	: Tahmin Hatasının Kareler Toplamı
Purelin	: Lineer Transfer Fonksiyonu
R ²	: Belirleme Katsayısı
R ² _{düz}	: Düzeltilmiş Belirleme Katsayısı
R ² _{tah}	: Tahmin Edilen Belirleme Katsayısı
RBF	: Radyal Tabanlı Yapay Sinir Ağı
RMSE	: Hataların Ortalama Karekökü
RSM	: Tepki Yüzeyleri Tasarımı
SSE	: Hatanın Kareler Toplamı
Tansig	: Hiperbolik Tanjant Sigmoid Transfer Fonksiyonu
VIF	: Varyans Artış Faktörü

ÖNSÖZ

Tez çalışmamda beni yönlendiren danışmanım Sayın Prof. Dr. Aysun SAĞBAŞ'a, laboratuvar çalışmalarımda bana yol gösteren Makine Mühendisliği bölümü öğretim elemanı Sayın Arş. Gör. Dr. Kenan ÇINAR'a, tez savunma sınavımda yaptıkları yapıcı eleştiriler ile tezin gelişimine katkılarını sunan değerli jüri üyeleri Sayın Doç. Dr. Tarık KÜÇÜKDENİZ ile Sayın Dr. Öğr. Üyesi Ulviye POLAT'a teşekkürlerimi borç bilirim.

1. GİRİŞ

Epoksi (reçine) inşaat, tekstil ve otomotiv sanayi gibi farklı alanlarda; fren disk balatası, yüzey kaplama, yapıştırma, onarım ve boyama işlemleri için sıklıkla kullanılan bir malzemedir. Aşınmaya karşı yüzey kaplama, koruma ve fren disk balatası olarak kullanıldığında, malzeme sürekli olarak aşındırıcı dış etkenlerle temas halinde olmaktadır. Bu nedenle malzemenin aşındırıcı yüzeylere karşı dayanıklı olması gerekmektedir. Aşınmaya karşı dayanıklılığının yüksek olması durumunda malzemenin kullanım ömrü ve etkinliği de arttırılmış olacaktır. Epoksi malzemenin aşınma dayanımı, malzemenin üretimi esnasında eklenecek katkı maddeleri ile arttırılabilmektedir. Hangi katkının seçileceği, hangi oranda katılacağı ve katkının parçacık büyüklüğünün ne olacağı gibi sorular bu işlem için yanıtlanması gereken sorulardandır. Bu durumda klasik deneme-yanılma yapılabileceği gibi çok farklı noktalarda üretimler yapılarak malzemenin aşınmasının nasıl bir değişim göstereceği de gözlemlenebilir. Ancak bu yöntem zaman ve maliyet açısından önemli ölçüde israfa yol açacaktır. Deneysel tasarım kullanıldığında ise tüm noktalarda deney yapılması gerekmeksizin tasarlanmış belli noktalarda ve istatistiksel olarak kabul edilebilir bir doğruluk derecesi ile tahminler gerçekleştirilebildiğinden önemli ölçüde zaman ve maliyet kaybının önüne geçilebilecektir.

Bu çalışmada, epoksiye kıyasla aşınmaya karşı daha dayanıklı olan ve maliyeti oldukça düşük olan cam ve ferrokrom tozlarının epoksi-sertleştirici karışımına katılmasıyla farklı epoksi numuneleri oluşturulmuş ve aşınma testleri ile bu numunelerin aşınma seviyeleri ölçülmüştür. Tepki değişkenindeki değişimin girdi faktörlerindeki değişimlerden etkilenme durumu ve derecesi, faktörlerin birbirleri arasındaki etkileşimler, aşınma tahmini için regresyon denklemi ve izdüşüm grafikleri elde edilmiştir. Aşınma tepki değişkeninin modellenmesi ve aşınma oranının en aza indirilmesi, Ar-Ge ve Ür-Ge çalışmaları açısından önemli bir yere sahiptir. Malzeme, bu şekilde aşınma performansı gerektiren kullanımlara daha kolay uyum sağlayabilecek ve malzemenin kullanım ömrü arttırılmış olacaktır. Yapılan tez çalışmasında aşınma minimizasyonu için iki farklı katkı (cam ve ferrokrom tozu) kullanılmıştır. Parçacık boyutu da tez kapsamında incelenen bir diğer girdi faktörüdür. Tez çalışmasını literatürdeki çalışmalardan ayıran birçok önemli nokta bulunmaktadır. Epoksi malzeme için farklı karbür ve cam katkıları ile aşınmanın azaltılmasına yönelik çalışmalar yapılmış olsa da cam ve ferrokrom katkılarının kullanılması ile aşınmanın optimizasyonu daha önceki çalışmalarda incelenmemiştir. Tez çalışması ile bu katkıların birlikte kullanımları durumunda epoksi malzemenin aşınma özelliğine etkisi incelenmiştir. Bununla beraber, literatürdeki çalışmalar genellikle tek veya iki tepki değişkeninin incelenmesi ile sınırlı kalırken yapılan tez

çalışmasında üç tepki değişkeni incelenmiştir. Böylece, çoklu tepki optimizasyonu ile daha fazla bağımlı değişken optimize edilmiştir. Ayrıca, literatürdeki çalışmalarda genellikle belli yapay sinir ağı modelleri malzeme özelliklerinin tespitinde kullanılırken tez çalışmasında oldukça farklı sayıda ağlar denenerek alınan sonuçlar tartışılmıştır. Yukarıda açıklanan ve literatürde eksik bırakılan konuların araştırılması, yapılan tez çalışmasının özgün yönünü oluşturmaktadır.

Bu tez çalışmasında amaç, istatistiksel deneysel tasarım uygulanarak farklı katkılar ilavesiyle epoksi malzemenin aşınma dayanımının optimize edilmesidir. Tepki yüzeyleri tasarımı metodolojisi kullanılarak yapılan optimizasyon çalışması ile epoksi malzeme için literatürde henüz çalışılmamış olan ferrokrom ve cam tozu katkılarının kullanılması durumundaki aşınma davranışı incelenmiştir. Tez çalışmasında çoklu tepki optimizasyonu için aşınma tepki değişkenine ilave olarak sertlik ve üretim maliyeti olmak üzere iki adet tepki değişkeni de çalışmaya dâhil edilmiştir. Böylece çalışmanın sonucunda elde edilen optimum nokta veya noktalarda malzemenin daha fazla özelliği optimize edilmiş olacaktır. Çoklu tepki optimizasyonunda farklı senaryolar kullanılmıştır. Tepki değişkenlerine farklı önem derecelerinin atandığı veya tepkilerin belirli bir aralıkta tutulduğu (hedef değer) senaryolar ile epoksinin kullanım alanında istenecek özelliklere göre seçimler yapılmıştır. Malzemenin kullanılacağı sektöre ve yere göre senaryo sayısında ve çeşitliliğini arttırmak mümkündür. Epoksi malzemenin aşınma, sertlik ve maliyet tepki değişkenleri için çoklu tepki optimizasyonu konusunda bir çalışmaya literatürde rastlanmamış olup, tez çalışması ile literatürde eksik bırakılan bu bölüm önemli ölçüde doldurulmuş olacaktır. Literatürdeki epoksi malzemeler için uygulanan tepki yüzeyleri çalışmaları çoğunlukla tek tepkinin ölçüm ve optimizasyonu ile sınırlı kalmaktadır. Tezde çoklu tepki optimizasyonu kullanılmıştır ve bu özelliği ile de tez çalışması, ileriki çalışmalar için ışık tutacak niteliktedir.

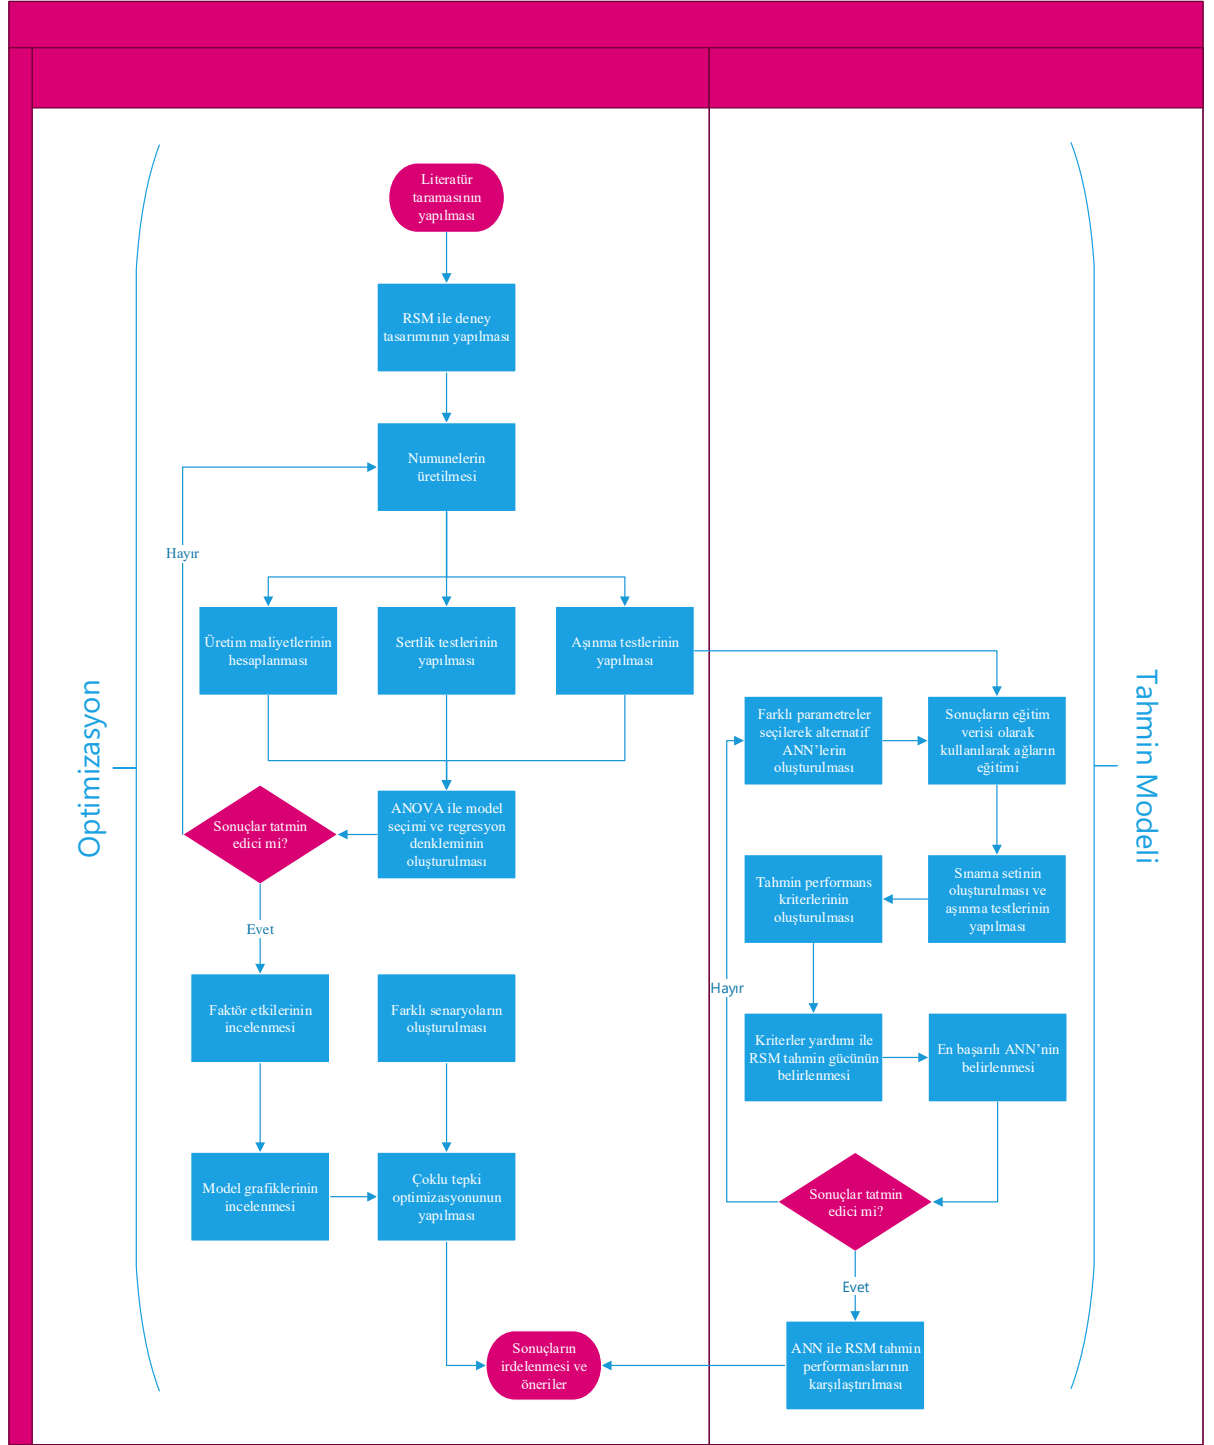
Aşınma oranının tahmini bazı durumlarda oldukça zor olabilmektedir. Bunun nedeni aşınmanın matematiksel olarak kolay modellenememesidir. Karşılaşılan modelleme güçlüğü ile başa çıkabilmek için son yıllarda karmaşık problemler için yapay sinir ağı uygulamaları yaygınlaşmış ve çoğu noktada matematiksel modellemenin yerini almaya başlamıştır. Yapay sinir ağları (Artificial Neural Networks-ANN) bir bilgiyi öğrendikten sonra o bilgiyi genelleyerek yeni bilgiler üretebilmektedir. Bu sayede ANN hiç karşılaşmadığı verileri, önceden görüp öğrendikleri ile yorumlayarak başarılı tahminler yürütür. Tez çalışmasında da ANN aşınma tahmini amacıyla kullanılmıştır. Farklı yapıda ANN'ler oluşturulmuş ve bu ağlar RSM'de kullanılan deney verileri ile eğitilmiştir. Eğitim sonrasında sınamaya seti oluşturulup bu

setteki deney verileri ile ağların başarı durumları karşılaştırılmıştır. Üç farklı performans kriteri belirlenmiş olup, bu kriterler ile ağlar birbirleri ile karşılaştırılmıştır. RSM'nin sınama verisi karşısında gösterdiği başarı da ANN alternatifleri ile karşılaştırılmıştır. Epoksinin aşınma tahmini, yapay zekâ ve regresyon modeli yardımıyla yapılarak karşılaştırılmış ve bu alandaki çalışmalarda bulunan önemli bir eksik nokta tez çalışmasında irdelenmiştir.

Epoksi malzeme aşındırıcı yüzeylerle temas halinde kullanıldığından (fren balatası ve yüzey kaplama gibi) aşınmaya karşı dayanıklı olması gerekmektedir. Özellikle bisikletlerdeki fren sistemlerinde fren pabuçu olarak kullanıldığında, aşınmaya karşı dirençli olması ve uzun süre yıpranmadan kullanılabilmesi gerekmektedir. Epoksi, herhangi bir katkı içermeksizin kullanıldığında belirli bir seviyeye kadar aşınma dayanımına sahiptir. Ancak malzemeye katkı eklenerek aşınma dayanımının artırılması malzemeyi daha uzun ömürlü hale getirecektir. Katkı eklendiği durumlarda da malzemenin diğer mekanik özelliklerinde veya üretim maliyetlerinde olumsuz değişimler meydana gelebilmektedir. Literatürde yapılmış olan çalışmaların büyük bir kısmı test parametrelerinde değişiklik yaparak bunun tepki üzerindeki değişimini tahminlemeye yöneliktir. Malzemeye eklenecek katkının cinsi ve parametreleri ile ilgilenecek bir çalışma önemlidir. Literatürde RSM çalışmaları çoğunlukla tek bir tepki üzerinden yapılmıştır. Epoksi reçinenin aşınma davranışının incelenmesinde RSM ile matematiksel model oluşturulduktan sonra ANN ile tahmin performanslarını karşılaştıran çalışma sayısı oldukça sınırlıdır. Tüm bu boşlukların doldurulması ve aşınmaya dayanıklı epoksi üretim konfigürasyonunun elde edilmesi tez çalışmasının öncelikli amacıdır.

Tez çalışmasında epoksi reçinenin aşınma dayanımı farklı katkıları ile arttırılmaya çalışılmıştır. Az sayıda deney yapılarak aşınma optimizasyonu ve tahmini gerçekleştirilmek istendiğinden tepki yüzeyleri tasarımı metodolojisi kullanılmıştır. Epoksi karışımına ilave edilecek cam toz oranı, ferrokrom toz oranı ve eklenecek katkıların büyüklüğü çalışmada kullanılan üç faktör olmuştur. Ferrokrom ve camın düşük maliyetli olması, kolay ulaşılabilir olması ve aşınma dayanımını arttırma amacıyla literatürdeki çalışmalarda kullanılmış olması nedenleriyle bu katkıları seçilmiştir. Numunelerin üretimi sonrasında aşınma ve sertlik testleri yapılmış ve üretim maliyetleri numune üretimi sırasındaki ortalama tüketimler göz önünde bulundurularak hesaplanmıştır. Design Expert 11 programı ile veriler analiz edilmiş olup, Minitab 17 ve PASW 18 programlarından da faydalanılmıştır. Sonuçlar analiz edilmiş ve tahmin çalışması yapılmıştır. Deneysel tasarım noktalarında üretilen malzemede elde edilen veriler ile genelleştirilmiş regresyon, radyal tabanlı ve ileri beslemeli geri yayımlı yapay sinir ağlarının eğitimi gerçekleştirilmiştir. Eğitim için genelleştirilmiş regresyon ve radyal tabanlı

ađlarda farklı yayılma katsayıları, ileri beslemeli geri yayılımlı ađda farklı nöron sayıları, aktivasyon fonksiyonları ve öğrenme algoritmaları kullanılmıştır. Yapay sinir ađları, çalışma yapısı tam kestirilemeyen ve uğraşılın probleme göre bir algoritma geliştiremeyen sistemler olduđu için tez çalışmasında deneme yanılma yoluyla en başarılı tahmin yapan ađa ulaşılmıştır. Eğitim verisinde kullanılmayan bir veri seti oluşturulmuş ve 25:100 oranı ile oluşturulan veriler ile ađların başarısı test edilmiştir. Sınama seti için RSM tahminleri de gerçekleştirilmiştir. Alternatif ANN yapıları arasında en başarılı olan ANN modelinin performansı RSM ile karşılaştırılmıştır. Tez çalışması için işlem adımları Şekil 1.1’de verilmiştir.



Şekil 1.1. Tez Çalışması İş Akış Diyagramı

2. LİTERATÜR ÖZETİ

Bu tez çalışmasında amaç, epoksi kompozitlerin aşınma davranışını modelleyerek karışım parametrelerini optimize etmektir. Literatürde bu kapsamda yapılan çalışmalarda yapay sinir ağlarının küçük veri setleri ile hızlıca öğrenerek malzeme özelliklerini başarı ile tahmin ettiği görülmüştür. İnceleme sonuçlarından görüleceği üzere; malzeme tasarımlarında tepki yüzeyleri metodu başarılı sonuçlar verdiği için malzeme özelliklerinin optimize edilmesinde sıklıkla kullanılmıştır. Bu kapsamda çalışma konusu ile ilgili makalelerden oluşan bir literatür taraması aşağıda sunulmuştur.

Briscoe ve ark. (1974) HDPE'nin (yüksek yoğunluklu polietilen) aşınma oranını inorganik katkıları ile azaltmayı başarmışlardır.

Yılmaz (2001) ferrokrom katkı kullanarak metal kompozitin aşınma ile kütle kaybını azaltmıştır. En düşük aşınmayı 40-60 mikrometre büyüklüğe sahip, kütlece %15 seviyesindeki parçacıklarla elde etmiştir.

Zhang ve ark. (2003) yaptıkları çalışmada üç farklı polimerin aşınma oranlarının tahmini için bir yapay sinir ağını eğiterek testlerini yapmışlardır. Üç farklı veri seti kullanılmış olup bu setlerin tamamı için R^2 ölçütü kullanılmıştır. R^2 değerleri %90'ın üzerine çıkarak başarılı sonuçlar vermiştir. Çalışmada geri beslemeli ağ kullanılmış olup eğitim veri adedinin test veri adedine oranı arttırıldıkça tahmin başarısının çoğu durumda arttığı gözlemlenmiştir. Girdi değişkeni olarak akma dayanımı, elastisite modülü, kristallilik, akma gerinimi, kırılma erki, poliüretan oranı gibi değişkenler kullanılırken çıktıda aşınma oranına bakılmıştır. Çalışmada bir adet gizli katman kullanılmıştır.

Suresha ve ark. (2006) yaptıkları birçok karışım deneyinde, cam-epoksi kompoziti için SiC (Silisyum Karbür) katkısının diğer karışımlarına kıyasla malzemenin aşınma dayanımının maksimum olduğu sonucuna ulaşmışlardır. Aşınma performansı konusunda daha başarılı bir cam-epoksi kompoziti elde edilmiştir.

Bezerra ve ark. (2007) yaptıkları çalışmada epoksi kompozitlerin kesme gerilimlerinin yapay zekâ ile tahminine yer vermişlerdir. İlk başta iki ayrı gizli katman kullanılarak yapılan ağ eğitiminde katmanların her birinde üçer adet nöron kullanılmıştır. Alınan ilk sonuçlar yetersiz bulununca nöron sayısı arttırılarak alınan sonuçların tahmin başarısı arttırılmıştır. Çalışmada Levenberg–Marquardt öğrenme algoritmasının iyi sonuçlar verdiği görülmüştür.

Transfer fonksiyonu olarak Tanjant Sigmoid fonksiyonu kullanılmıştır. Ağ modelinin üç girdisi kesme gerinimi, fiber numunesi ve açısıdır.

Lakshminarayanan ve Balasubramanian (2008) yaptıkları çalışma ile alüminyum alaşımların çekme mukavemetinin tahmininde RSM ve ANN kullanmışlar ve bu yöntemlerin tahmin güçlerini karşılaştırmışlardır. Orijinal üretim aralığının dışına çıkılmak istenmediği için CCF ($\alpha=1$) kullanılarak 20 adet numune ile bir veri tabanı oluşturulmuştur. Sinir ağı modelinin daha güçlü (robust) ve tahmin gücünün yüksek olduğu görülmüştür.

Youssefi ve ark. (2009) yaptıkları çalışmada nar suyunun kalitesini birkaç metrik ile tanımlayarak bu metriklerin tahminini gerçekleştirmişlerdir. CCRD (Merkezi Döndürülebilir Kompozit Tasarımı) ve yapay sinir ağları metodlarının tahmin performansları bağımsız bir veri seti ile test edilmiştir. RSM ile geri beslemeli çok katmanlı ağ RMSE, MAE ve R^2 olmak üzere üç farklı performans göstergesi ile kıyaslanmış ve yapay sinir ağının tahmin doğruluğunun daha yüksek olduğu sonucuna ulaşılmıştır.

Gyurova ve Friedrich (2010) yaptıkları çalışmada 124 adet verinin bulunduğu bir set yardımıyla bir yapay sinir ağını eğitmişlerdir. PPS (polipropilen sülfat) kompozitlerin aşınmasını tahmin etmek için geliştirilen ağ, farklı veri setleri ile test edilerek yeterli bulunmuştur. GDX ve CGB öğrenme algoritmaları karşılaştırılmış olup, hız ve doğruluk açısından GDX daha üstün görülüp çalışmada kullanılmıştır. ANN'nin girdi değişkenleri malzeme bileşimi (PPS, karbon fiber, grafit, TiO_2 , PTFE), kayma hızı ve uygulanan yük olurken, çıktı (bağımlı) değişkenleri sürtünme çarpanı, aşınma oranı ve tribolojik karakteristik olmuştur.

Kranthi ve Satapathi (2010) çalışmalarında talaşla güçlendirilmiş epoksinin belli parametrelerinin aşınmaya etkisini yapay sinir ağları ile tahmin etmeye çalışmışlardır. Ürettikleri epoksinin deneyleri Taguchi L_9 ortogonal tasarım ile yapılmış olup faktör etkileri incelenmiştir. 0,002 öğrenme hızı ve bir adet gizli katman ile eğitilen ağın tahmin sonuçlarının MAPE (mutlak hataların ortalamasının yüzdesi) değeri %9'un altında bulunmuştur.

Mirmohseni ve Zavareh (2010) CCD kullanarak epoksi malzemeye belirli ağırlık oranlarında ABS (Akrilonitril Bütadien Stiren), kil ve TiO_2 katkı ekleyerek malzemenin mekanik özelliklerini izlemişlerdir. Çalışmada optimum katkı oranları belirlenerek darbe dayanımı yüksek epoksi üretilmiştir.

Siddharta ve ark. (2011) çalışmalarında TiO_2 katkı oranı, kayma hızı, yük, kayma mesafesi gibi girdileri kullanarak Taguchi tasarım ile epoksi malzemede aşınmayı

modellemiştir. Kompozitin mikroskop incelemelerinde TiO₂ katkısının epoksinin mekanik özelliklerini olumlu yönde etkilediği görülmüştür.

Basaravajappa ve ark. (2011) yayımladıkları çalışmada cam katkılı epoksi malzemenin aşınma davranışını incelemiştir. Kompozitteki cam katkısı seviyesi sabit tutularak üç farklı faktörün üç seviyesi denenmiştir. Bu faktörler test cihazının parametreleri olan yük, kayma hızı ve kayma mesafesi olmuştur. Taguchi tasarım yapılmış ve faktör etkileri gözlemlenmiştir.

Rout ve Satapathy (2012) yaptıkları çalışmada pirinç çeltiği ile güçlendirilmiş epoksi malzemenin aşınma oranını tespit etmeye çalışmışlardır. Taguchi L₁₆ ile yapılan tahmin sonuçları yapay sinir ağları ile yapılan tahmin sonuçlarıyla karşılaştırılmıştır. Yapay sinir ağlarında hataların ortalaması %5,22 olarak bulunurken. Taguchi tasarımında %6,09 olarak bulunmuştur.

Rajesh ve ark. (2012) Box Behnken ve Taguchi metodu ile alüminyum kompozite katılan kırmızı çamur'un ve diğer test makinesi parametrelerinin etkilerini görmeye çalışmışlardır.

Diler ve İpek (2013) alüminyumun silisyum karbür ile aşınma performansının güçlendirilmesi ve CCD ile bu aşınmanın modellenmesi çalışmasını yapmışlardır. Çalışmada %17,5'lik katkı hacmine kadar kompozitin aşınma dayanımında artış gözlemlenirken, bu seviyeden sonra katkının alüminyum içerisinde kümelenmesinden ötürü aşınma dayanımında bir düşüş gözlemlenmiştir.

Agarwal ve ark. (2013) cam-epoksi kompozitine silisyum karbür ekleyerek malzeme sertliğini dolayısıyla aşınma performansını arttırmaya çalışmışlardır. Silisyum karbür, kompozitin aşınma oranını azaltmıştır. Kütlenin %15'i üzerindeki oranlardaki katkıların aşınma oranına pozitif bir etkisi olmamıştır.

Bagci ve Imrek (2013) 5 farklı faktörün (epoksinin fiber yapısı, aşındırıcı kum büyüklüğü, borik asit katkısı, tanecik çarpma açısı ve hızı) epoksi malzemedeki aşınma oranına etkisini Taguchi L₃₆ tasarım ile tespit etmişlerdir.

Rostamiyan ve ark. (2014) karışımdaki polistiren, silika ve sertleştirici oranları girdilerini kullanıp karışım tasarımı yaparak çoklu tepkiyi analiz etmişlerdir. Bu tepki değişkenleri; gerilme, bükme, sıkıştırma ve darbe dayanımları olmuştur. Malzemenin gerilme, sıkıştırma ve darbe dayanımları artarken bükülme dayanımında bir artış görülmemiştir.

Kumar ve ark. (2014) yaptıkları çalışma ile sinterlenmiş Cu-SiC-Gr kompozitinin aşınma davranışını incelemişlerdir. Bu çalışmada sinir ağının öğrenmesi genetik algoritma ile sağlanmıştır. Genetik algoritma kullanılan ağ ile kullanılmayan ağın tahmin başarısında büyük bir farklılık tespit edilememiştir.

Padhi ve Satapathi (2014), epoksi aşınma oranını Taguchi L_{16} tasarımıyla inceleyerek faktör etkilerini ve Signal-to-Noise katsayısını belirlemişlerdir. Bu çalışmada Bağcı ve İmrek'inkine ek olarak yapay sinir ağları tanıtılmıştır. Yapay zekanın algoritmasının aşınma davranışını tahmin etmedeki başarısından bahsedilmiştir.

Rao ve ark. (2014) yayımladıkları makalede karbon dokuma destekli epoksi kompozitin aşınmasının yapay sinir ağları ile modellenmesi üzerine çalışmışlardır. Çalışmada grafit katkılı ve katkısız olmak üzere iki farklı malzeme kullanılmıştır. Kullanılan geri yayımlı ağda bir tane gizli katman bulunup, bu katmanda beş adet nöron kullanılmıştır. Katkı oranı, kayma hızı ve uygulanan yük ağ yapısının girdi değişkenleri olmuştur. Farklı öğrenme algoritmaları deneme yanılma yöntemi ile test edilmiş ve sınama (test) veri seti için en doğru tahmini yapan algoritma Levenberg–Marquardt olarak bulunmuştur. Farklı yapıdaki ağların tahmin güçlerinin karşılaştırılması MRE, SSE, MSE ve R^2 metrikleri ile yapılmıştır.

Rostamiyan ve ark. (2015) epoksinin sönümlenme özelliklerini arttırmak amacıyla yaptıkları çalışmayı yayımlamışlardır. Bu çalışmada bir katkı karışımı belirlenerek epoksi malzemeye bu karışım eklenmiştir. Karışımın belirlenmesinde karışım tasarımı (mixture design) kullanılmış olup; polistiren, silika ve sertleştirici karışımı hazırlanarak epoksi malzemeye eklenmiştir. Sönümlenmeyi maksimize edecek karışım tasarımı belirlenmiştir. Optimum karışımda hiç polistiren bulunmazken 0,37 seviyesinde silika 0,62 seviyesinde sertleştirici bulunmuştur.

Speck ve ark. (2016) yayımladıkları makalede Rodamin B'nin çökmesini modellemişlerdir. CCD ile dört farklı faktörün (Fe^{2+} ve H_2O_2 yoğunluğu, işlem süresi, boya yoğunluğu) çökelmeye olan etkileri belirlenmiş ve ikinci dereceden bir regresyon denklemi oluşturulmuştur. Optimum tepki için gerekli faktör seviyeleri RSM ile belirlenmiştir. Yapay sinir ağı da tahminde kullanılmak istenmiş ve 10 adet nöronlu oluşan, bir gizli katmanlı, Levenberg–Marquardt öğrenme algoritması kullanan bir ağ eğitilmiştir. Sinir ağı ile elde edilen tahmin sonucunun doğruluğu RSM sonucundan yüksek bulunmuştur.

Sharma ve ark. (2016) CCD kullanarak metal kompozitin (Alüminyum) aşınma incelemesi ve optimizasyonu üzerine çalışmışlardır. Grafit katkı yüzdesi, test yükü, kayma hızı

ve kayma mesafesi incelenen faktörler olmuştur. Katkı oranının aşınmayı azalttığı sonucuna ulaşılmıştır.

Purohit ve Satapathy (2017) FCCCD ($\alpha=1$) kullanarak aşınma tahmini yapmışlardır. Faktörler; LDS katkı yüzdesi, aşındırıcı parçacıkların çarpma açısı, çarpma hızı, sıcaklığı ve büyüklüğü olmuştur. Sonuçlar göstermiştir ki, çarpma hızı ve katkı miktarı aşınma miktarını etkileyen en önemli faktörler olmuştur. Çarpma hızı artışı, tepkiyi pozitif bir ilişki ile etkilerken, katkı oranı aşınma miktarını negatif etkilemiştir.

Satyanarayana ve ark. (2018) nano boyutlardaki kırmızı kil katkılı alüminyumun yapay sinir ağı ve matematiksel regresyon ile aşınma tahminini yapmışlardır. Yapay sinir ağları modeli regresyondan daha başarılı bir tahmin gerçekleştirmiştir. Farklı ağ yapıları denenmiş olup MAPE, RMSE ve R^2 değerleri performansların karşılaştırılması için kullanılmıştır. Ağ yapısının girdisi; test parametrelerinden yük ve kayma hızı olurken, malzeme parametrelerinden deformasyon ve katkı oranı olmuştur.

Agbeleye ve ark. (2018) yaptıkları çalışmada alüminyum-kil kompozitinin aşınma oranının incelenmesinde yapay sinir ağı kullanmışlardır. Soğutma ortamları, çözündürme sıcaklığı, kayma hızı ve yük değerleri çalışmada ağ girdileri olarak kullanılmıştır. Diğer çalışmalarda olduğu gibi bu çalışmada da farklı ağ yapıları denenmiştir. Tek katmanında 10 nörona sahip Levenberg-Marquardt öğrenme algoritmali ağ en başarılı sonucu vermiştir.

Literatürde önemli olarak bulunan çalışmalar matris halinde Çizelge 2.1’de verilmiştir. Çalışmalarda görüldüğü üzere numunelerin test edildiği makinelerin parametreleri sabit tutulmayıp tasarıma dahil edildiği zaman Taguchi metodu daha sık kullanılmaktadır. Test makine parametreleri sabit tutulduğunda ise değiştirilebilir faktör sayısı daha az olacağından CCD ve karışım tasarımı daha çok tercih edilmektedir. Tam faktöriyel ve kesirli faktöriyel gibi tasarımların optimizasyondan daha çok eleme deneyleri için kullanıldığı görülmektedir. Yapay sinir ağları genel olarak karmaşık yapıdaki verileri daha rahat çözümleyebildiğinden malzeme özellikleri ve aşınma tahminlerinde sıklıkla kullanılmıştır. Çoğunlukla uygulanan metot, birden fazla ağ yapısının denenip, karşılaştırılarak en başarılı ağ yapısının seçilmesidir. Literatürde incelenen çalışmaların ışığında; tez çalışmasında RSM ile model kurulup, aşınma, sertlik ve maliyet tepki değişkenleri tahmin edilmiş ve optimum üretim noktaları tespit edilmiştir. Malzemenin abrasif aşınması incelenmiş ve elde edilen aşınma değerleri için RSM ile ANN metotlarının tahmin performansları karşılaştırılmıştır.

Çizelge 2.1. Literatür Matrisi

No	Çalışmanın Adı	Yıl	Amaç	Yöntem	Faktörler	Tepki
1	Modeling and optimization of a new impact-toughened epoxy nanocomposite using response surface methodology	2010	Darbeye dayanıklı epoksi elde edilmesi	RSM-CCD	ABS %, Kil %, TiO ₂ %	Darbe dayanımı
2	A Study on Tribological Behavior of Alumina- Filled Glass-Epoxy Composites Using Taguchi Experimental Design	2010	Test parametrelerinin aşınmaya olan etkilerinin incelenmesi	Taguchi L ₂₇	Çarpma hızı ve açısı, aşındırıcı sıcaklığı, vuruş mesafesi	Aşınma oranı
3	Mechanical and dry sliding wear characterization of epoxy-TiO ₂ particulate filled functionally graded composites materials using Taguchi design of experiment	2011	TiO ₂ katkının epoksinin aşınması üzerindeki etkisinin incelenmesi	Taguchi L ₂₇	Kayma hızı, TiO ₂ %, yük, kayma mesafesi	Aşınma oranı
4	Dry sliding wear behaviour of organo-modified montmorillonite filled epoxy nanocomposites using Taguchi's techniques	2011	OMMT destekli epoksi malzemenin aşınma optimizasyonu	Taguchi L ₉	Kayma hızı, yük, OMMT %, kayma mesafesi	Aşınma oranı
5	Abrasive wear behaviour of hard powders filled glass fabric-epoxy hybrid composites	2011	Karbür katkısının epoksi malzemede aşınmaya olan etkisi	Kontrollü Deneysel	Farklı karbür katkıları	Aşınma Oranı
6	Abrasive Wear Behavior of Granite-Filled Glass-Epoxy Composites by SiC Particles Using Statistical Analysis	2011	Cam katkılı epoksi malzemenin aşınma davranışının incelenmesi	Taguchi L ₂₇ , ANOVA	Yük, hız, mesafe, granit oranı	Aşınma sonrası kütle kaybı
7	Analysis of dry sliding wear behaviour of rice husk filled epoxy composites using doe and ANN	2012	Pirinç çeltiği ile güçlendirilmiş epoksi malzemenin aşınma davranışının incelenmesi	Deneysel tasarım, Taguchi L ₁₆	Kayma hızı, yük, pirinç %, kayma mesafesi	Aşınma oranı
8	Investigation in to Wear behavior of coir Fiber Reinforced Epoxy Composites with the Taguchi Method	2012	Fiber katkının epoksi malzemenin aşınması üzerindeki etkisinin incelenmesi	Taguchi L ₉	Fiber %, fiberin işlem görme durumu, yük, dönme hızı	Aşınma oranı
9	Application of Taguchi method on optimization of testing parameters for erosion of glass fiber reinforced epoxy composite materials	2013	Epoksi aşınma oranının azaltılması	Taguchi L ₃₆ -SN Oranı	Fiber açısı, aşındırıcı büyüklüğü, borik asit %, çarpma açısı, çarpma hızı.	Aşınma oranı
10	Main and interaction effects of matrix particle size, reinforcement particle size and volume fraction on wear characteristics of Al-SiCp composites using central composite design	2013	Alüminyumun aşınma karakteristiğinin tespit edilmesi	CCD	Hacim payı, matris ve güçlendirici parçacık büyüklüğü	Aşınma oranı
11	Solid Particle Erosion Behavior of BFS-Filled Epoxy-SGF Composites Using Taguchi's Experimental Design and ANN	2014	BFS-Epoksinin aşınma davranışının incelenmesi	Taguchi L ₁₆ -Yapay sinir ağları	Çarpma hızı, çarpma açısı, BFS %, aşındırıcı büyüklüğü, aşındırıcı sıcaklığı	Aşınma oranı
12	Optimization of tribological parameters in abrasive wear mode of carbon-epoxy hybrid composites	2014	Aşınma dayanıklı malzeme elde edilmesi için parametre optimizasyonu	Taguchi L ₁₈	Aşındırıcı büyüklüğü, katkı tipi, katkı yüzdesi, yük, kayma mesafesi	Aşınma oranı
13	Experimental study and optimization of damping properties of epoxy-based nanocomposite: Effect of using nanosilica and high-impact polystyrene by mixture design approach	2015a	Epoksinin sönmülendirme özelliklerinin optimizasyonu	Karışım tasarımı	HIPS %, SiO ₂ %, Sertleştirici	Sönümleme miktarı
14	Experimental and optimizing flexural strength of epoxy-based nanocomposite: Effect of using nano silica and nano clay by using response surface design methodology	2015b	Bükülme mukavemeti optimizasyonu	RSM-CCD	SiO ₂ %, Kil %, Fiber açısı	Bükülme mukavemeti
15	Microwave absorption properties of polypyrrole- SrFe ₁₂ O ₁₉ -TiO ₂ -epoxy resin nanocomposites: Optimization using response surface methodology	2016	Mikrodalga emilim optimizasyonu	RSM-CCD	% TiO ₂ %, SrFe ₁₂ O ₁₉ %, SrFe ₁₂ O ₁₉ -PPy	Yansıtma kaybı (emilim)

3. MATERYAL ve YÖNTEM

3.1. Kullanılan Malzemeler

Literatürde yapılmış olan çalışmaların incelenmesi sonucu bağımlı değişkenlerin tahmin ve optimizasyonunda kullanılan RSM yönteminin son yıllarda malzeme alanında kullanımının yaygınlaştığı görülmüştür. Çalışmada epoksinin aşınma, sertlik ve üretim maliyeti gibi mekanik ve ekonomik özellikleri incelenmiş ve bu üç tepki değişkeni için de optimum değerlere sahip bir üretim değeri belirlenerek malzemenin özelliklerinde ve maliyetinde iyileşme sağlanmıştır. Epoksi malzeme günümüzde pek çok alanda yoğunlukla kullanılmaktadır. Otomotiv, tekstil, inşaat, plastik sanayi gibi birçok alan buna örnektir. Yaygın kullanımın nedenleri arasında epoksi malzemenin;

- Kimyasallara karşı dayanıklı olması
- Dekoratif uygulamalarda geniş bir renk yelpazesine sahip olması
- Kolay temizlenir ve hijyenik olması
- Yağ ve kimyasallara karşı dirençli olması
- Estetik olması ve kaymaz zeminler oluşturması
- Solvent içermemesi gösterilebilir (<http://www.niseboya.com.tr/yazilar/epoksi-kullanim-alanlari/>, erişim tarihi 2.4.2018).

Tez çalışmasında deney numuneleri üretilirken kullanılan ana malzemeler; epoksi ve sertleştiricidir. Ana malzeme olarak epoksi ile üretime başlanmış sonrasında, ürün reçetesinde yazdığı gibi, her bir birim epoksi için 0,4 birim sertleştirici karışıma eklenmiştir. Bu iki malzeme ile numunelerin ana bileşeni oluşturulmuştur. Sonrasında çeşitli katkı eklemeleriyle numuneler farklılaştırılmıştır. Çalışmada kullanılan epoksi (L285) ve sertleştirici (H285) malzemelerinin reçeteleri Çizelge 3.1 ve 3.2 ile verilmiştir.

Çizelge 3.1. MGS L285 Epoksi Malzeme Sertifikası ve Özellikleri

Sertifika	German Federal Aviation
Uygulama Alanı	Planör, motorlu planör, motorlu uçak, bot, gemi, spor aletleri, model uçaklar, kalıp ve genel uygulamalar
Çalışma Sıcaklığı	-60°C/+50°C Isıl işlem uygulanmadan -60°C/+80°C Isıl işlem uygulanarak
Proses Sıcaklığı	+10°C/+50°C
Özellikleri	Çok üst düzey uyumluluk Çok iyi mekanik ve ısıl özellikler 45 dakikadan 4 saate kadar çalışma süresi
Depolama	Açılmamış ambalajında 24 ay
Miktar	MGS L285 Reçine (1 kg) + H285 Sertleştirici (0,4 kg)
Çalışma Süresi	1 saat (100 ml karışım 23°C)

Çizelge 3.2. H285 Sertleştirici Özellikleri

Sertleştirici	H285
Yoğunluk (gr/cm³)	0,94-0,97
Vizkosite (mPas)	50-100
Amin değeri (mgr KOH/gr)	480-550
Refraktör indeksi	1,5020-1,5500
Ölçüm Şartları	25°C

Tekstil, elektronik, kimya, otomotiv ve inşaat gibi birçok sanayi alanında kullanılan epoksi malzemenin farklı mekanik özelliklere sahip olması beklenir. Epoksi malzemenin özellikle yapı sanayiinde kullanım amacı olan koruma ve onarma gibi fonksiyonları yerine getirebilmesi için aşınma oranının minimum olması gerekmektedir. Optimizasyon yapılırken yalnızca bir tepkinin incelenmesi yerine uygulamada birçok tepki değişkenini aynı anda optimize eden girdi değişkenlerinin belirlenmesi önemli bir konudur. Farklı tepkiler bir arada ele alınıp optimize edildiğinde elde edilen sonuçlar uygulamada daha fazla fayda sağlayacaktır. Böylece gerçek hayat problemlerine daha uygun ve uygulanabilir çözümler üretilmesi mümkün olacaktır. Bu çalışmada optimizasyon çalışması çoklu tepki optimizasyonu yöntemi ile ele alınmış olup seçilen senaryolar kapsamında optimum noktalar bulunmuştur. Sonrasında aşınma için oluşturulan RSM modeli ile yapay sinir ağlarının aşınma tahmin performansları karşılaştırılmıştır.

Epoksi malzeme ile sertleştirici karışımına eklenen inorganik katkılar malzemenin aşınma oranını azaltmaktadır. Epoksi malzemenin içeriğine eklenecek katkılar ile böylece

aşınma dayanımı yüksek epoksi elde edilecek olup, epoksi kompozitin kullanım alanı ve kullanım ömrü arttırılmış olacaktır. Epoksi malzemenin kullanıldığı yere bağlı olarak farklı fiziksel ve kimyasal özelliklere sahip olması beklenebilir. İyi mekanik güç, sertlik, sıcaklık ve kimyasal direnç epoksinin daha geniş bir alanda kullanımına olanak sağlar. Farklı malzeme katkılarıyla (karbon fiber, grafit, TiO₂ vb.) epoksi malzemenin aşınma dayanımında iyileştirmeler yapmak mümkündür (Zhang ve ark. 2004). Epoksi malzemelerde aşınma direnci arttırılırken farklı katkılar kullanılmıştır. Literatür incelendiğinde katkı eklemesi ile malzemenin moleküler şekline bağlı olarak %30'a varan bir aşınma dayanımı artışından bahsetmek mümkündür. Şu ana kadarki ulaşılan en iyi aşınma direnci geleneksel katkılar (grafit, karbon fiber ve titanyum dioksit) ile elde edilmiştir (Marquis 2011). Aşınma dayanımının artışı için epoksiye eklenecek malzemeler cam tozu ve ferrokrom (karbür) tozu olarak belirlenmiştir. Bunun nedeni bu malzemelerin kolay ulaşılabilir, düşük maliyete sahip ve literatürdeki çalışmalarda kullanılmış olmalarıdır. Cam tozu, atık camların öğütülmesinden elde edilmektedir ve maliyeti oldukça düşüktür. Ayrıca piyasada hazır öğütülmüş halde de satılmaktadır. Karbür de dışarıdan külçeler halinde satın alınıp öğütücülere konularak toz haline getirilmektedir. Karbür'deki krom oranı %55-60 arasında değişmektedir. Tezde kullanılan ferrokrom karbürün içerik bilgisi Çizelge 3.3 ile verilmiştir.

Çizelge 3.3. Karbür İçeriği (<http://www.altinkumdokum.com/tr/urun/Ferrokrom>, erişim tarihi 23.3.2019)

Element	Miktar
Krom	% 55-60
Karbon	% 6-8
Silisyum	Maksimum % 3
Fosfor	Maksimum % 0,03
Kükürt	Maksimum % 0,04

Literatürde bu iki katkının (karbür ve cam tozu) birarada kullanıldığı durumda görülen etkinin incelendiği bir çalışmaya rastlanmamıştır. Bu katkıların seviyelerinin belirlenmesinde tepki yüzeyleri tasarımı yöntemlerinden kompozitlerin tasarımlarında sıklıkla kullanılan Merkezi Birleşik Tasarım (CCD-Central Composite Design) kullanılmıştır.

3.2. Tepki Yüzeyleri Tasarımı

Tez çalışmasında epoksinin mekanik özelliklerinin optimizasyonu için tepki yüzeyleri tasarımı kullanılmıştır. Tepki yüzeyleri tasarımı bir veya daha fazla tepki değişkeni ile girdi değişkenleri (faktör) arasındaki ilişkiyi polinomlar ile model kurarak göstermeyi ve optimize etmeyi hedefleyen matematiksel ve istatistiksel tekniklerin bütünüdür. Tepki değişkenleri Y_1 , Y_2 , Y_3 ile gösterilir. Tepki değişkenlerini etkileyen faktörler ise X_1 , X_2 , X_3 ile gösterilir. Genelde girdi ve çıktı değişkenleri arasındaki ilişki başlangıçta bilinmez. Ancak ilişki düşük dereceli polinomlar ile yaklaşık olarak tahmin edilebilir (Khuri ve Mukhopadhyay 2010). Tepki değişkenleri bir veya birden fazla olabilir. Birden çok tepkinin optimize edilmesinde birbirlerinden farklı amaçlar olacağından tepkiler arasında önem dereceleri belirleme veya belirli bir amacı optimize ederken diğerlerini bir aralıkta sabit tutma gibi yöntemler ile çoklu tepki optimizasyonu yapılmaktadır. RSM tekniğinde çoklu tepki optimizasyonu için istenirlik (desirability) fonksiyonu kullanılır. Toplam istenirlik düzeyinin maksimize edilmesi (önem dereceleri kıstas alınarak) çoklu tepki optimizasyonun amacıdır. İstenirlik fonksiyonu (3.1) bağıntısı ile hesaplanır (Montgomery 2001).

$$d = \frac{U - y}{U - T} \quad (3.1)$$

*d: istenirlik değeri U: maksimum tepki değeri
y: optimizasyonu sonucu elde edilen tepki T: hedeflenen tepki değeri*

Deneysel verinin bir tepkinin modeline uydurulması veya veriyi tanıma benzeri çalışmalar istatistiksel deneysel tasarım, regresyon modelleme tekniği ve optimizasyon yöntemlerini belirli ölçülerde kullanmayı gerektirir. Bu üç yöntemin birleşimine genel olarak tepki yüzeyleri metodolojisi adı verilir (Carley ve ark. 2004).

Deneysel farklı deneysel tasarımlar kullanılarak deneyler planlanır (Taguchi, CCD, Faktöriyel, Box-Behnken vb.). Probleme ve amaca uygun olarak seçilecek deney tasarımı ile, tepki değişkeninin haritalandırılması için, deney noktaları belirlenip bu noktalarda deneyler yapılarak laboratuvar çalışması tamamlanır. Sadece belirlenen noktalarda deneyler yapılacağından hem zamandan hem de maliyetten kazanç sağlanır. Deneysel tasarımların en önemli özelliği maliyet ve zaman açısından fazla sayıda deneyin önüne geçmektir. Deneysel tasarımın üç temel prensibi bulunmaktadır (Montgomery 2001);

Deney Tekrarı (Replikasyon): Mükün mertebe deneydeki faktörlerin belirli noktalarındaki deneylerin birden fazla kez tekrar edilmesi gerekmektedir. Böylelikle deneydeki üretim, test ve insan hatalarından kaynaklı hatalar en aza indirilebilir.

Bloklama: Deneyde kontrol edebildiğimiz değişkenler kadar kontrol edemediklerimiz de bulunmaktadır. Bu faktörleri ses faktörleri denir ve gerekli durumlarda bloklama yapılarak deneydeki tepki değişkenine katılan ses etkileri azaltılarak daha sağlıklı bir model elde edilebilmektedir.

Rassallık: Deneylerde insana bağlı olan yanlılık olarak adlandırılan hataları azaltmak için deneylerin rassal bir sırayla yapılması uygun olacaktır. Testler sonrasında kurulacak regresyon modelinin tahmin hatalarının rassal olması beklenmektedir. Hataların rassallığı için deneylerin de rassal olması gerekmektedir.

Tepki yüzeyleri metodolojisinde faktörler modelde gerçek değerlerin yerine kodlanmış seviyeleri ile de kullanılmaktadır. Aşağıdaki bağıntı (3.2) yardımıyla faktörlerin gerçek seviyelerinden kodlanmış seviyelerine geçiş yapmak mümkündür (Tanyildizi ve ark. 2005).

$$x_i = \frac{(X_i - X_0)}{\Delta X_i} \quad (3.2)$$

X_0 : orta nokta X_i : gerçek değişken
 x_i : kodlanmış değişken ΔX_i : yarı genişlik

Analiz sonucunda elde edilen kodlanmış değişkenlere bağlı regresyon denklemi de bu ifade ile gerçek seviyelere güncellenebilir. Tepki yüzeyleri tasarımı metodolojisinin kullandığı araçlardan biri de regresyon modelleridir. Faktörlerin tepki değişkenine olan etkisinin, kendi aralarındaki etkileşimlerinin ve tepkinin tahmini amacıyla regresyon modelleri kullanılmaktadır. Birinci dereceden regresyon denklemi (3.3) bağıntısı ile gösterilmektedir (Khuri ve Mukhopadhyay 2010). Regresyon katsayıları en küçük kareler yöntemi ile hesaplanmakta olup %95 güven aralığı için alt ve üst sınırları da (3.4) bağıntısı ile hesaplanmaktadır (Montgomery 2001).

$$Y = \beta_0 + \sum_{i=1}^k \beta_i X_i + \varepsilon \quad (3.3)$$

$$\hat{\beta}_j - t_{\alpha/2, n-p} se(\hat{\beta}_j) \leq \beta_j \leq \hat{\beta}_j + t_{\alpha/2, n-p} se(\hat{\beta}_j) \quad (3.4)$$

Tepki deęişkeninin eğrilięine göre buradaki denkleme daha yüksek dereceli terimler veya etkileşim terimleri eklenebilir. Deneyler tamamlandıktan sonra En Küçük Kareler Yöntemi yardımıyla β parametreleri belirlenir ve regresyon denklemi oluşturulur (Bezerra ve ark. 2008).

Tez çalışmasında CCD kullanılmıştır. CCD kullanılmasının nedeni, CCD ile sistemin daha geniş aralıklarda tasarlanmasının mümkün olmasıdır. CCD’de α ek tasarım noktaları ile faktöriyel tasarımdan farklı olarak daha fazla noktada gözlem yapılacağından elde edilecek modelin tahmin gücü ve kalitesi arttırılmış olacaktır. Merkezi noktalarda ve yüksek sayıda deney tekrarı ile tepkideki deęişimler ve eğrilikler daha detaylı şekilde tespit edilmiştir. Bununla beraber literatürde benzer konularda (kompozitin optimum bileşiminin belirlenmesi vb.) yapılmış çalışmalarda çoęunlukla CCD kullanılmıştır. Zolgharnein vd. yaptıkları çalışmada (2013) kurşunun yüzeye tutunma özelliğini Box-Behnken, Doehlert matrisi ve CCD olmak üzere üç farklı deney tasarımı kullanarak tahmin etmeye çalışmışlardır. En başarılı tahmin sonucu CCD deney tasarımı ile alınmıştır.

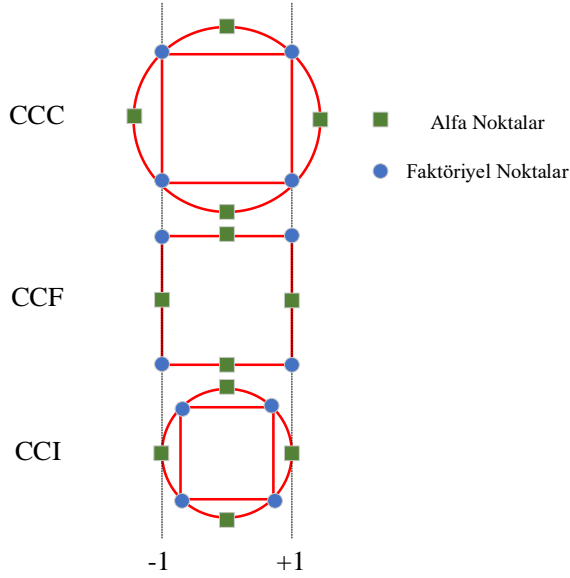
Birden çok bağımsız deęişken ve bunların etkileşimleri söz konusu olduğunda RSM optimizasyon için uygun bir metodolojidir. RSM model uydurmak için CCD, Box-Behnken gibi deneysel tasarımlar kullanılır.

CCD 3’e ayrılır;

- CCC: CCD’nin asıl şeklidir. Her faktörün 5 farklı seviyesi bulunmaktadır.
- CCI: Alt üst limitlerin dışına çıkılmadığı durumlarda kullanılmaktadır. Her faktörün 5 farklı seviyesi bulunmaktadır.
- CCF: α noktaları +1, -1 seviyesine denk gelmektedir. Üç farklı seviye alınır.


Üç farklı CCD tasarımının geometrik gösterimleri Şekil 3.1’deki gibidir

(<https://www.itl.nist.gov/div898/handbook/pri/section3/pri3361.htm>, erişim tarihi 1.4.2018).



Şekil 3.1. Tasarımların Geometrik Gösterimleri (Anonim 2018)

İki farklı faktör için (X_1 ve X_2) için kübik CCD gösterimi Şekil 3.2’de verilmiştir. İlave deney noktaları (α) ile birlikte 9 adet deney yapılması gerekmektedir.



Şekil 3.2. CCD’nin Kübik Gösterimi (Montgomery 2001)

Tahmin ve optimizasyon çalışmasında kullanılacak metodoloji olan tepki yüzeyleri tasarımının pek çok avantajı bulunmaktadır. Endüstriyel uygulamalarda, kalite geliştirme süreçlerinde, 6 sigma süreçlerinde, Ar-Ge ve Ür-Ge alanlarında sıklıkla kullanılan RSM, kullanım kolaylığının yanında faktör değişkenlerinin tepki üzerindeki etkilerinin izlenmesi ve haritalandırılması gibi çalışmalarda büyük kolaylık sağlamaktadır. Tepki yüzeylerinin deney

tasarımı sayesinde daha az deney ile optimizasyon gerçekleşeceğinden düşük deney maliyetleri ve zaman kazancı elde edilmiş olacaktır. Bu sayede düşük maliyet ile aşınmayı optimize edecek malzeme yapısının belirlenmesi mümkün olacaktır.

3.2.1. Model yeterlilik testleri

Modelin doğru ve yalın olduğunu gösteren iki farklı model istatistiği (AIC ve BIC) bulunmaktadır. AIC (Akaike's Information Criteria) ve onun küçük veri setleri için geliştirilmiş versiyonu AIC_c (Corrected AIC), model seçiminde ve model karmaşıklığını azaltmada kullanılmaktadır. Model sadeleştirilirken, modelden çıkan terimler sonucu oluşacak bilgi kaybı da kaçınılmaz bir durumdur ve izlenmesi gerekmektedir (Quaiser ve ark. 2011). AIC hem hatanın kareler toplamını hem de model içindeki tahmin parametrelerinin sayısını ölçtüğünden önemli bir parametredir. Genel eğilim, modeldeki gözlem sayısı yüksek ise AIC kullanımı yönündedir. Ancak gözlem sayısı arttıkça, küçük gözlemler için kullanılan AIC_c , AIC'ye yakınsayacağından AIC_c 'nin kullanılmasında bir sakınca yoktur. BIC de (Bayesian Information Criteria) AIC'nin bir alternatifi olup model seçiminde kullanılan bir ölçüttür. Alternatif modeller karşılaştırılırken küçük olan AIC ve/veya BIC değerine sahip model daha uygundur. Bu metriklerin hesaplanması (3.5) ve (3.6) bağıntısındaki gibidir (Burnham ve Anderson 2004).

$$AIC_c = -2\log L(\hat{\theta}) + 2k + \frac{2k(k+1)}{n-k-1} \quad (3.5)$$

$$BIC = -2\log(L) + k\log(n) \quad (3.6)$$

n: gözlem sayısı *k*: modeldeki parametre sayısı

PRESS (Prediction Error Sum of Squares) istatistiği sırasıyla tüm gözlemlerin model parametre eğitim setinin dışında tutularak tahminlerinin yapılması ile elde edilir. PRESS, her bir *i* gözlemi için tahmini değerlerin gerçek değerlerden farkının karelerinin toplamına eşittir. R^2_{tah} değerinin hesaplanmasında kullanılan PRESS değeri modelin bilinmeyen bir veri ile karşılaştığındaki tahmin gücünü gösterir (Montgomery 2001). PRESS değerinin düşük seviyede olması istenen bir durumdur. Hesaplanması için kullanılan formül (3.7) bağıntısında verilmiştir.

$$PRESS = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3.7)$$

Yapılan tahmin sonucu geliştirilen model, deneyler sonucu elde edilen sonuçları tam olarak temsil etmeyebilir. Bu durum test edilmelidir. Modelin tahmin gücünü test etmenin en uygun yolu varyans analizi (ANOVA) yapmaktır. ANOVA tepki değişkenindeki değişimlerin ne kadarının girdi değişikliklerinden, ne kadarının deney hatalarından kaynaklandığını gösterir. Bu analiz ile oluşturulan modelin anlamlılığı da hesaplanır (Bezerra ve ark. 2008).

Tahmin modellerinde modelin yeterliliğinin tespiti için kullanılan performans göstergeleri bulunmaktadır. Sıklıkla kullanılan performans göstergeleri aşağıda özetlenmiştir (Hyndman ve Koehler 2006).

- Hata ortalamalarının kareler toplamı (Mean Square Error-MSE)
- Hata ortalamalarının kareler toplamının karekökü (Root Mean Square Error-RMSE)
- Mutlak hataların ortalaması (Mean Absolute Error-MAE)
- Mutlak hataların medyanı (Median Absolute Error-MedAE)

Bir diğer gösterge ise R^2 (Coefficient of Determination) performans göstergesidir. Modelin hatalar toplamının tüm hatalar toplamına oranı ile elde edilir. R^2 ne kadar yüksekse regresyon modelinin uyumu da o kadar yüksektir (<http://www.datascience.istanbul/2017/07/11/r-kare-ve-duzeltilmis-r-kare/>, erişim tarihi 28.3.2018). Tepkideki değişimlerin ne kadarının girdi faktörlerindeki değişimler ile açıklanabildiğini ve gözlemlenen çıktılarının yüzdelik olarak ne kadarının regresyon eğrisi üzerinde kaldığını göstermektedir. Bunun yanında, Düzeltilmiş R^2 ($R^2_{düz}$) ve Tahmin edilen R^2 (R^2_{tah}) metrikleri de modelin gücünü görmek için kullanılmaktadır. $R^2_{düz}$ hesaplamaya serbestlik derecelerini de dahil ettiğinden, modele yalnızca tepkiye etki eden faktörler ilave edildiğinde artmaktadır. R^2 için böyle bir durum söz konusu olmayıp modele eklenen her terim ile R^2 artmaktadır ve bu nedenle tek başına R^2 'ye bakılması kimi zaman yanıltıcı olabilmektedir. R^2_{tah} ise formülde PRESS değerini kullandığından modelin, eğitimde kullanılmayan veri ile karşılaştığında tahmin başarısının ne olacağı konusunda fikir vermektedir. Modele uygulanan F ve uyum eksikliği (Lack of Fit) testleri de modelin geçerliliğinin belirlenmesi için önemli kriterlerdir. R^2 , $R^2_{düz}$ ve R^2_{tah} için formüller (3.8), (3.9) ve (3.10) bağlantılarında verilmiştir (Montgomery 2001).

$$R^2 = \frac{SS_{Model}}{SS_{Toplam}} \quad (3.8)$$

$$R_{düz}^2 = 1 - \frac{SS_E + df_E}{SS_{Toplam}/df_{Toplam}} \quad (3.9)$$

$$R_{tah}^2 = 1 - \frac{PRESS}{SS_{Toplam}} \quad (3.10)$$

Kesinlik yeterliliği (Adeq Precision), tasarım noktalarındaki tahmini değerlerin değer aralıkları ile ortalama tahmin hatalarını karşılaştırır. Dörtten büyük değerler modelin yeterliliğini gösterir (Anderson ve Whitcomb 2000).

Tez çalışmasında RSM ile model oluşturulduktan sonra istatistiksel olarak anlamsız terimler modelden çıkartılmıştır. Bu süreçte bilgi kaybı olmaması açısından modelin PRESS, AIC_c ve BIC istatistikleri izlenmiştir. Yapay sinir ağı ve RSM tahmin performanslarının karşılaştırılması ise mutlak hata yüzdelerinin ortalaması (Mean Absolute Percentage Error-MAPE), MSE ve R² ile yapılmıştır.

3.2.2. Tahmin modeli seçimi

Design Expert 11 programı yardımıyla aşınma ve sertlik tahminlerinin yapılması için varyans analizi ve regresyon denklemi oluşturulmuştur. Model seçiminde yanlılık ve bilgi kaybına neden olmamak için literatürde model seçimlerinde kullanılan AIC_c, BIC, PRESS metrikleri dikkate alınmıştır. Çalışmada sertlik ve aşınma tepki değişkenleri için ikinci, üçüncü ve dördüncü dereceden polinomlar program yardımıyla oluşturulmuştur. Aşınma modelinde ikinci ve üçüncü dereceli modellerde; sertlik modelinde ise üçüncü ve dördüncü dereceli modellerde uyum eksikliğine rastlandığından bu modeller tez çalışmasında kullanılmamıştır. Aşınma için dördüncü dereceli modelin, sertlik için ise beşinci dereceli modelin kullanılmasına karar verilmiştir. Modelin oluşturulmasının ardından her iki model için de istatistiki olarak önemsiz kabul edilen terimler (p≥0,05) çıkartılarak modeller daraltılmıştır. İstatistiksel olarak anlamsız terimler modelden çıkartıldıktan sonra AIC_c, BIC, PRESS metrikleri ile model doğrulanmıştır. Maliyet tepki değişkeni ise doğrusal bir yapıya sahip olduğundan birinci dereceden doğrusal model kullanılmıştır.

3.3. Yapay Sinir Ağları


Yapay sinir ağları isminden de anlaşılacağı üzere; insan veya hayvan sinir sistemindeki sinir hücrelerinden (nöronlar) oluşan ve karar destek sistemlerini simüle etmeye çalışan hesaplama ağlarıdır. Bu simülasyon hücreden hücreye yapılan simülasyonların toplamıdır. Yapay sinir ağları sinir sisteminin nöronlar ve nöronlar arası iletişim ağını alarak kullanır. Bu nedenle insan beyninin yerini alıp onu geliştiren geleneksel (dijital veya analog) hesaplama makinelerinden farklılık gösterir (Graupe 2013).

Yapay sinir ağları girdi ile çıktı arasındaki ilişkiyi öğrenerek sonrasında daha önce hiç karşılaşmadığı örneklerde öğrendiği bilgileri kullanan, genelleştirmeler yapan ve buna dayalı kararlar verebilen sistemlerdir. Yapay sinir ağları, her birinin farklı ağırlık değerine sahip olduğu bağlar ile birbirine bağlı nöronlardan oluşur. Ağ, eğitim sırasında bu ağırlıkları ayarlayarak danışman tarafından verilen çıktılara ulaşmaya çalışır. Ağların çalışma şekli tam olarak açıklanamamaktadır. Ağ parametrelerinin seçimi için belirli bir kriter, metrik veya teknik henüz bulunamamıştır. Eğitimin ne zaman bitirileceği de tam olarak bilinmemektedir. Ancak tüm bu eksikliklere rağmen, yapay sinir ağlarının kullanım alanı her geçen gün genişlemektedir. Sınıflandırma, örüntü tanıma ve optimizasyon çalışmalarında yapay sinir ağları en yaygın kullanılan tekniklerden biridir. Veri madenciliği, optimum rota belirleme, parmak izi tanıma, malzeme analizi, iş çizelgelemesi gibi birçok alanda başarılı örneklerine rastlamak mümkündür (Öztemel 2012).

Sinir ağlarının en küçük elemanı nöronlardır. Nöronlar sinyal iletimini gerçekleştiren iletişim elemanlarıdır. Yapay sinir ağlarının bilgi aktarımı aynı biyolojik nöronlarda olduğu gibi nöronların sinapslarıyla sağlanır. Alınan sinyalin diğer hücrelere aktarımı ise aksonlar yardımıyla gerçekleştirilir. Veri aktarılırken toplama fonksiyonu aracılığıyla toplandıktan sonra aktivasyon fonksiyonundan geçerek sıradaki hücrenin reseptörlerine ulaşır. Hücreler birbirleriyle bağlantılı olup her bağlantının kendi ağırlık değeri bulunmaktadır. Hücreler üçer ayrı bölüme ayrılarak katmanlaşırlar. Girdi ve çıktı katmanı olmak üzere iki ayrı katman bulunmakta olup bunların dışında bir de sayısı değişkenlik gösterebilen bir diğer katman olan ara (gizli) katman bulunmaktadır. Veri; girdi, ara katmanlar ve en sonunda çıktı katmanı sırası ile tüm katmanlardan işlenerek geçer. Bağlantıların ağırlık değerleri başlangıçta rassal olarak belirlenmiş olup, ağın eğitilmesi de esasen bu ağırlıkların değiştirilerek çıktılara göre ayarlanması sürecini içermektedir (Öztemel 2012).

Nöronların iki ucu bulunmaktadır. Kısalara dentrit uzunlara akson denilmektedir. Hücre dendritlerden reseptörler aracılığıyla alınan uyarıları akson yardımıyla kendinden sonraki

hücreye iletir (<http://www.yenibiyoloji.com/sinir-hucresinin-noronun-yapisi-gorevleri-ve-noron-cesitleri-1556/>, erişim tarihi 10.10.2018). Bir sinir nöronunun yapısı Şekil 3.3’de verilmiştir.



Şekil 3.3. Sinir Nöronlarının Yapısı (Basheer ve Hajmeer 2000)

Yapay sinir ağlarının kullanım alanı beynin karar proseslerine benzerliği ile sınırlı değildir. ANN'nin özörgütlenme özelliği karmaşık yapay zekâ algoritmaları kullanılarak geleneksel dijital bilgisayarlara aktarılabilir. ANN, yüksek programlama bilgisi gerektirmeden karmaşık problemlerin çözümüne olanak sağlar. Özellikle analitik, doğrusal ve durağan olmayan veya stokastik problemlerin çözümü için ANN kullanılmaktadır. Ayrıca nöronların paralel çalışmasından ötürü herhangi bir iletkende meydana gelen bir hata sonucu tüm işlem zarar görmez. Bu durum beyinde her yıl binlerce nöronun yok olmasına rağmen beyin fonksiyonlarının yine de devam etmesine benzer (Graupe 2013).

3.3.1. Toplama fonksiyonu

Bir yapay sinir hücresi kendi çevresinden girdi algıladığında bu bilgileri tek bir değer oluşturacak şekilde toplar. Hücrenin kendi sahip olduğu eşik değer alınan sinyalin iletilme kararının verilmesinde önemli rol oynamaktadır. Eğer hesaplanan net değer hücrenin eşik değerinden büyük ise sinyalin sıradaki sinir hücresine aktarımı gerçekleştirilir. Bu şekilde sadece net değeri eşik değerinden yüksek olan uyarıcıların sinyali tetiklemesine izin verilir (Basheer ve Hajmeer 2000).

Matematiksel olarak k nöronunun çıktı değeri aşağıdaki (3.11) ve (3.12) bağıntıları ile hesaplanmaktadır.

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (3.11)$$

$$y_k = \varphi(u_k b_k) \quad (3.12)$$

Denklemden x_1, x_2, \dots, x_j değerleri girdi sinyalleri, $w_{k1}, w_{k2}, \dots, w_{kj}$ değerleri nöronun sinaps ağırlıkları, u_k değeri input sinyallerinin toplamı, b_k değeri yanlılık (bias), φ aktivasyon fonksiyonu ve y_k değeri çıktı sinyalidir. Görüldüğü gibi haricen uygulanan yanlılık, aktivasyon fonksiyonunun net girdisini arttırıcı veya azaltıcı etki gösterebilmektedir. Eşik değeri aktivasyonunun kullanıldığı durumlarda $u_k + b_k$ değeri 1'den büyük olursa sinyal oluşmaktadır (Haykin 1998).

3.3.2. Öğrenme fonksiyonu

Yapay sinir ağının ilham aldığı beyin, deneyimlerinden öğrenir. Yapay sinir ağlarında da işleyiş benzerdir. Yapay sinir ağları, bağlantı ağırlıklarını değiştirerek öğrenme ile probleme bir çözüm ürettiğinden makine öğrenme algoritması olarak tanımlanabilir. Nöronlar arası bağlantıların şiddeti bağlantının ağırlık değeri olarak depolanır. Sistem yeni bilgiyi bu ağırlıkların ayarlanması sayesinde öğrenir. Ağın mimarisi ve kullanılan algoritmik metod ağın öğrenme kabiliyetini doğrudan etkiler (<http://osp.mans.edu.tr/rehan/ann/Artificial%20Neural%20Networks.htm>, erişim tarihi 04.10.2018).

Öğrenme zekanın en temel özelliğidir. Öğrenmenin tam tanımını yapmak zor olsa da, ANN'nin öğrenme süreci ağın belirli bir amacı etkin bir biçimde gerçekleşmesi için ağ yapısının ve bağlantılarının güncellenmesi olarak görülebilir. Performans, tekrarlı bir şekilde ağırlıklar güncellendiğinden zamanla geliştirilir. ANN girdi çıktı ilişkisini insanlar tarafından verilecek temel kurallar ile öğrenmek yerine verilen örnek veriden deneme yanılma yoluyla öğrenir. Bu, ağın en önemli avantajlarından biridir. Öğrenme prosesini anlamak ve tasarlamak için öncelikle ANN'nin çalıştığı çevreye ilişkin bir modele sahip olunması gerekmektedir. Ağ için hangi bilgilerin kullanılabilir olduğunun bilinmesi gerekmektedir. Ağ ağırlıklarının nasıl

güncellendiği (öğrenme kurallarının prosesi yönetme şekli) bilinmelidir. Öğrenme algoritması ise öğrenme kurallarının ağırlıklarının güncellenmesi prosedürüdür (Jain ve Mao 1996).

Yapay sinir ağı eğitim verisi ile desteklendikçe eğitim gerçekleşir. Kesinlik arz etmeyen, bulanık, başka faktörlerin etkisi altında olan veriye rağmen yapay sinir ağları yüksek kalitede çıktılar üretir ve eğitim verisinde öğrendiklerini daha önce hiç rastlamadığı veriye yönelik uygulayabilir (Basheer ve Hajmeer 2000). ANN üç farklı öğrenme ile karşımıza çıkmaktadır.

Danışmansız öğrenme: Gizli nöronlar dışarıdan yardım almadan kendileri bir yolunu bulup organize olmak zorundadırlar. Bu yaklaşımda ağı, sonuçlara bakarak tahmin performansını göreceği hiçbir çıktı verilmez. Ağ bir öğreticiye ihtiyaç duymadan deneyerek ilerler. Bu yöntemde ağ veriyi oluşturan yapıyı araştırır ve korelasyonları bulur. Bu korelasyonlar ile örnekleri kategorilere ayırır.

Danışmanlı öğrenme: Dışarıdan destek ile çalışan ağıdır. Gizli katmandaki nöronlar arası bağlantı rastgele ayarlanır. Ağı eğitim esnasında dışarıdan doğru cevaplar sağlanır. Ağ doğru yolda olup olmadığını bu cevaplara bakarak görür. Ağın problemin çözümüne yakın olma durumuna göre yeniden düzenlenir. Destekli öğrenme danışmanlı öğrenmenin bir varyasyonudur. Bu öğrenmede doğru cevaplar yerine ağın cevaplarının doğruluğu üzerinde yorumlar yapılmaktadır. Bir danışman veri ile ağı eğitir veya sonuçların yeterliliği üzerinden başarısını ölçer.

Hibrit öğrenme: Danışmanlı ve danışmansız öğrenmeyi birlikte uygular. Ağırlıklar genellikle danışmanlı öğrenme ile belirlenirken, diğerleri danışmansız öğrenme ile elde edilir (Jain ve Mao 1996).

Öğrenme kuralları, yapay sinir ağları öğrenmesinde temel prensip bağlantı ağırlıklarının ayarlanmasıdır. Bu öğrenme gerçekleştirilirken ağın çevrimiçi veya çevrimdışı olması durumuna göre farklı kurallar çerçevesinde öğrenme gerçekleşir. Bunlardan bazıları aşağıdaki gibidir (Öztemel 2012).

Hebb Kuralı: Hücreler ilettikleri sinyali alan komşu hücrelerle olan bağlantıları güçlendirmeye çalışmaktadır.

Hopfield Kuralı: Dışarıdan alınan bir sabit değer ile öğrenme gerçekleştirilir. Bu değer ölçüsünde bağlantılar kuvvetlendirilir veya zayıflatılır.

Delta Kuralı: Danışmanlı öğrenmede doğru sonuçlar ağı verildiğinden ağ bu cevaplara ulaşmaya çalışarak bağlantı ağırlıklarını ayarlar. Burada hedef değerleri ile ağın o iterasyonda

ürettiği çıktılar arasındaki hatanın karelerinin ortalamasına bakılır ve bu değerin minimuma yakınsaması amaçtır.

Kohonen Kuralı: Sadece belirli sayıda hücrenin ağırlıkları değiştirilmektedir. Hücreler ağırlığı değişen hücre olmak için yüksek çıktı üretmelidirler.

Farklı mimari ve öğrenme kurallarına göre kullanılan algoritmalar Çizelge 3.4’de verilmiştir.

Çizelge 3.4. Öğrenme Algoritmaları (Jain ve Mao 1996)

Öğrenme	Öğrenme Kuralı	Mimari	Öğrenme Algoritması	Kullanım Alanı
Danışmanlı	Hata düzeltme	Tek veya çok katmanlı perceptron	Perceptron öğrenme algoritmaları Geri yayımlı Adaline ve Madaline	Örüntü sınıflandırma Model uydurma ve kontrol
	Boltzmann	Yinelemeli	Boltzmann öğrenme algoritması	Örüntü sınıflandırma
	Hebbian	Çok katmanlı ileri besleme	Lineer diskriminant analizi	Veri analizi Örüntü sınıflandırma
	Rekabetçi	Rekabetçi	Öğrenme vektör nicelemesi	Öğrenme vektör nicelemesi
ART ağı		ARTMap	ARTMap	Örüntü sınıflandırma Sınıf içi kategorizasyonu
Danışmansız	Hata düzeltme	Çok katmanlı ileri besleme	Sammon’s projection	Veri analizi
	Hebbian	İleri beslemeli veya rekabetçi	Temel bileşen çözümlemesi	Veri analizi Veri sıkıştırma
		Hopfield ağı	Çağrışimli bellek öğrenmesi	Çağrışimli bellek
	Rekabetçi	Rekabetçi	Vektör niceleme	Kategorizasyon Veri sıkıştırma
		Öz-düzenleyici haritalar (Kohonen)	Öz-düzenleyici haritalar (Kohonen)	Kategorizasyon Veri analizi
ART ağı		ART1, ART2	Kategorizasyon	
Hibrit	Hata düzeltme ve rekabetçi	RBF ağı	RBF öğrenme algoritması (radyal tabanlı)	Örüntü sınıflandırma Model uydurma ve kontrol

Geri Yayılım: Geri yayılım algoritmasının amacı, diğer pek çok öğrenme algoritmasında olduğu gibi ağırlıkları ayarlayarak minimum hata ile çıktıların uydurulmasıdır. Geri yayılım bir gradyan inme yaklaşımı olup, birinci dereceden türevlerin minimizasyonu ile optimum çözüm bulunur. Eğitim esnasında algoritma tekrarlı olarak genelleştirilmiş delta kuralı ile ağırlıkları ayarlayarak üretilen çıktıların istenen çıktılara yaklaşmasına çalışır. İleri beslemeli ağ yapılarında en sık kullanılan öğrenme algoritmasıdır. Geri yayılım algoritmasının ileri beslemeli ağlarda kullanımının belirli avantaj ve dezavantajları bulunmaktadır. Avantajları; ayarlanması gereken parametre sayısının az olması nedeniyle kullanımının ve uygulamasının kolay olması, farklı birçok problem türünde kullanılabilir olması ve doğrusal olmayan kompleks problemleri modellemede başarılı olması olarak sıralanabilir. Dezavantajları ise; katman ve nöron sayılarının öngörülemez oluşu, öğrenme hızının düşük olması, yeni öğrenilen bilginin eskinin üzerine yazılıyor olması ve değişimleri kendiliğinden tespit edememesi nedeniyle bilinen çıktılar ile çalışılması gerekliliğidir (Priddy ve Keller 2005). Tüm ağ yapıları

nöronların bilgisayar simülasyonlarından oluşmaktadır. Yazılım tasarımı tamamlandıktan sonra yapay sinir ağlarının eğitimi ve geçerlilik kontrolü yapılmalıdır. ANN'nin kullanılış amacına göre seçilmesi gereken birbirinden farklı öğrenme algoritmaları bulunmaktadır. Ancak geri yayılım algoritması en sık kullanılandır (Drew ve Monson 2000).

Levenberg–Marquardt (LM Algoritması): Bir diğer doğrusal olmayan optimizasyon algoritmasıdır. Geri yayılımdaki gibi bağlantı ağırlıklarının değişimleri hesaplanır. Ancak LM daha kısıtlıdır. Bellek gerekliliği ağırlıkların sayısının karesi ile orantılıdır. Dolayısıyla büyük ağlar için LM'nin uygulanması güçtür. Algoritma göreceli olarak daha küçük ağlara çözüm üretebilmektedir. Hata fonksiyonları ile çalıştığından tahmin modellerinde de sıklıkla kullanılmaktadır (Bishop 1995, Masters 1995). Her ağırlık değişiminden sonra hatalar hesaplanır. Hatalarda önceki iterasyona göre bir iyileşme yok ise değişiklik yapılmaz. Minimum noktaya yaklaştıkça doğrusallık artacağından fonksiyonun doğrusal olduğu varsayılarak minimum nokta aranır. Minimum nokta olmayan durumlarda da gradyan inme kullanılacağından sonuç ileriki iterasyonlarda minimum noktaya doğru yakınsayacaktır (Priddy ve Keller 2005).

Değişken öğrenme hızlı gradyan inme: Gradyan inme öğrenmesi (GDX) basit bir çalışma prensibine sahiptir. Bu basit yapısına rağmen birçok farklı algoritmanın geliştirilmesinde önemli bir yere sahiptir (Baldi 1995). Gradyan inme öğrenmesinin performansı, sabit öğrenme hızı yerine uyarlamalı değişken öğrenme hızı ile yüksek seviyelere çıkabilmektedir. Öncelikli olarak başlangıç ağırlıklarının çıktısı ve hata miktarı belirlenir. İterasyonlar ile ağırlık öğrenme hızı değişir ve ağırlıklar ile yanlılık güncellenir. Yeni çıktılara ulaşıp hata hesaplandıktan sonra yeni hatanın önceki iterasyon hatasının bir eşik değeri kadar üzerinde olup olmadığına bakılır. Eğer hata bu değerin üzerinde ise yeni ağırlıklar ve yanlılık kabul edilmez ve öğrenme hızı düşürülür. Eğer hata belirlenen sınırın altında ise ağırlıklar kabul edilir ve önceki hatanın da altında ise öğrenme hızı artırılır (Singh ve ark. 2015).

3.3.3. Aktivasyon fonksiyonları

Aktivasyon fonksiyonu nöron çıktı sinyali şiddetinin belirli bir aralıkta kalmasını sağlar. En sık kullanılan aktivasyon fonksiyonları doğrusal olmayan problemlerde kullanılan Tek Kutuplu Sigmoid, İki Kutuplu Sigmoid, Hiperbolik Tanjant, Koni Kesit ve Radyal Tabanlı Fonksiyondur (Karlık 2011).

Tek Kutuplu Sigmoid: Geri yayılımlı algoritmalar ile eğitilen ağlarda kullanımı avantaj sağlamaktadır. Ayrım yaparken zorlanmadığı için eğitim esnasındaki hesaplamalarda kolaylık sağlar. “S” şekline sahip bir fonksiyondur. Çıktı değerleri (0,1) aralığındadır.

İki Kutuplu Sigmoid: Tek kutupluya benzer. Çıktıların (-1,1) arasında değer alması istendiğinde tercih edilir.

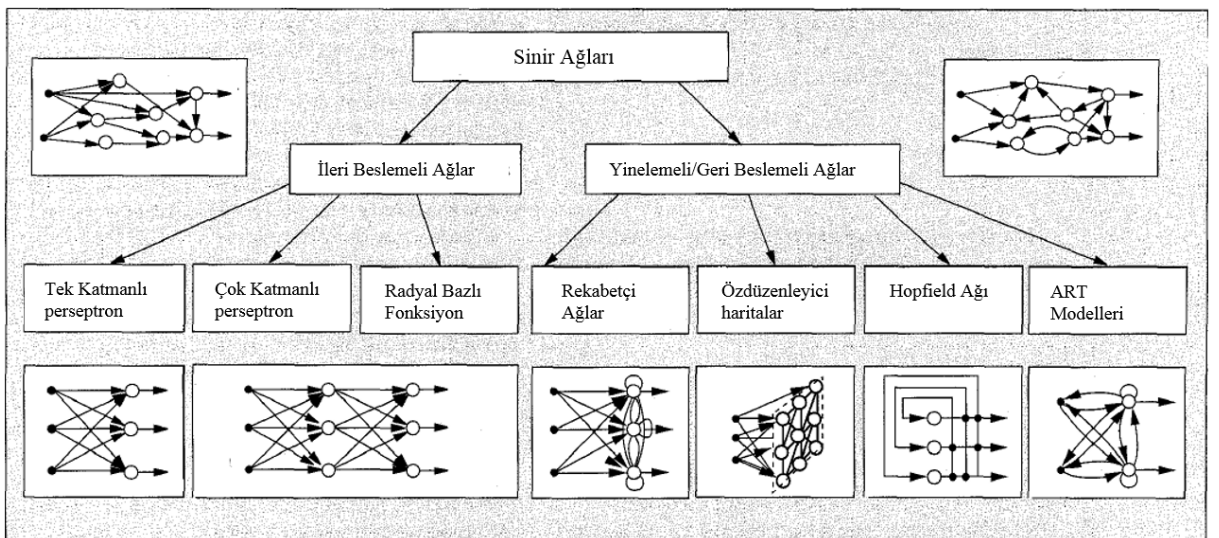
Hiperbolik Tanjant: Hiperbolik sinüs ve kosinüs fonksiyonların oranı ile hesaplanır. Şekil olarak Sigmoid fonksiyonlarına benzemektedir. Çıktı değerleri (-1,1) aralığındadır.

Koni Kesit: Bu fonksiyonda bir koninin kesitini andıran bir parabol yardımı ile aktivasyon işlemi gerçekleştirilmektedir.

Radyal Tabanlı: Gaus dağılımına sahiptir. Dağılımın ortalamasını alarak bu değeri hedef değer olarak belirler. Birden fazla radyal tabanlı fonksiyon birlikte çalışabilir. Bu fonksiyonun aktivasyon olarak kullanıldığı ağlara radyal tabanlı ağ denir. Tek katmanlı ve oldukça basit ağlardır. Genellikle verilen bir fonksiyonun yaklaşımında model uydurma amacıyla kullanılmaktadırlar.

Yapay sinir ağlarının gizli katmanları ağa doğrusal olmama durumlarını tanıtmak için aktivasyon fonksiyonuna ihtiyaç duyar. Doğrusal olmama durumlarında çok katmanlı ağlar efektif bir biçimde çalışır. Aktivasyon fonksiyonlarının her birinin uygun olacağı problem türü farklıdır. Hedef değerler pozitifse ancak üst sınır bilinmiyorsa üssel çıktı aktivasyon fonksiyonu kullanılmalıdır. Eğer çıktılar ikili sistemde (binary) ise Tanjant ve Sigmoid fonksiyonlar uygun olacaktır. Aktivasyon fonksiyonları deneme yanılma ile çıktıların dağılımlarının hedef değerlere uygunluğuna göre seçilmelidir (Karlık ve Olgaç 2011).

Yapay sinir ağları bilgi akışının yönüne göre iki farklı şekilde sınıflandırılabilir; ileri beslemeli ve geri beslemeli ağlar (Şekil 3.4).



Şekil 3.4. İleri ve Geri Beslemeli Ağ Yapılarının Sınıflandırılması (Jain ve Mao 1996)

3.3.4. İleri beslemeli ağlar

İleri beslemeli ağlar geri beslemeli (tekrarlayan) ağlarla karşılaştırıldığında daha basit ve sade ağ yapısına sahiptirler. Çok sayıda nöron katmanlarda birleşerek organize olurlar. Bu katmanlar girdi katmanı, gizli katman ve çıktı katmanı şeklindedir. Ağın çalışması sırasında içsel dönüşlere izin verilmez sinyalin sadece girdi katmanı-gizli katman-çıkı katmanı yönünde akmasına izin verilir (aynı katmandaki nöronlar arasında da bilgi alışverişi olmaz). İleri beslemeli ağların katmanlarının tasarımı ve kullanımı sırasında bazı sorunlar da olabilmektedir. Bunlar katman sayısına karar verilmesi, her katmanda kaç adet nöron çalıştırılacağına karar verilmesi, eğitim setinde olmayan verilerle karşılaştığı zaman ağın nasıl sonuç vereceğinin tam olarak bilinmemesi, eğitim verisinin genişliğinin ne kadar olması (tüm veri setinden eğitime ayrılan yüzdelik) gibi belirsizliklerdir. İleri beslemeli geri yayımlı ağlar sıklıkla kullanılmasına rağmen halen kural geliştirilememiş olması bu sorunlara yol açmaktadır. Dolayısıyla halen deneme yanılma yoluyla yöntem uygulanmakta ve optimum parametreler belirlenmektedir (Jain ve Mao 1996).

İleri beslemeli ağlar tek katmanlı perseptron, çok katmanlı perseptron ve radyal tabanlı ağlar olmak üzere üçe ayrılır.

Tek katmanlı perseptron: Tek katmanlı ağlarda gizli katman bulunmayıp, ağ yalnızca girdi ve çıktı katmanlarından meydana gelmektedir. Her bir girdi değerinin ağırlıklandırıldıktan sonra eşik girdi değeri ile toplanması ile çıktı elde edilir. Çıktının hesaplanma yöntemi (3.13) bağlantısındaki gibidir (Öztemel 2006).

$$\text{Çıktı} = f\left(\sum_{i=1}^m w_i x_i + \phi\right) \quad (3.13)$$

Eğer toplam değeri sıfırın üzerinde ise çıktı +1 değerini alırken aksi durumlarda 0 değerini alır.

Çok katmanlı perseptron: Çok katmanlı perseptron (MLP) hücrelerin bağlanmaları ile meydana gelen yapay sinir ağıdır. Girdi katmanı, gizli katman ve çıktı katmanından oluşur. Bu ağlar danışmanlı öğrenme yöntemi ile eğitilirler. Ağ, danışman vasıtası ile önceden bilinen hedef çıktı değerlerine göre ağırlıklarını ayarlar ve sonrasında farklı veri setinde bu öğrendiği bilgiyi genelleyerek uygular. Ağ delta öğrenme kuralı ile öğrenme gerçekleştirir. Doğrusal olmayan çıktı fonksiyonu kullanıldığından tek katmanlı ağlardan farklı olarak uygulama alanı daha geniştir. Özellikle girdi çıktı arasında doğrusal bir ilişkinin olmadığı durumlarda tercih edilirler (Öztemel 2006).

3.3.5. Radyal tabanlı yapay sinir ağı

Üst üste binen alıcı alanlar serebral korteksin çalışılan alanlarından birisidir. Biyolojik alıcı alanlardan alınan ilham ile radyal tabanlı yapay sinir ağı (RBF) geliştirilmiştir. Fonksiyon haritalama için RBF alıcı alanları kullanır (Jung ve Sun 1993). Radyal tabanlı ağı eğitim süresi MLP'ye göre daha kısadır. MLP'de gizli katman sayısı ve katmanlardaki nöron sayıları gibi parametrelere kural oluşturmak oldukça zordur. RBF'de ise ağ, tek gizli katmanla sınırlı olduğundan karar verilecek parametre sayısı azdır ve daha pratiktir (<https://towardsdatascience.com/radial-basis-functions-neural-networks-all-we-need-to-know-9a88cc053448>, erişim tarihi 15.02.2019). Her bir radyal taban fonksiyonu elemanı için çıktı (3.14) bağıntısındaki gibi hesaplanır. P girdi vektörlerini; C_i girdi vektörlerinin prototiplerini; $\|\cdot\|$ ifadesi ise öklit normunu göstermektedir.

$$R_i(P) = R_i(\|P - C_i\|) \quad i = 1, \dots, u \quad (3.14)$$

Radyal tabanlı fonksiyon seçiminde genellikle gauss fonksiyonu kullanılır. Formüldeki σ_i ifadesi kullanılan radyal taban fonksiyonu elemanının yayılma parametresidir (3.15).

$$R_i(P) = \exp\left[-\frac{\|P - C_i\|^2}{\sigma_i^2}\right] \quad (3.15)$$

RBF'nin çıktıları aşağıdaki bağıntı (3.16) ile hesaplanır. Burada; $w(j,i)$ i alıcı alanının j çıktısına etkisi; $w(j,0)$ ise j çıktısı için yanlılıktır (Er ve ark. 2002).

$$y_i(P) = \sum_{i=1}^u R_i(P) * w(j, i) \quad (3.16)$$

3.3.6. Genelleştirilmiş regresyon ağı

Genelleştirilmiş regresyon yapay sinir ağı (GRNN) radyal tabanlı fonksiyonun bir çeşidi olup tahminleme çalışmalarında sıklıkla kullanılan bir ağıdır. Eğitim sonunda her bir deseni hafızaya alarak geri yayılıma ihtiyaç duymadan çalışır. Ağ regresyon, tahminleme, sınıflandırma ve model uydurma problemlerinde kullanılmaktadır. GRNN geri yayılımlı ağıdan tahmin doğruluğu ve eğitim süresi anlamında daha başarılıdır. GRNN'nin gizli katmanında nöron artış limiti gibi bazı kısıtları bulunmaktadır. Ancak bu sorun, sadece uygun desenlerin belleğe alınmasını sağlayan özel bir algoritmanın kullanılması ile çözülebilmektedir (Al-

Mahasneh ve ark. 2018). D_i mesafesi, bağıntı'daki (3.17) gibi, girdi (X) ile eğitim verisi (X_i) değerleri arasındaki uzaklıktır. D_i mesafesi ne kadar düşük ise o eğitim elemanı çıktıya o kadar fazla etki eder. Y değeri (3.18), her i için eğitim verisi çıktıları iken σ değeri yayılma parametresidir (Al-Mahasneh ve ark. 2018).

$$D_i = (X - X_i)^T (X - X_i) \quad (3.17)$$

$$\hat{Y} = \frac{\sum_{i=1}^N Y e^{(-D_i/2\sigma^2)}}{\sum_{i=1}^N e^{(-D_i/2\sigma^2)}} \quad (3.18)$$

3.3.7. Geri beslemeli ağlar

Genel olarak girdi ile çıktının birbirlerinden bağımsız olmadığı durumlarda kullanılır. Aynı zamanda tekrarlı ağlar olarak da isimlendirilirler. Bunun nedeni çıktının katmanlardaki hesaplamalara bağlı olduğu durumlarda dizideki her eleman için aynı işlemin yapılmasıdır. Kısa süreli bir hafızaya sahiptir. Hafızası yardımıyla birkaç adım geride yapılan hesaplamaları belleğinde tutarak oluşacak çıktı sinyalini denetler (<http://www.wildml.com/2015/09/recurrent-neural-networks-tutorial-part-1-introduction-to-rnns>, erişim tarihi 22.10.2018). İleri beslemeli ağ yapısının aksine bilgi akışı yalnızca girdi-gizli-çıkı katmanları yönünde olmayıp tam tersi bilgi akışları da söz konusu olabilmektedir. Ağda ilerleyen veya ağdan çıkmış bir sinyal geri dönüp tekrar ağa bilgi akışı sağlayabilir. Geri beslemeli ağlarda sonucun alınması için tüm sinyallerin son katmandan çıkış yapmasına gerek olmadığından ağ, çalışırken de tahminler yapabilmektedir. İleri beslemeli ağlardan ayrılan öğrenme programı ile konveks olmayan fonksiyonlarda daha iyi sonuç alınırken, konveks problemlerde ise sonuçların yakınsama hızında artış olabilir (Wu ve Shen 2016).

3.4. ANN-RSM Modellerinin Karşılaştırılması

Tahmin yöntemi olarak RSM ve ANN metotları karşılaştırıldığında görülecektir ki; RSM, girdi faktörlerinin tepki değişkeni üzerindeki etkilerini tahmin eden bir yaklaşım olup, faktörlerin istatistiksel olarak önemli ve önemsiz olarak belirlenmesini sağlamaktadır. Bu sayede istatistiksel olarak önemsiz olan etkiler modelden çıkartılabilir ve model daha anlamlı sonuçlar verecek şekilde sadeleştirilebilmektedir. Her bir faktör için faktör seviyeleri ve seviye aralığının iyi tanımlanmış olması gerekmektedir. ANN ise doğrusallık içermeyen veri çalışıldığında RSM'ye göre daha uygun olmaktadır. ANN modelinin oluşturulması çok sayıda

iterasyon ve hesaplama gerektirirken RSM tepki modelini daha kolay bir şekilde oluşturabilmektedir. Eğitim süreleri açısından düşünüldüğünde RSM'nin eğitimi ANN'ye göre daha kısa sürmektedir. ANN, problemin karmaşıklığına ve veri setinin büyüklüğüne bağlı olarak ciddi miktarda hesaplama zamanına ve maliyetine sahip olabilmektedir (Lakshminarayanan ve Balasubramanian 2008). Yapay sinir ağları RSM ile karşılaştırıldığında iki yöntemin de uygun olabileceği problemler bulunmaktadır. Eğer çalışmadaki amaç, faktörler arası etkileşimin yoğun ve karmaşık olduğu ve doğrusallığın bulunmadığı bir veri setinde çıktı tahmini yapmak ise ANN daha uygun metot olacaktır. Regresyon modelleri öncelikli amaç daha çok model geliştirmek ve çıktı ile girdi arasındaki nedensellik ilişkisini açıklamak olduğunda kullanılmaktadır (Tu 1996). İki yöntemin de en iyi özelliklerini alarak oluşturulan hibrit teknikler de en iyi sonucun alınmasını sağlayabilir (Spackman 1992). Yapay sinir ağları karmaşık doğrusal olmayan veri setlerinin analizindeki başarısı nedeniyle son yıllarda özel bir ilgi görmüştür (Drew ve Monson 2000). Tanıma, tanı, filtreleme, tahmin ve kontrol problemleri yapay sinir ağları için uygun problemlerdir (Graupe 2013).

3.5. Uygulanan Deney Tasarımı

Tez çalışmasında epoksi malzemenin abrasif aşınma oranı iki ayrı katkı kullanılarak azaltılmaya çalışılmıştır. Çalışmada geliştirilen aşınma modeli için faktör etkileri ve etkileşimleri görülmüş olup, hangi faktör seviyelerinin aşınmayı minimize ettiği belirlenmiştir. Daha geniş bir çalışma aralığında deneyleri gerçekleştirmek ve sistemdeki eğrilikleri görmek için deney planı CCD (Central Composite Design) ile yapılmıştır. Literatürde CCD yaklaşımı özellikle kompozit malzeme tasarımlarında sıklıkla kullanılmaktadır. α noktaları ile tasarım bölgesinin dışarısında kalan noktalarda da deney yapılarak modelin tahmin gücü geliştirilir ve eğrilikler daha kolay belirlenir.

Deneysel tasarım çalışmasında CCD'nin girdi değişkenleri iki formda kullanılmıştır;

- Kategorik Faktörler: Eklenecek Katkının Büyüklüğü.
- Devamlı Faktörler: Ağırlıkça Ferrokrom (Karbür) Katkı Oranı, Cam Katkı Oranı.

Katkı büyüklüğü faktörü için deneylerde kullanmak üzere iki farklı seviye belirlenmiştir. Bu seviyeler çalışmanın yapıldığı laboratuvarında bulunan parçacık eleklerine göre seçilmiştir. Bir adet 50 mikronluk elek ve bir adet 75 mikronluk elek yardımı ile karbür ve cam parçacıkları sırasıyla elenerek, 50 mikron altı ve 50-75 mikron arası olacak şekilde katkı boyutlarına göre ikiye ayrılmıştır. Katkı büyüklüğü faktörünün kategorik faktör olarak

belirlenmesinin nedeni; büyüklüğün iki farklı seçenek olması ve bu seçeneklerin dışında inceleme yapılmayacağından sonuçların da bu değerlerde kalmasını sağlamaktır. Bu faktörün iki farklı seviyesi “-1” ve “+1” olarak ifade edilmiştir (Çizelge 3.5). Cam ve karbür katkı oranı seviyeleri ise faktör seviyelerinin belirlendiği aralıkta [-1,+1] sonsuz değer alabileceğinden devamlı faktör olarak çalışmada yer almıştır. Mikrometre boyutundaki parçacıkların katkı olarak polimerlere katılması sürecinde hacim olarak %20 üzerindeki seviyeleri ulaşılabilirlik, malzemenin görünüşü, yoğunluk ve yıpranma açısından malzemeyi kötü yönde etkilemektedir (Bonner 1962, Rothon 1997). Literatürde incelenen çalışmalarda çoğunlukla %20 altındaki katkı oranı seviyeleri çalışılmıştır. Bu nedenle α değerleri %0-20 aralığında deneysel tasarım oluşturulmuştur. Kodlanmış ve gerçek değişkenler için faktör seviyeleri Çizelge 3.6’da verilmiştir.

Tüm deney noktalarında üçer tekrarlı deney gerçekleştirilecek şekilde deney tasarımı oluşturulmuştur. Böylece deney ve test hataları başta olmak üzere deneyi etkileyebilecek diğer hataların etkileri azaltılmaya çalışılmıştır. Tekrarlar ile birlikte oluşturulan tasarımda 54 adet numune elde edilmiştir. Oluşturulan deney tasarımı Çizelge 3.7’de verilmiştir. Deneylerde çevresel faktör etkileri önemsiz sayılabilecek kadar küçük olduğundan bloklama yapılmamıştır. Tüm üretimler ve testler rastgele sırayla yapılmıştır.

Çizelge 3.5. Katkı Büyüklüğü İçin Kodlanmış ve Gerçek Değişken Seviyeleri

Kodlanmış Seviye	Gerçek Seviye (μ)
-1	0-50
1	50-75

Çizelge 3.6. Katkı Oranı İçin Kodlanmış ve Gerçek Değişken Seviyeleri

Kodlanmış Seviye	Gerçek Seviye (%)
-1,41421	0
-1	2,929
0	10
1	17,071
1,41421	20

Çizelge 3.7. CCD Deneysel Tasarım Noktaları

Denev	Cam Oranı %	Karbür Oranı %	Katkı Büyüklüğü (μ)
1	2,929	2,929	0-50
2	2,929	2,929	0-50
3	2,929	2,929	0-50
4	17,071	2,929	0-50
5	17,071	2,929	0-50
6	17,071	2,929	0-50
7	2,929	17,071	0-50
8	2,929	17,071	0-50
9	2,929	17,071	0-50
10	17,071	17,071	0-50
11	17,071	17,071	0-50
12	17,071	17,071	0-50
13	0	10	0-50
14	0	10	0-50
15	0	10	0-50
16	20	10	0-50
17	20	10	0-50
18	20	10	0-50
19	10	0	0-50
20	10	0	0-50
21	10	0	0-50
22	10	20	0-50
23	10	20	0-50
24	10	20	0-50
25	10	10	0-50
26	10	10	0-50
27	10	10	0-50
28	2,929	2,929	50-75
29	2,929	2,929	50-75
30	2,929	2,929	50-75
31	17,071	2,929	50-75
32	17,071	2,929	50-75
33	17,071	2,929	50-75
34	2,929	17,071	50-75
35	2,929	17,071	50-75
36	2,929	17,071	50-75
37	17,071	17,071	50-75
38	17,071	17,071	50-75
39	17,071	17,071	50-75
40	0	10	50-75
41	0	10	50-75
42	0	10	50-75
43	20	10	50-75
44	20	10	50-75
45	20	10	50-75
46	10	0	50-75
47	10	0	50-75
48	10	0	50-75
49	10	20	50-75
50	10	20	50-75
51	10	20	50-75
52	10	10	50-75
53	10	10	50-75
54	10	10	50-75

3.6. Numunelerin Hazırlanması ve Uygulanan Testler

Epoksi malzemenin başlıca iki bileşeni bulunmaktadır. Bunlar reçine (epoksi) ve sertleştiricisidir. Sertleştirici malzeme reçinenin kürleşmesine yardımcı olma amacıyla kullanılmaktadır. Numunelerin üretilmesinde “L285” kodlu reçine ve bu reçine ile birlikte satılan ve uyumlu olan “H285” kodlu sertleştirici kullanılmıştır. Üretime başlanmadan önce deneme üretimleri yapılmıştır. Kullanılması gereken epoksi miktarı ve karışımın katılma süreleri gibi parametreler bu deneme üretimleri ile belirlenmiştir. Kullanılan kalıplar üç adet gözden oluşmaktadır. Her bir deney noktasında üretim yapılırken, kalıpları sınırına kadar doldurması ve üç yuvayı doldurduktan sonra fazla israf olmaması için ortalama 6 gram ağırlığındaki reçine oda sıcaklığında hassas terazide tartıldıktan sonra karışım kabına dökülmüştür. Ardından ürünün reçetesinde yazdığı miktarda (100:40) sertleştirici kaba eklenmiştir. Karışıma gerekli cam ve karbür katkıları eklendiğinde kaptaki karışım son halini almıştır. Oluşan karışım bir karıştırıcı yardımıyla yeterince karıştırılıp, ikinci karıştırma işlemi için beklemeye bırakılmıştır. Karışım, 0-50 mikron büyüklüğündeki parçacıklar için 30 dakika; 50-75 mikron büyüklüğündeki parçacıklar için ise 40 dakika bekletilmiştir. Karbür katkıları ağır olduğundan ilk karıştırma sonrasında kalıplara dökme işlemi gerçekleştirildiği takdirde bu parçacıklar dibe çökecek ve katılma bu şekilde gerçekleşecektir. Bu durum numunelerin homojenliğinin bozulmasına ve dolayısıyla deney sonuçlarında hataya neden olacaktır. Bekleme sonrasında viskozitesi artmış olan karışım tekrar karıştırılarak homojenlik bir kez daha sağlanmış ve karışımlar kalıplara dökülmüştür. Karışımın kısmi sertleşmesi ile dibe çökelen katkı da minimize edilmiştir. Daha sonrasında karışımlar birer gün boyunca döküldükleri kalıplarda bekletilmişlerdir. Katılmanın ardından numuneler kalıplardan çıkartılmış ve boşalan kalıp gözlerine yeni karışımlar dökülerek sürece devam edilmiştir ve 54 adet numunenin üretimi tamamlanana kadar bu işlem tekrarlanmıştır. RSM çalışmasında üç farklı tepki (aşınma, sertlik ve üretim maliyeti) kullanılacağından bu tepkilerin testleri ve hesaplamaları yapılmıştır. Elde edilen tüm tepkiler Design Expert 11 programı yardımıyla analiz edilmiş ve elde edilen bulgular yorumlanmıştır.

3.6.1. Aşınma testleri

Üretimleri tamamlanan numunelerin aşınma özelliğinin ölçülmesi amacıyla aşınma testleri, modifikasyon ile tamburlu abrasif aşınma cihazına dönüştürülen torna tezgahında yapılmıştır. Testte numunelere uygulanan abrasif aşınma, katı aşındırıcı yüzey ile aşındırılacak malzemenin etkileşime girmesi sonucu oluşan aşınmadır. Aşınma cihazına (Şekil 3.5) tamburu boyunca zımpara kâğıdı sarılmıştır. Numuneler iki tarafından bilerek iki yüzü doğrusal hale

getirilmiş ve bu sayede tutacağa rahatça yerleştirilmiştir. Tutacağa takılan numuneler, belirli bir yükün altında belirli bir hızda dönen tambura bağlı zımpara kâğıdı ile aşınmaya tabi tutulmuştur. Numuneler bir süre abrasif aşınmaya maruz bırakıldıktan sonra tamburun dönüşü durdurulmuş ve numuneler cihazdan çıkartılmıştır. Başlangıçta hassas terazide ölçümlenen numune kütlesi aşınma işlemi sonunda alınan kütle ile oranlanarak aşınma oranı (%) tespit edilmiştir.



Şekil 3.5. Aşınma Testinde Kullanılan Cihaz

Aşınma test cihazının test parametreleri aşağıdaki gibidir.

- Aşındırıcı yüzey olan zımpara kâğıdı 320 kumluktur.
- Zımpara kâğıdının bağlı olduğu tambur 184 devir/dakika ile dönmektedir.
- Numunelere uygulanan yük 1480 gramdır.
- Numuneler dönen zımpara kâğıdına 30 saniye boyunca maruz bırakılmışlardır.
- Tamburun çapı 165 mm'dir.

3.6.2. Sertlik testleri

Aşınma testleri tamamlandıktan sonra tüm numunelerin sertlik testleri yapılmıştır. Sertlik testlerinin gerçekleştirilmesi için rockwell dijital sertlik cihazı kullanılmıştır. Sertlik testi yapılacak parçanın karşılıklı iki yüzünün doğrusal ve paralel olması gerekmektedir. Bu nedenle aşınma testine maruz kalan ve iki ucu arasındaki doğrusallık kaybolan numunelerin bir

hazırlık işlemine tabi tutulması gerekmektedir. Numunelerin aşınma testi sonrası deforme olan uçları öncelikle alın tornalama işlemine alınmıştır. İki ucu düzeltilerek sertlik testine uygun hale getirilen numuneler, alın tornalama sonrasında kalan çapakların da zımpara kâğıdı ile düzeltilmesinden sonra sertlik test cihazında (Şekil 3.6) test edilmiştir.



Şekil 3.6. Sertlik Testinde Kullanılan Cihaz

Rockwell sertlik cihazı çelik, alüminyum gibi sert malzemenin sertliklerinin belirlenmesinde kullanıldığı gibi, uygun test parametreleri seçimi ile daha yumuşak malzemelerin de sertlik ölçümlerini yapabilmektedir. Test parametrelerinin seçimi için epoksi malzeme üzerinde yapılan deneme testi sonucunda malzemenin sertlik ölçümü için Rockwell HRH ölçeğinin uygun ölçek olduğu tespit edilmiştir. Bu ölçekte numuneler, 60 kilogramlık yük altındaki 1/8 inçlik (3,125 milimetre çap) çelik bilyanın etkisinde testten geçmişlerdir. Testler, numunelerin aşınıp tornada düzeltilmiş taraflarına uygulanmıştır. Numune bilyanın altına yerleştirilmesinden sonra makine numuneye baskı uygulamaya başlamıştır. Bu süreç yaklaşık

15 saniye sürmüş olup, sonrasında numunelerin HRH birimi ile sertlik değerleri cihazın ekranına düşmüştür.

3.6.3. Maliyet hesaplamaları

Numunelerin üretim maliyetleri üretimler tamamlandıktan sonra toplam malzeme giderleri üzerinden yaklaşık olarak hesaplanmıştır (Çizelge 3.8). Üretimi yapılan numunelerin temel olarak üretimleri sırasında üç farklı maliyet kalemi ile karşılaşılmıştır. Bu maliyetler; katkı maliyetleri (karbür ve cam), epoksi reçine ve reçine sertleştiricisi maliyetleridir. Maliyetler Ocak 2019 itibari ile hesaplanmış olup, sonraki tarihler için tekrarlanacak bir çalışmada enflasyon ve döviz kuru etkisi dikkate alınarak hesaplamaların tekrar yapılması gerekmektedir. Tez çalışmasında kullanılan epoksi ve sertleştirici ürünlerinin satın alındığı internet sayfasındaki (www.kompozit.net) güncel fiyatları sırasıyla 223,78 ve 220,18 TL'dir. Malzemenin maliyeti epoksi için 0,2238 TL/gram, sertleştirici için ise 0,2202 TL/gram olarak belirlenmiştir. Cam tozu için ise satıcıdan (www.camkumu.com) fiyat teklifi alınmış olup malzemenin birim maliyeti 0,0015 TL olarak belirlenmiştir. Karbür malzemesinin yurt içindeki tedarikçisinden fiyat teklifi alınamamıştır. Bu nedenle Çin'deki orijinal tedarikçisinin internet fiyatı dikkate alınmıştır. Ürünün birim fiyatı araştırmanın yapıldığı zamandaki döviz kuru üzerinden TL'ye çevrilmiş olup 0,0083 TL olarak bulunmuştur. Karbür büyük parçalar halinde olduğundan halkalı öğütücü ile öğütülmesi ve toz haline getirilmesi gerekmektedir. Tez çalışmasında kullanılmak üzere 100 gramlık karbür parçası laboratuvardaki halkalı öğütücüye konulmuş ve yarım saat boyunca öğütülerek tez çalışmasında kullanılan toz haline getirilmiştir. Laboratuvarda kullanılan elektriğin birim fiyatı Aralık 2018'de 0,4268 TL/kWh olarak faturalandırılmıştır. Öğütücünün motor gücü 3 kW olduğundan makinenin yarım saat çalıştırılması sonucu oluşan elektrik gideri 0,6402 TL olmuştur. Yapılan hesaplamalar sonrasında ürünün toplam birim maliyeti 0,0147 TL olarak bulunmuştur.

Çizelge 3.8. Karışım Malzemeleri İçin Birim Maliyetler

Maliyet	Karbür	Cam	Epoksi	Epoksi Sertleştiricisi
Elektrik Giderleri (TL/g)	0,006402	-	-	-
Malzeme Fiyatı (TL/g)	0,00825	0,001475	0,22378	0,22018
Toplam Maliyet (TL/g)	0,014652	0,001475	0,22378	0,22018

4. BULGULAR ve TARTIŞMA

4.1. Test Sonuçları

Önceki bölümde bahsedilen test parametreleri ile oda sıcaklığında tüm numunelerin testleri tamamlanmıştır. Testi tamamlanan 54 adet numuneden elde edilen sonuçlar Çizelge 4.1'deki gibidir. Alınan sonuçlar Design Expert 11 programında incelenmiştir.

Çizelge 4.1. Aşınma Test Sonuçları

Deney No	W _(ilk)	W _(son)	Aşınma (%)	Deney No	W _(ilk)	W _(son)	Aşınma (%)
1	2,817	2,539	9,869	28	2,623	2,332	11,094
2	2,548	2,293	10,008	29	2,554	2,287	10,454
3	2,581	2,327	9,841	30	2,633	2,376	9,761
4	2,918	2,632	9,801	31	3,017	2,641	12,463
5	2,916	2,679	8,128	32	3,027	2,751	9,118
6	2,862	2,593	9,399	33	2,933	2,598	11,422
7	2,949	2,629	10,851	34	2,88	2,481	13,854
8	3,083	2,753	10,704	35	2,793	2,459	11,958
9	3,029	2,660	12,182	36	3,126	2,729	12,700
10	3,174	2,834	10,712	37	2,97	2,687	9,529
11	3,154	2,851	9,607	38	3,111	2,847	8,486
12	3,392	3,097	8,697	39	3,064	2,782	9,204
13	2,876	2,532	11,961	40	2,669	2,426	9,105
14	2,758	2,407	12,727	41	2,608	2,354	9,739
15	2,784	2,486	10,704	42	2,644	2,354	10,968
16	3,035	2,706	10,840	43	3,034	2,752	9,295
17	3,020	2,772	8,212	44	3,151	2,905	7,807
18	3,079	2,745	10,848	45	2,976	2,687	9,711
19	2,667	2,361	11,474	46	2,847	2,292	19,494
20	2,709	2,435	10,114	47	2,72	2,219	18,419
21	2,706	2,449	9,497	48	2,876	2,326	19,124
22	3,035	2,641	12,982	49	3,108	2,71	12,806
23	3,230	2,872	11,084	50	3,065	2,573	16,052
24	3,337	2,907	12,886	51	2,93	2,488	15,085
25	3,034	2,786	8,174	52	2,817	2,381	15,477
26	3,053	2,770	9,270	53	2,885	2,348	18,614
27	2,870	2,591	9,721	54	2,832	2,336	17,514

Sertlik testleri Rockwell dijital sertlik cihazı ile oda sıcaklığında yapılmış olup alınan sonuçlar Çizelge 4.2'de verilmiştir.

Çizelge 4.2. Sertlik Test Sonuçları

Deney No	Sertlik (HRH)	Deney No	Sertlik (HRH)
1	31,1	28	26,0
2	34,1	29	29,7
3	34,7	30	28,8
4	37,4	31	11,5
5	39,7	32	14,7
6	39,3	33	13,8

7	33,9	34	21,5
8	26,6	35	20,7
9	29,2	36	24,6
10	42,2	37	22,1
11	41,5	38	23,2
12	39,6	39	21,3
13	33,8	40	11,7
14	35,1	41	12,3
15	32,7	42	12,8
16	38,2	43	24,1
17	39,4	44	21,6
18	37,3	45	26,2
19	27,6	46	14,0
20	28,5	47	18,6
21	30,0	48	23,1
22	42,6	49	6,0
23	39,2	50	6,5
24	42,4	51	6,4
25	37,8	52	8,6
26	36,7	53	4,4
27	36,2	54	9,7

Üretimlerde numunelerin her birisi için yaklaşık 2 gram epoksi kullanılmıştır. Epoksi malzemesine %40 oranında (0,8 gram) sertleştirici eklenmiştir. Dolayısıyla katkısız numuneler yaklaşık 2,8 gram ağırlığındadırlar. Parçacık boyutu maliyette etkisiz olduğundan (tozların elekten geçirilmesi esnasındaki işçilik maliyeti ihmal edilmiştir), yalnızca 0-50 mikron aralığındaki parçacıklar için maliyetler oluşturulmuş ve Çizelge 4.3’de verilmiştir. Test numunelerinin tamamının ((0-50 mikron) ve (50-75 mikron)) maliyetlerinin aynı olduğu varsayılmıştır.

Çizelge 4.3. Numunelerin Toplam Maliyetleri

Deney No	Cam Oranı (%)	Karbür Oranı (%)	Toplam Maliyet (TL)
1	2,929	2,929	0,62503
2	2,929	2,929	0,62503
3	2,929	2,929	0,62503
4	17,071	2,929	0,62561
5	17,071	2,929	0,62561
6	17,071	2,929	0,62561
7	2,929	17,071	0,63083
8	2,929	17,071	0,63083
9	2,929	17,071	0,63083
10	17,071	17,071	0,63141
11	17,071	17,071	0,63141
12	17,071	17,071	0,63141
13	0	10	0,62781
14	0	10	0,62781
15	0	10	0,62781
16	20	10	0,62863

17	20	10	0,62863
18	20	10	0,62863
19	10	0	0,62412
20	10	0	0,62412
21	10	0	0,62412
22	10	20	0,63232
23	10	20	0,63232
24	10	20	0,63232
25	10	10	0,62822
26	10	10	0,62822
27	10	10	0,62822

4.2. Uygulanan İstatistiksel Analiz

Aşınma ve sertlik deney sonuçlarının istatistiksel analizi için ANOVA testi uygulanacağından, öncelikle ANOVA testi yapılabilmesi için gerekli üç temel varsayım test edilmiştir. Bunlar normallik, varyansların homojenliği ve uç noktaların (outlier) olmaması varsayımlarıdır. Tez çalışmasında iki sürekli bir kategorik değişken girdi değişkeni olarak seçilmiştir. Kategorik değişkenin (parçacık büyüklüğü) iki seviyesi için (0-50 mikron ve 50-75 mikron) aşınma ve sertlik test sonuçlarına normallik, varyansların homojenliği ve outlier testleri uygulanmıştır. Normallik varsayımı için testler PASW 18 (SPSS) programı kullanılarak yapılmış olup gözlem sayısı 50'nin altında olduğundan Shapiro-Wilk sonuçlarına göre normallik varsayımları test edilmiştir. Tez çalışması kapsamında güven derecesi $\alpha=0,05$ olarak seçilmiştir. Çizelge 4.4'de verilen sonuçlar incelendiğinde aşınma değişkeni için 2.grup deney sonuçları haricindeki testlerin p değerleri 0,05'in üzerinde olduğundan bu veri gruplarının normal dağılıma sahip oldukları kabul edilmiştir. Aşınma değişkeni için 2.grup verilerinin ise normal dağılıma uymadığı görülmüştür. Levy (1978) ANOVA testinin, normalliğin ihlal edildiği durumlardan ciddi bir biçimde etkilenmediğini ortaya koymuştur. Blanca ve ark. (2017) yaptıkları çalışmada verinin normal olmadığı durumlarda, ANOVA'nın 1.Tip hata hata oranının Bridley kriter sınırları içerisinde kalması nedeniyle ANOVA'nın robust olduğunu tespit etmişlerdir.

Çizelge 4.4. Tepki Değişkenlerinin Normallik Testi Sonuçları

	Kolmogorov-Smirnov			Shapiro-Wilk		
	İstatistik	Ser. Der.	p	İstatistik	Ser. Der.	p
Aşınma (1.Grup)	,108	27	,200	,958	27	,328
Aşınma (2.Grup)	,150	27	,123	,894	27	,010
Sertlik (1.Grup)	,106	27	,200	,950	27	,219
Sertlik (2.Grup)	,160	27	,075	,942	27	,139

Varyansların eşitliği (homojenliği) testi PASW 18 programı ile yapılmıştır. Aşınma ve sertlik verileri, kategorik değişkenin iki farklı değeri için test edilmesi gerektiğinden iki gruba ayrılmıştır. Varyansların eşitliği testi yine aynı dört veri grubu için yapılmıştır. Varyansların eşitliği testi hipotezi aşağıdaki gibi kurulmuştur. Kurulan hipotezlerin analiz sonuçları Çizelge 4.5'deki gibidir.

H₀: Tüm varyanslar eşittir.

H₁: En az bir varyansta farklılık vardır.

Çizelge 4.5. Tepki Değişkenlerinin Hata Varyanslarının Eşitliği Testi Sonuçları

	F	Ser. Der. 1	Ser. Der. 2	p
Aşınma	1,528	8	18	,216
Aşınma	1,362	8	18	,277
Sertlik	1,929	8	18	,118
Sertlik	1,844	8	18	,134

Levene testinin p değeri 0,05'in üzerindeki gruplar için H₀ reddedilemez ve varyansların eşit olduğu sonucu çıkartılır. Alınan test istatistikleri incelendiğinde tüm veri grupları için ANOVA varyansların eşitliği varsayımının geçerli olduğu görülmüştür.

Test edilen son ANOVA varsayımı; veri setinde herhangi bir uç noktanın (outlier) bulunmaması varsayımdır. Bu test için analizi gerçekleştirilecek verinin kutu diyagramı oluşturulur ve persentil çizgilerinin altında veya üzerinde kalan bir gözlem değeri olup olmadığına bakılır. Bir diğer metot ise Grubbs' test istatistiği ile kontrol etmektir. Grubbs' testinin p değeri 0,05 seviyesinin üzerinde olduğunda veri setinde uç nokta bulunmadığı sonucuna ulaşılır. Minitab 17 programı ile yapılan analiz sonucu elde edilen veri (Çizelge 4.6.) incelendiğinde veride herhangi bir uç nokta bulunmadığı görülmüştür.

Çizelge 4.6. Tepki Değişkenlerinin Grubbs' Testi Sonuçları

Değişken	N	Ortalama	S. Sapma	Min	Mak	G	P
Aşınma (1.Grup)	27	10,381	1,380	8,130	12,980	1,88	1,000
Aşınma (2.Grup)	27	12,565	3,638	7,810	19,490	1,90	1,000
Sertlik (1. Grup)	27	35,807	4,688	26,600	42,600	1,96	1,000
Sertlik (2. Grup)	27	17,18	7,60	4,40	29,70	1,68	1,000

Maliyet tepki değişkenleri teorik hesaplamalar ile elde edildiğinden herhangi bir deney hatası içermemektedir. Veri tamamen doğrusaldır ve faktör-tepki ilişkisi halihazırda belli ve

mevcut olduğundan, ANOVA varsayımlarının ihlal edilmesi herhangi bir olumsuzluğa neden olmayacaktır. Bu nedenle maliyet tepkisi için ANOVA varsayımları kontrol edilmemiştir. Sertlik ve aşınma tepki değişkenleri için ANOVA varsayımları kontrol edilmiş ve bir test grubunda normallığın ihlali dışında herhangi bir ihlale rastlanmamıştır. Normallik ihlallerinde ANOVA'nın robust olması nedeniyle herhangi bir veri transformasyonuna veya parametrik olmayan teste başvurulmamıştır. Bu bağlamda ANOVA'nın tez kapsamındaki veri setinde kullanılması uygundur.

4.3. Aşınma Tahmin Modeli

Aşınma tepki değişkeni için Design Expert 11 programı ile yapılan analiz sonrası oluşturulan ANOVA tablosu Çizelge 4.7'de verilmiştir.

Çizelge 4.7. Aşınma Tepki Değişkeni ANOVA Tablosu

Terim	Kareler Toplamı	Serbestlik Derecesi	Ortalama Kare	F-değeri	p-değeri
Model	412,76	16	25,80	20,99	<0.0001**
A-Cam	6,01	1	6,01	4,89	0,0333**
B-Karbür	4,35	1	4,35	3,54	0,0677*
C-Parçacık	99,55	1	99,55	81,01	<0.0001**
AB	9,78	1	9,78	7,96	0,0077**
AC	0,5178	1	0,5178	0,4213	0,5203
BC	29,96	1	29,96	24,38	<0.0001**
A ²	35,25	1	35,25	28,68	<0.0001**
B ²	3,66	1	3,66	2,98	0,0928*
ABC	4,73	1	4,73	3,85	0,0573*
A ² B	6,27	1	6,27	5,10	0,0299**
A ² C	112,96	1	112,96	91,92	<0.0001**
AB ²	0,4610	1	0,4610	0,3751	0,5440
B ² C	11,46	1	11,46	9,32	0,0042**
A ² B ²	35,18	1	35,18	28,63	<0.0001**
A ² BC	10,57	1	10,57	8,60	0,0057**
AB ² C	0,7537	1	0,7537	0,6133	0,4385
Artık	45,47	37	1,23		
Uyum eksikliği	4,10	1	4,10	3,57	0,0669
Hata	41,37	36	1,15		
Toplam	458,23	53			

** : İstatistiksel olarak anlamlı terimler

* : İstatistiksel olarak ihmal edilebilecek kadar önemsiz olup model hiyerarşisi için kullanılacak terimler

Modelin anlamlılığına karar vermek için F tablosundan kritik F değerine bakılır ve modelin anlamlılığı için hesaplanan F değerinin tablo değerinden büyük olması beklenir. Modelin anlamlılığını test etmek için bir diğer yol da elde edilen p anlamlılık değerinin seçilen

p değerinden (%5 anlamlılık düzeyi) küçük olmasıdır. Aşınma modeli %95 güvenilirlik düzeyinde anlamlı olarak bulunmuş olup, anlamlı olan ana etki ve etkileşimler belirlenmiştir. ANOVA tablosunda aşınma tepki değişkeni üzerinde etkisi önemli bulunan 10 ana etki ve etkileşim mevcut olup, ana etkilerden; cam oranı aşınmayı önemli ölçüde etkilerken karbür oranı istatistiksel olarak önemsiz bulunmuştur. En önemli ana etki parçacık büyüklüğü olarak belirlenmiştir. Parçacıkların küçük veya büyük olması aşınma oranını doğrudan etkilemektedir. İstatistiksel olarak etkisi önemsiz görülen terimlerin p anlamlılık değerleri 0,05 değerinden büyüktür. Terimlerin bir kısmı model hiyerarşisini desteklemektedir. Kodlanmış değişkenli regresyon denklemi ile gerçek değişkenler ile oluşturulan regresyon denkleminin tahminlerinin uyuşma göstermesi için model hiyerarşisinin korunması gerekmektedir. Bu nedenle model hiyerarşisini destekleyen terimlerden p değeri 0,10 seviyesinin altında olan B, B², ABC terimleri regresyon denklemi oluşturulurken modele dahil edilmiştir. Buna göre modele dahil edilmeyen terimler AC, AB² ve AB²C terimleri olarak belirlenmiştir. Uyum eksikliği testi sonucunda başlangıçtaki modelin uyum eksikliği önemsiz bulunmuştur. Bu sonuç gözlemlenen aşınma verileri ile tahmin edilen değerlerin uyumunda bir eksiklik bulunmadığı göstermektedir. Ancak p değerinin 0,05'e yakın olması (0,0669) istenmeyen bir durumdur. Daraltma sonrası oluşturulan modelde ise uyum eksikliğinin p değeri 0,3439 olmuştur. Modelin daraltılması ile modelin uyumluluğu da arttırılmıştır. Diğer model istatistiklerinin, modelden terim çıkartılmadan önce ve sonraki durumları Çizelge 4.8'deki gibidir.

Çizelge 4.8. Aşınma Tepki Değişkeni Model İstatistikleri

İstatistik	4.Derece Model	Daraltılmış Model
PRESS (Tahmin Edilen Artık Kareler Toplamı)	97,05	96,68
BIC (Bayes Bilgi Kriteri)	211,77	201,26
AIC_c (Akeike Bilgi Kriteri)	194,96	184,18

Modelden çıkartılan terimler sonrasında üç ayrı model istatistiğinde de gözle görülür iyileşme olmuştur. Buna göre daraltılmış modelin nihai model olmasına karar verilmiştir. Çizelge 4.9'da aşınma modelinin uyum istatistikleri verilmiştir.

Çizelge 4.9. Aşınma Tepki Değişkeni Model Uyum İstatistikleri

Standart Sapma	1,08	R²	0,8981
Ortalama	11,47	R²_{düz}	0,8649
Varyans Faktörü (%)	9,42	R²_{tah}	0,8108
		Kesinlik Yeterliliği	18,9402

R^2 değerleri modelin tahmin gücünü gösterdiğinden, R^2 , R^2_{tah} ve $R^2_{\text{düz}}$ değerlerinin üçünün de 0,80'in üzerinde olması modelin güçlü bir tahmin yeteneğine sahip olduğunu göstermektedir. R^2 değerinin 0,8981 olarak bulunması, modelin tepkideki değişimlerin %89,8'ini açıklayabildiğini göstermektedir. Gözlemlenen verilerin %89,8'i model ile oluşturulan regresyon eğrisinin üzerinde yer almaktadır. R^2_{tah} ve $R^2_{\text{düz}}$ değerleri arasındaki fark 0,2'den küçük olduğundan aralarında bir uyumluluk mevcuttur. R^2_{tah} değeri, eğitimde kullanılmayan bir veri seti ile model test edildiği takdirde %81,08 oranında R^2 değeri elde edilebileceğini öngörmektedir. Kesinlik yeterliliği değeri dördün üzerinde çıkmıştır. Kesinlik yeterliliği, tasarım noktalarındaki tahmini değerlerin değer aralıkları ile ortalama tahmin hatalarını karşılaştırır. Dörtten büyük değerler modelin yeterliliğini gösterir (https://www.statease.com/media/productattachments/files/e/d/edme7_one-factor_tut.pdf, erişim tarihi 11.12.2018). Modelin gücü ve yeterliliği açısından yeterince iyi sonuçlar alınmıştır. Ortalamaya oranla standart sapma (Varyans Faktörü) 9,42 olarak bulunmuştur.

Model oluşturulduktan sonra, regresyon denkleminin oluşturulması için regresyon katsayıları Design Expert 11 programında En Küçük Kareler Yöntemi ile hesaplanmış olup güven aralıkları Çizelge 4.10'da verilmiştir.

Çizelge 4.10. Aşınma Tepki Değişkeni Regresyon Katsayıları

Faktör	Katsayı	Standart Hata	95% Alt Bant	95% Üst Bant	VIF
Sabit Terim	13,13	0,4411	12,24	14,02	
A-Cam	-0,5983	0,1560	-0,9136	-0,2831	1,0000
B-Karbür	-0,4259	0,2206	-0,8717	0,0199	2,00
C-Parçacık	4,07	0,4411	3,18	4,96	9,00
AB	-0,6383	0,2206	-1,08	-0,1925	1,0000
BC	-1,12	0,2206	-1,56	-0,6714	2,00
A ²	-1,48	0,2701	-2,03	-0,9383	1,83
B ²	0,4782	0,2701	-0,0678	1,02	1,83
ABC	-0,4440	0,2206	-0,8898	0,0018	1,0000
A ² B	0,7229	0,3119	0,0924	1,35	2,00
A ² C	-2,54	0,2586	-3,07	-2,02	4,12
B ² C	-0,8102	0,2586	-1,33	-0,2875	4,12
A ² B ²	-1,71	0,3119	-2,34	-1,08	1,11
A ² BC	0,9385	0,3119	0,3081	1,57	2,00

Yukarıda kodlanmış değişkenler ile oluşturulan regresyon denkleminin katsayıları (β değerleri) verilmiştir. Alt ve üst bantlar %95 güven aralığında katsayıların bulunabilecekleri aralıkları göstermektedir ve önceki bölümde verilen bağıntı (3.4) ile hesaplanmıştır. VIF

(varyans artış faktörü) faktörler arasında çoklu eşdoğrusallık (multicollinearity) olup olmadığını görmek için kullanılır. Faktörler arasında yüksek ilişki bulunması istenmeyen bir durumdur. Franke (2010) varyans artış faktörünün 10'un üzerinde olduğu durumlarda olası çoklu eşdoğrusallık durumunun sonuçları etkilemesinden bahsetmiştir. Tüm VIF değerlerinin 10'un altında olması ve mümkün olduğunca 1'e yakın olması istenen durumdur. Çizelge incelendiğinde tüm VIF değerlerinin 10'un altında değer aldığı görülmüştür.

Terim katsayıları (β_i) diğer tüm değişkenler sabit tutulduğunda (*ceteris paribus*), faktörlerin kodlanmış seviyelerinde yapılacak bir birim değişikliğin tepki değişkeni üzerindeki etkisini göstermektedir. Kodlanmış değişkenlerle oluşturulan regresyon denklemi faktörlerin tepki üzerindeki görece etkilerini incelemek için oldukça yararlıdır. Faktörlerin gerçek değerleri önceki bölümde verilen (3.2) bağıntısı ile kodlanmış seviyelere dönüştürüldükten sonra bu denkleme alınarak hesaplama yapılmalıdır. Denklem yine aynı bağıntı kullanılarak gerçek regresyon denklemine dönüştürüldüğü takdirde gerçek faktör değerleri ile aşınma tahmini yapılabilmektedir. Ancak, aşınma modelinde hiyerarşiyi destekleyen ifadelerden bazıları istatistiksel olarak anlamsız bulunup modelden çıkartıldığından gerçek regresyon denkleminin sonuçları kodlanmış regresyon denkleminin sonuçları ile uyumlayabilir. Bu nedenle gerçek regresyon denklemi oluşturulmamış ve tez sonuçlarının analizinde bağıntı (4.1) ile verilen kodlanmış regresyon denklemi* kullanılmıştır.


$$y_{Aşınma} = 13,13 - 0,60A - 0,43B + 4,07C - 0,64AB - 1,12BC - 1,48A^2 + 0,48B^2 - 0,44ABC + 0,72A^2B - 2,54A^2C - 0,81B^2C - 1,71A^2B^2 + 0,94A^2BC \quad (4.1)$$

*Bu ve bundan sonraki tüm regresyon denklemlerinde A terimi; cam katkı oranını, B terimi; karbür katkı oranını, C terimi; parçacık büyüklüğünü temsil etmektedir.

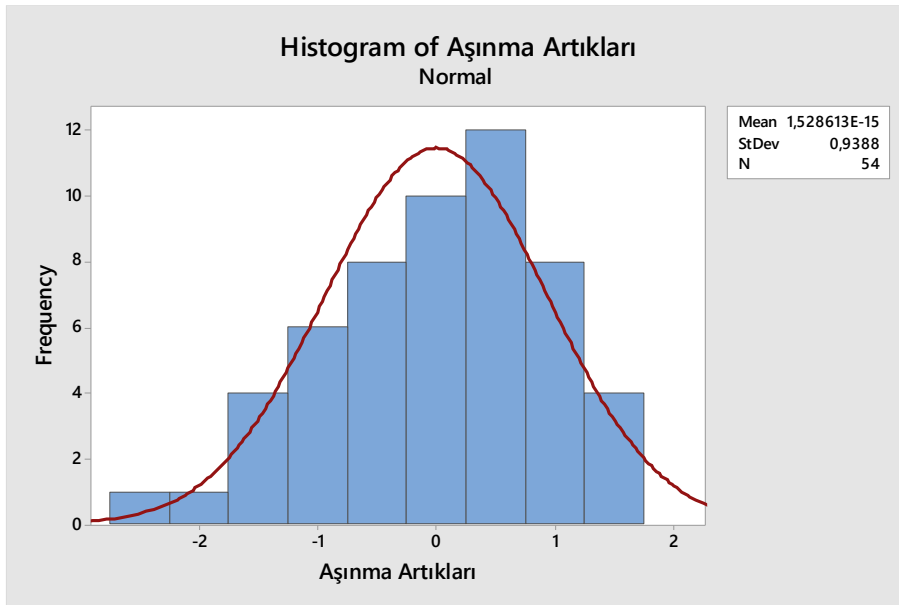
Aşınma modeli katsayılarına bakıldığında A faktörünün etkisinin B faktörünün etkisine göre, görece yüksek olduğu görülmektedir. Tepki değişkenine etkisi en yüksek olan faktör parçacık büyüklüğü olarak belirlenmiştir. Aşınma tepki değişkeni ile pozitif ilişkiye sahip terimler; C, A^2B ve A^2BC olarak bulunmuştur. Bu terimlerdeki artışın aşınmayı da arttıracığı söylenebilir. Diğer tüm terimler aşınma tepki değişkeni ile negatif bir ilişkiye sahiptir. Aşınma tepki değişkenini en çok etkileyen üç terim sırasıyla; C, A^2C ve A^2B^2 olarak bulunmuştur.

Regresyon modeli oluşturulduktan sonra tahmin modelinin temsil gücünü, başarısını ve yansız tahmin yaptığını doğrulamak için artıklar incelenmiştir. Gerçek değerler ile tahmini değerler arasındaki fark ($e = y - \hat{y}$) regresyon denkleminin artıkları olarak hesaplanmıştır.


Artıkların sıfırın etrafında herhangi bir yanlılık göstermeden normal dağıldığını göstermek için Minitab 17 programı kullanılmıştır. Analiz sonucu elde edilen normallik, histogram ve saçılma grafikleri Şekil 4.1, 4.2 ve 4.3’de gösterilmiştir. Veri sayısı 50’nin üzerinde olduğundan artıklara yapılacak normallik testi için Kolmogorov-Smirnov seçilmiştir. Bu testte p değerinin 0,05’den büyük olduğu durumlarda sıfır hipotezi kabul edilir (Ghasemi ve Zahediasl 2012) ve “istatistiksel olarak verinin normal dağılmadığını gösteren yeterli kanıt yoktur” denilir. Oluşturulan modelin saçılma grafiğinde artıklar herhangi bir aykırı desen oluşturmamıştır. Artıkların ortalaması “sıfır” olurken normallik testinin p değeri 0,05’ten yüksek çıkmıştır.



Şekil 4.1. Aşınma Tepki Değişkeni Artıklarının Normallik Testi




Şekil 4.2. Aşınma Tepki Değişkeni Artıklarının Histogram Dağılımı



Şekil 4.3. Aşınma Tepki Değişkeni Artıklarının Saçılma Diyagramı


Verilen bilgiler ekseninde grafikler incelendiğinde; artıklar sıfırın etrafında normal ve rassal dağılmıştır sonucuna ulaşılmıştır. Dolayısıyla modelin herhangi bir yanlılık göstermeden tahmin yaptığı söylenebilir.

Ana etkiler grafiği Şekil 4.4 ve 4.5’de verilmiştir (“Küçük parçacıklar”: 0-50 mikron büyüklüğündeki katkılar. “Büyük parçacıklar”: 50-75 mikron büyüklüğündeki katkılar). Cam oranı faktörünün ana etki grafiği, her bir parçacık büyüklüğü için, karbür oranı (0) noktasında (%10) sabit tutularak elde edilmiştir. Karbür oranı faktörünün ana etki grafiği de her bir parçacık büyüklüğü için, cam oranı (0) noktasında (%10) sabit tutularak elde edilmiştir.



Şekil 4.4. Aşınma Tepki Değişkeninin Ana Etkiler Grafiği (Küçük Parçacıklar)

Şekil 4.4'de küçük parçacıklar için ana etkiler grafiği gösterilmiştir. Cam oranı $[0,0.5]$ aralığındayken aşınma oranı minimumdur. Karbür oranı $[-0.5,0]$ aralığında ise aşınma minimize olduğu değerdedir. Parçacık büyüklüğüne bağlı aşınma grafiğine bakıldığında; küçük parçacıklardaki aşınma değeri büyük parçacıklara göre daha düşük değer almıştır. Büyük parçacık kullanıldığında (Şekil 4.5) cam oranı (1) seviyesinde iken aşınma minimum olmuştur. Cam katkısının $[-1,0]$ aralığı için epoksiye katkı eklenmesi aşınmayı arttırmıştır. Aşınma eğrisinin tepe noktasından (0) sonraki cam katkısı artışlarında aşınma oranı azalmıştır. Karbür oranının artışı aşınmayı azaltıcı etki göstermiştir. Aşınma oranı, özellikle büyük katkı büyüklüğünde cam ve karbür oranı değişimlerinden yüksek oranda etkilenmiştir. Bu etkilenme küçük katkı büyüklükleri için daha düşük seviyede olmuştur. Küçük parçacıklarda karbür tozu artışı genel olarak aşınma üzerinde olumsuz etki gösterirken büyük parçacıklarda bu artış aşınmayı azaltmıştır.



Şekil 4.5. Aşınma Tepki Değişkeninin Ana Etkiler Grafiği (Büyük Parçacıklar)


Modelde yüksek dereceli terimler bulunduğundan, sadece ana etkiye bakarak yorum yapmak yanıltıcı olacaktır. Bu nedenle etkileşim ve izdüşüm grafiklerinin de incelenmesi gerekmektedir.

Aşınma

X1 = A: Cam
X2 = B: Karbür

Actual Factor
C: Parçacık = 50

■ B- -1
▲ B+ 1



Şekil 4.6. Aşınma Tepki Değişkeninin Etkileşim Grafiği (Küçük Parçacıklar)


Etkileşim grafiklerinde AB terimi için karbürün yüksek seviyesi (▲), düşük seviyesi (■) sembolü ile gösterilmektedir. Şekil 4.6 ve 4.7’de verilen AB etkileşim grafiğine bakıldığında küçük boyutlu katkılar için karbür eklentisinin düşük seviyeden (%2,93) yüksek seviyeye (%17,07) çıkartılmasının tepki açısından olumsuz sonuç oluşturduğu görülmektedir. Karbürün iki seviyesinde de cam oranındaki artış aşınmayı azaltmıştır. Bu azalma karbür seviyesinin (1) olduğu durumda görece daha fazla olmuştur. Büyük boyutlu katkılarda ise tepkinin AB faktöründeki değişimlere daha duyarlı olduğu söylenebilir. Düşük karbür seviyelerinde cam oranının (-1) ve (1) seviyeleri aşınmanın en az olduğu yerler olurken, sıfır noktasının yakın komşuluklarında aşınma oldukça yüksek olmuştur. Karışımdaki karbür oranı arttırıldığında, çoğu deney noktasında bu artış aşınmaya olumlu olarak yansımıştır. Karbürün (1) seviyesinde aşınma performansının en iyi olduğu nokta cam katkısının (1) seviyesinde olduğu nokta olmuştur. Sonuç olarak küçük parçacıklarda karbür tozunun karışımdaki yoğunluğunun arttırılması aşınmaya olumsuz yansırken, cam tozunun yoğunluğunun arttırılması aşınmaya olumlu etki etmiştir. Büyük parçacıklardaysa camın sıfır seviyelerinde olması aşınmayı olumsuz etkilemiştir. Karbür artışı da eğer cam (-1) seviyelerinde ise olumsuz, eğer daha yüksek seviyelerde ise aşınmaya olumlu yansımıştır.

Aşınma

X1 = A: Cam
X2 = B: KARBÜR

Actual Factor
C: Parçacık = 75


■ B- -1
▲ B+ 1



Şekil 4.7. Aşınma Tepki Değişkeninin Etkileşim Grafiği (Büyük Parçacıklar)

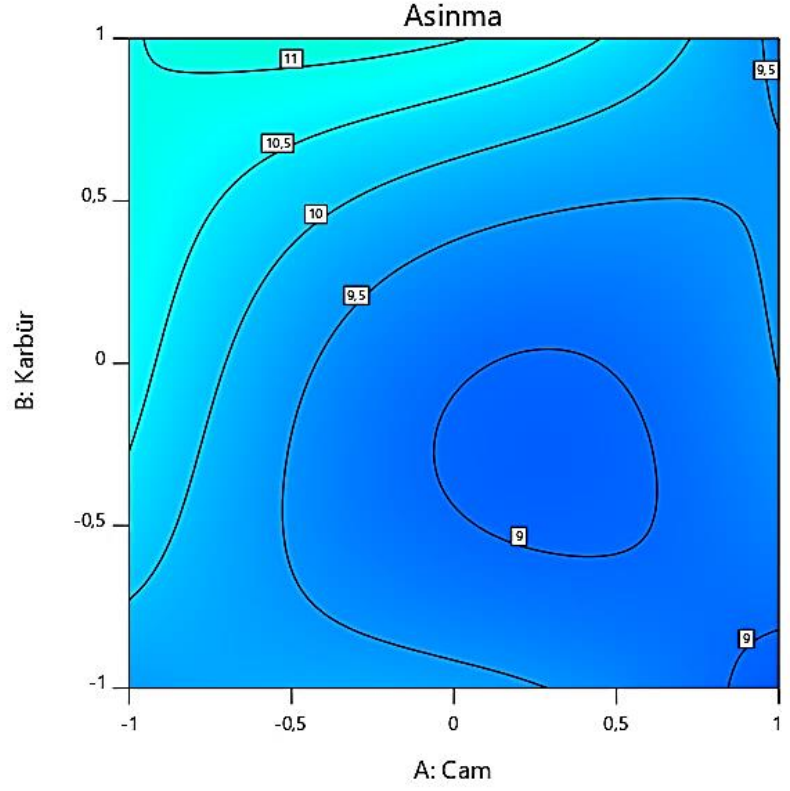
Şekil 4.8 ve 4.9’da verilerin analizi sonrasında elde edilen küçük ve büyük parçacıklar için izdüşüm grafikleri verilmiştir. Grafikte deney tasarım aralığındaki $[-1,1]$ tüm noktalar için aşınma sonuçlarının bilgisi bulunmaktadır. Grafikteki %9 eğrisinin içerisinde kalan alanlar, aşınmanın en düşük olduğu yerlerdir. Küçük parçacıklar için aşınmanın minimum olduğu nokta %8,81 değeri ile $(1,-1)$ noktası olmuştur. Bu değeri takip eden ikinci çözüm %8,89 aşınma değeri ile $(0.274,-0.269)$ noktası olmuştur. Büyük parçacıklar için elde edilen grafiğe bakıldığında, çizgilerin yükseklik farkı ve eğimi yüksek olduğundan, katkıların aşınmayı önemli ölçüde azaltma veya artırma gücü olduğu sonucuna ulaşılmıştır. Bu grafikteki minimum aşınma, %9,57 ile camın ve karbürün ikisinin birden maksimum seviye olan (1) olmaları durumunda elde edilmiştir. İkinci çözüm $(0.98,1)$ noktasında elde edilen %9,73 aşınma oranıdır (Optimizasyon çalışmasına çoklu tepki optimizasyonu bölümünde detaylı olarak değinilmiştir).

Design-Expert® Software
Factor Coding: Actual

Asınma
7,80705  19,4942

X1 = A: Cam
X2 = B: Karbür

Actual Factor
C: Parcacik = 50



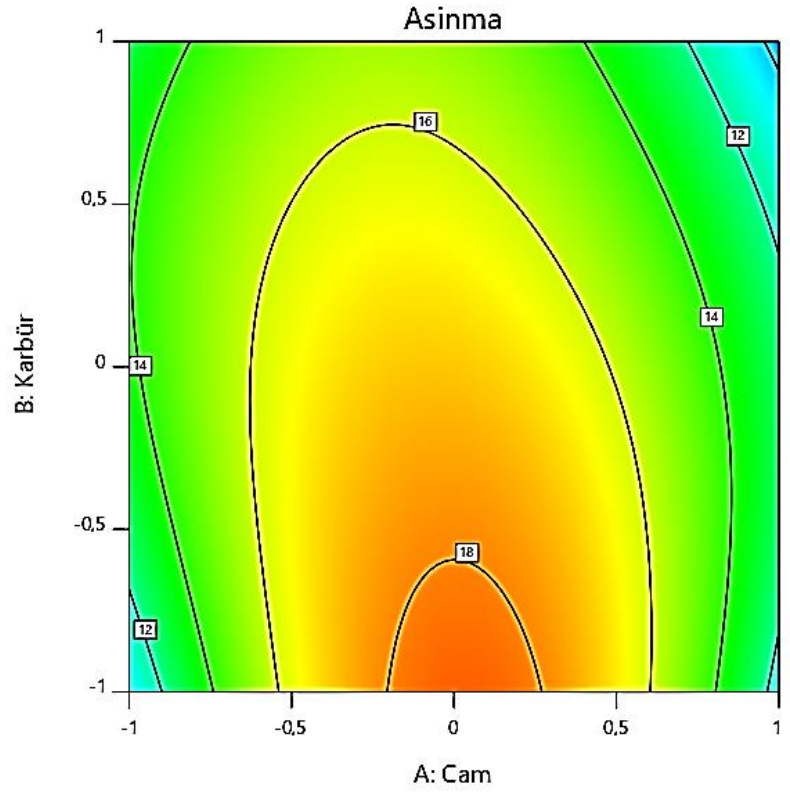
Şekil 4.8. Aşınma Tepki Değişkeninin İzdüşüm Grafiği (Küçük Parçacıklar)

Design-Expert® Software
Factor Coding: Actual

Asınma
7,80705  19,4942


X1 = A: Cam
X2 = B: Karbür

Actual Factor
C: Parcacik = 75




Şekil 4.9. Aşınma Tepki Değişkeninin İzdüşüm Grafiği (Büyük Parçacıklar)

Şekil 4.10 ve 4.11’de üç boyutlu grafiklerde optimum noktalar gösterilmiştir. İzdüşüm grafikler üç boyutlu grafiklerin izdüşümü olduğundan izdüşüm grafiklerindeki noktalar üç boyutlu grafikteki noktaların birebir aynısıdır. Bu optimum noktalar için istenirlik fonksiyonu değerleri hesaplanmıştır. Veri setindeki en yüksek aşınma değeri %19,49’dur. Hedeflenen değer (T) ise veri setindeki en düşük aşınma değeri %7,81 olarak belirlenmiştir. İstenirlik fonksiyonu formülünde “y” yerine sırasıyla %8,81 ve %9,57 değerleri yazıldığında, küçük parçacıklar için istenirlik değeri 0,914 olurken büyük parçacıklar için 0,849 olmuştur. İstenirlik değeri 0 ile 1 arasında değer almaktadır. Optimizasyonun başarı ölçütü olduğundan istenirliğin 1 değerine yakın olması hedeflenen tüm koşulların aynı anda sağlandığını gösterir. İki parçacık büyüklüğü için de bire yakın değer almış olup, küçük parçacıklı katkılarda daha yüksek istenirlik değeri elde edilmiştir. Küçük parçacıklar için aşınmanın minimum olduğu nokta %8,81 değeri ile (1,-1) noktası olmuştur.



Şekil 4.10. Aşınma Tepki Değişkeninin Üç Boyutlu Tepki Grafiği (Küçük Parçacıklar)



Şekil 4.11. Aşınma Tepki Değişkeninin Üç Boyutlu Tepki Grafiği (Büyük Parçacıklar)

4.4. Sertlik Tahmin Modeli

Çizelge 4.11’de beşinci derece modeli oluşturulan sertlik tepki değişkeni için elde edilen ANOVA tablosu verilmiştir.

Çizelge 4.11. Sertlik Tepki Değişkeni ANOVA Tablosu

Terim	Kareler Toplamı	Serbestlik Derecesi	Ortalama Kare	F-değeri	p-değeri
Model	6605,32	17	388,55	93,42	< 0.0001**
A-Cam	195,21	1	195,21	46,93	< 0.0001**
B-Karbür	0,1408	1	0,1408	0,0339	0,8550
C-Parçacık	1290,67	1	1290,67	310,31	< 0.0001**
AB	157,08	1	157,08	37,77	< 0.0001**
AC	39,60	1	39,60	9,52	0,0039**
BC	467,50	1	467,50	112,40	< 0.0001**
A ²	94,74	1	94,74	22,78	< 0.0001**
B ²	9,10	1	9,10	2,19	0,1478
ABC	30,83	1	30,83	7,41	0,0099**
A ² B	0,2948	1	0,2948	0,0709	0,7916
A ² C	129,20	1	129,20	31,06	< 0.0001**
AB ²	82,81	1	82,81	19,91	< 0.0001**
B ² C	45,11	1	45,11	10,85	0,0022**
A ² B ²	123,84	1	123,84	29,77	< 0.0001**
A ² BC	290,70	1	290,70	69,89	< 0.0001**
AB ² C	328,81	1	328,81	79,05	< 0.0001**
A ² B ² C	108,30	1	108,30	26,04	< 0.0001**
Hata	149,73	36	4,16		
Toplam	6755,05	53			

** : İstatistiksel olarak anlamlı terimler

* : İstatistiksel olarak ihmal edilebilecek kadar önemsiz olup model hiyerarşisi için kullanılacak terimler

Beşinci derece modelden önce oluşturulan üçüncü ve dördüncü dereceden modellerde uyum eksikliği görülmüştür. Bu nedenle beşinci dereceden modelin kullanılmasına karar verilmiştir. Beşinci dereceli terimlerden sadece A²B²C teriminin tepki üzerinde etkisi olduğu görülmüştür. Bu terimin modele eklenmesiyle uyum eksikliği sorunu giderilmiştir. Kareler toplamı sifıra eşit olan diğer üç, dört ve beşinci derece terimler modele eklenmemiştir. Modelin F testi yapıldığında; p anlamlılık değeri 0,05’den küçük olduğundan sıfır hipotezi reddedilir ve modelde kullanılan faktörlerden en az birisinin ortalamasının farklı olduğu ve incelenen tepkinin girdi faktörlerinden etkilendiği sonucu çıkartılır. Bu aynı zamanda, bağımsız değişkenler modelde olmadan da modelin eşit derecede iyi tahmin yapabileceği hipotezinin reddi anlamına gelmektedir. Modelin anlamlı olduğu kabul edilir ve uyum eksikliği önemsiz olarak kabul edilir. Model terimlerine bakıldığında %5 önem seviyesinin altında kalan, istatistiksel olarak tepkiyi açıklamak için kullanılabilecek terimler “***” ile işaretlenmiştir.

Kalan üç terimin tepki üzerindeki etkisi istatistiksel olarak önemsiz sayılabilecek bir seviyededir. Bu terimler hiyerarşiyi destekleyen terimler olsa da p değerleri oldukça yüksek olduğundan etkileri önemsiz olarak kabul edilmiş ve modele dâhil edilmemişlerdir. ANOVA testi sonrasında istatistiksel olarak önemli bulunan terimler A, C, AB, AC, BC, A², ABC, A²C, AB², B²C, A²B², A²BC, AB²C ve A²B²C olmuştur. Ana etkilerden parçacık büyüklüğü ve cam oranı tepki üzerinde anlamlı etkiye sahip olurken, karbür oranının etkisi istatistiksel olarak %5 önem düzeyinde anlamsız bulunmuştur. Aşınma modelindeki anlamlı terimler ile sertlik modelindeki anlamlı terimler bu noktada büyük ölçüde paralellik göstermiştir. İstatistiksel olarak anlamsız terimler modelden çıkartıldıktan sonra modelin F değeri ise 114,62 seviyesine çıkmıştır. Uyum eksikliği ise başlangıç modelinde çok düşük olduğu için program tarafından hesaplanmamıştır. Daraltma sonrasında program uyum eksikliği p değerini 0,4782 olarak hesaplamıştır. Dolayısıyla herhangi bir uyum eksikliği tespit edilmemiştir. Modeldeki daraltma sonrası diğer model istatistikleri Çizelge 4.12’de verilmiştir.

Çizelge 4.12. Sertlik Tepki Değişkeni Model İstatistikleri

İstatistik	5.Derece Model	Daraltılmış Model
PRESS (Tahmin Edilen Artık Kareler Toplamı)	336,90	297,13
BIC (Bayes Bilgi Kriteri)	280,12	271,83
AIC_c (Akeike Bilgi Kriteri)	263,86	254,63

Modelden çıkartılan terimler sonrasında; üç ayrı model istatistiğinde de gözle görülür bir iyileşme olmuştur. Buna göre daraltılmış modelin nihai model olmasına karar verilmiştir. Aşınma modeli ile karşılaştırıldığında; sertlik modeli için bu üç istatistik (PRESS, BIC, AIC_c) daha yüksek çıkmıştır. Bu da artıkların kareler toplamının sertlik modelinde aşınma modeline kıyasla daha yüksek olmasıyla ilişkilidir. Artıkların kareler toplamını en çok arttıran bileşen saf hata (pure error) olmuştur. Çizelge 4.13’de sertlik modelinin uyum istatistikleri verilmiştir.

Çizelge 4.13. Sertlik Tepki Değişkeni Model Uyum İstatistikleri

Standart Sapma	2,03	R²	0,9763
Ortalama	26,49	R²_{düz}	0,9678
Varyans Faktörü (%)	7,65	R²_{tah}	0,9560
		Kesinlik Yeterliliği	32,9239

R² değerlerinin tamamı (R², R²_{düz}, R²_{tah}) 0,95’in üzerinde bulunmuştur. Gözlemlenen verilerin %97 kadarı regresyon eğrisi üzerine düşmüştür. R²_{tah} 0,956 olarak bulunduğundan eğitimde kullanılmayan başka bir veri ile model test edilir ise modelin başarısı %95 olarak

öngörülmüştür. Kesinlik yeterliliğinde dörtten büyük değer alınmıştır. Sertlik modelinin PRESS, BIC ve AIC_c metriklerinde aşınma modeline kıyasla daha başarısız sonuçlar alınmasına rağmen, R² değerlerinde sertlik modeli daha başarılı bulunmuştur. Sertlik modelinde daha yüksek artık olmasına karşın, tahmin modelinin gerçek veri ile uyumluluğu daha yüksek olmuştur. Sertlik modelinde varyans faktörü 7,65 olarak bulunmuştur. Sertlik modeli sonuçlarında, aşınma sonuçlarına kıyasla daha düşük varyans faktörü elde edilmiştir.

Model ve modelde yer alan anlamlı terimler belirlendikten sonra sertlik tepki değişkeninin tahmininin yapılması için regresyon denklemi oluşturulmuştur. Kodlanmış değişken seviyeleri için regresyon denklemi Design Expert 11 programında yapılan analiz sonucunda oluşturulmuştur. Regresyon katsayıları, bu katsayıların %95 güven aralıkları, standart hataları ve varyans artış faktörleri Çizelge 4.14 ile verilmiştir.

Çizelge 4.14. Sertlik Tepki Değişkeni Regresyon Katsayıları


Faktör	Katsayı	Standart Hata	95% Alt Bant	95% Üst Bant	VIF
Sabit Terim	23,24	0,4778	22,27	24,21	
A-Cam	2,85	0,4138	2,01	3,69	2
C-Parçacık	-14,67	0,8276	-16,34	-12,99	9
AB	2,56	0,4138	1,72	3,40	1
AC	1,28	0,4138	0,4476	2,12	2
BC	-4,41	0,4138	-5,25	-3,58	2
A ²	1,93	0,3778	1,17	2,69	1,02
ABC	1,13	0,4138	0,2963	1,97	1
A ² C	2,84	0,5068	1,82	3,87	4,5
AB ²	-2,63	0,5852	-3,81	-1,44	2
B ² C	1,68	0,5068	0,6540	2,70	4,5
A ² B ²	3,46	0,5603	2,33	4,60	1,02
A ² BC	4,92	0,5852	3,74	6,11	2
AB ² C	-5,23	0,5852	-6,42	-4,05	2
A ² B ² C	3,00	0,5852	1,82	4,19	2

Kodlanmış faktörler ile oluşturulan regresyon denklemiyle tepki değişkeni değerinin tahmini yapılabilmektedir. Regresyon denkleminde faktörlerin üst seviyeleri (1), alt seviyeleri ise (-1) ile kodlanmıştır. Denkleminde terimlerin katsayıları ile her bir terimin bağımlı değişken üzerindeki görece etkisinin değerlendirilmesi mümkündür. Tepki üzerinde en önemli etkiyi sırasıyla C, AB²C, A²BC, BC ve A²B² faktörleri oluşturmaktadır. Sertlik tepki değişkeni için kodlanmış değişkenlerle oluşturulan regresyon denklemi (4.2) bağıntısında verilmiştir.


$$y_{Sertlik} = 23,24 + 2,85A - 14,67C + 2,56AB + 1,28AC - 4,41BC + 1,93A^2 + 1,13ABC + 2,84A^2C - 2,63AB^2 + 1,68B^2C + 3,46A^2B^2 + 4,92A^2BC - 5,23AB^2C + 3,00A^2B^2C \quad (4.2)$$

Regresyon denkleminde sertlik tepki değişkeni ile pozitif ilişkiye sahip olan terimler; A, AB, AC, A², ABC, A²C, B²C, A²B², A²BC ve A²B²C olurken, negatif ilişkiye sahip olan terimler C, BC, AB² ve AB²C olmuştur. Kodlanmış değişkenler önceki bölümde verilen (3.2) bağıntısı ile gerçek değişkenlere dönüştürüldüğünde gerçek regresyon denklemi elde edilebilmektedir. Ancak modelin analizleri esnasında kodlanmış faktörlerle oluşturulan regresyon denklemi kullanılmıştır. Bunun en önemli nedeni tahmin modelinin hiyerarşik olmayışıdır. Çizelgedeki varyans artış faktörü incelendiğinde her bir faktör için elde edilen değerler tolere edilebilecek en yüksek VIF değeri olan 10'dan küçük olarak bulunmuşlardır. Buradan faktörler arası çoklu eşdoğrusallık (multicollinearity) durumunun sonuçları etkileyebilecek seviyede olmadığı anlamı çıkarılır.

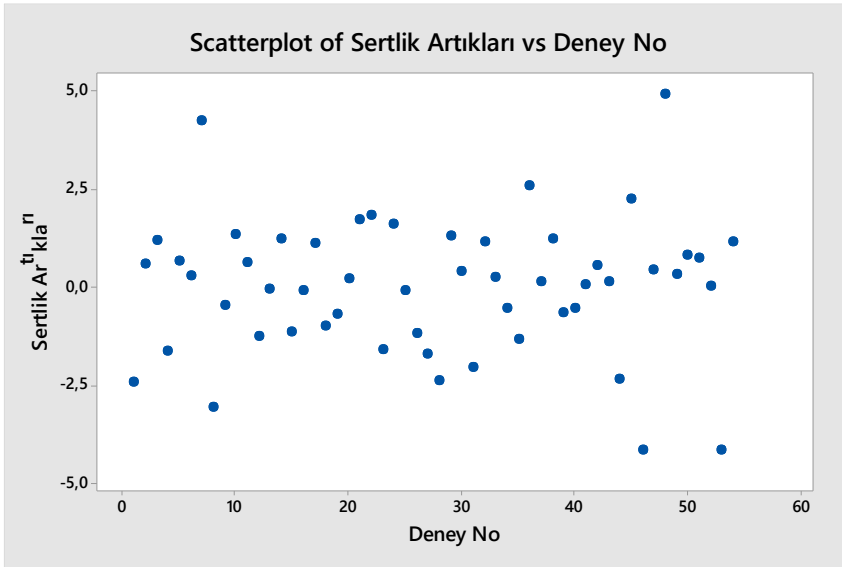
Regresyon modeli oluşturulduktan sonra tahmin modelinin temsil gücünü, başarısını ve yansız tahmin yaptığını test etmek amacıyla artıklar incelenmiştir. Gerçek değerler ile tahmini değerler arasındaki farkın ($e = y - \hat{y}$) sıfırın etrafında normal bir şekilde dağılmış olması gereklidir. Artıkların (e) analizi için Minitab 17 programı kullanılmıştır. Analiz sonucu elde edilen normallik, histogram ve saçılma grafikleri Şekil 4.12, 4.13 ve 4.14'de gösterilmiştir. Analiz edilen veri sayısı 50'nin üzerinde olduğundan artıklara yapılacak normallik testi için Kolmogorov-Smirnov seçilmiştir. Kolmogorov-Smirnov testinde p değerinin 0,05'den büyük olduğu durumlarda verinin istatistiksel olarak normal dağıldığı kabul edilir.



Şekil 4.12. Sertlik Tepki Değişkeni Artıklarının Normallik Testi



Şekil 4.13. Sertlik Tepki Değişkeni Artıklarının Histogram Dağılımı



Şekil 4.14. Sertlik Tepki Değişkeni Artıklarının Saçılma Diyagramı


Oluşturulan modelin saçılma grafiğinde artıklar herhangi bir desen oluşturmamıştır. Ancak grafiğin üst ve alt kısmındaki gözlemlere bakıldığında bu veriler uç nokta olabilecek noktardır. Bu nedenle artıklara bu testlere ek olarak Grubb's outlier testi de uygulanmıştır. Çizelge 4.15'de Grubb's testinin sonuçları verilmiştir. Elde edilen sonuçlara göre herhangi bir uç noktaya rastlanmamıştır.

Çizelge 4.15. Sertlik Tepki Değişkeni Artıklarının Grubb's Testi Sonuçları

Değişken	N	Ortalama	S. Sapma	Min	Mak	G	P
Sertlik Artıkları	54	0	1,739	-4,172	4,928	2,83	0,178

Artıklara yapılan tüm testler incelendiğinde, artıkların ortalaması sıfır olurken dağılımı normal dağılım olarak bulunmuştur. Artıkların sıfırın etrafında normal ve rassal dağıldığı sonucuna ulaşılmıştır. Dolayısıyla, modelin herhangi bir yanlılık göstermeden tahmin yaptığı söylenebilir.


Yapılan istatistiksel analiz sonrasında elde edilen ana etkiler grafiği Şekil 4.15 ve 4.16'da verilmiştir. Karbür oranı (B) istatistiksel olarak önemsiz bulunup modelden çıkartıldığından ana etki olarak yalnızca A ve C etkileri incelenmiştir. Cam oranı faktörünün ana etki grafiği, her bir parçacık büyüklüğü için, karbür oranı sıfır noktasında (%10) sabit tutularak elde edilmiştir. Parçacık büyüklüğü faktörünün grafiği diğer faktörler (cam ve karbür oranları) %10 seviyesinde tutularak oluşturulmuştur.



Şekil 4.15. Sertlik Tepki Değişkeninin Ana Etkiler Grafiği (Küçük Parçacıklar)

Şekil 4.15'de küçük parçacıklar için ana etkiler gösterilmiştir. Cam oranı (1) seviyesindeyken sertlik en yüksek değeri almıştır. Eklenen cam miktarı sertlik artışına neden olmuştur. Parçacık büyüklüğüne bağlı sertlik grafiğine bakıldığında küçük parçacıklarda daha

yüksek sertlik elde edilmiştir. Parçacık büyüklüğünün artışı sertliği azaltırken önceki bölümde de görüldüğü gibi aşınmayı arttırmıştır. Bu açıdan aşınma ile sertliğin birbirleriyle negatif korelasyon içerisinde oldukları görülmektedir. Büyük parçacıklar için yalnızca cam oranı ana etki grafiği verilmiştir. Yukarıda verilen parçacık büyüklüğü grafiği küçük ve büyük parçacıklar için aynı grafikte gösterilmiştir. Şekil 4.16'da verilen cam oranı ana etki grafiği göstermiştir ki; küçük parçacıklarda olduğu gibi büyük parçacıklarda da cam katkısı oranının artması, sertlik üzerinde olumlu etkiye sahip olmuştur. $[-1,0]$ aralığında cam eklenmesi sertlik değerinde çok küçük bir azalmaya neden olmuştur. $[0,1]$ aralığında camın sertlik üzerinde doğrudan arttırıcı bir etkisi olmuştur. Yani, cam katkısı %10 seviyesine ulaştıktan sonra eklenen her birim cam katkı, sertliği arttırmıştır. Cam katkısının sertlik üzerindeki göreceli etkisi büyük parçacıklarda daha fazla olmuştur. Aşınma tepki değişkeni için de benzer durum söz konusu olmuştur.



Şekil 4.16. Sertlik Tepki Değişkeninin Ana Etkiler Grafiği (Büyük Parçacıklar)

Ana etkiler ile birlikte ikili etkileşim ve izdüşüm grafikleri, tepkinin faktörlere bağlı nasıl şekillendiğini anlamada kolaylık sağlamaktadır. Şekil 4.17 ve 4.18'de AB etkileşim grafikleri verilmiştir.

Sertlik

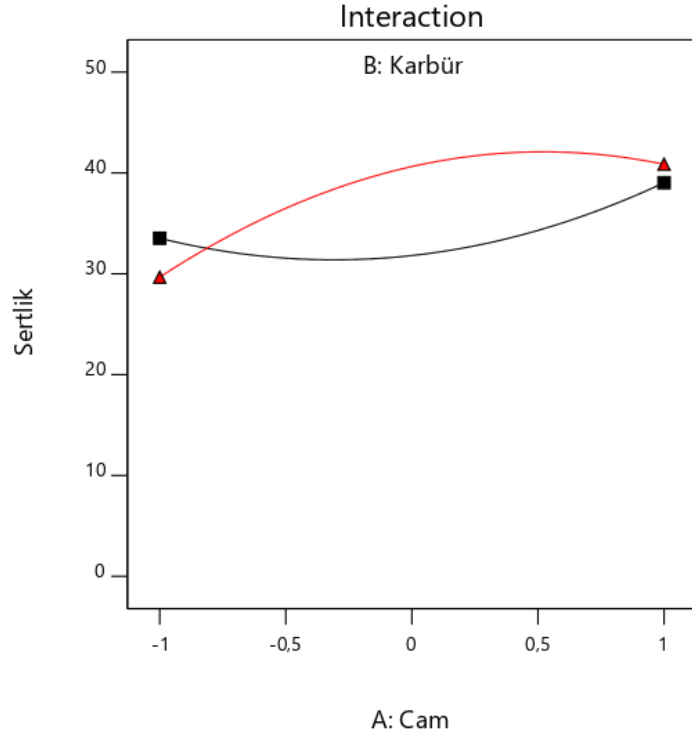
X1 = A: Cam
X2 = B: Karbür

Actual Factor

C: Parçacık = 50

■ B- -1

▲ B+ 1



Şekil 4.17. Sertlik Tepki Değişkeninin Etkileşim Grafiği (Küçük Parçacıklar)

AB etkileşim grafiklerinde karbürün yüksek seviyesi (▲), düşük seviyesi (■) sembolü ile gösterilmektedir. Küçük parçacıklarda (Şekil 4.17), camın (-1) seviyesi için karbür seviyesi arttıkça sertlik azalırken diğer cam seviyelerinde karbürün artışı sertliği arttırmıştır. Düşük karbür seviyesinde, camın [-1,0] aralığında arttırılması sertliği azaltırken, sıfır seviyesinden sonraki artışlar sertliğin artmasına katkı sağlamıştır. Yüksek karbür seviyesinde, (0,5) seviyesine kadar eklenen camlar sertliği arttırırken, bu seviyeden sonra cam eklenmesi ile sertlik azalmıştır. Camın (1) seviyesinde epoksideki karbür miktarının sertlik üzerinde çok düşük bir etkisi olmuştur. En yüksek sertlik, karbürün (1), camın (0,5) seviyelerinde olduğu noktada elde edilmiştir. Büyük parçacıkların sertlik üzerindeki etkisini incelemek için verilen Şekil 4.18 incelendiğinde; büyük parçacıkların epoksi sertleştirmede kullanılmasının istenilen etkiyi yaratamadığı görülmektedir. Büyük parçacıklarda alınan en yüksek sertlik değeri yaklaşık 28 HRH olmuştur. En yüksek sertlik değeri (28 HRH) katkıların ikisinin de (-1) olduğu durumda alınmıştır. Düşük karbür seviyesinde karışıma eklenen cam oranının artışı sertlik değerinde sürekli olarak düşüşe neden olmuştur. Yüksek karbür oranında ise camın (-1) ve (1) seviyeleri sertliğin en yüksek olduğu noktalar olmuştur. Cam oranının [-1,0.5] aralığında olduğu durumlarda karbürün (-1) seviyesinde olması daha yüksek sertlik sonucu elde edilmesini sağlarken, diğer cam seviyelerinde karbürün (1) seviyesi daha başarılı sonuç vermiştir.

Sertlik


X1 = A: Cam
X2 = B: KARBÜR

Actual Factor

C: Parçacık = 75

■ B- -1


▲ B+ 1



Şekil 4.18. Sertlik Tepki Değişkeninin Etkileşim Grafiği (Büyük Parçacıklar)


Şekil 4.19 ve 4.20’de sertlik tepki değişkeni sonuçları için yapılan analizin izdüşüm grafikleri verilmiştir. Küçük parçacıklar ve büyük parçacıklar için iki farklı analiz verilmiştir. İzdüşüm grafik çizgileri küçük parçacıklarda 32 ile 40 arasında olurken, büyük parçacıklarda 10 ile 25 arasında olmuştur. Buradan hareketle küçük parçacıklı katkılar ile daha yüksek sertlik değeri elde edildiği sonucuna ulaşılmıştır. Küçük parçacıklarda en yüksek istenirlik değeri 0,99 seviyeleri olurken büyük parçacıklarda en yüksek istenirlik 0,63 seviyelerinde olmuştur. Büyük parçacık grafiğinde izdüşüm grafikleri daha geniş bir aralıkta elde edilmiştir. Buradan da büyük parçacıklar için sertlik sonuçlarının daha yüksek standart sapmaya sahip olduğu anlamı çıkartılacaktır. Küçük parçacık kullanıldığında tepkinin katkı oranına bağlı değişimi daha kısıtlı olmuştur. Küçük parçacıklarda sertliğin maksimum olduğu nokta (0,52,1) olmuştur. Bu noktanın sertliği 42,1 HRH, istenirlik değeri 0,99 olarak tahmin edilmiştir. Bu noktayı hemen hemen aynı istenirlik ve sertlik değeri ile (0,53,1) noktası takip etmiştir. Büyük parçacıklar için (-1,-1) noktası optimum nokta olmuştur. Bu noktanın sertlik değeri 28,4 HRH, istenirlik değeri ise 0,63 olmuştur. İkinci çözüm noktası (-0,96,-1) olmuştur. Bu noktanın sertlik değeri 27,53 HRH, istenirlik değeri 0,61 olmuştur.

Design-Expert® Software
Factor Coding: Actual

Sertlik
4,4  42,6


X1 = A: Cam
X2 = B: Karbür

Actual Factor
C: Parçacık = 50



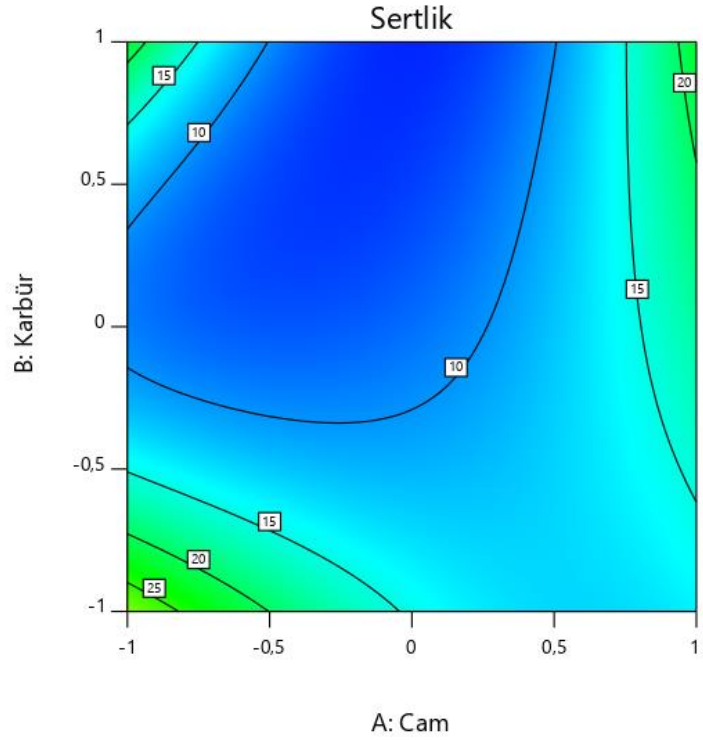
Şekil 4.19. Sertlik Tepki Değişkeni İzdüşüm Grafiği (Küçük Parçacıklar)

Design-Expert® Software
Factor Coding: Actual

Sertlik
4,4  42,6


X1 = A: Cam
X2 = B: Karbür

Actual Factor
C: Parçacık = 75




Şekil 4.20. Sertlik Tepki Değişkeni İzdüşüm Grafiği (Büyük Parçacıklar)

Şekil 4.21 ve 4.22’de üç boyutlu grafiklerde optimum noktalar verilmiştir. İzdüşüm grafikler üç boyutlu grafiklerin iki boyutlu çizimleri olduğundan; izdüşüm grafiklerindeki çözüm noktaları, üç boyutlu grafikteki çözüm noktalarının birebir aynısıdır. İzdüşüm grafiğinde verilen optimum noktaların yerleri bu grafiklerde gösterilmiştir. Aşınma grafikleri ile sertlik grafikleri birbirleri ile karşılaştırıldığında aşınmanın genellikle sertlik ile ters korelasyon halinde olduğu görülmüştür. Özellikle katkı büyüklüğü grafiklerindeki değişimlere bakıldığında; küçük katkı büyüklüğünden büyük katkı büyüklüğüne geçiş yapıldığında aşınma oranı bariz bir şekilde artarken, sertlik seviyesi bariz bir şekilde azalmıştır. Bu durum iki tepki arasındaki negatif korelasyonu göstermektedir.



Şekil 4.21. Sertlik Tepki Değişkeninin Üç Boyutlu Tepki Grafiği (Küçük Parçacıklar)



Şekil 4.22. Sertlik Tepki Değişkeninin Üç Boyutlu Tepki Grafiği (Büyük Parçacıklar)

4.5. Maliyet Tahmin Modeli

Tez çalışmasında hazırlanan numunelerde kullanılan malzemelerin maliyetleri çalışmanın yapıldığı dönem döviz kuru üzerinden yaklaşık olarak hesaplanmıştır. Kullanılan malzemelerin ve katkıların birim maliyetleri ayrı ayrı hesaplanmış olup, her bir deney noktası için toplam maliyetler hesaplanmıştır. Her numunenin üretiminde kullanılan epoksi ve sertleştirici malzeme miktarları sabit kabul edildiğinden maliyetleri aynıdır. Maliyetlerde değişkenlik yaratan unsur; numuneye hangi katkıdan hangi yüzde ile malzeme ekleneceğidir. Maliyetler teorik olarak hesaplama sonrası elde edildiğinden deney tekrarlarında veya deneyler arasında herhangi bir ölçüm hatası bulunmamaktadır. Elde edilen veriler istatistiksel analize tabi tutulmuştur ve ANOVA analizi için lineer model seçilmiş olup, sonuçlar Çizelge 4.16'da verildiği gibidir.

Çizelge 4.16. Maliyet Tepki Değişkeni ANOVA Tablosu

Terim	Kareler Toplamı	Serbestlik Derecesi	Ortalama Kare	F-değeri	p-değeri
Model	0,0004	3	0,0001	7,249E+	< 0.0001**
A-Cam Oranı	4,094E-06	1	4,094E-06	2,182E+	< 0.0001**
B-Karbür Oranı	0,0004	1	0,0004	2,153E+	< 0.0001**
C-Parçacık	0,0000	1	0,0000	0,0000	1.0000
Artık	9,382E-15	50	1,876E-16		
Uyum Eksikliği	9,382E-15	14	6,701E-16		
Hata	0,0000	36	0,0000		
Toplam	0,0004	53			

** : İstatistiksel olarak anlamlı terimler

* : İstatistiksel olarak ihmal edilebilecek kadar önemsiz olup model hiyerarşisi için kullanılacak terimler

Buna göre model anlamlı olarak bulunmuş ve beklenildiği gibi cam ve karbür oranı faktörlerinin maliyet ve tepki değişkenine etkisi çok önemli iken, parçacık büyüklüğünün maliyet üzerinde herhangi bir etkisinin olmadığı ya da etkisinin istatistiksel olarak ihmal edilebilecek kadar önemsiz olduğu görülmüştür. Buna göre model istatistikleri Çizelge 4.17'deki gibi bulunmuştur. R^2 değerleri %100 olarak bulunmuş olup, maliyet değerlerinin standart sapması sıfır olarak hesaplanmıştır. Hata terimleri sıfır olduğundan artıkların normal dağılım testleri yapılmamıştır.

Çizelge 4.17. Maliyet Tepki Değişkeni Model Uyum İstatistikleri

Standart Sapma	1,370E-08	R²	1,0000
Ortalama	0,6282	R²_{düz}	1,0000
Varyans Faktörü (%)	2,180E-06	R²_{tah}	1,0000
		Kesinlik Yeterliliği	-

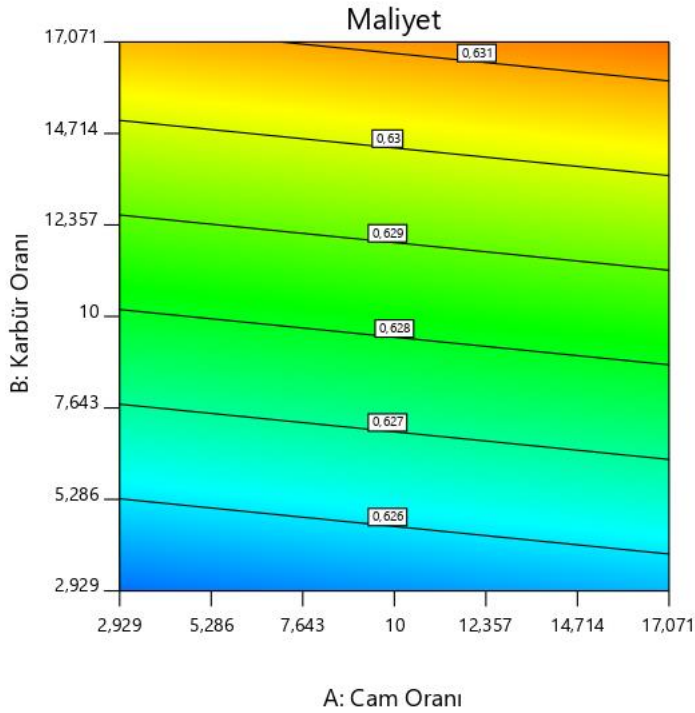
İstatistiksel olarak parçacık büyüklüğü terimi önemsiz bulunup modelden çıkartılmıştır. Sonrasında elde edilen model ile kodlanmış regresyon denklemi oluşturulmuş ve bağıntı (4.3) ile verilmiştir.

$$y_{Maliyet} = 0,6282 + 0,0003A + 0,0029B \quad (4.3)$$

Regresyon denklemi gerçek faktörlere uyarlanarak güncellenmiştir. Gerçek değişkenli regresyon denklemi bağıntı (4.4) ile verilmiştir. Parçacık büyüklüğü tepkiyi etkileme açısından anlamsız olarak bulunduğu ve modelden çıkartıldığı için her iki parçacık büyüklüğü için gerçek değişkenlerin kullanıldığı aşağıdaki denklem geçerlidir.

$$y_{Maliyet} = 0,6237 + 0,00004 * Cam + 0,00041 * Karbür \quad (4.4)$$

Şekil 4.23’de maliyet tepkisinin izdüşüm grafiği verilmiştir. Regresyon denkleminde olduğu gibi izdüşüm grafiğinde de iki parçacık büyüklüğü için de geçerli tek grafik oluşturulmuştur. Grafik incelendiğinde çizgilerin lineer davrandığı ve en ekonomik üretimin (-1,-1) noktasında olduğu görülmektedir. Aşınma ve sertlik grafiklerinin aksine maliyet modelinde analizler gerçek regresyon denklemi ile yapıldığından eksenlerde kodlanmış değişkenler yerine yüzdesel ifadeler bulunmaktadır.



Şekil 4.23. Maliyet Tepki Değişkeni İzdüşüm Grafiği

4.6. Aşınma Sertlik Korelasyonu

Uygulamadaki deneyimlerden ve literatürden sertlik ve aşınma tepki değişkenlerinin negatif korelasyon içerisinde olmaları beklenir. Bu korelasyonun belirlenmesi amacıyla aşınma ve sertlik testleri sonrasında elde edilen tepki değişkenlerinin korelasyonu incelenmiş ve elde edilen değerler Çizelge 4.18’de verilmiştir.

Çizelge 4.18. Sertlik-Aşınma Değişkenleri Arasındaki Korelasyon

Korelasyon			
		Sertlik	Aşınma
Sertlik	Pearson Korelasyon	1	-,504**
	Sig. (2 taraflı)		,000
	N	54	54

Aşınma	Pearson Korelasyon	-,504**	1
	Sig. (2 taraflı)	,000	
	N	54	54
**. 0,01 α değerine göre korelasyon bulunmaktadır. (2 taraflı).			

PASW 18 programına girişi yapılan aşınma ve sertlik test sonuçlarının pearson korelasyon analizi yapılmıştır. Çizelge incelendiğinde, aşınma ve sertlik arasında negatif bir korelasyonun mevcut olduğu ve korelasyon değerinin -0,504 olduğu görülmektedir. Bu da malzemenin sertliği arttıkça aşınmasının azaldığını göstermektedir. Çoklu tepki optimizasyonu gerçekleştirilirken gerçek uygulamalarda olduğu gibi aşınma değerinin minimumda, sertlik değerinin ise maksimumda olması durumuna göre analizler gerçekleştirilmiştir. Eğer tepki değişkenleri arasında yüksek korelasyon negatif olursa (-1), bu durumda aşınmanın minimizasyonu ile maksimum sertlik değeri elde edilebilir. Bu nedenle korelasyonun -0,504 olarak bulunması çoklu tepki optimizasyonunu anlamlı hale getirmiştir.

4.7. Çoklu Tepki Optimizasyonu

Elde edilen üç farklı tepki değişkeni (aşınma, sertlik ve maliyet) Design Expert 11 programında analiz edilerek çoklu optimizasyon çalışması yapılmıştır. Çoklu tepki optimizasyonunda amaç; farklı tepki değişkenlerini bir arada optimize ederek tepkilerin toplam istenirlik puanını maksimize etmektir. Tepki değişkenleri için farklı amaçlar hedeflenebilir. Yapılan tez çalışmasında aşınma ve maliyet tepki değişkenlerinin minimum olması istenirken, sertlik tepki değişkeninin maksimum olması istenmektedir. Bu üç tepki değişkeninin tekil optimum çözüm noktaları birbirlerinden farklıdır. Bu nedenle üç tepki değişkenini aynı anda sağlayan optimum noktayı elde etmek amacıyla istenirlik fonksiyonunu maksimize edecek bir çözüm oluşturulmuştur. Bu kapsamda farklı senaryolar (6 adet) geliştirilmiştir (Çizelge 4.19) ve bu senaryolar için optimum çözümler elde edilmiştir. Senaryolarda amaçlara farklı ağırlıklar (w) verilmiş ve bu ağırlıklar ile optimizasyon yapılmıştır. Ağırlıkların varsayılan değerleri 1'dir. Bir tepki değişkeni için ağırlık değeri arttırıldıkça (maksimum 10 değerini alabilir) ilgili tepkinin hedef (target) değere yakın olması önemli hale getirilmektedir. Bu değer 1'in altına düşürüldüğünde (minimum 0,1 değerini alabilir) ise hedef değere uzak olma durumuna izin verilmektedir. Ağırlıklandırma işlemine kısaca hedef değere yakın olma durumunun istenirlik değerindeki etkisinin artması veya azalması denilebilir. Bu da bazı tepkilerin hedef değerine erişmesini önemli hale getirirken bazılarını önemsiz hale getirmektedir. Bazı senaryolarda (5

ve 6) belirlenen tepki için maksimizasyon veya minimizasyon yapılması yerine tepki önceden belirlenen aralıklarda tutularak diğer tepki değişkenlerinin optimizasyonu gerçekleştirilmiştir.

Çizelge 4.19. Çoklu Tepki Optimizasyonu İçin Oluşturulan Senaryolar

Senaryo	Aşınma Tepki Değişkeni	Sertlik Tepki Değişkeni	Maliyet Tepki Değişkeni
1	Minimum (w=1)	Maksimum (w=1)	Minimum (w=1)
2	Minimum (w=10)	Maksimum (w=0,1)	Minimum (w=0,1)
3	Minimum (w=0,1)	Maksimum (w=10)	Minimum (w=0,1)
4	Minimum (w=0,1)	Maksimum (w=0,1)	Minimum (w=10)
5	Aralık [7,8-10] %	Maksimum (w=1)	Aralık [0,624-0,630] TL
6	Minimum (w=1)	Aralık [30-42,6] HRH	Minimum (w=1)


Her senaryo için elde edilen çözüm noktası (Cam oranı, Karbür Oranı, Parçacık Büyüklüğü), bu noktanın tepki ve istenirlik değerleri Çizelge 4.20 ile verilmiştir.

Çizelge 4.20. Tepki Değişkenleri İçin Oluşturulan Senaryoların Çözümü

Senaryo	Tasarım	Aşınma Oranı (%)	Sertlik (HRH)	Maliyet (TL)	İstenirlik
1	(1,-1,-1)	8,811	39,032	0,626	0,878
2	(1,-1,-1)	8,811	39,032	0,626	0,734
3	(0.52,1,-1)	10,391	42,099	0,631	0,886
4	(-1,-1,-1)	9,619	33,533	0,625	0,666
5	(0.40,0.57,-1)	9,650	40,609	0,630	0,948
6	(-1,-1,-1)	9,619	33,533	0,625	0,867

Senaryoların ilkinde tüm ağırlıklar 1 olarak girilmiş olup ağırlıkların aynı olduğu durumda çözüm bulunmuştur. Senaryo 2, 3 ve 4 için sırasıyla aşınma, sertlik ve maliyet tepki değişkenlerinin ağırlığı artırılırken, diğer tepki değişkenlerinin ağırlığı azaltılmıştır. Senaryo 5 ve 6'da ise seçilen tepkiler belirlenen değer aralığında tutulurken diğer tepkiler optimize edilmiştir. Çizelge 4.20'de maksimum istenirlik değerlerini sağlayan tasarım noktaları gösterilmiştir. Tasarım noktaları kodlanmış değişkenler ile ve sırasıyla (cam oranı, karbür oranı, parçacık büyüklüğünü) gösterir bir biçimde verilmiştir. Tepki değişkeni ve senaryo çözümlerinin istenirlik değerleri de aynı çizelgede verilmiştir. Hemen sağında tepki değişkeni değerleri ve senaryo çözümlerinin istenirlik değerleri verilmiştir. Bu değerler (istenirlik değerleri) sadece aday çözümler arasından seçimde kullanılmıştır ve senaryolar arasında kıyaslama amacıyla kullanılmamalıdır. İlk senaryo tüm tepkilerin eşit ağırlıkta bulunduğu

senaryodur ve tepkilerin eşit derecede önemli olduğu durumda geçerlidir. Bu senaryonun optimum çözüm noktası; aşınmanın tek tepki olarak optimize edildiği nokta ile aynıdır. Kodlanmış seviyeler gerçek değişkenlere dönüştürüldüğünde %17,071 cam, %2,929 karbür ve 0-50 mikronluk parçacık büyüklüğü girdileri optimal noktayı oluşturmaktadır. Bu senaryo için istenirlik oranı izdüşüm grafiği Şekil 4.24’de verilmiştir.



Şekil 4.24. Çoklu Tepki Optimizasyonu İstenirlik Oranı İzdüşüm Grafiği

Diğer senaryolar için izdüşüm grafikleri verilmemiştir. Tez kapsamında oluşturulan senaryoların sayısının artırılması mümkündür. Ürünün kullanılacağı sektör ve yere göre malzemenin özelliklerinde farklı spesifikasyonlar tanımlanabilir ve bu özellikleri sağlayan üretim konfigürasyonunu sağlayan noktalar bulunabilir.

4.8. ANN ile Aşınma Oranı Tahmini

Yapay sinir ağı literatüründe, çözüme ulaştırılmak istenen problem özelinde herhangi bir kural mevcut değildir. Karmaşık bir işleyişe sahip olması ve bunun açıklanamaması nedeniyle yapay sinir ağlarında genellikle uygun ağın seçimi için deneme yanılma kullanılmaktadır. Literatürdeki çalışmalarda kullanılan ve başarılı bulunan ağların belirli parametrelerini almanın çoğu durumda fayda sağlamadığı görülmüştür. Bu durum her veri

yapısı için farklı ağ parametrelerinin uygun olmasından kaynaklanmaktadır. Farklılık gösteren diğer bir durum ise, başlangıçtaki ağırlıklar ve yanlılık değerlerindeki rassallıktır. Bu nedenle deneme yanılma, yapay sinir ağlarında en sık başvurulan metottur. Farklı ağ yapıları kullanılarak ve ağ mimarisinde değişiklikler yapılarak 57 adet ağ alternatifi oluşturulmuştur. Bu ağlar RSM modelinin oluşturulmasında kullanılan 54 adet veri ile eğitilmişlerdir. Ağların geçerlilik testi için dışarıda tutma (hold-out) metodu kullanılmıştır. Bu metotta eldeki veri seti ile ağın eğitimi yapılır. Sonrasında eğitimi tamamlanan ağların performansının görülebilmesi için ağın gelecekte karşılaşma ihtimali olan durumları temsil için bağımsız bir sına (test) seti oluşturulur ve ağın tahminleri bu sına setinin sonuçları ile karşılaştırılarak tahmin gücü belirlenir. Eğitim veya sına setleri çapraz doğrulama benzeri metotlardaki gibi herhangi bir nedenle bölünmez. Doğrulama ve sına metodu olarak dışarıda tutma yönteminin kullanılmasının iki nedeni bulunmaktadır. Bunların birincisi veri setinin bölünmek istenmemesidir. Eğitim veri seti bölüdüğü takdirde RSM ile ANN'nin eğitildiği setler farklı olacaktır. Sına seti bölüdüğü takdirde ise RSM ile ANN'nin sınaıldığı setler farklılık gösterecek ve metotların başarılarının karşılaştırılması zorlaşacaktır. İkinci neden ise, bu yöntemde hem programlama hem de çözüm süreleri oldukça kısalmaktadır. Yüksek sayıda alternatif ağın eğitildiği ve test edildiği bir çalışmada hızlı çözüm elde etmek önemli bir parametre haline gelmektedir. Dolayısıyla literatürde RSM ve ANN kıyaslamalarında sıkça kullanılan dışarıda tutma yönteminin kullanılmasına karar verilmiştir. Matlab 2018b programının önceden tanımlı eğitim parametrelerinde herhangi bir değişiklik yapılmadan ağların eğitimleri yapılmıştır. Ağların performanslarının karşılaştırılması için RSM'nin modeli oluşturulduktan ve ANN alternatiflerinin eğitimleri tamamlandıktan sonra eğitimde kullanılmamış numunelerle yeni bir sına seti oluşturulmuştur. Sına noktaları rassal bir şekilde ve $[-1,1]$ tasarım aralığında seçilmiş olup Çizelge 4.21'de verilmiştir. Bu aralığın kullanılmasının nedeni α noktaların esas tasarım değil ek noktalar olması ve bu noktaların sına setine dâhil edilmesi halinde yanıltıcı sonuçların oluşma ihtimalidir. Sına verileri eğitimde olduğu gibi üç tekrarlı şekilde üretilmiştir. Çalışmada 18 adet sına verisi kullanılmıştır. Böylece sına veri sayısı/toplam veri sayısı oranı %25 olmuştur. Literatürde incelenen çalışmalarda bu oran %10 ile %30 arasında değişiklik göstermektedir.

Çizelge 4.21. Üretilen Numuneler İçin Sınama Veri Seti

Numune	Cam Oranı (%)	Karbür Oranı (%)	Katkı Büyüklüğü (μ)
1	15	9	0-50 Mikron
2	15	9	0-50 Mikron
3	15	9	0-50 Mikron
4	12	7	0-50 Mikron
5	12	7	0-50 Mikron
6	12	7	0-50 Mikron
7	7	12	0-50 Mikron
8	7	12	0-50 Mikron
9	7	12	0-50 Mikron
10	6	16	50-75 Mikron
11	6	16	50-75 Mikron
12	6	16	50-75 Mikron
13	3	11	50-75 Mikron
14	3	11	50-75 Mikron
15	3	11	50-75 Mikron
16	16	4	50-75 Mikron
17	16	4	50-75 Mikron
18	16	4	50-75 Mikron

Numunelerin üretimi tamamlandıktan sonra eğitim veri seti ile aynı şartlarda sınama seti numunelerinin testleri tamamlanmıştır. Testler oda sıcaklığında, dakikada 184 devir ile dönen 165 mm yarıçaplı tambura sarılı 320 kumluk zımpara kâğıdına 1480 gramlık yük altındaki numunelerin 30 saniye maruz bırakılmaları suretiyle yapılmıştır. Test sonucu elde edilen aşınma oranları Çizelge 4.22 ile verilmiştir.

Çizelge 4.22. Sınama Veri Setinin Aşınma Test Sonuçları

Numune	Cam Oranı (%)	Karbür Oranı (%)	Katkı Büyüklüğü (μ)	W_{ilk}	W_{son}	Aşınma Oranı (%)
1	15	9	0-50 Mikron	2,4082	2,147	10,85
2	15	9	0-50 Mikron	2,2835	2,049	10,27
3	15	9	0-50 Mikron	2,3353	2,081	10,89
4	12	7	0-50 Mikron	2,4517	2,258	7,90
5	12	7	0-50 Mikron	2,2953	2,078	9,47
6	12	7	0-50 Mikron	2,2787	2,048	10,12
7	7	12	0-50 Mikron	2,3026	2,052	10,88
8	7	12	0-50 Mikron	2,2451	2,019	10,07
9	7	12	0-50 Mikron	2,2764	2,083	8,50
10	6	16	50-75 Mikron	2,3434	2,019	13,84
11	6	16	50-75 Mikron	2,2572	1,937	14,19
12	6	16	50-75 Mikron	2,4723	2,127	13,97
13	3	11	50-75 Mikron	1,8194	1,55	14,81
14	3	11	50-75 Mikron	1,9534	1,674	14,30
15	3	11	50-75 Mikron	2,2581	1,972	12,67
16	16	4	50-75 Mikron	1,9886	1,708	14,11
17	16	4	50-75 Mikron	2,3586	2,065	12,45
18	16	4	50-75 Mikron	2,1206	1,852	12,67

ANN eğitimleri için Matlab 2018b programı yardımıyla alternatif ağlar oluşturulmuştur. Ağlar eğitilmeden önce deney verileri $a = (x - x_{min}) / (x_{max} - x_{min})$ formülü ile normalize edilmiştir. Ağlar eğitildikten sonra sınama veri seti ile test edilmişlerdir. Testler tamamlandıktan sonra ağ çıktıları $x = a(x_{max} - x_{min}) + x_{min}$ formülü ile denormalize edilerek verinin gerçek değerleri elde edilmiştir. Ağların başarıları MAPE, MSE ve R^2 ile ölçülmüştür. Elde edilen sonuçlara göre MAPE değerleri dikkate alınmış, bu değerlerin birbirine yakın oldukları durumda ise MSE ve R^2 metriklerine göre başarı karşılaştırılması yapılmıştır. Veri seti geniş olmadığı için eğitimler kısa sürmüştür, bu nedenle eğitim süresi bir başarı kriteri olarak tez kapsamında değerlendirilmemiştir.

4.8.1. Genelleştirilmiş regresyon ANN modeli


GRNN’de ağlar arasında farklılık gösteren tek nokta, yayılma parametresidir. Bu nedenle yalnızca yayılma parametrelerinde değişiklikler yapılmıştır. Yayılma parametresi yükseldikçe, ağ daha yumuşak (smooth) fonksiyon tahminleri yapacağından eğrilikler daha doğru tahmin edilir. GRNN’nin tek gizli katmanı bulunmaktadır. Gizli katmanda radyal tabanlı nöronlar bulunmaktadır. Çıktı katmanında ise toplama yapan nöronlar vardır. İlk katmandan gelen değerler bu katmanda toplanarak çıktı üretilir. Bu kapsamda dört farklı ağ oluşturulmuştur. Eğitilen dört alternatif ağın performansı Çizelge 4.23 ve 4.24’de gösterilmiştir. Yayılma parametresinin 0,2 olduğu durumda istatistiklere göre en başarılı tahmin yapılmıştır. Bu ağ ile elde edilen sonuçlar Şekil 4.25 ve Çizelge 4.25’de verilmiştir. Parametrenin 0,2 değerinin üzerinde olduğu durumlar hesaplamalara dâhil edilmemiştir. Yayılma parametresinin 0,2’nin üzerinde olduğu durumlarda sınama setinin sonuçlarının, eğitim setinin sonuçlarından daha başarılı olduğu gözlemlenmiştir. Bu durum aşırı genelleştirme olduğunu ve sınama setinin eğitim setine kıyasla daha başarılı olduğunu göstermektedir. Bunun en önemli nedeni GRNN’de yüksek yayılma parametreleri için aşırı genelleştirme görülmesidir. Bunun dışında, eğitim seti, sınama setine göre daha çok zorluk içerdiğinden böyle bir sonuçla karşılaşılabilir. Eğitim setinde ağın zorlu uç noktaları öğrenmesi beklenirken sınama setinde aralık [-1,1] aralığında tutularak görece daha kolay veri ile testler yapılmıştır. Diğer ihtimal ise sınama setindeki gürültü faktörünün eğitim setindeki gürültüden daha düşük olmasıdır. Sınama verisinin üretim ve testleri her ne kadar eğitimdeki üretim/testlerle aynı şartlar altında yapılmış olsa da farklı zamanlarda yapılmış olması gürültü seviyesinin farklılık göstermesine neden olabilir.

Çizelge 4.23. GRNN Eğitim Verisi Sonuç İstatistikleri

Eğitim Verisi		MAPE	R ²	MSE
Yayılma Katsayısı	0,05	6,63	90,97	0,77
	0,1	6,63	90,97	0,77
	0,15	6,67	90,96	0,77
	0,2*	7,20	90,27	0,93

Çizelge 4.24. GRNN Sınama Verisi Sonuç İstatistikleri

Sınama Verisi		MAPE	R ²	MSE
Yayılma Katsayısı	0,05	14,00	53,44	4,47
	0,1	13,92	53,79	4,41
	0,15	12,52	60,42	3,46
	0,2*	10,04	68,58	2,21



Şekil 4.25. En Başarılı GRNN Ağının Sınama Verisi Performans Grafiği

Çizelge 4.25. En Başarılı GRNN Ağına Aşınma Tahmin Sonuçları

	No	Gerçek Değerler	Tahmini Değerler		No	Gerçek Değerler	Tahmini Değerler	
Eğitim	1	9,869	10,055	Eğitim	37	9,529	9,532	
	2	10,008	10,055		38	8,486	9,532	
	3	9,841	10,055		39	9,204	9,532	
	4	9,801	9,251		40	9,105	10,250	
	5	8,128	9,251		41	9,739	10,250	
	6	9,399	9,251		42	10,968	10,250	
	7	10,851	11,330		43	9,295	9,181	
	8	10,704	11,330		44	7,807	9,181	
	9	12,182	11,330		45	9,711	9,181	
	10	10,712	9,864		46	19,494	17,870	
	11	9,607	9,864		47	18,419	17,870	
	12	8,697	9,864		48	19,124	17,870	
	13	11,961	11,602		49	12,806	14,177	
	14	12,727	11,602		50	16,052	14,177	
	15	10,704	11,602		51	15,085	14,177	
	16	10,840	9,879		52	15,477	16,706	
	17	8,212	9,879		53	18,614	16,706	
	18	10,848	9,879		54	17,514	16,706	
	19	11,474	10,232		Sınama	1	10,846	9,459
	20	10,114	10,232			2	10,269	9,459
	21	9,497	10,232			3	10,889	9,459
	22	12,982	12,029			4	7,901	9,278
	23	11,084	12,029			5	9,467	9,278
	24	12,886	12,029			6	10,124	9,278
	25	8,174	9,197			7	10,883	9,930
	26	9,270	9,197			8	10,071	9,930
	27	9,721	9,197			9	8,496	9,930
	28	11,094	11,058			10	13,843	13,575
	29	10,454	11,058			11	14,186	13,575
	30	9,761	11,058			12	13,967	13,575
	31	12,463	11,471			13	14,807	11,368
	32	9,118	11,471			14	14,303	11,368
	33	11,422	11,471			15	12,670	11,368
	34	13,854	12,812			16	14,110	11,774
	35	11,958	12,812			17	12,448	11,774
	36	12,700	12,812			18	12,666	11,774

4.8.2. Radyal tabanlı ANN modeli

Aşınma verileri için radyal tabanlı ağ oluşturularak eğitimleri tamamlanmıştır. Yayılma parametresi olarak [0,1] aralığı kullanılarak beş farklı ağ oluşturulmuştur. Radyal tabanlı ağın yapısı GRNN'nin yapısı ile benzerdir. İlk katmanda radyal tabanlı nöronlar bulunmaktadır. Bu nöronların transfer fonksiyonu radyal tabanlı fonksiyondur. Bu katmanda her bir alternatif ağ için, tezin kapsamında çözüm süreleri değerlendirilmeyeceğinden, maksimum 25 adet nöron bulundurulmuştur. Her gösterimde nöron sayısı birer arttırılmıştır. İkinci katmanda ise ilk


katmandan gelen aktivasyon deęerleri toplanarak çıktı üretilmiřtir. Bu katmanda lineer transfer fonksiyonu kullanılmıřtır. Aęın eęitimi sırasında MSE hedefi tüm aęlar için 0,001 olarak belirlenmiřtir. Eęitim verisinin tahmin MAPE deęeri %6-7 bandında olurken (Çizelge 4.26) en başarılı sınaama verisi tahmini, yayılma parametresi 0,7 olan aędan alınmıřtır (Çizelge 4.27). Bu aęın MAPE deęeri %9,62 olurken, R^2 deęeri %76,51 ve MSE deęeri 1,55 olarak bulunmuřtur.

Çizelge 4.26. RBF Eęitim Verisi Sonuç İstatistikleri


Eęitim Verisi		MAPE	R^2	MSE
Yayılma Katsayısı	0,1	6,63	90,97	0,77
	0,3	6,63	90,97	0,77
	0,5	6,63	90,97	0,77
	0,7*	6,63	90,97	0,77
	0,9	8,05	86,23	1,17

Çizelge 4.27. RBF Sınama Verisi Sonuç İstatistikleri

Sınama Verisi		MAPE	R^2	MSE
Yayılma Katsayısı	0,1	16,82	1,78	4,37
	0,3	11,45	66,59	2,56
	0,5	11,78	71,41	2,74
	0,7*	9,62	76,51	1,55
	0,9	10,13	76,78	1,57



Şekil 4.26. En Başarılı RBF'nin Eęitim Performansı



Şekil 4.27. En Başarılı RBF'nin Sınama Verisi Performans Grafiği

Şekil 4.26 ve 4.27'de en başarılı radyal tabanlı ağıın grafikleri verilmiştir. Ağıın tüm tahmin sonuçları Çizelge 4.28'deki gibidir.


Çizelge 4.28. En Başarılı RBF'nin Tahmin Sonuçları

	No	Gerçek Değerler	Tahmini Değerler		No	Gerçek Değerler	Tahmini Değerler
Eğitim	1	9,869	9,906	Eğitim	37	9,529	9,073
	2	10,008	9,906		38	8,486	9,073
	3	9,841	9,906		39	9,204	9,073
	4	9,801	9,109		40	9,105	9,937
	5	8,128	9,109		41	9,739	9,937
	6	9,399	9,109		42	10,968	9,937
	7	10,851	11,246		43	9,295	8,938
	8	10,704	11,246		44	7,807	8,938
	9	12,182	11,246		45	9,711	8,938
	10	10,712	9,672		46	19,494	19,012
	11	9,607	9,672		47	18,419	19,012
	12	8,697	9,672		48	19,124	19,012
	13	11,961	11,797		49	12,806	14,648
	14	12,727	11,797		50	16,052	14,648
	15	10,704	11,797		51	15,085	14,648
	16	10,840	9,967		52	15,477	17,202
	17	8,212	9,967		53	18,614	17,202
	18	10,848	9,967		54	17,514	17,202
Sınama	19	11,474	10,362	Sınama	1	10,846	8,743
	20	10,114	10,362		2	10,269	8,743
	21	9,497	10,362		3	10,889	8,743

22	12,982	12,317	4	7,901	8,713
23	11,084	12,317	5	9,467	8,713
24	12,886	12,317	6	10,124	8,713
25	8,174	9,055	7	10,883	9,766
26	9,270	9,055	8	10,071	9,766
27	9,721	9,055	9	8,496	9,766
28	11,094	10,436	10	13,843	15,068
29	10,454	10,436	11	14,186	15,068
30	9,761	10,436	12	13,967	15,068
31	12,463	11,001	13	14,807	13,062
32	9,118	11,001	14	14,303	13,062
33	11,422	11,001	15	12,670	13,062
34	13,854	12,838	16	14,110	12,642
35	11,958	12,838	17	12,448	12,642
36	12,700	12,838	18	12,666	12,642

4.8.3. İleri beslemeli geri yayımlı ANN modeli

Genelleştirilmiş regresyon ve radyal tabanlı ağlarına ek olarak ileri beslemeli geri yayımlı yapay sinir ağ yapıları oluşturulmuş ve bu ağların eğitim ve testleri tamamlanmıştır. İki farklı öğrenme algoritması; Levenberg-Marquardt (LM) ve Değişken öğrenme hızlı geri yayılım (GDX), gizli katmandaki nöron sayıları (4, 8, 12 ve 16), transfer fonksiyonları; Log-Sigmoid (logsig), Hiperbolik Tanjant Sigmoid (tansig) ve Lineer transfer fonksiyonu (purelin) kullanılarak 48 adet alternatif ağ oluşturulmuştur. Tez çalışmasında kullanılan tek gizli katmanlı ve bu katmanda dört adet nöron bulunan ileri beslemeli geri yayımlı ağ yapısı Şekil 4.28 ile verilmiştir.



Şekil 4.28. Dört Katmanlı İleri Beslemeli Geri Yayımlı Ağ Yapısı

Eğitim ve sınamaları tamamlanan 48 adet alternatif FFBP ağından alınan sonuçlar Çizelge 4.29 ve 4.30'daki gibidir.

Çizelge 4.29. FFBP'nin Eğitim Verisi Sonuç İstatistikleri

Gizli Katman Transfer Fonksiyonu	Çıktı Katmanı Transfer Fonksiyonu	Eğitim Verisi		Öğrenme Algoritması		Öğrenme Algoritması		Öğrenme Algoritması	
				LM	GDX	LM	GDX	LM	GDX
				MAPE		R ²		MSE	
Tansig	Logsig	Gizli Katmandaki Nöron Sayısı	4	6,83	6,68	90,05	90,40	0,84	0,81
			8	6,63	6,63	90,97	90,90	0,77	0,77
			12	6,63	6,63	90,97	90,97	0,77	0,77
			16	6,63	6,63	90,97	90,97	0,77	0,77
Logsig	Tansig	Gizli Katmandaki Nöron Sayısı	4	7,02	10,06	89,74	78,86	0,87	1,84
			8	6,63	10,41	90,97	72,42	0,77	2,36
			12	6,63	10,27	90,97	74,88	0,77	2,17
			16	6,63	6,91	90,97	90,51	0,77	0,84
Tansig	Tansig	Gizli Katmandaki Nöron Sayısı	4	6,64	8,10	90,97	87,09	0,77	1,11
			8	6,63	7,18	90,97	89,12	0,77	0,96
			12	6,63	6,65	90,97	90,77	0,77	0,79
			16	6,63	6,68	90,97	90,91	0,77	0,78
Logsig	Logsig	Gizli Katmandaki Nöron Sayısı	4	6,90	7,33	88,51	88,57	0,98	0,97
			8	6,63	7,48	90,97	89,30	0,77	0,91
			12	6,63	6,64	90,97	90,97	0,77	0,77
			16	6,63	6,61	90,97	90,96	0,77	0,77
Tansig	Purelin	Gizli Katmandaki Nöron Sayısı	4	7,04	7,71	89,37	88,45	0,90	0,98
			8	6,63	7,31	90,97	88,36	0,77	0,99
			12	6,63	6,88	90,97	90,17	0,77	0,83
			16	6,63	6,74	90,97	90,83	0,77	0,78
Logsig	Purelin	Gizli Katmandaki Nöron Sayısı	4	6,72	8,99	90,44	83,02	0,81	1,44
			8	6,63	8,59	90,97	83,39	0,77	1,41
			12	6,63	8,07	90,97	85,72	0,77	1,21
			16	6,63	6,94	90,97	89,82	0,77	0,86

Çizelge 4.30. FFBP'nin Sınama Verisi Sonuç İstatistikleri

Gizli Katman Transfer Fonksiyonu	Çıktı Katmanı Transfer Fonksiyonu	Sınama Verisi		Öğrenme Algoritması		Öğrenme Algoritması		Öğrenme Algoritması	
				LM	GDX	LM	GDX	LM	GDX
				MAPE		R ²		MSE	
Tansig	Logsig	Gizli Katmandaki Nöron Sayısı	4	14,83	14,35	50,20	50,76	4,22	4,07
			8	12,52	13,15	61,00	58,74	3,01	3,22
			12	9,82	8,54	53,28	79,89	2,53	1,38
			16	8,88	8,18	77,83	77,86	1,26	1,33
Logsig	Tansig	Gizli Katmandaki Nöron Sayısı	4	8,36	9,87	69,70	67,09	1,45	1,84
			8	11,16	11,63	70,63	57,91	2,70	3,20
			12	12,18	12,10	34,93	74,18	3,64	2,52
			16	11,43	10,55	74,04	70,00	2,53	1,97
Tansig	Tansig	Gizli Katmandaki Nöron Sayısı	4	13,63	10,31	74,35	56,22	3,47	2,38
			8	12,11	14,63	82,30	42,05	2,62	4,41
			12	17,75	10,27	63,25	43,64	7,22	3,14
			16	15,90	17,25	57,36	60,67	4,41	5,90
Logsig	Logsig	Gizli Katmandaki Nöron Sayısı	4	15,58	12,24	38,91	49,96	5,33	3,10
			8	9,38	9,35	74,43	71,56	1,69	1,56
			12	9,06	13,84	76,04	67,94	1,49	3,71
			16	9,25	13,14	60,11	75,04	2,00	4,53
Tansig	Purelin	Gizli Katmandaki Nöron Sayısı	4	41,39	10,12	40,26	58,64	34,90	1,95
			8	9,62	11,01	64,95	66,85	1,59	2,27
			12	8,90	8,96	63,21	48,95	1,72	2,53
			16	10,53	12,24	72,57	64,44	2,36	2,99
Logsig	Purelin	Gizli Katmandaki Nöron Sayısı	4	16,53	12,97	50,02	69,23	5,68	3,27
			8	14,36	12,19	60,57	58,76	3,86	3,61
			12	9,78	12,07	71,75	44,17	1,96	2,71
			16	9,93	13,04	53,04	36,22	2,35	3,72

Eğitim verisi tahminlerinin MAPE değeri %6-8 aralığında olurken, sınama verisi için alternatif 48 ağın MAPE değerleri %8-17 aralığında yoğunlaşmıştır. Çizelge 4.31, 4.32 ve 4.33'de sınama verisi sonuçlarının belirli parametreleri değiştirilip diğer parametrelerinin performans ortalamaları alınarak oluşturulan özet bilgiler bulunmaktadır. Çizelge 4.31 incelendiğinde görülecektir ki; diğer parametreler sabit tutulduğunda nöron sayısının artışı ağ performansını olumlu yönde etkilemiştir. Dördün üzerindeki nöron sayılarında MAPE, R² ve MSE değerlerinin üçü de iyileşmiştir. En iyi MAPE değeri 12 nöron sayısı ile elde edilirken, en iyi R² değeri 16 nöron ile ve en iyi MSE değeri 8 nörona sahip ağ ile elde edilmiştir.

Çizelge 4.31. Nöron Sayılarına Göre FFBP Ağının Performansı

Nöron Sayıları	MAPE	R ²	MSE
4	15,01	56,28	5,97
8	11,76	64,15	2,81
12	11,11	60,10	2,88
16	11,69	64,93	2,94

Çizelge 4.32 incelendiğinde; değişken öğrenme hızlı öğrenme algoritmasının MAPE ve MSE performans kriterleri baz alındığında Levenberg-Marquardt öğrenme algoritmasından daha başarılı olduğu görülmektedir. R² değeri göz önünde bulundurulduğunda Levenberg-Marquardt öğrenmesinin daha başarılı bir sonuç verdiği görülmüştür.

Çizelge 4.32. Eğitim Algoritmasına Göre FFBP Ağının Performansı

	MAPE	R ²	MSE
GDX	11,75	60,45	2,97
LM	13,04	62,28	4,33

Çizelge 4.33 incelendiğinde görülmüştür ki; logsig-tansig transfer fonksiyonu sırasıyla girdi ve çıktı katmanlarında kullanıldığında her üç ölçüt için de en başarılı sonuçlar elde edilmiştir. Girdi ve çıktı katmanı ayrı ayrı değerlendirildiğinde; Log-sigmoid transfer fonksiyonu, Lineer ve Tanjant Sigmoid transfer fonksiyonlarına kıyasla daha başarılı performans sergilemiştir.

Çizelge 4.33. Transfer Fonksiyonlarına Göre FFBP Ağının Performansı

Gizli Katman Transfer Fonksiyonu	Çıktı Katmanı Transfer Fonksiyonu	MAPE	R ²	MSE
Tansig	Logsig	11,28	63,70	2,63
Logsig	Tansig	10,91	64,81	2,48
Tansig	Tansig	13,98	59,98	4,19
Logsig	Logsig	11,48	64,25	2,93
Tansig	Purelin	14,09	59,99	6,29
Logsig	Purelin	12,61	55,47	3,39


En başarılı FFBP ağının seçimi için tez çalışmasında iki adım uygulanmıştır. Öncelikle en başarılı beş ağ seçilmiş daha sonrasında bu ağların arasından en doğru tahmin performansına sahip ağa karar verilmiştir. Tüm alternatifler MAPE, R² ve MSE performans kriterleri açısından

değerlendirilmiştir. Bu üç kriter için ağlar en başarılıdan en az başarılıya doğru sıralanmıştır. Kriterlerin en az ikisinden en iyi beş ağda yer almayan alternatifler elenmiş olup 48 ağdan geriye beş farklı alternatif ağ kalmıştır bunlar Çizelge 4.34’de verilmiştir.

Çizelge 4.34. En Başarılı Beş FFBP Ağı

Alternatifler	MAPE	R ²	MSE
A1	8,54	79,89	1,38
A2	8,88	77,83	1,26
A3*	8,18	77,86	1,33
A4	8,36	69,70	1,45
A5	9,06	76,04	1,49

MAPE kriterine göre Alternatif 3 en başarılı ağ, Alternatif 4 onu takip eden ikinci başarılı ağ; R² kriterine göre Alternatif 1 en başarılı ağ, Alternatif 3 onu takip eden ikinci başarılı ağ; MSE kriterine göre ise Alternatif 2 en başarılı ağ, Alternatif 3 onu takip eden ikinci başarılı ağ olmuştur. Her üç kriterde de yüksek performans göstermesi ve tez kapsamında MAPE kriterinin daha öncelikli dikkate alınacak bir kriter olması nedeniyle alternatif ağlar arasından Alternatif 3 (A3) ağı en başarılı FFBP ağı olarak seçilmiştir. A3 ağının gizli katmanında tansig, çıktı katmanında ise logsig transfer fonksiyonu kullanılmıştır. Ağda tek gizli katman bulunmakta olup bu katmanda bulunan nöron sayısı 16’dır. Öğrenme algoritması GDX’dir. Ağın test sonuç grafiği Şekil 4.29’da, eğitim ve sınama tahmin sonuçları ise Çizelge 4.35’de verilmiştir.



Şekil 4.29. A3 Ağının Sınama Verisi Performans Grafiği

Çizelge 4.35. A3 Ağının Tahmin Sonuçları

	No	Gerçek Değerler	Tahmini Değerler		No	Gerçek Değerler	Tahmini Değerler	
Eğitim	1	9,869	9,909	Eğitim	37	9,529	9,131	
	2	10,008	9,909		38	8,486	9,131	
	3	9,841	9,909		39	9,204	9,131	
	4	9,801	9,107		40	9,105	9,937	
	5	8,128	9,107		41	9,739	9,937	
	6	9,399	9,107		42	10,968	9,937	
	7	10,851	11,244		43	9,295	8,862	
	8	10,704	11,244		44	7,807	8,862	
	9	12,182	11,244		45	9,711	8,862	
	10	10,712	9,672		46	19,494	18,977	
	11	9,607	9,672		47	18,419	18,977	
	12	8,697	9,672		48	19,124	18,977	
	13	11,961	11,794		49	12,806	14,641	
	14	12,727	11,794		50	16,052	14,641	
	15	10,704	11,794		51	15,085	14,641	
	16	10,840	9,965		52	15,477	17,225	
	17	8,212	9,965		53	18,614	17,225	
	18	10,848	9,965		54	17,514	17,225	
	19	11,474	10,361		Sınama	1	10,846	11,270
	20	10,114	10,361			2	10,269	11,270
	21	9,497	10,361			3	10,889	11,270
	22	12,982	12,319			4	7,901	9,444
	23	11,084	12,319			5	9,467	9,444
	24	12,886	12,319			6	10,124	9,444
	25	8,174	9,059			7	10,883	9,619
	26	9,270	9,059			8	10,071	9,619
	27	9,721	9,059			9	8,496	9,619
	28	11,094	10,445			10	13,843	16,006
	29	10,454	10,445			11	14,186	16,006
	30	9,761	10,445			12	13,967	16,006
	31	12,463	11,007			13	14,807	13,820
	32	9,118	11,007			14	14,303	13,820
	33	11,422	11,007			15	12,670	13,820
	34	13,854	12,830			16	14,110	12,685
	35	11,958	12,830			17	12,448	12,685
	36	12,700	12,830			18	12,666	12,685

İleri beslemeli geri yayımlı ağlar, eğitimin başlangıcında nöronlar arası ağırlıkları rassal bir şekilde belirleyip eğitimin tamamlanmasına kadar bu değerleri verilen çıktıya uyum sağlaması için güncellemektedir. Dolayısıyla eğitim için yazılan matlab kodu her bir çalıştırılışında farklı sonuçlar elde edilmektedir. Oluşacak belirsizliğin önüne geçmek amacıyla ağların eğitimleri tamamlanıp test verileri için sonuçlar alındığında yanlılık ve ağırlıklar matlab çalışma alanına kaydedilmiştir. Buna göre Alternatif 3'ün eğitim sonucunda güncellenmiş yanlılık ve ağırlıkları Çizelge 4.36'da verilmiştir.

Çizelge 4.36. A3'ün Yanlılık ve Ağırlıkları

Gizli Katman Yanlılık	Çıktı Katmanı Yanlılık	Girdi-Gizli Katman Arası Ağırlıklar			Gizli-Çıktı Katman Arası Ağırlıklar
-3,253722101	-1,633203171	5,021809949	0,532252039	-5,142661768	-0,119749736
0,789284507		1,329093776	-6,596155462	-2,075778359	-0,203346223
0,078132128		-4,195712907	3,904799357	4,067544963	-0,199779912
-0,983836855		-3,900450663	4,201555291	4,169599494	0,705600335
-2,881983224		4,007495301	2,473462165	-5,045240475	0,429597946
6,59520849		-6,714232457	-2,200644744	-0,729008374	1,968534603
-1,930205738		0,394842564	7,317007081	1,758140384	-0,384857829
3,948285731		-7,137385414	0,068399995	-2,189373301	-1,226758779
-5,077173245		5,357316388	4,851272836	1,359017886	-1,065775882
-5,519966786		5,510455039	2,94400161	3,702286419	2,059862805
0,142142268		-0,214076998	5,609397061	-4,186910608	0,097930691
4,406880803		-2,164377564	-3,548477559	-5,519448804	0,820012577
3,178622704		-4,741230216	-0,764413366	-5,18991684	0,323127051
-2,874072119		2,110625862	4,12381832	5,600693977	1,735918062
3,07126614		-4,561514772	-4,171095055	-3,331510959	0,216704146
3,055419403		-4,400673554	-3,492173974	-4,071359081	1,239559976

A3 ağıının geçerlilik kontrolü için ağıın eğitiminde kullanılan 54 adet eğitim seti yardımıyla k katlamalı çapraz doğrulama yapılmıştır. Her grupta dokuz veri olacak şekilde veri seti rassal olarak altı gruba ayrılmıştır. Her grup birer kere seçilmiş olup, kalan beş grup ile ağıın eğitimleri gerçekleştirilmiş ve seçilen grup sınama seti olarak kullanılmıştır. Elde edilen sonuçlar Çizelge 4.37'de verilmiştir.

Çizelge 4.37. Çapraz Doğrulama Sonuçları

Sınama Seti	1. Grup	2. Grup	3. Grup	4. Grup	5. Grup	6. Grup	Ortalama
MAPE	8,52	12,19	12,47	7,66	10,19	8,63	9,94
R ²	95,17	86,74	81,22	53	42,58	63,39	70,35
MSE	1,06	2,58	2,68	0,95	1,70	1,38	1,72

Çapraz doğrulama sonuçlarına göre ağıın MAPE, R² ve MSE değerleri sırasıyla 9,94, 70,35 ve 1,72 olarak bulunmuştur. A3 ağı için, dışarıda tutma yöntemine göre çapraz doğrulamada daha başarısız sonuçlar alınmıştır. Bunun en önemli sebebi, eğitim dışarıda tutma yönteminde 54 adet veri ile yapılırken, çapraz doğrulamada 45 adet veri ile yapılmasıdır. Ayrıca eğitim seti CCD tasarımı ile oluşturulduğundan α noktalar içermektedir. Bu noktalar faktöriyel noktaların dışında yer aldığından tahmin edilmesi faktöriyel noktalara göre daha zordur.

4.8.4. ANN tahmin modelleri performans karşılaştırması

RBF, GRNN ve FFBP ağlarının tahmin gücü açısından karşılaştırılması için ağların farklı alternatiflerinin sonuçlarının ortalaması alınarak Çizelge 4.38’de verilmiştir.

Çizelge 4.38. Yapay Sinir Ağlarının Performans Ortalamaları

	MAPE	R ²	MSE
GRNN	12,62	59,06	3,64
RBF	11,96	58,61	2,56
FFBP	12,39	61,36	3,65

Buna göre MAPE ölçütüne göre en başarılı ağ radyal tabanlı ağ olurken en başarısız ağ genelleştirilmiş regresyon olmuştur. İleri beslemeli geri yayımlı ağın sonuçlarında görülen uç değerler de ortalamaya dahil edildiğinden, ağın başarısı radyal tabanlı ağın gerisinde kalmıştır. MSE ölçütüne göre radyal tabanlı ağ en başarılı tahminde bulunan ağ olurken diğer iki ağ hemen hemen birbirleriyle aynı sonucu vermişlerdir. R² ölçütü için de %61,36 değeri ile ileri beslemeli geri yayımlı ağ en başarılı ağ olmuştur. Her bir ağın ayrı ayrı performansları karşılaştırıldığında (57 alternatif ağın arasında) en başarılı ağ ileri beslemeli geri yayımlı ağ (A3) olarak bulunmuştur. Bu ağın tahmin performansı ile RSM modelinin tahmin performansı karşılaştırılarak en başarılı performansa sahip metot tespit edilmiştir.

4.8.5. RSM-ANN tahmin performanslarının karşılaştırılması

RSM modelinin tahmin sonuçları Design Expert 11 programı kullanılarak elde edilmiş ve Çizelge 4.39’da verilmiştir. Regresyon denkleminde faktörler kodlanmış seviyeleri ile alındığından sınama setindeki faktör seviyeleri kodlanmış seviyelere dönüştürülmüştür.

Çizelge 4.39. Sınama Setinin RSM Tahmini Sonuçları

No	Cam Oranı (%)	Karbür Oranı (%)	Katkı Büyüklüğü (μ)	RSM Aşınma Oranı Tahmini (%)
1	0,707	-0,141	-1	9,107
2	0,707	-0,141	-1	9,107
3	0,707	-0,141	-1	9,107
4	0,283	-0,424	-1	8,915
5	0,283	-0,424	-1	8,915
6	0,283	-0,424	-1	8,915
7	-0,424	0,283	-1	9,786
8	-0,424	0,283	-1	9,786
9	-0,424	0,283	-1	9,786
10	-0,566	0,849	1	15,277
11	-0,566	0,849	1	15,277
12	-0,566	0,849	1	15,277
13	-0,99	0,141	1	13,969

14	-0,99	0,141	1	13,969
15	-0,99	0,141	1	13,969
16	0,849	-0,849	1	13,735
17	0,849	-0,849	1	13,735
18	0,849	-0,849	1	13,735

Bu tahmini deęerler gözlemlenen veriler ile karşılaştırılarak RSM modelinin MAPE, MSE ve R^2 istatistikleri elde edilmiştir. En başarılı yapay sinir ağı ile RSM modelinin karşılaştırmalı sonuçları Çizelge 4.40 ile verilmiştir. Buna göre MAPE kriterinde ANN başarılı olurken dięer iki kriterde RSM modeli daha başarılı olmuştur. RSM modelinin bu kadar rekabetçi olmasının nedeni yüksek dereceden (4. derece) modelin kullanılmış olmasıdır. Ancak bunun bir dezavantajı olmuştur. Yüksek dereceden terimler modelde yer aldığından faktör etkilerinin yorumlanması karmaşık hale gelmiştir. Bunun dışında ANN'nin tahmin gücü daha yüksek sayıda eğitim verisi kullanılarak arttırılabilir. Her iki tahmin metodu da %10 MAPE seviyesinin altında sonuç vererek Witt ve Witt'in (1992) ölçülendirmesi ile yüksek doğruluk dereceli tahmin modeli olmuşlardır. Beklenildięi gibi eğitim sonuçları sınama sonuçlarından daha başarılı olmuştur. Eğitim verisinde, üç kriter için de ANN'nin başarısı RSM modeline kıyasla daha yüksek olduğundan ANN'nin daha iyi bir öğrenme gerçekleştirdięi söylenilebilir. Bir dięer nokta ise aşınma modelinde elde edilen R^2_{tah} (%81,08) deęeri ile sınama verisi tahmininde elde edilen R^2 (%81,13) deęerlerinin birbirlerine oldukça yakın olarak bulunmasıdır.

Çizelge 4.40. Tahmin Modellerinin Sonuç İstatistikleri

Veri Seti	MAPE	R^2	MSE
RSM Eğitim	6,980	89,807	0,865
RSM Sınama	9,420	81,131	1,317
ANN Eğitim	6,633	90,965	0,767
ANN Sınama	8,183	77,860	1,333

5. SONUÇLAR ve DEĞERLENDİRME

Tez çalışmasında epoksi kompozit malzemesinin aşınma ve sertlik gibi mekanik özelliklerinin RSM ve ANN teknikleriyle tahmin edilmesi ve optimizasyonu yapılmıştır. Cam ve karbür katkıları ile malzemenin aşınma ve sertlik gibi mekanik özellikleri geliştirilmeye çalışılmıştır. RSM yaklaşımında CCD deney tasarımı ile oluşturulan noktalarda üretilen numunelerin aşınma ve sertlik tahmin modeli oluşturulmuştur. Malzemenin üretim maliyeti hesaplamaları yapılmış ve bir RSM modeli oluşturularak çoklu tepki optimizasyonu (mekanik özellikler ve maliyet) çalışması yapılmıştır. Her bir tepkiyi eniyileyen noktalar belirlenmiştir. Üç tepkinin birlikte değerlendirilerek optimizasyonunun yapılması için çoklu tepki optimizasyonu yöntemi kullanılmıştır. Optimal noktaların bulunmasının ardından yapay sinir ağları ile aşınma tahmininde kullanılan RSM modelinin aşınma tahmin model performansları karşılaştırılmış ve en başarılı metod seçilmiştir. Öncelikli olarak RSM modelleri oluşturulmuştur. Faktör etkileri ve etkileşimleri bulunmuş ve önemli bulunan terimler ile regresyon denklemleri oluşturulmuştur. Oluşturulan izdüşüm grafikleri ile aşınma ve sertlik tepkileri için optimum noktalar belirlenmiştir. Model istatistikleri incelenmiş ve modellerin tahmin gücü ve hata değerleri hesaplanmıştır. Üretim maliyetleri hesaplanmış ve bu üç tepkinin önem seviyeleri değiştirilerek farklı senaryolar oluşturulmuştur. Çoklu tepki optimizasyonunun farklı senaryoları için optimum üretim noktaları belirlenmiştir.

Design Expert 11 programı kullanılarak yapılan analiz sonuçlarına göre; aşınma ve sertlik tepki değişkenleri için cam oranı ve parçacık büyüklüğü faktörleri aşınma ve sertlik üzerinde etkili olurken, karbür oranı istatistiksel olarak önemsiz bulunmuştur. Aşınma modelinde karbür faktörünün p anlamlılık değeri 0,05'e oldukça yakın olduğundan model hiyerarşisini korumak amacıyla modelden çıkartılmamıştır. Sertlik modelinde karbür oranı faktörü istatistiksel olarak anlamsız bulunarak modelden çıkartılmıştır. Ana etkiler incelendiğinde (parçacık büyüklüklerinin ortalama tepki değerleri dikkate alınır), aşınma tepki değişkeni için cam oranının ve karbür oranındaki artışın aşınmayı azalttığı görülmüştür. Sertlik tepki değişkeni için de cam oranının artması sertlik değerini artırırken karbür oranındaki değişimlerin sertlik değişkeni üzerinde bir etkisinin olmadığı görülmüştür. Parçacık büyüklüğünde ise, büyük parçacıkların katkı olarak kullanılması (50-75 mikron) daha yüksek seviyede malzeme aşınmasına sebep olmuştur. Faktör etkileşimleri incelendiğinde, en düşük aşınma değerinin, katkıların ikisinin birden en düşük veya en yüksek olduğu noktada elde edildiği görülmüştür. En yüksek sertlik değeri de yine cam ve karbür katkısının en düşük veya

en yüksek olduğu noktada elde edilmiştir. Aşınma oranı ile sertlik arasında ters korelasyon olduğu da bu şekilde görülmüştür.

Modellerin tahmin başarılarının karşılaştırılması amacıyla farklı özelliklere sahip 57 adet ANN tasarımı oluşturulmuştur. Bu yapay sinir ağları, RSM modelinde kullanılmış olan 54 adet veri ile eğitilmiştir. Eğitimi tamamlanan ağları ve RSM modelini test etmek için bağımsız bir sına seti oluşturulmuş ve yapılan testler ile aşınma değerleri elde edilmiştir. Gözlemlenen sonuçlar ile tahmini sonuçlar karşılaştırılarak MAPE, R^2 ve MSE tanımlayıcı istatistikleri ile yapay sinir ağlarının başarıları ölçülmüştür. Öncelikle alternatif ağlar arasında en başarılı tahmini yapan ağ (ileri beslemeli geri yayımlı ağ) belirlenmiştir. Sonrasında bu ağ ile RSM modeli karşılaştırılmıştır. MAPE tanımlayıcı istatistiğine göre yapay sinir ağları ile daha başarılı sonuç elde edilmiştir. Diğer iki tanımlayıcı istatistik (R^2 ve MSE) için RSM modeli daha iyi sonuç vermiştir. Tez kapsamında öncelikli olarak MAPE metriği dikkate alındığından ANN'nin RSM'ye göre daha başarılı olduğu görülmüştür. RSM modelinin de oldukça iyi derecede tahmin performansı gösterdiği belirlenmiştir. RSM modelinin bu denli başarılı performans göstermesinin nedeni; yüksek dereceden terimlerin modelde kullanılmış olmasıdır. Bu sayede RSM modeli, sistemdeki eğrilikleri ve kompleks yapıyı daha rahat tahmin edebilmiştir. Ancak yüksek dereceden model kullanımının dezavantajı; faktörlerin tepki üzerindeki etkilerinin yorumlanmasını güçleştirmesidir. Bununla beraber ANN'nin daha iyi performans göstermesi için eğitim veri setindeki veri sayısı arttırılmalıdır. Yapay sinir ağ alternatifleri arasında; ileri beslemeli ağlarda %10 MAPE değerinin altında çok sayıda alternatif ağ bulunmuştur. Genelleştirilmiş regresyon ve radyal tabanlı ağ alternatiflerinde hata oranı genellikle %10'dan büyük olduğundan ağlar başarısız olarak kabul edilmiştir. İleri beslemeli ağ alternatiflerinde çok farklı parametreler denendiğinden tahmin hatalarının standart sapması da yüksek olmuştur. Bu nedenle ağların hata ortalamaları alındığında; ileri beslemeli ağın değil radyal tabanlı ağ tasarımının en başarılı sonuçlara sahip olduğu görülmüştür.

Tez kapsamında geliştirilen modeller için bulunan optimum noktalar çoğunlukla tasarımın kenar veya köşe noktalarında elde edilmiştir. Bu da global optimumların tasarım noktasının dışında olabileceğini göstermektedir. Bu noktaları gözardı etmemek amacıyla farklı veya daha geniş aralıklarda RSM yaklaşımının uygulanması ileriki çalışmalarda dikkat edilmesi gereken bir konudur. Tez kapsamında abrasif aşınma testleri, TNKÜ Çorlu Mühendislik Fakültesi Makine Mühendisliği laboratuvarında bulunan torna tezgâhı olarak kullanılan tezgâhın modifiye edilmesiyle elde edilen cihazda gerçekleştirilmiştir. Kalibrasyonlu ve sertifikalı bir cihaz kullanılamaması, tez sonuçlarının literatürde yapılan çalışmaların

sonularıyla kıyaslanmasını zorlařtırmıřtır. Numunelerin üretiminde karıřımlar hazırlandıktan sonra kalıplara dökülmeden karıřımlar belirli aralıklarla karıřtırılmıřtır. İleriki alıřmalarda daha homojenik bir biimde karıřımların hazırlanması iin, endüstriyel karıřtırıcıların kullanılması önem arz etmektedir.

6. KAYNAKLAR

- Agarwal G, Patnaik O, Sharma RK (2013). Thermo-mechanical properties of silicon carbide-filled chopped glass fiber-reinforced epoxy composites. *International Journal of Advanced Structural Engineering*.
- Agbeleye AA, Esezobor DE, Agunsoye JO, Balogun SA, Sosimi AA (2018). Prediction of the abrasive wear behaviour of heat-treated aluminium-clay composites using an artificial neural network, *Journal of Taibah University for Science*, 12: 235-240.
- Al-Mahasneh AJ, Anavatti SG, Garratt MA (2018). Review of Applications of Generalized Regression Neural Networks in Identification and Control of Dynamic Systems. *School of Engineering and Information Technology*.
- Anderson, M, Whitcomb, P (2000). DOE Simplified. Productivity Inc. https://www.statease.com/media/productattachments/files/e/d/edme7_one-factor_tut.pdf erişim tarihi 11.12.2018)
- Anonim (2018). R kare ve düzeltilmiş r kare. <http://www.datascience.istanbul/2017/07/11/r-kare-ve-duzeltilmis-r-kare/> (erişim tarihi 28.3.2018).
- Anonim (2018). Central Composite Designs. <https://www.itl.nist.gov/div898/handbook/pri/section3/pri3361.htm> (erişim tarihi 1.4.2018).
- Anonim (2018). Epoksi kullanım alanları. <http://www.niseboya.com.tr/yazilar/epoksi-kullanim-alanlari/> (erişim tarihi 2.4.2018).
- Anonim (2018). Recurrent neural network tutorial. <http://www.wildml.com/2015/09/recurrent-neural-networks-tutorial-part-1-introduction-to-rnns/> (erişim tarihi 22.10.2018).
- Anonim (2018). Artificial Neural Networks <http://osp.mans.edu.eg/rehan/ann/Artificial%20Neural%20Networks.htm> (erişim tarihi 04.10.2018).
- Anonim (2018). Coefficient of determination. <https://www.statisticshowto.datasciencecentral.com/probability-and-statistics/coefficient-of-determination-r-squared/> (erişim tarihi 11.12.2018).
- Anonim (2019). Ferrokrom. <http://www.altinkumdokum.com/tr/urun/Ferrokrom> (erişim tarihi 23.3.2019).
- Baldi P (1995). Gradient descent learning algorithm overview: A general dynamical systems perspective. *IEEE Transactions on Neural Networks*, 6: 182-195.
- Basavarajappa S, Yadav SM, Kumar S, Arun KV, Narendranath, S (2011). Abrasive Wear Behavior of Granite-Filled Glass-Epoxy Composites by SiC Particles Using Statistical Analysis. *Polymer-Plastics Technology and Engineering*, 50: 516-524.
- Bagci M, Imrek H (2013). Application of Taguchi method on optimization of testing parameters for erosion of glass fiber reinforced epoxy composite materials. *Materials & Design*, 46: 706-712.
- Bezerra E, Ancelotti A, Pardini L, Rocco J, Iha, K, Ribeiro C (2007). Artificial neural networks applied to epoxy composites reinforced with carbon and E-glass fibers: Analysis of the shear mechanical properties. *Materials Science and Engineering: A*, 464: 177-185.

- Bezerra MA, Santelli RE, Oliveira EP, Villar LS, Escalera LA (2008). Response surface methodology (RSM) as a tool for optimization in analytical chemistry. *Talanta*, 76: 965-977.
- Bishop CM (1995). *Neural Networks for Pattern Recognition*. Oxford University Press, Oxford.
- Biswas S, Satapathy A (2010). A Study on Tribological Behavior of Alumina-Filled Glass–Epoxy Composites Using Taguchi Experimental Design. *Tribology Transactions*, 53: 520-532.
- Blanca M, Alarcon R, Arnau J, Bono R, Bendayan R (2017). Non-normal data: Is ANOVA still a valid option? *Psicothema*, 29: 552-557.
- Bonner WH (1962). Aromatic polyketones and preparation thereof. U.S. Patent Specification.
- Briscoe B, Pogolian A, Tabor D (1974). The friction and wear of high density polythene: The action of lead oxide and copper oxide fillers. *Wear*, 27: 19-34.
- Burnham KP, Anderson DR (2004). Multimodel Inference. *Sociological Methods & Research*, 33: 261-304.
- Carley KM, Kamneva NY, Reminga J (2004). *Response Surface Methodology*.
- Chandra Rao CH, Madhusudan S, Raghavendra G, Venkateswara Rao E (2012). Investigation in to Wear behavior of coir Fiber Reinforced Epoxy Composites with the Taguchi Method. *International Journal of Engineering Research and Applications*, 2: 371-374.
- Diler EA, Ipek R (2013). Main and interaction effects of matrix particle size, reinforcement particle size and volume fraction on wear characteristics of Al–SiCp composites using central composite design. *Composites Part B: Engineering*, 50: 371-380.
- Dorraj MS, Rasoulifard M, Amani-Ghadim A, Khodabandloo M, Felekari M, Khoshrou M, Hajimiri I (2016). Microwave absorption properties of polypyrrole-SrFe₁₂O₁₉-TiO₂ - epoxy resin nanocomposites: Optimization using response surface methodology. *Applied Surface Science*, 383: 9-18.
- Drew PJ, Monson JRT (2000). Artificial neural networks. *Surgery*, 127: 3-11.
- Er MJ, Wu S, Lu J, Toh HL (2002). Face recognition with radial basis function (RBF) neural networks. *IEEE Transactions on Neural Networks*, 13: 697-710.
- Feir-Walsh BJ, Toothaker LE (1974). An Empirical Comparison of the Anova F-Test, Normal Scores Test and Kruskal-Wallis Test Under Violation of Assumptions. *Educational and Psychological Measurement*, 34: 789-799.
- Franke GR (2010). *Multicollinearity*. Wiley International Encyclopedia of Marketing.
- Ghasemi A, Zahediasl S (2012). Normality Tests for Statistical Analysis: A Guide for Non-Statisticians. *Int J Endocrinol Metab*, 10: 486-489.
- Graupe D (2013). *Principles of artificial neural networks*. World Scientific Publ, Singapur.
- Gyurova LA, Miniño-Justel P, Schlarb AK (2010). Modeling the sliding wear and friction properties of polyphenylene sulfide composites using artificial neural networks. *Wear*, 268: 708-714.
- Haykin S (1998). *Neural networks: A comprehensive foundation*. Macmillan, New York.

- Hyndman RJ, Koehler AB (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22: 679-688.
- Jain AK, Mao J (1996). Artificial neural networks: a tutorial. *Computer*, 29: 31-44.
- Jang J, Sun C (1993). Functional equivalence between radial basis function networks and fuzzy inference systems. *IEEE Transactions on Neural Networks*, 4: 156-159.
- Karlık B, Olgaç AV (2001). Performance Analysis of Various Activation Functions in Generalized MLP Architectures of Neural Networks. *International Journal of Artificial Intelligence And Expert Systems*, 1: 111-122.
- Khuri AI, Mukhopadhyay S (2010). Response surface methodology. *Wiley Interdisciplinary Reviews: Computational Statistics*, 2: 128-149.
- Kumar PS, Maniseka K, Narayanasamy R (2014). Experimental and Prediction of Abrasive Wear Behavior of Sintered Cu-SiC Composites Containing Graphite by Using Artificial Neural Networks. *Tribology Transactions*, 57: 455-471.
- Lakshminarayanan A, Balasubramanian V (2008). Comparison of RSM with ANN in predicting tensile strength of friction stir welded AA7039 aluminium alloy joints. *Transactions of Nonferrous Metals Society of China*, 19: 9-18.
- Levy KJ (1978). An empirical comparison of the ANOVAF-test with alternatives which are more robust against heterogeneity of variance. *Journal of Statistical Computation and Simulation*, 8: 49-57.
- Marquis DM, Guillaume E, Chivas-Joly C (2011). Properties of Nanofillers in Polymer, Nanocomposites and Polymers with Analytical Methods, Dr. John Cuppoletti (Ed.), InTech, <http://www.intechopen.com/books/nanocomposites-and-polymers-with-analyticalmethods/properties-of-nanofillers-in-polymer> (Erişim tarihi 2018)
- Masters T (1995). *Advanced Algorithms for Neural Networks: A C++ Sourcebook*. John Wiley & Sons, New York.
- Mirmohseni A, Zavareh S (2010). Modeling and optimization of a new impact-toughened epoxy nanocomposite using response surface methodology. *Journal of Polymer Research*, 18: 509-517.
- Mohan N, Natarajan S, Kumareshbabu S (2011). Abrasive wear behaviour of hard powders filled glass fabric–epoxy hybrid composites. *Materials & Design*, 32: 1704-1709.
- Montgomery DC (2001). *Design and Analysis of Experiment*. John Wiley and Sons Inc, 12-13, ABD.
- Öztemel E (2012). *Yapay sinir ağları*. Papatya yayıncılık, İstanbul.
- Padhi PK, Satapathy A (2014). Solid Particle Erosion Behavior of BFS-Filled Epoxy–SGF Composites Using Taguchis Experimental Design and ANN. *Tribology Transactions*, 57: 396-407.
- Priddy KL, Keller PE (2005). *Artificial neural networks: An introduction*. SPIE Press, ABD.
- Purohit A, Satapathy A (2017). Processing, characterization, and parametric analysis of erosion behavior of epoxy-LD sludge composites using Taguchi technique and response surface method. *Polymer Composites*, 39.

- Quaiser T, Dittrich A, Schaper F, Mönnigmann M (2011). A simple work flow for biologically inspired model reduction - application to early JAK-STAT signaling. *BMC Systems Biology*, 5: 30.
- Rajesh S, Rajakarunakaran S, Pandian RS (2012). Modeling And Optimization Of Sliding Specific Wear And Coefficient Of Friction Of Aluminum Based Red Mud Metal Matrix Composite Using Taguchi Method And Response Surface Methodology, *Materials Physics and Mechanics*, 150-166.
- Ramesh B, Suresha B (2014). Optimization of tribological parameters in abrasive wear mode of carbon-epoxy hybrid composites. *Materials & Design*, 59: 38-49.
- Rao SK, Varadarajan YS, Rajendra N (2014). Artificial neural network approach for the prediction of abrasive wear behaviour of carbon fabric reinforced epoxy composite. *Indian Journal of Engineering and Material Science*, 21: 16-22.
- Rashmi, Renukappa NM, Suresha B, Devarajaiah R, Shivakumar K (2011). Dry sliding wear behaviour of organo-modified montmorillonite filled epoxy nanocomposites using Taguchi's techniques. *Materials & Design*, 32: 4528-4536.
- Rostamiyan Y, Mashhadzadeh AH, Salmankhani A (2014). Optimization of mechanical properties of epoxy-based hybrid nanocomposite: Effect of using nano silica and high-impact polystyrene by mixture design approach. *Materials & Design (1980-2015)*, 56: 1068-1077.
- Rostamiyan Y, Fereidoon A, Ghalebahman AG, Mashhadzadeh AH, Salmankhani A (2015a). Experimental study and optimization of damping properties of epoxy-based nanocomposite: Effect of using nanosilica and high-impact polystyrene by mixture design approach. *Materials & Design (1980-2015)*, 65: 1236-1244.
- Rostamiyan Y, Fereidoon A, Rezaeiashtiyani M, Mashhadzadeh AH, Salmankhani A (2015b). Experimental and optimizing flexural strength of epoxy-based nanocomposite: Effect of using nano silica and nano clay by using response surface design methodology. *Materials & Design*, 69: 96-104.
- Rothon RN (1997). Mineral Fillers in Thermoplastics: Filler Manufacture. *Journal of Adhesion*, 64: 87-109.
- Rout A, Satapathy A (2012). Analysis of Dry Sliding Wear Behaviour of Rice Husk Filled Epoxy Composites Using Design of Experiment and ANN. *Procedia Engineering*, 38: 1218-1232.
- Satyanarayana G, Naidu GS, Babu NH (2018). Artificial neural network and regression modelling to study the effect of reinforcement and deformation on volumetric wear of red mud nano particle reinforced aluminium matrix composites synthesized by stir casting. *Boletín De La Sociedad Española De Cerámica Y Vidrio*, 57: 91-100.
- Sharma P, Khanduja D, Sharma S (2016). Dry sliding wear investigation of Al6082/Gr metal matrix composites by response surface methodology. *Journal of Materials Research and Technology*, 5: 29-36.
- Siddhartha S, Patnaik A, Bhatt AD (2011). Mechanical and dry sliding wear characterization of epoxy-TiO₂ particulate filled functionally graded composites materials using Taguchi design of experiment. *Materials & Design*, 32: 615-627.

- Singh BK, Verma K, Thoke A (2015). Adaptive Gradient Descent Backpropagation for Classification of Breast Tumors in Ultrasound Imaging. *Procedia Computer Science*, 46: 1601-1609.
- Suresha B, Chandramohan G, Prakash JN, Balusamy V, Sankaranarayanan K (2006). The Role of Fillers on Friction and Slide Wear Characteristics in Glass-Epoxy Composite Systems. *Journal of Minerals and Materials Characterization and Engineering*, 5: 87-101.
- Tanyildizi MS, Özer D, Elibol M (2005). Optimization of α -amylase production by *Bacillus* sp. using response surface methodology. *Process Biochemistry*, 40; 2291-2296.
- Tu JV (1996). Advantages and disadvantages of using artificial neural networks versus logistic regression for predicting medical outcomes. *Journal of Clinical Epidemiology*, 49: 1225-1231.
- Witt SF, Witt CA (1992). Modeling and forecasting demand in tourism. Academic, Londra.
- Wu TL, Shen BK (2016). Feedback based Neural Networks. https://web.stanford.edu/class/cs331b/2016/projects/wu_shen.pdf (erişim tarihi: 19.10.2018).
- Yılmaz O (2001). Abrasive wear of FeCr (M7C3–M23C6) reinforced iron based metal matrix composites. *Materials Science and Technology*, 17: 1285-1292.
- Youssefi S, Emam-Djomeh Z, Mousavi SM (2009). Comparison of Artificial Neural Network (ANN) and Response Surface Methodology (RSM) in the Prediction of Quality Parameters of Spray-Dried Pomegranate Juice. *Drying Technology*, 27: 910-917.
- Zhang Z, Breidt C, Chang L, Hauptert F, Friedrich K (2004). Enhancement of the wear resistance of epoxy. *Composites: Part A*, 35: 1385-1392.
- Zhang Z, Barkoula N, Karger-Kocsis J, Friedrich K (2003). Artificial neural network predictions on erosive wear of polymers. *Wear*, 255: 708-713.
- Zolgharnein J, Shahmoradi A, Ghasemi JB (2013). Comparative study of Box-Behnken, central composite, and Doehlert matrix for multivariate optimization of Pb (II) adsorption onto Robiniatree leaves. *Journal of Chemometrics*, 27: 12-20.

ÖZGEÇMİŞ

Necip Fazıl KARAKURT, 28/05/1992 yılında Sivas’da doğdu. 2010 yılında Sivas Fen Lisesi’nden mezun oldu. 2010 yılında Orta Doğu Teknik Üniversitesi Endüstri Mühendisliği Bölümüne giriş yaptı ve 2015 yılında mezun oldu. Kısa bir özel sektör tecrübesinden sonra 2016 yılında Namık Kemal Üniversitesi Çorlu Mühendislik Fakültesi Endüstri Mühendisliği Bölümünde Araştırma Görevlisi olarak işe başladı. Aynı yıl Namık Kemal Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalında Yüksek Lisans eğitimine başladı. Halen burada çalışmakta ve yüksek lisans eğitimini sürdürmektedir.