



# Düzce Üniversitesi Bilim ve Teknoloji Dergisi

*Araştırma Makalesi*

## Manyetik Aktif Karbon Modifiyeli Bitümün Kompleks Modül Değerlerinin Yapay Sinir Ağlarıyla Tahmini

 Ahmet Münir ÖZDEMİR<sup>a</sup>,  Bahadır YILMAZ<sup>a,\*</sup>,  Nurten AKGÜN TANBAY<sup>a</sup>

<sup>a</sup> İnşaat Mühendisliği Bölümü, Mühendislik ve Doğa Bilimleri Fakültesi, Bursa Teknik Üniversitesi, Bursa, TÜRKİYE

\* Sorumlu yazarın e-posta adresi: bahadir.yilmaz@btu.edu.tr

DOI: 10.29130/dubited.919452

### ÖZ

Bu çalışmada Manyetik Aktif Karbon (MAK) ile modifiye edilmiş bitümlü bağlayıcının reolojik özellikleri araştırılmış ve sonuçlar yapay sinir ağları ile tahmin edilmiştir. Çalışma kapsamında B160/220 penetrasyon sınıfı bitümlü bağlayıcıya %5, %10 ve %15 oranlarında MAK ilave edilerek modifiye bitümler elde edilmiş, ardından bitümler üzerinde Dinamik Kayma Reometresi (DSR) cihazı ile on farklı frekansta (0.01-10Hz) ve dört farklı sıcaklıkta (40°,50°,60°,70°C) frekans taraması testi gerçekleştirilmiştir. Sonuçlar, MAK ilavesinin kompleks modül değerlerini artırıp, faz açısı değerlerini azaltarak bitümlü bağlayıcının elastik özelliklerini geliştirdiğini göstermiştir. Daha sonra frekans, katkı oranı ve sıcaklık değerlerine bağlı olarak değişen kompleks modül ve faz açısı değerleri yapay sinir ağları yöntemi ile tahmin edilmiştir. Sonuçlar, kompleks modül ve faz açısı değerlerinin oldukça yüksek doğrulukta düşük hata ile elde edilebileceğini göstermiştir.

**Anahtar Kelimeler:** Bitüm, Reoloji, Manyetik aktif karbon, Modifikasyon, Yapay sinir ağları

## Predicting The Complex Modulus of Magnetic Activated Carbon Modified Bitumen Using Artificial Neural Networks

### ABSTRACT

In this study, the rheological properties of the bitumen modified with Magnetic Activated Carbon (MAC) were investigated and the results were predicted with artificial neural networks. Within the scope of the study, modified bitumens were obtained by adding 5%, 10% and 15% MAC to the B160/220 penetration grade bituminous binder. Then, a frequency sweep test at ten different frequencies (0.01-10Hz) and four different temperatures (40 °, 50 °, 60 °, 70 ° C) was carried out on original and modified bitumens with the Dynamic Shear Rheometer (DSR) device. The results showed that the addition of magnetic activated carbon improves the elastic properties of the binder by increasing the complex modulus and decreasing the phase angle values. Then, complex modulus and phase angle values, which vary depending on the frequency, addition content and temperature value, were predicted by artificial neural networks. The results showed that complex modulus and phase angle values of the bitumen can be obtained with very high accuracy and low error with artificial neural networks.

**Keywords:** Bitumen, Rheology, Magnetic activated carbon, Modification, Artificial neural networks

# I. GİRİŞ

Bağlayıcı malzeme olarak bitüm ve iskelet yapısını oluşturmak üzere agregalardan meydana gelen bitümlü sıcak karışımlar (BSK), artan trafik yükleri, sıcaklık değişimleri, çevresel etkiler ve tasarım eksiklikleri gibi sebeplerden dolayı zamanla bozulmaya uğramaktadırlar [1]. Başlıca bozulmalardan yorulma çatlakları aşırı yüklemeler veya temel tabakalarının eksikliklerinden kaynaklanmakta; termal çatlaklar, aşırı ve düzensiz sıcaklık değişimlerinden kaynaklanmaktadır. Tekerlek izi ise karışım tasarımı aşamasındaki hatalardan, bağlayıcı malzemedeki eksikliklerden veya aşınma tabakasında normalden fazla meydana gelen plastik deformasyondan dolayı oluşurlar. Bu nedenle, tekerlek izi oluşumu bağlayıcı özellikleri ile doğrudan ilgilidir [2]. Bitümlü bağlayıcıların tekerlek izine karşı dayanımlarını artırmak amacıyla çeşitli katkı malzemeleri kullanılmaktadır. Yaygın olarak polimer malzemeler [3], [4], karbon siyahı [5], kauçuk, organik atıklar [6], [7], lifler vb. katkı malzemeleri tercih edilmektedir. Kimyasal yapısı itibarıyla oldukça karmaşık bir madde olan bitüm, ağırlıkça %90-98 oranında hidrokarbon içermektedir. Bu sebeple, kullanılan katkı malzemesi karbon içerikli olduğunda katkı malzemesi ile bitümlü bağlayıcı arasında kuvvetli etkileşimler sağlanmaktadır. Yapılan çalışmalar sonucunda karbon içerikli katkı malzemelerinin kullanımı ile bitümlü bağlayıcıların ve BSK'ların fiziksel [8], iletkenlik [9], [10] termal, mekanik [11], [12] ve reolojik [13], [14] özelliklerinin iyileştiği görülmüştür.

Aktif karbon, gıda, metal ve savunma sanayi gibi çeşitli endüstriyel alanlarda özellikle kirlilik giderimi ve arıtımı gibi adsorban madde ihtiyacı olan yerlerde kullanılmaktadır [15]. Ayrıca aktif karbon, kömür, odun, meyve çekirdekleri, kabukları ve atık organik maddeler kullanılarak düşük maliyetle elde edilmektedir [16]–[19]. Piroliz, diğer bir deyişle karbonizasyon, yüksek sıcaklıklarda meydana gelen termo-kimyasal bozulmadır ve bu bozulma sonucunda maddenin üç halinde de (katı-sıvı-gaz) ürünler elde edilebilmektedir. Piroliz yöntemiyle üretilen sıvı ürünlere biyoyağ (bio-oil), katı ürünlere de biyokömür (bio-char) denilmektedir [6], [20]. Biyokömlere uygulanan bazı işlemler sonucunda aktif karbon elde edilebilmektedir. Son zamanlarda araştırmacılar tarafından biyokömür ve aktif karbonun bitümlü bağlayıcıların ve BSK'ların çeşitli özelliklerini geliştirmek amacıyla katkı malzemesi olarak kullanımı ile ilgili çeşitli çalışmalar yapılmıştır. Zhang ve ekibi yapmış oldukları çalışmada bitümlü bağlayıcıya iki farklı partikül boyutuna sahip biyokömür katkı malzemesini üç farklı oranda (%2, %4 ve %8) ilave etmiştir. Deneysel sonuçta biyokömür ilavesinin bitümlü bağlayıcıların viskozite değerlerini yükseltip, düşük sıcaklıklarda çatlak oluşumuna karşı gösterdikleri direnci artırdığı sonucuna varmıştır [21]. Bir başka çalışmada piroliz işlemi sonucu elde edilen biyokömür bitümlü bağlayıcıya ilave edilmiş ve bağlayıcılar üzerinde dönel viskozimetre ve çeşitli DSR deneyleri uygulanmıştır. Deneysel sonuçlarına göre, biyokömür ilavesi bitümlü bağlayıcıların viskozite değerlerini ve tekerlek izi dayanım parametrelerini artırmıştır [22]. Seyrek ve ekibi yaptıkları çalışmada tarım atıklarından elde ettikleri aktif karbonu bitümlü bağlayıcılarda katkı malzemesi olarak kullanmış ve katkılı bitüm ile elde edilen BSK'ların Marshall stabilite, rijitlik ve yorulmaya karşı direnç değerlerinin geliştiği belirlenmiştir [20].

Son yıllarda bitümlü bağlayıcılar ve karışımlar üzerinde uygulanan deneylerin sonuçlarının tahmininde [23]–[26], karışım dizayn metodlarının ve çeşitli hesaplama yöntemlerinin optimizasyonunda [27], [28], görüntü işleme ile çatlak oluşumlarının, bozulmaların ve karışımın davranışlarının saptanmasında [29]–[31] ve bunun gibi çeşitli alanlarda yapay zeka yöntemleri kullanılmaktadır. Yapay zeka yöntemleri arasında hızlı sonuç alma, kullanım kolaylığı gibi sebeplerden dolayı Yapay Sinir Ağları (YSA) çokça tercih edilmektedir. Kök ve ekibi yaptıkları çalışmada YSA kullanarak farklı şartlarda Stiren – Butadien – Stiren (SBS) ile modifiye edilmiş bitümlü bağlayıcıların kompleks modül değerlerini yüksek doğrulukla elde etmişlerdir [32]. Özşahin ve Oruç, yapay sinir ağlarını kullanarak emülsifiye bitümün esneklik modülünü deneysel verilerle yüksek benzerlik elde ederek tahmin etmiştir. Saltan ve Terzi yaptıkları çalışmada kaplama tabaka kalınlığına göre, kaplamada meydana gelen defleksiyon miktarını yapay sinir ağları kullanarak tahmin etmişlerdir [33]. Yapılan farklı çalışmalarda araştırmacılar YSA kullanarak bitümlü bağlayıcıların ve BSK'ların farklı özelliklerini

(dinamik modül [34], viskozite [35], tekerlek izi derinliği [36], rijitlik [37], Marshall stabilite [38]) elde etmişlerdir.

Bu çalışmada şeker üretimi sonucu açığa çıkan bir çeşit tarımsal atık olan şlempe-cibreden elde edilen aktif karbon kullanılarak, kimyasal çöktürme ve hidrotermal yöntem ile MAK sentezlenmiş ve bitümlü bağlayıcılara üç farklı oranda (%5, %10, %15) ilave edilmiştir. Daha sonra DSR cihazı ile dört farklı sıcaklıkta (40, 50, 60, 70°C) ve 0.01-10 Hz aralığında frekans taraması yapılmıştır. Elde edilen sonuçlar oluşturulan farklı YSA modelleri ile tahmin edilerek model performansları karşılaştırılmıştır.

## **II. MATERYAL VE METOT**

### **A. MATERYAL**

#### **A.1. Manyetik Aktif Karbon (MAK)**

Çalışma kapsamında şlempe-cibreden hazırlanmış aktif karbon kullanılarak kimyasal çöktürme ve hidrotermal yöntem ile MAK elde edilmiştir. Katkı malzemesi olarak kullanılan MAK'ın görüntüsü Şekil 1'de, özellikleri Tablo 1'de verilmiştir.



*Şekil 1. Katkı maddesi MAK'ın görüntüsü.*

*Tablo 1. MAK'ın özellikleri.*


<b>Özellik</b>	<b>Değer</b>
<b>Görünür yoğunluk (g/cm<sup>3</sup>)</b>	1.2814
<b>Gerçek yoğunluk (g/cm<sup>3</sup>)</b>	2.52245
<b>BET yüzey alanı (Mikro+Mezo)( m<sup>2</sup>/g)</b>	310.9
<b>Mikroporyüzey alanı (m<sup>2</sup>/g)</b>	210.1
<b>Mikroporhacmi (cm<sup>3</sup>/g)</b>	0.2957
<b>Porçapı (Å)</b>	24.9
<b>Partikülboyutu [Ağırlıklıortalama(D[4,3]), µm]</b>	11.552

## A.2. Bitümlü Bağlayıcı ve Modifiye İşlemi

160/220 penetrasyon sınıfına sahip bitümlü bağlayıcı TÜPRAŞ Batman rafinerisinden temin edilmiştir. Bağlayıcının fiziksel özellikleri Tablo 2’de gösterilmiştir. Saf bağlayıcıya %5, %10 ve %15 olmak üzere üç farklı oranda MAK ilave edilerek, 1000 devir/dk hızda 180°C sabit sıcaklıkta 1 saat karıştırılıp modifiye bitümler elde edilmiştir. Modifiye mikseri ve modifiye işleminde kullanılan 4 bıçaklı pervane Şekil 2’de gösterilmiştir. Modifiye işlemi sonrası hazırlanan ve beherlere aktarılan saf ve MAK modifiyeli bitümlü bağlayıcı numuneleri Şekil 3’te gösterilmiştir.

Tablo 2. Bitümlü bağlayıcının fiziksel özellikleri.

Özellikler	Değer	Şartname
Penetrasyon (25°C, dmm)	176.7	ASTM D-5
Yumuşama Noktası (°C)	43.7	ASTM D-36
Düktilite (25°C, cm)	100+	ASTM D-113
Parlama Noktası (°C)	223	ASTM D-92
Özgül ağırlık (25°C, g/cm <sup>3</sup> )	1.018	ASTM D-70
Viskozite (135°C, cP)	275	ASTM D-4402
Viskozite (165°C, cP)	100	ASTM D-4402



Şekil 2. Modifiye Mikseri ve 4 bıçaklı pervane.




Şekil 3. Hazırlanan MAK modifiyeli bitümlü bağlayıcılar.

## B. METOT

### B.1. Dinamik Kayma Reometresi (DSR) Deneyi (AASHTO TP5)

DSR deneyi, asfalt çimentosunun kompleks kayma modülü ( $G^*$ ) ve faz açısı ( $\delta$ ) değerlerini belirlemek amacıyla yapılmakta ve bitümlü bağlayıcının elastik tepkilerini belirlemektedir.  $G^*$ , bitümlü bağlayıcıda meydana gelen tekrarlı kayma gerilmeleri sebebiyle oluşan deformasyonlara karşı bağlayıcının gösterdiği direncin bir ölçüsüdür. Kompleks kayma modülü, elastik modül ( $G'$ ) ve viskoz ( $G''$ ) olmak üzere iki kısım ile tanımlanır [39]. Bu kısımlar  $G^*$  ve  $\delta$  değerleriyle ilişkilidir. Faz açısı, uygulanan gerilme ile meydana gelen deformasyon arasındaki zaman farkına eşittir. Faz açısı  $0^\circ$  iken malzemenin davranışının tamamen elastik,  $90^\circ$  iken tamamen viskoz olduğu kabul edilmektedir [40] (Şekil 4).



Şekil 4. Bitümün viskoelastik özelliği [40].

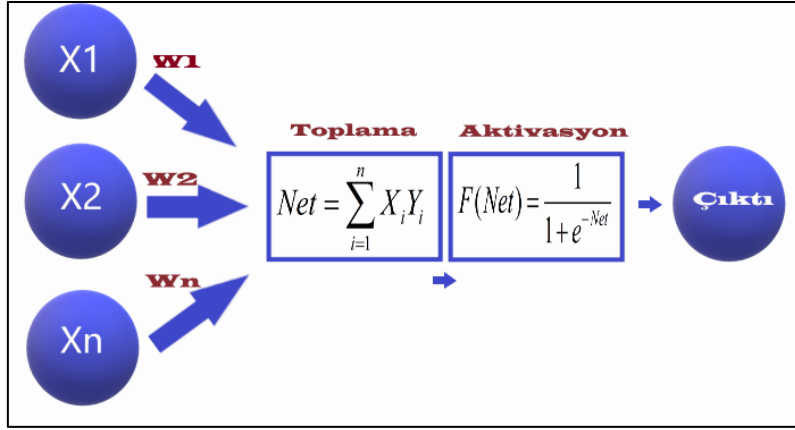
Frekans taraması testi asfalt kaplama üzerinde seyreden bir aracın hızını simüle edebilmektedir. 10 Hz'lik yükleme frekansı 60 km/saat'lik hıza tekabül ederken, 15 Hz'lik yükleme frekansı 90 km/saat hıza karşılık gelmektedir. Kompleks modül ve faz açısı değerleri sıcaklık ve frekans ile önemli ölçüde değişmektedir [41].

Bu çalışmada bitümlü bağlayıcılar üzerinde  $40^\circ\text{C}$ ,  $50^\circ\text{C}$ ,  $60^\circ\text{C}$  ve  $70^\circ\text{C}$  sıcaklıklarda, 0.01-10Hz aralığında DSR cihazı ile frekans taraması testi uygulanmıştır. Numune geometrisi 25mm çapta ve 1mm yükseklikte olacak şekilde belirlenmiştir.

### B.2. Yapay Sinir Ağları (YSA)

YSA insan beyninin çalışma prensiplerinden esinlenerek oluşturulan hücrelerden ibaret olup, kendilerine verilen bilgiler ile öğrenme amacıyla programlanabilen yapılardır. YSA'da insandaki sinir hücrelerine benzeyen yapılar (nöronlar) mevcuttur [42]. YSA çözülmesi gereken problem için mevcut verilerden bilgileri alır, öğrenir ve bu öğreneyi kullanarak çözüm üretip tahminde bulunur [43].

Bir YSA yapısında girdiler ( $X_1, X_2, X_3, \dots$ ), ağırlıklar ( $W_1, W_2, W_3, \dots$ ), birleştirme (toplama) fonksiyonu, aktivasyon (transfer) fonksiyonu ve çıktı ( $Y$ ) olmak üzere beş bölüm mevcuttur. Girdiler, nöronlara ağırlıklar ile birlikte girmekte, birleştirme fonksiyonundan geçirilerek aktivasyon fonksiyonuna aktarılmaktadır. Daha sonra hücre çıktı değerleri hesaplanır [44]. YSA hücresinin genel yapısı Şekil 5'te sunulmuştur. Tüm yapay sinir ağı modelleri için aynı fonksiyonların kullanılma zorunluluğu yoktur. Bu çalışmada aktivasyon fonksiyonu olarak Sigmoid (Logsig) Fonksiyonu kullanılmıştır (Şekil 5). Sigmoid fonksiyonunun tercih edilmesinin sebebi, fonksiyonun 0 ile 1 arasında olması ve bu nedenle özellikle çıktı olarak tahminlerde bulunmayı sağlamasıdır.



Şekil 5. YSA yapısı.

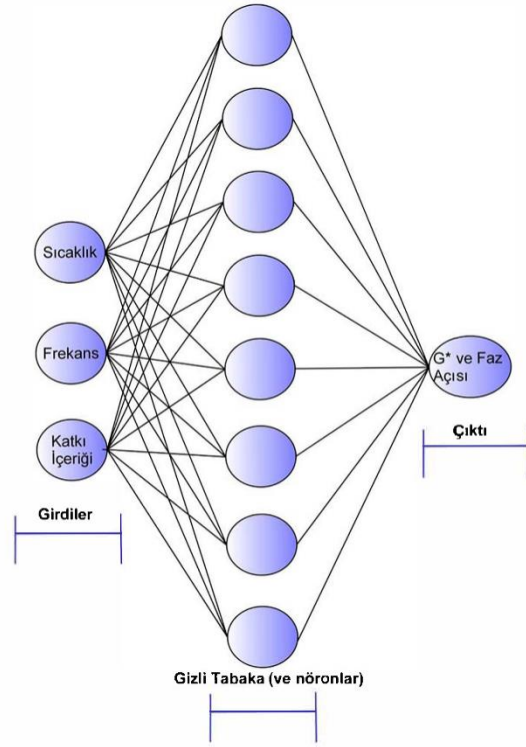
YSA'nın en ideal biçimde çalışması ve sonuç verebilmesi için eğitilmesi gerekmektedir. Eğitim işlemi için uygun algoritmaların seçilmesi önem arz etmektedir [44]. Bu çalışmada YSA'lar MATLAB ortamında çalıştırılmış ve Levenberg-Marquardt (LM), Bayesian Regularization (BR) ve Scaled Conjugate Gradient (SCG) olmak üzere üç farklı eğitim algoritması tercih edilmiştir.

LM temelinde en küçük kareler yöntemi yardımıyla hesaplama yöntemidir. Bu algoritma Gauss-Newton ve gradient-descent algoritmalarının en başarılı özelliklerine sahiptir. Bu eğitim algoritmasında yavaş yakınsama problemleri yaşanmaz. Oldukça hızlı bir algoritmadır [45], [46].

Matlab kodu "trainbr" olan BR eğitim algoritması, ağırlık değerlerini LM optimizasyonuna göre günceller. Ağırlık değerlerindeki dengesizlikleri düzenler ve büyük ağırlıkların çıktıyı etkilemesini engeller. Hataları ve ağırlık kombinasyonunu en aza indirir ve daha sonra iyi bir şekilde genelleştiren bir ağ oluşturmak için doğru kombinasyonu belirler. Bu süreç Bayesian Düzenleme olarak isimlendirilmektedir [44], [47].

Standart geri yayılım algoritmalar, büyük ölçekli problemlerde iyi performans gösterememektedir. Bu sebeple danışmanlı algoritmalar geliştirilmiştir ve bunlardan biri de SCG eğitim algoritmasıdır [48].

Veri setinin %70'i eğitim, %15'i doğrulama ve %15'i ise test amacıyla kullanılmak üzere ayrılmıştır. Eğitime başlarken YSA katmanlarında kaç adet nöron bulunması gerektiği çeşitli hesaplarla bulunabileceği gibi deneme yanılma yolu ile istenilen performans değerleri elde edilene kadar denenerek bulunabilmektedir. Bu sebeple en yüksek doğruluğu en düşük hata oranı ile elde etmek amacıyla her bir algoritma için üç farklı nöron sayısı (8, 10, 12) model tekrar denenmiştir. Kurulan YSA modellerinin isimleri ve nitelikleri Tablo 3'te verilmiştir. Aynı modeller hem G\* hem de faz açısı değerleri için ayrı ayrı çalıştırılarak tahminler elde edilmiştir. Çalışmada kompleks modül ve faz açısı değerlerini tahmin etmek için kullanılan YSA mimarilerinden biri (sekiz nöronlu) Şekil 6'te verilmiştir.



Şekil 6. YSA mimarisi.

Tablo 3. Kurulan YSA modellerinin isimleri ve nitelikleri.

YSA Modeli	Niteliği
LM8	Eğitim Algoritması: Levenberg-Marquardt Nöron Sayısı: 8
LM10	Eğitim Algoritması: Levenberg-Marquardt Nöron Sayısı: 10
LM12	Eğitim Algoritması: Levenberg-Marquardt Nöron Sayısı: 12
BR8	Eğitim Algoritması: Bayesian Regularization Nöron Sayısı: 8

**Tablo 3 (devam).** Kurulan YSA modellerinin isimleri ve nitelikleri.

BR10	Eğitim Algoritması: Bayesian Regularization Nöron Sayısı: 10
BR12	Eğitim Algoritması: Bayesian Regularization Nöron Sayısı: 12
SCG8	Eğitim Algoritması: Scaled Conjugate Gradient Nöron Sayısı: 8
SCG10	Eğitim Algoritması: Scaled Conjugate Gradient Nöron Sayısı: 10
SCG12	Eğitim Algoritması: Scaled Conjugate Gradient Nöron Sayısı: 12

Model performansını ve hataları değerlendirmek için çeşitli yöntemler mevcuttur. Oluşturulan YSA modelinin hata oranının kabul edilebilir seviyede olması gerekmektedir. Bu çalışmada Belirleme Katsayısı ( $R^2$ ), Ortalama Hata Kareleri (Mean Square Error-MSE) ve Ortalama Hata Kareleri Karekökü (Root Mean Square Error-RMSE) olmak üzere üç istatistiksel metot tercih edilmiştir.

$Y^{deneyse}$  = Gerçek, deneysel veriler,

$Y^{tahmin}$  = Tahmin edilen veriler ve n deneysel veri sayısı olmak üzere:

$$R^2 = 1 - \frac{\sum_{i=1}^n (Y_i^{tahmin} - Y_i^{deneyse})^2}{\sum_{i=1}^n (Y_i^{deneyse})^2} \quad (1)$$

$$MSE = \frac{\sum_{i=1}^N (Y_i^{tahmin} - Y_i^{deneyse})^2}{n} \quad (2)$$


$$RMSE = \sqrt{\frac{\sum_{i=1}^N (Y_i^{tahmin} - Y_i^{deneyse})^2}{n}} \quad (3)$$




### III. BULGULAR

#### A.1. DSR Sonuçları

Dört farklı sıcaklıkta, 0.01-10 Hz aralığında gerçekleştirilen frekans tarama testi sonucu elde edilen kompleks modül ( $G^*$ ) değerleri Şekil 7’de, faz açısı ( $\delta$ ) değerleri Şekil 8’de verilmiştir. Şekiller incelendiğinde artan frekans ile birlikte  $G^*$  değerleri tüm bağlayıcı numuneleri için artmıştır. Katkı oranı arttıkça  $G^*$  değerleri saf bağlayıcıya göre artış göstermiştir.



Şekil 7. Kompleks modül ( $G^*$ ) değerleri.



Şekil 8. Faz açısı ( $\delta$ ) değerleri.

Katkı oranının ve frekansın artmasıyla tüm bağlayıcı numunelerinde tekerlek izi dayanımlarının arttığı görülmektedir. Faz açısı deney sonuçlarına göre düşük frekanslarda değerler azalırken, frekansın artmasıyla neredeyse sabit kalmıştır.  $G^*$  değerlerinin artıp, faz açısı değerlerinin azalması bitümlü bağlayıcının elastik özelliklerinin arttığı anlamına gelmektedir. Aynı frekans değerlerinde farklı sıcaklıklar için kompleks modül değerleri incelendiğinde, sıcaklığın artmasıyla  $G^*$  değerlerinin azaldığı görülmektedir. Örneğin 40°C ve 10Hz frekans altında %10 MAK modifiyeli bitümün  $G^*$

değeri 5610 Pa iken, 70°C’de 1837 Pa’dır. Deney sonuçlarına bağlı olarak üç bağımsız değişken de (sıcaklık, katkı oranı ve frekans) bağımlı değişkenler üzerinde ( $G^*$ ,  $\delta$ ) etkilidir denebilmektedir.

## A.2. YSA Sonuçları

Oluşturulan YSA modellerinin performanslarını değerlendirmek amacıyla elde edilen  $R^2$ , MSE ve RMSE sonuçları Tablo 4 ve 5’te verilmiştir. Tablo 4 incelendiğinde Levenberg-Marquart (LM) ve Bayesian Regularization (BR) ile eğitilen YSA modelleri, Scaled Conjugate Gradient (SCG)’ye kıyasla daha düşük hata ile daha yüksek doğrulukta sonuçlar vermiştir. Genel olarak  $G^*$  ve faz açısı için oluşturulan YSA modelleri karşılaştırıldığında faz açısını tahmin etmek için kurulan YSA modelleri çok daha az hata ile yüksek doğrulukta değerleri sunmuştur.  $G^*$  için oluşturulan YSA modelleri incelendiğinde en küçük  $R^2$  değerini SCG10, en yüksek  $R^2$  değerini ise BR10 modeli sunmuştur. Ancak modellerin RMSE değerlerine bakıldığında en düşük hata değeri LM10 modelinde elde edilmiştir (4.89).  $G^*$  değerlerinin ortalama  $10^2$  ile  $10^4$  arasında olduğu düşünüldüğünde, RMSE, yani gerçek ile tahmin edilen değerler arasındaki uzaklığın 4.89 olarak elde edilmesi model performansının oldukça yüksek olduğunu göstermektedir.

Faz açısı YSA modelleri için en düşük hata oranı ile en yüksek doğruluğu BR10 modeli sunmuştur. Ancak hem faz açısı hem de kompleks modül modelleri birlikte düşünüldüğünde en iyi sonucu LM10 yapay sinir ağı modelinin verdiği kabul edilmiştir. Bu sebeple çalışmanın geri kalanında, YSA’nın diğer sonuçları ve grafiklerinin elde edilmesi LM10 modeli üzerinden hesaplanmış ve değerlendirilmiştir.

**Tablo 4.**  $G^*$  değerlerinin tahmini için oluşturulan YSA modellerinin  $R^2$ , MSE ve RMSE sonuçları.


	<b>R2</b>	<b>MSE</b>	<b>RMSE</b>
LM8	0.9976337246	1659.49966	40.73695694
<b>LM10</b>	<b>0.9994338231</b>	<b>23.97301928</b>	<b>4.896225003</b>
LM12	0.9801637864	20024.65153	141.5084857
BR8	0.9999130541	1056.104922	32.49776795
BR10	0.9999332672	1890.23835	43.47687144
BR12	0.9998082399	2576.803007	50.76222027
SCG8	0.971557735	65097.71442	255.1425375
SCG10	0.780974186	176338.5073	419.926788
SCG12	0.9087417068	134668.9298	366.9726553

**Tablo 5.** Faz açısı değerlerinin tahmini için oluşturulan YSA modellerinin  $R^2$ , MSE ve RMSE sonuçları.

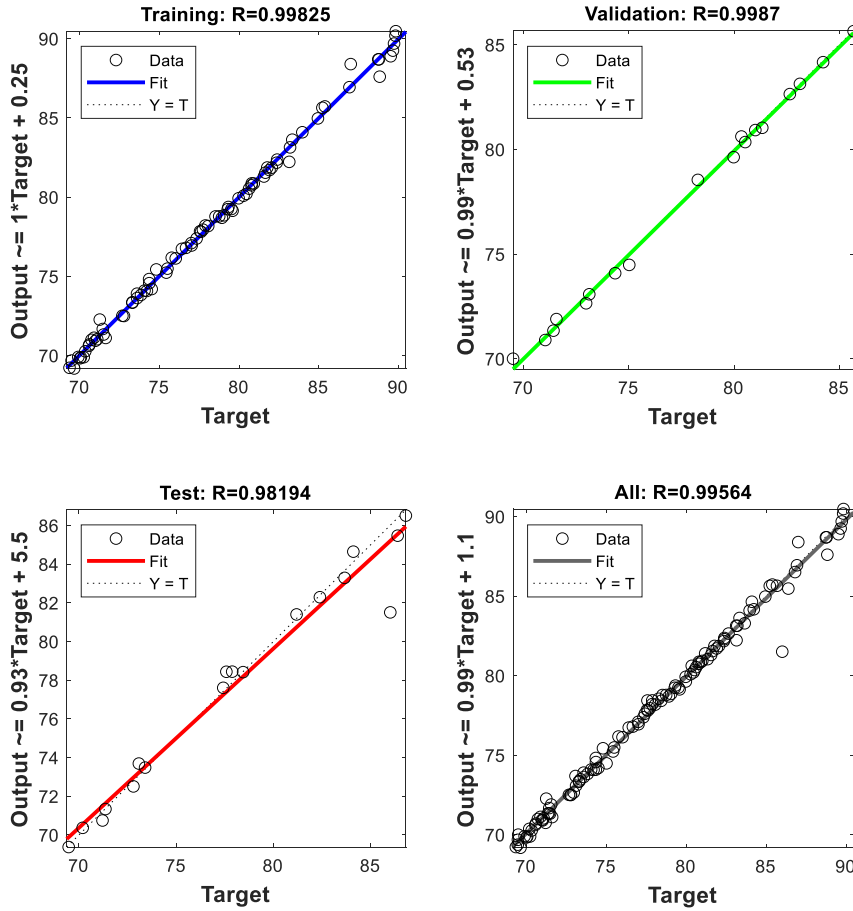
	<b>R2</b>	<b>MSE</b>	<b>RMSE</b>
LM8	0.8096542578	0.06768650716	0.3420823783
<b>LM10</b>	<b>0.9912898514</b>	<b>0.0002959543658</b>	<b>0.0926101036</b>
LM12	0.9347481574	0.0004906809715	0.3275719367
BR8	0.9961247036	0.000006713987187	0.1616246654

SCG8	0.7692484608	0.1253890421	0.4919896999
SCG10	0.7435386795	0.000007350297006	0.1395828437
SCG12	0.9233633162	0.001042320044	0.2194478918
BR10	0.9989713478	0	0.003974277382
BR12	0.9991780125	0.00003006452533	0.0003963019206

On nöron sayısına sahip ve LM eğitim algoritması ile eğitilmiş YSA modelinin eğitim, doğrulama ve test aşamalarında gösterdiği performansın ölçüsü olarak korelasyon katsayısı (R) değerleri ve grafikleri kompleks modül için Şekil 9’da, faz açısı için Şekil 10’da verilmiştir.

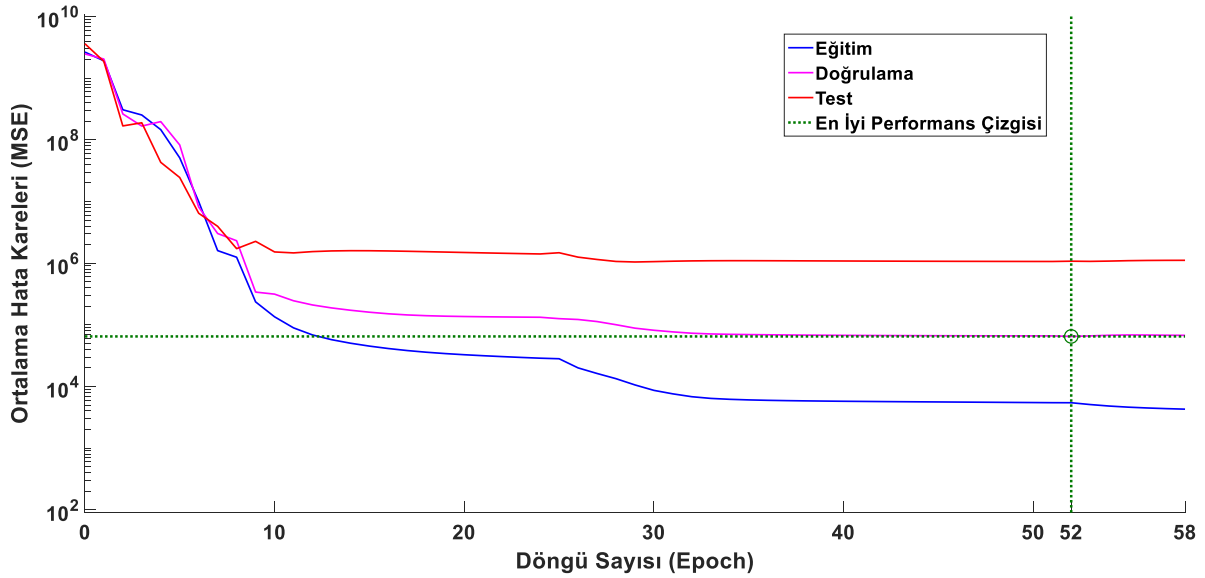


Şekil 9. Kompleks Modül ( $G^*$ ) için LM10 modelinin R değerleri.



Şekil 10. Faz Açısı için LM10 modelinin R değerleri.


Şekil 9 ve 10 incelendiğinde hem eğitim, hem doğrulama hem de test aşamasında LM10 modelinin oldukça başarılı olduğu görülmektedir. Tahmin edilen ve gerçek değerler arasındaki ilişki oranı oldukça yüksektir. Şekil 11’de yapay sinir ağının performansı verilmiştir (LM10).




Şekil 11. Yapay sinir ağının performansı.

Eğitim sırasında tüm eğitim verilerinin ağı gösterilme sayısına “epoch (döngü sayısı)” denir. Döngü sayısı arttıkça genellikle hata azalır. Kurulan modelin aşırı uydurmaya (overfitting) maruz kalmaması

için doğrulama veri setindeki hata oranı azalmaya başladığında eğitim durdurulur. En iyi performans, doğrulama veri setindeki en düşük hata oranını veren döngü sayısında temsil edilir. Şekil 11 incelendiğinde kurulan ağda 52 döngüde en iyi performans elde edilmiştir. Şekil 12 ve 13'te en iyi (LM10) ve en kötü (SCG10) performansı gösteren iki yapay sinir ağı ile elde edilen kompleks modül değerleri ile deneysel kompleks modül değerleri karşılaştırılmıştır.



Şekil 12. Kompleks modül ( $G^*$ ) için tahmin edilen ve deneysel değerlerin karşılaştırılması (LM10).



Şekil 13. Kompleks modül ( $G^*$ ) için tahmin edilen ve deneysel değerlerin karşılaştırılması (SCG10).

Şekil 12'de LM10 YSA modelinin oldukça yüksek doğrulukta sonuçlar vererek başarıyla  $G^*$  değerlerini tahmin ettiği, Şekil 13'te ise SCG10 YSA modelinin buna nazaran tahmin performansının düşük olduğu açıkça görülmektedir.

## **IV. SONUÇ VE TARTIŞMA**

Bu çalışmada saf ve üç farklı oranda Manyetik Aktif Karbon (MAK) ilave edilerek elde edilen modifiye edilmiş bitümler üzerinde DSR cihazı ile dört farklı sıcaklıkta (40, 50, 60, 70°C) ve 0.01-10Hz frekans aralığında frekans taraması testi gerçekleştirilerek reolojik parametreler araştırılmıştır. Daha sonra oluşturulan yapay sinir ağları (YSA) ile bu parametreler elde edilmiştir. Kompleks modül

(G\*) değeri sıcaklık ve frekansa bağılı olarak önemli miktarlarda değişmektedir. DSR deney sonuçlarına göre frekansın artması ile tüm bağlayıcı numuneleri için kompleks modül değerleri artmıştır. MAK oranı arttıkça kompleks modül değerlerinin saf bağlayıcıya göre arttığı, aynı zamanda faz açısı değerlerinin ise azalarak bağlayıcının elastik özelliklerinin geliştiği sonucuna varılmıştır. Farklı sıcaklıklarda aynı frekanslarda elde edilen kompleks modül (G\*) sonuçlarına göre sıcaklığın artmasıyla G\* değerlerinde düşüş meydana gelmiştir.

Levenberg-Marquardt (LM), Bayesian Regularization (BR) ve Scaled Conjugate Gradient (SCG) eğitim algoritmaları kullanılarak kompleks modül değerleri modellenmiş ve tahmin edilmiştir. En uygun sonuçlar LM eğitim algoritması ile eğitilen yapay sinir ağı ile elde edilmiştir. Sonuçlar, farklı frekans sıcaklık ve katkı oranı değerleri ile saf ve modifiye bitümlerin kompleks modüllerinin YSA ile başarılı bir şekilde tahmin edilebileceğini göstermiştir. En iyi sonucu  $R^2=0.999$  doğrulukla ve  $RMSE=4.89$  hatayla Levenberg-Marquardt eğitim algoritmasıyla eğitilen ve 10 adet nöron sayısıyla oluşturulan yapay sinir ağı modeli sunmuştur. Laboratuvarlarda ve test merkezlerinde gerçekleştirilen deneyler için yüksek miktarda malzeme ve zaman harcanmaktadır. Yapay zeka teknikleri kullanılarak yaklaşık olarak elde edilecek sonuçların tahmin edilmesi gerek kullanılacak malzeme miktarı gerekse zaman açısından oldukça faydalı olacaktır. Gelecek çalışmalarda deney çeşitliliği artırılarak, daha çok girdi ile derin öğrenme modelleri oluşturulabilir.

**TEŞEKKÜR:** Manyetik Aktif Karbon (MAK) katkısının sentezlenmesindeki katkılarından dolayı Kırşehir Ahi Evran Üniversitesi Mühendislik-Mimarlık Fakültesi, Kimya ve Proses Mühendisliği Bölümü Öğretim Üyesi Doç. Dr. Hasan Arslanoğlu'na teşekkür ederiz.

## **V. KAYNAKLAR**

- [1] R. Hunter, A. Self, and J. Read, *The shell bitumen handbook, 6th edition*, London, UK: ICE Publishing, 2015.
- [2] D. N. Little, D. H. Allen, and A. Bhasin, *Modeling and design of flexible pavements and materials*, Springer International Publishing AG, 2017.
- [3] Y. Erkuş, B. V. Kök, and M. Yılmaz, "Evaluation of performance and productivity of bitumen modified by three different additives," *Construction and Building Materials*, vol. 261, pp. 120553, 2020.
- [4] B. V. Kök, M. Yılmaz, and M. Akpolat, "Evaluation of the conventional and rheological properties of SBS+Sasobit modified binder," *Construction and Building Materials*, vol. 63, pp. 174–179, 2014.
- [5] P. Cong, P. Xu, and S. Chen, "Effects of carbon black on the anti aging, rheological and conductive properties of SBS/asphalt/carbon black composites," *Construction and Building Materials*, vol. 52, pp. 306–313, 2014.
- [6] S. Zhao, B. Huang, X. P. Ye, X. Shu, and X. Jia, "Utilizing bio-char as a bio-modifier for asphalt cement: A sustainable application of bio-fuel by-product," *Fuel*, vol. 133, pp. 52–62, 2014.
- [7] Ç. Muhammed Ertugrul, Y. Mehmet, B. V. Kök, and E. Yalçın, "Effects of various biochars on the high temperature performance of bituminous binder," Jun. 2016.
- [8] X. Hu, K. Dai, and P. Pan, "Investigation of engineering properties and filtration characteristics of porous asphalt concrete containing activated carbon," *Journal of Cleaner Production*, vol. 209, pp. 1484–1493, 2019.
- [9] Y. Rew, A. Baranikumar, A. V. Tamashauskyy, S. El-Tawil, and P. Park, "Electrical and

mechanical properties of asphaltic composites containing carbon based fillers,” *Construction and Building Materials*, vol. 135, pp. 394–404, 2017.

[10] B. Huang, X. Chen, and X. Shu, “Effects of electrically conductive additives on laboratory-measured properties of asphalt mixtures,” *Journal of Materials in Civil Engineering*, vol. 21, no. 10, pp. 612–617, 2009.

[11] M. Bostancıoğlu and Ş. Oruç, “Effect of activated carbon and furan resin on asphalt mixture performance,” *Road Materials and Pavement Design*, vol. 17, no. 2, pp. 512–525, 2016.

[12] C. Li, F. Ning, and Y. Li, “Effect of carbon black on the dynamic moduli of asphalt mixtures and its master curves,” *Frontiers of Structural and Civil Engineering*, vol. 13, no. 4, pp. 918–925, 2019.

[13] R. Casado-Barrasa, P. Lastra-González, I. Indacoechea-Vega, and D. Castro-Fresno, “Assessment of carbon black modified binder in a sustainable asphalt concrete mixture,” *Construction and Building Materials*, vol. 211, pp. 363–370, 2019.

[14] M. A. Notani *et al.*, “Investigating the high-temperature performance and activation energy of carbon black-modified asphalt binder,” *SN Applied Sciences*, vol. 2, no. 2, pp. 303, 2020.

[15] Ö. Gerçel ve G. Seydioğlu, “Kiraz çekirdeğinden granül aktif karbon üretimi,” *Anadolu Üniversitesi Bilim ve Teknoloji Dergisi A- Uygulamalı Bilimler ve Mühendislik*, c. 16, s. 2, ss. 189, 2015.

[16] İ. Demiral, C. Şamdan, ve H. Demiral, “Şeftali çekirdeğinden çinko klorür aktivasyonu ile aktif karbon üretimi ve karakterizasyonu,” *Eskişehir Osmangazi Üniversitesi Mühendislik ve Mimarlık Fakültesi Dergisi*, c. 28, s. 1, ss. 73–82, 2020.

[17] E. Ülkeryıldız Balçık, M. Torun, ve H. Şahin Nadeem, “Gıda atıklarından aktif karbon üretimi ve aktif karbonun gıda endüstrisinde uygulamaları,” *Gıda*, c. 45, s.2, ss. 217–229, 2020.

[18] Ö. Açıslı, “Doum palm meyve kabuklarından aktif karbon üretimi ve karakterizasyonu,” *Avrupa Bilim ve Teknoloji Dergisi*, s. 16, ss. 544–551, 2019.

[19] Z. E. Sayın, C. Kumaş, ve B. Ergül, “Fındık kabuğundan aktif karbon üretimi,” *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, c. 16, s. 2, ss. 409–419, 2016.

[20] E. Seyma Seyrek, E. Yalcin, M. Yilmaz, B. Vural Kök, and H. Arslanoglu, “Effect of activated carbon obtained from vinasse and marc on the rheological and mechanical characteristics of the bitumen binders and hot mix asphalts,” *Construction and Building Materials*, vol. 240, pp. 117921, 2020.

[21] R. Zhang, Q. Dai, Z. You, H. Wang, and C. Peng, “Rheological performance of bio-char modified asphalt with different particle sizes,” *Applied Sciences*, vol. 8, no. 9, pp. 1665, 2018.

[22] A. Kumar, R. Choudhary, R. Narzari, R. Kataki, and S. K. Shukla, “Evaluation of bio-asphalt binders modified with biochar: a pyrolysis by-product of Mesua ferrea seed cover waste,” *Cogent Engineering*, vol. 5, no. 1, pp. 1548534, 2018.

[23] A. Behnood and E. Mohammadi Golafshani, “Predicting the dynamic modulus of asphalt mixture using machine learning techniques: An application of multi biogeography-based programming,” *Construction and Building Materials*, vol. 266, pp. 120983, 2021.

[24] F. Hussain, Y. Ali, M. Irfan, M. Ashraf, and S. Ahmed, “A data-driven model for phase angle behaviour of asphalt concrete mixtures based on convolutional neural network,” *Construction and*

*Building Materials*, vol. 269, p. 121235, 2021.

- [25] M. Yilmaz, B. V. Kok, B. Sengoz, A. Sengur, and E. Avci, "Investigation of complex modulus of base and EVA modified bitumen with adaptive-network-based fuzzy inference system," *Expert Systems with Applications*, vol. 38, no. 1, pp. 969–974, 2011.
- [26] B. V. Kok, M. Yilmaz, B. Sengoz, A. Sengur, and E. Avci, "Investigation of complex modulus of base and SBS modified bitumen with artificial neural networks," *Expert Systems with Applications*, vol. 37, no. 12, pp. 7775–7780, 2010.
- [27] H. Sebaaly, S. Varma, and J. W. Maina, "Optimizing asphalt mix design process using artificial neural network and genetic algorithm," *Construction and Building Materials*, vol. 168, pp. 660–670, 2018.
- [28] S. Lv *et al.*, "Performance and optimization of bio-oil/Buton rock asphalt composite modified asphalt," *Construction and Building Materials*, vol. 264, pp. 120235, 2020.
- [29] C. Xing, H. Xu, Y. Tan, D. Wang, and C. Zhai, "Strain field distribution of asphalt mortar using digital image processing," *Construction and Building Materials*, vol. 238, pp. 117624, 2020.
- [30] F. Tang, C. Han, T. Ma, T. Chen, and Y. Jia, "Quantitative analysis and visual presentation of segregation in asphalt mixture based on image processing and BIM," *Automation in Construction*, vol. 121, pp. 103461, 2021.
- [31] N.-D. Hoang, "Automatic detection of asphalt pavement raveling using image texture based feature extraction and stochastic gradient descent logistic regression," *Automation in Construction*, vol. 105, pp. 102843, 2019.
- [32] B. V. K k, M. Yilmaz, M.  akirođlu, N. Kulođlu, and A. Őeng r, "Neural network modeling of SBS modified bitumen produced with different methods," *Fuel*, vol. 106, pp. 265–270, 2013.
- [33] M. Saltan and S. Terzi, "Modeling deflection basin using artificial neural networks with cross-validation technique in backcalculating flexible pavement layer moduli," *Advances in Engineering Software*, vol. 39, no. 7, pp. 588–592, 2008.
- [34] D. Singh, M. Zaman, and S. Commuri, "Artificial neural network modeling for dynamic modulus of hot mix asphalt using aggregate shape properties," *Journal of Materials in Civil Engineering*, vol. 25, no. 1, pp. 54–62, 2013.
- [35] L. P. Specht, O. Khatchaturian, L. A. T. Brito, and J. A. P. Ceratti, "Modeling of asphalt-rubber rotational viscosity by statistical analysis and neural networks," *Materials Research*, vol. 10, no. 1, pp. 69–74, 2007.
- [36] N. Kamboozia, H. Ziari, and H. Behbahani, "Artificial neural networks approach to predicting rut depth of asphalt concrete by using of visco-elast"ic parameters," *Construction and Building Materials*, vol. 158, pp. 873–882, 2018.
- [37] M. A. Abed, Z. N. M. Taki, and A. H. Abed, "Artificial neural network modeling of the modified hot mix asphalt stiffness using bending beam rheometer," *Materials Today: Proceedings*, 2021.
- [38] E. Ozgan, "Artificial neural network based modelling of the Marshall Stability of asphalt concrete," *Expert Systems with Applications*, vol. 38, no. 5, pp. 6025–6030, 2011.
- [39] J. Zaniewski and M. Pumphrey, "Evaluation of performance graded asphalt binder equipment



and testing protocol,” 2004.

[40] E. Yalçın, “Saf ve modifiye bitümlerin farklı frekans ve sıcaklıklardaki reolojik özelliklerinin incelenmesi,” *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, c. 9, s. 2, ss. 901–909, 2020.

[41] W. Huang *et al.*, “Rheological characteristics evaluation of bitumen composites containing rock asphalt and diatomite,” *Applied Sciences*, vol. 9, no. 5, pp. 1023, 2019.

[42] E. Öztemel, *Yapay sinir ağları*, İstanbul, Türkiye: Papatya Yayıncılık Eğitim, 2008.

[43] D. Graupe, *Principles of artificial neural networks*, 3rd edition., World Scientific Publishing Company, 2013.

[44] F. Sönmez Çakır, *Yapay sinir ağları matlab kodları ve matlab toolbox çözümleri*, Ankara, Türkiye: Nobel Akademik Yayıncılık, 2019.

[45] D. Aşkin, İ. İskender, ve A. Mamizadeh, “Farklı yapay sinir ağları yöntemlerini kullanarak kuru tip transformatör sargısının termal analizi,” *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, c. 26, s.4, 2011.

[46] H. Yu and B. M. Wilamowski, “Levenberg–marquardt training,” in *Intelligent Systems*, CRC Press, 2018, pp. 12-1-12–16.

[47] B. Eren, M. Yağub, and V. Eyüpoğlu, “Assessment of neural network training algorithms for the prediction of polymeric inclusion membranes efficiency,” *SAÜ Fen Bilimleri Enstitüsü Dergisi*, vol. 20, no. 3, 2016.

[48] M. F. Møller, “A scaled conjugate gradient algorithm for fast supervised learning,” *Neural Networks*, vol. 6, no. 4, pp. 525–533, 1993.