

Evaluation of the Performance of ANN Algorithms with the Bidirectional Functionally Graded Circular Plate Problem

Munise Didem Demirtaş ^{a,1}, Didem Çakır ^b

^a Erciyes University, Faculty of Engineering, Mechanical Engineering, Kayseri, Turkey
ORCID ID: 0000-0001-8043-6813

^b Cappadocia University, Cappadocia Vocational College, Computer Programming, Nevşehir, Turkey
ORCID ID: 0000-0001-7682-6923

Abstract

Functionally graded materials (FGMs) are materials composed of metals and ceramics in which the distribution of material components varies according to a particular volumetric function. FGMs are often used in high-temperature applications. In our study, models were created in the Artificial Neural Network depending on the equivalent stress levels in the compositional gradient exponent, which is the most important parameter in determining the thermo-mechanical behavior of circular plates functionally staggered in two directions, and the performances of these models were evaluated. These models were obtained with four different training algorithms: Levenberg-Marquardt, Backpropagation Algorithm, Resilient Propagation Algorithm, Conjugate Gradient Backpropagation with Powell-Beale Restarts To train the ANN, equivalent stress levels were obtained by performing numerical analyzes at different compositional gradient upper values. The data sets were created by considering the largest value of the equivalent stress levels, the smallest value of the largest value, the largest value of the smallest value, and the smallest value of the smallest value. In this study, training stages and performance values were examined and interpreted with 4 training algorithms in detail.

Keywords: “Two-directional functionally graded circular plates, finite difference method, thermal stress analysis, artificial neural network, training algorithms.”

1. Giriş

Malzeme biliminde basit gerilmelere mukavim metallere sonra kompozitler ve seramikler gibi çoklu yapı malzemelerin geliştirilmesi ile daha zorlu çalışma şartları için mekanik ve aynı zamanda termal malzeme mukavemeti sağlanmıştır. Yapay zeka bilimlerinin, farklı analiz yöntem ve yaklaşımlarının gelişmesi ile istenilen özellikte ve yapıda makine malzemesi üretilmesi mümkün olmuştur. Sürekli gelişmekte olan bilgisayar bilimleri ve yapay zeka uygulamalarına sayesinde malzeme davranışlarını önceden kestirebilmek ve ileri teknoloji malzeme kompozisyonunu belirleyebilmek mümkün olmuştur. Bahsedilen ileri teknoloji malzemelerinden ve yüksek termal mukavemet istenen çalışmalar kullanılan bir yüzeyi metal karşı yüzeyi seramik olmak üzere metalden seramiğe geçiş ise bir hacimsel fonksiyona göre olan fonksiyonel kademeli malzeme (FKM)'dir. FKM ile malzeme bileşenlerinin geçiş bölgesinde süreklilik sağlanarak olası ara yüzeyde oluşabilecek malzeme kusurları engellenebilmiştir [1-3].

Literatürde yapılan çalışmalar, belirli sınır şartları altında malzeme çalışma koşullarını ve termo-mekanik davranışı belirleyen kompozisyonel gradyant üst değerinin tayin edilmesine odaklanmıştır. Alışılmadık çalışma şartlarına uyum sağlayabilecek malzeme tayininde, malzemenin bileşenleri arasında optimum dağılımın tespiti için sayısal analiz yöntemleri kullanılmış ve Sürü Optimizasyonları, Genetik Algoritmalar (GA),Yapay Sinir Ağları (YSA) ve Evrimsel Algoritmalar gibi sezgisel optimizasyon yöntemlerinde farklı çalışma koşulları için çeşitli tasarım modelleri uygulanmıştır. Literatürde yapılmış birkaç çalışma açıklanmıştır.

Cho ve Ha [4], termal yük altında FKM'nin termo-elastik davranışını, Sonlu Farklar Metodunu (SFM) kullanarak farklı sınır şartlarında iki boyutlu hacimsel dağılım için en uygun değeri araştırdılar. Ara yüzeylerde oluşan en yüksek gerilme seviyesini minimize etmek için YSA algoritması geliştirdiler. Nemat-Alla [5], havacılık sanayisinde verimli çalışabilecek ve yüksek termal gerilmeye dayanabilecek iki boyutlu FKM'nin geliştirilmesi için Sonlu Elemanlar Metodu (SEM) ile ideal tasarımı sundu.

Ootao ve arkadaşları [6], içi boş kürede termal yüklemeye altında malzeme kompozisyonunun optimizasyonunu YSA yöntemini kullanarak yaptılar. Doğrusal olmayan programlama ile YSA'nın doğruluğunu test ettiler. YSA'nın ilk verilerden sonra optimum

¹ Corresponding Author
E-mail Address: mddemirbas@erciyes.edu.tr


sonuca gayet hızlı bir şekilde ulaştığını tespit ettiler. Khoshnoodi ve arkadaşları [7], çok yönlü kademeli FKM'nin analizi için optimum değerlere yarı analitik yöntem ile ulaştılar. Analiz çalışmasında SSDQM ve YSA yöntemini kıyasladılar. Başlangıç verilerine ulaşma zamanı dikkate alınmadığında YSA'nın daha hızlı olduğunu belirttiler. Xu ve You [8], FK boruların kritik frekansını Legendre yöntemi ile hesapladılar. Levenberg-Marquart(L-M) algoritmasını ve optimizasyon yöntemi olarak YSA'yı tercih ettiler. Yapılan çalışma ile kompozisyonel gradyant üst değerinin gerçek ile tahmini değerlerinin birbirine yakınsadığını vurguladılar. Singh ve arkadaşları [9], kompozit malzemelerde aşınma dayanımını araştırdılar. Kompozit ve FKM üretmek için santrifüj yöntemini ve malzemeleri mekanik olarak karıştırmayı denediler. Geliştirilen malzemeyi Taguchi Yöntemi ve Varyans Analizi ile analiz ederek verileri YSA ile doğruladılar. FKM'lerin üretilen diğer kompozitlere göre aşınma dayanımlarını oldukça başarılı buldular. Ghatage ve arkadaşları [10], FKM'lerin malzeme teknolojisinde yeni yöntemlerle daha çok gelişebileceğini, uygun malzeme kompozisyonu, ideal modelleme ve doğru analiz ile her türlü gerilime dayanabileceğini belirttiler. Medikal teknolojisinde ve insan sağlığına zarar vermeyecek FKM'ler için çalışma yaptılar. Lineer olmayan yüklemeler altındaki FKM'ler için literatürde yapılan analizlerin sınırlı olduğuna değindiler. Yakın gelecekte FKM'ler üzerine yapılacak çalışmaların inovatif analiz yöntemleri ile daha uygulanabilir ve faydalı olabileceğini belirttiler. Na ve Kim [11], 3 boyutlu FKM'nin termal ve mekanik yük altında burkulma analizi için en önemli kriter olan kompozisyonel gradyant üst değerini araştırdılar. SEM kullanarak malzemede oluşabilecek gerilme dağılımının optimum olması için gerekli ideal hacimsel kompozisyonu bulmaya çalıştılar. Demirbaş ve Çakır [12], FK plakanın termal yüklemeye altında eşdeğer gerilmelerini hesapladılar. Belli sınır koşullar altında optimum kompozisyonel gradyant üst değerini bulmak için YSA kullanarak bir model oluşturdular. Khayat ve arkadaşları [13], Budiansky ve Ruth'un kriterlerine dayalı silindirik kabukların termal ve mekanik gerilme tesirindeki FKM'de dinamik kararlılığını araştırdılar. Bu çalışmada belirsiz değerleri ortandan kaldırmak için nokta tahmini ve YSA ile termal yüklemeye altındaki davranışı araştırdılar. Demirbaş ve arkadaşları[14] termal yüklemeye altındaki malzemenin yapısındaki deformasyonları belirlemede kullanılan eşdeğer gerilme değerlerini göz önünde tutarak malzemenin kompozisyonel gradyant üst değerini bulmak için sonlu farklar metodunu kullandılar. Bu yöntemle oluşturdukları veri setiyle genetik programlamada optimizasyona yol gösterecek formülleri ürettiler.

Literatürde FKM'lerin malzeme dağılımını belirleyen kompozisyonel gradyant üst değerinin tahmini veya gerçek değeri üzerine çok sayıda çalışma yapılmaktadır. Kompozisyonel gradyant üst değerinin optimizasyonu ile ağır çalışma şartları için ideal malzeme mukavemeti sağlanabilmektedir. GA ve YSA gibi literatürde sıkça yer alan yapay zeka yöntemleri ile birlikte çeşitli varyasyonlarla geliştirilen hibrit optimizasyon yöntemleri sayesinde yüksek değerde FKM tasarım çalışmaları devam etmektedir. Bu çalışmada henüz seri üretimi gerçekleştirilemeyen ve yüksek sıcaklık uygulamalarında sıkça kullanılan FK malzeme yapıları için daha önceden yapılan YSA çalışmalarında kullanılmayan eğitim algoritmaları değerlendirilerek performanslarının kıyaslanması amaçlanmıştır.

2. Materyal ve Metot

2.1. Fonksiyonel Kademelenirilmiş Dairesel Plaka

FKM'ler birbirinden farklı nitelikte malzemelerin bir hacimsel fonksiyona göre malzemede ara yüzey formasyonu oluşturmayacak ve bileşenlerin malzeme içindeki geçişleri kademeli olacak şekilde birleştirilmesi ile elde edilen henüz seri üretimi olmayan teknolojik malzemelerdir. Kademeli malzeme geçişi ile seri üretim ile üretilmiş standart malzemelerden farklı olarak malzemenin ara yüzey bölgesindeki malzeme süreksizliğine bağlı olarak meydana gelebilecek yapısal düzensizlikler ve ara yüzey çatlakları makul seviyeye indirgenebilmiştir. En uygun hacimsel dağılımı belirlerken malzemenin performansı/verimli çalışabilmesi ile birlikte gelişmiş termo-mekanik nitelikler de arzu edilmektedir. Bu özellikler optimum hacimsel kompozisyon ve kompozisyonel gradyant üst değerinin belirlenmesi ile mümkün olmaktadır .



Şekil 1. FK dairesel plaka [15]

Şekil 1'de FK dairesel plaka için radyal yönde kademelenirilmiş gösterilmiştir. Radyal kademelenirilmiş aşağıda gösterilen seramik malzemenin hacimsel dağılım formülü ile gerçekleştirilmiştir. $p = 0.5$ olup, periyodik fonksiyonun periyotudur.

$$V_s(\bar{r}) = \left(\frac{\bar{r}}{l_R}\right)^n \quad (1)$$

$$V_s^\theta(\theta) = (|\sin(p\theta)|)^m \quad (2)$$

R_i ve R_o sırasıyla plakanın iç ve dış yarıçapı olup $\bar{r} = r - R_i$, $l_R = R_o - R_i$ 'dir ve V_s , seramik malzemenin hacimsel oranını vermektedir. Radyal ve teğetsel yöndeki hacimsel oran denklem 1 ve denklem 2'de verilmektedir.

V_s ve V_m olarak verilen seramik ve metalin hacimsel dağılımına denklem 3 ve 4 ile ulaşılmaktadır;


$$V_s(\bar{r}, \theta) = V_s^r(\bar{r}, \theta) \cdot V_s^\theta(\bar{r}, \theta) \quad (3)$$

$$V_m(\bar{r}, \theta) = 1 - V_s(\bar{r}, \theta) \quad (4)$$

Hacimsel dağılımına bağlı olarak plakanın termal ve mekanik özellikleri Mori-Tanaka [16] şeması esas alınarak belirlenmiştir. Kısıklık adına problemin sayısal analiz ile ilgili diğer formülasyonlar [15-18] detaylı olarak yer almaktadır.

2.2. YSA Algoritması

Optimizasyon yöntemleri genellikle doğadaki canlıların var olma, organizasyon yapısı ve çalışma şekillerinden esinlenerek tasarlanmıştır. Hiyerarşik/organizasyonel yapı ve görev paylaşımları gibi süreçler göz önünde tutularak bunların en uygun sonuca ulaşma aşamaları gözlemlenmiştir. Bu optimizasyon yöntemlerinden biri olan YSA da insan beyninin sinirsel aktivitesi, bilgiyi işleme ve iletme şekli ve karar verme aşamaları düşünülerek ortaya çıkmıştır [19]. Bu süreçte bilgilerin/verilerin alınması, değerlendirilmesi, işlenmesi ve sonuca ulaşması aşamaları bulunmaktadır.



Şekil 2. YSA'nın basit bir nöron işleyiş modeli [25]

YSA yöntemi birden fazla giriş ve çıkış değeri olabilen lineer ya da non-lineer çeşitli problemlerin çözülmesinde geniş yer bulmaktadır. YSA giriş değerleri, nöron sayısı ve çıkış değerleri dikkate alınarak yapılandırılır. Şekil 2'de YSA'nın yapısında yer alan basit bir nöron için çalışma modeli gösterilmiştir. Nöronlara gelen giriş değerleri kümülatif toplam fonksiyonunda kullanılarak (denklem 5) net girdi oluşturulur ve Denklem 6'daki aktivasyon fonksiyonuna gönderilir. Denklem 5'te x giriş değerini, w ağırlık değerini ve b eşik değerini göstermektedir. Çalışmamızda aktivasyon fonksiyonu olarak sigmoid fonksiyonu tercih edilmiştir.

$$net\ girdi = \sum_{m=1}^m (x_i * w_i + b_i) \quad (5)$$

$$f(net\ girdi) = \frac{1}{1 + e^{-net\ girdi}} \quad (6)$$

Bu aşamaların sonucu olarak tahmini çıktı değerleri bulunur. Gerçek ile tahmini değerler arasındaki farkı ve yakınsamayı görebilmek için bir hata fonksiyonu belirlenmelidir. Denklem 7'de ortalama karesel hata fonksiyonu (RMSE) gösterilmiştir. Denklem 7'de yer alan y_d gerçek değer ve y_d tahmini değerdir.

$$e = \frac{1}{2} \sum_{m=1}^m (y_d - y)^2 \quad (7)$$

Problemimizde 4 farklı YSA eğitim algoritması ile modeller kurularak sonuçlar detaylı bir şekilde incelenmiştir.

L-M algoritması; YSA'nın kuruluş temelinde eğitim algoritmaları işlem yapar. Bu algoritmalar hep daha iyiyi bulmak için problem türüne göre iyileştirilmiştir. L-M algoritması hessian matrisindeki işlem sürecini ortadan kaldırmak için Gauss-Newton algoritması ve gradyant azaltma metodunun birleştirilmesiyle oluşturulmuştur [20]. Denklem 9 ve 10 'da H Hessian matrisini ve g gradyant formülleri gösterilmektedir [21]. Birçok geri beslemeli ağ türlerinin aksine L-M algoritması ileri beslemeli ağ türüdür ve performansı birçoğuna göre daha iyidir. Denklem 11'de J Jacobian matrisini, Denklem 14'te I birim matrisi ve μ marquardt katsayısını göstermektedir. Ağın performansını ikinci dereceden türevleri belirler. Bu algoritma Hessian matrisini hesaplamaya gerek duymadan gerçek değerlere daha yakın tahmini değerler üretmektedir [20].

$$x_{k+1} = x_k - H^{-1}g \quad (8)$$

$$g = \left[\frac{\partial E(w)}{\partial w_1} \quad \frac{\partial E(w)}{\partial w_2} \quad \dots \quad \frac{\partial E(w)}{\partial w_n} \right]^T \quad (9)$$

$$H = \begin{bmatrix} \frac{\partial E(w)}{\partial w_1^2} & \frac{\partial E(w)}{\partial w_1 \partial w_2} & \dots & \frac{\partial E(w)}{\partial w_1 \partial w_n} \\ \frac{\partial E(w)}{\partial w_2 \partial w_1} & \frac{\partial E(w)}{\partial w_2^2} & \dots & \frac{\partial E(w)}{\partial w_2 \partial w_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial E(w)}{\partial w_n \partial w_1} & \frac{\partial E(w)}{\partial w_n \partial w_2} & \dots & \frac{\partial E(w)}{\partial w_n^2} \end{bmatrix} \quad (10)$$

$$J = \begin{bmatrix} \frac{\partial e_1}{\partial w_1} & \frac{\partial e_1}{\partial w_2} & \dots & \frac{\partial e_1}{\partial w_n} \\ \frac{\partial e_2}{\partial w_1} & \frac{\partial e_2}{\partial w_2} & \dots & \frac{\partial e_2}{\partial w_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_n}{\partial w_1} & \frac{\partial e_n}{\partial w_2} & \dots & \frac{\partial e_n}{\partial w_n} \end{bmatrix} \quad (11)$$

$$H \cong J^T J \quad (12)$$

$$g = J^T e \quad (13)$$

$$x_{k+1} = x_k - [J^T J + \mu I]^{-1} J^T e \quad (14)$$

Geriye Yayılım Algoritması (Gradient Descent Backpropagation); YSA'nın bir çok alanda kullanılan bir eğitim algoritmasıdır. Öğrenme aşamalarında her nöron için gradyant azaltma tekniği uygulanır. Bu yöntemde çıkış değerlerinden giriş değerlerine doğru hata değerlerinin azaltılması işlemi yapılır [25]. Algoritmanın kuruluş mantığına göre hata oranları ve ağırlıklar kısmı türevler üzerinden işlenir ve tahmini değerlerin gerçek değerlere yakınsaması istenir. Bu algorithmada, ilk koşullar çok önemlidir ayrıca yakınsama hızı diğer algoritmalara nazaran yavaştır. İlk atanan ağırlık vektörleri hata değerine yakınsa öğrenme süreci hızlı olur. Öğrenme katsayısı "n" ile gösterilir ve 0.1-0.9 arasında bir değer alır [22]. GYA Denklem 15'te verilmiştir.

$$w_{ij} = w_{ij-1} + n \left(\frac{\partial e_{ij}}{\partial w_{ij-1}} \right) \quad (15)$$

Esnek Yayılım Algoritması (Resilient Propagation Algorithm); Riedmiller ve Braun tarafından geliştirilmiş olup amacı kısmi türevlerin olumsuz etkilerini öğrenme işleminden kaldırmaktır. Ağırlıkların tekrar hesaplanma yönü sadece türevlerin işaretlerine bakılarak yapılır. Yapılan bu işlem Esnek Yayılım Algoritmasını diğer algoritmalarından ayıran en önemli özelliktir. Bu özellik esnek yayılma denmiştir ve algoritmaya hızlı çözüme varma yeteneği kazandırmıştır. Her adımda hata fonksiyonu 'e' ve ağırlık

değişim değeri wa_{ij} 'nin bulunması ile süreç başlar ve ağırlık değişimleri Denklem 17'deki gibi değerlendirilir. η ve μ , $0 < \eta < 1 < \mu$ aralığında artma ve azaltma faktörleridir [23].

$$w_{ij} = \begin{cases} -wa_{ij}, \text{ eğer } \frac{\partial e_{ij}}{\partial w_{ij}} > 0 \\ +wa_{ij}, \text{ eğer } \frac{\partial e_{ij}}{\partial w_{ij}} < 0 \\ 0, \text{ aksi halde} \end{cases} \quad (16)$$

$$wa_{ij} = \begin{cases} \eta wa_{ij-1} wa_{ij-1}, \text{ eğer } \left(\frac{\partial e_{ij-1}}{\partial w_{ij-1}} \right) \left(\frac{\partial e_{ij}}{\partial w_{ij}} \right) > 0 \\ \mu wa_{ij-1}, \text{ eğer } \left(\frac{\partial e_{ij-1}}{\partial w_{ij-1}} \right) \left(\frac{\partial e_{ij}}{\partial w_{ij}} \right) < 0 \\ wa_{ij-1}, \text{ aksi halde} \end{cases} \quad (17)$$

Powell-Beale Yeniden Başlatma ile Eşlenik Gradyan Geri Yayılımı (Conjugate Gradient Backpropagation with Powell-Beale Restarts); algoritma, geriye yayılım algoritmasının değerlerini eğimin negatif yönünde dengeler ve eğim azaltım yöntemindeki doğrultulardan daha hızlı yakınsayan eşleştirme doğrultularında bir arama işlemi gerçekleştirir. Öğrenme oranı her bir iterasyonda güncellenir. İlk iterasyon negatif eğim değeri belirlendiği noktadan başlar. Fletcher-Reeves'in β_{ij} skaler değeri p_{ij-1} ve p_{ij} doğrultusunun performans fonksiyonunun ikinci dereceden türev değerleri ile eşleştirilmesi ile ulaşılır. Denklem 19'da β_{ij} güncelleme yaklaşımı gösterilmiştir [23].

$$p_{ij} = g_{ij} + \beta_{ij} p_{ij-1} \quad (18)$$

$$\beta_{ij} = \frac{g_{ij}^T g_{ij}}{g_{ij-1}^T g_{ij-1}} \quad (19)$$

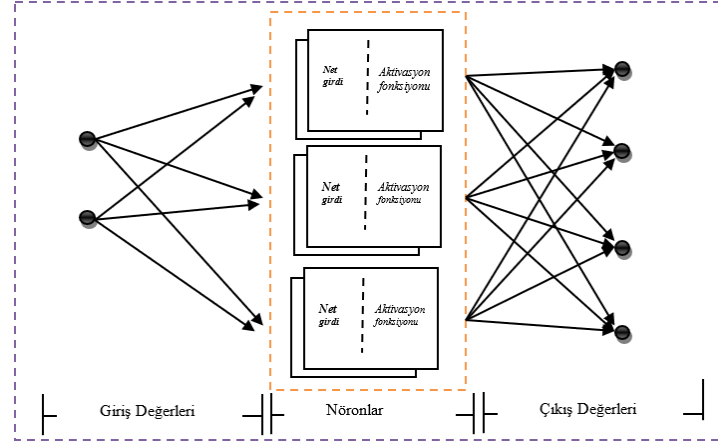
3. Problem Tarifi ve YSA ile Modelleme

3.1. Problemin Tarifi


Seramik (ZrO_2) ve metal (Ti-6Al-4V) olmak üzere iki farklı malzemenin birleşimi ile oluşturulan fonksiyonel kademelendirilmiş dairesel plaka n ve m kompozisyonel gradyant üst değerleri olmak üzere iki yönde kademelendirilmiştir. Hacimsel dağılıma etkisi olan kompozisyonel gradyant üst değeri göz önünde tutularak fonksiyonel kademelendirilmiş dairesel plakanın dış kenarı doğrultusunda 200 KW/m^2 ısı akısına maruz bırakılmış ve dış kenarda sıcaklık herhangi bir nokta da 1800 K olana kadar uygulanmıştır. Isı akısı tesirindeki plaka hem iç ve de dış kenarı boyunca sabitlenerek her iki yönde yer değiştirmeler engellenmiş böylece termo-mekanik etki oluşturulmuştur. Tariflenen sınır şartları için sonlu farklar metodu kullanılarak sayısal analizler yapılmış ve eş değer gerilme değerleri hesaplanmıştır. $[0.1-1]$ değer aralığında 112 farklı kompozisyonel gradyant üst değer için eşdeğer gerilme seviyeleri kullanılarak veri setleri oluşturulmuştur. Eşdeğer gerilme seviyelerinin; en büyük değerinin en büyüğü ve en küçüğü ile en küçük değerinin en büyüğü ve en küçüğü için veri setleri oluşturularak YSA analizleri ve sayısal çalışmalar için Matlab [24] programlama dili kullanılmıştır. Bu veri setleri ile YSA eğitim algoritmalarının performansı değerlendirilmiştir.

3.2. YSA ile Modelleme

YSA modelinde 112 farklı kompozisyonel gradyant üst değeri ile veri seti oluşturulmuştur. Bu veri seti değerleri eğitim ve test seti olarak yarı yarıya dağıtılmıştır. Dört farklı eğitim algoritması ile değerler karşılaştırılmıştır. Şekil 3'te gösterilen şekli ile YSA modelimizde tüm eğitim algoritmaları n ve m kompozisyonel gradyant üst değerleri olmak üzere iki giriş, tek katmanlı, üç nöronlu ve eşdeğer gerilme seviyelerinin; en büyük değerinin en büyüğü ve en küçüğü ile en küçük değerinin en büyüğü ve en küçüğü olmak üzere dört çıkış değerine sahiptir.




Şekil 3. YSA'da tek katmanlı ağ modeli [25]



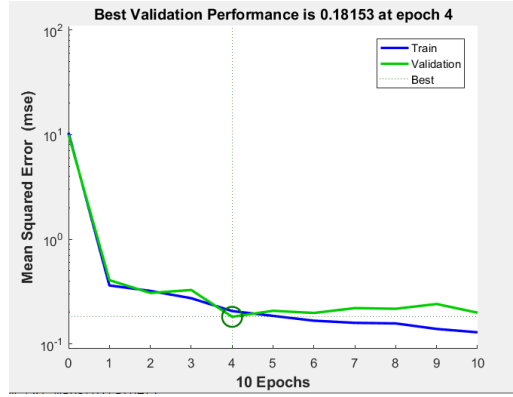
Şekil 4. L-M eğitim algoritması ile model tahmin değerleri

Belirlenen algoritmalarından L-M algoritması ile oluşturulan model için ağın eğitim ve test tahmin değerleri Şekil 4' de gösterilmiştir. Bu modelde çıkış verilerimiz, en iyi hedeflenen eğitim tahmin değerine %89 ve test tahmini değerine ise %83 oranında doğrulukla çözümüne ulaşmıştır.




Şekil 5. L-M algoritması ile kurulan model için gradyanın, momentumun ve başarısız doğrulamanın çevrim sayısına göre değişimi

Şekil 5' te gösterilen grafikler ışığında gradyan 0.15843, momentum 0.001, başarısız doğrulama 6, maksimum çevrim sayısı 10'dur. Şekil 6 çıkış verilerimizin hedeflenen eğitim, doğrulama ve tahmin değerinin 0.89 üzerinde bir değerle hesaplandığını göstermektedir. Burada çevrim sayısı arttıkça eğitim ile doğrulama tahmini hata değeri arasındaki farkın arttığı görülmüştür. En iyi doğrulama performansı ise 4 çevrim için 0.18153' tür.




Şekil 6. L-M algoritmasının performansı



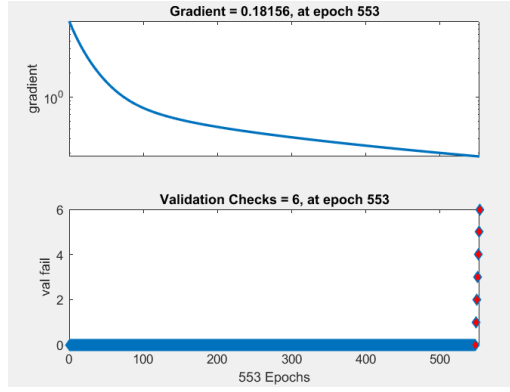
Şekil 7. L-M algoritması için tüm tahmin değerleri

Şekil 7’de L-M algoritmasının tüm tahmin değerleri gösterilmektedir. Burada eğitim için tahmin değeri 0.89042, doğrulama için tahmin değeri 0.89414 ve toplam tahmin değeri 0.89047’dir. Bu çalışmada çıkış verilerimize göre, en iyi hedeflenen eğitimi değeri, doğrulama değeri ve tüm tahmin değeri 0.88281 üzerinde tahmin ile hesaplanmaktadır. Bu durumda ağızımızın iyi eğitildiği anlaşılmaktadır.




Şekil 8. Geriye Yayılım Algoritması algoritması ile model tahmin değerleri

Geriye Yayılım Algoritması ile oluşturduğumuz model için Şekil 8’ de ağız eğitimi ve test tahmini değerlerini gösterilmektedir. Bu modelde çıkış verilerimiz, en iyi hedeflenen eğitim tahmin değeri olan %80’nin üzerinde bir değerle hesaplanmıştır. Test verilerinin gerçek verilere %77 oranında doğrulukla sonuca ulaşmıştır.




Şekil 9. Geriye Yayılım Algoritması ile eğitilen modelde gradyanın ve başarısız doğrulamanın çevrim sayısına göre değişimi

Şekil 9’ da Gradyant (Gradient) 0.18156 ve 553 çevrimde başarısız doğrulama değerleri 6’dır. Şekil 10 ’da çıkış verilerimizin, en iyi eğitim ve tahmin değerini %80’nin üzerinde bir değerle hesaplandığını göstermektedir. Bu algorithmada çevrim sayısı arttıkça eğitim ile doğrulamanın tahmini hata değerleri arasındaki fark değişmemektedir. En iyi doğrulama performansı ise 547 çevrim için 0.18156’ dır.




Şekil 10. Geriye Yayılım Algoritmasının performansı




Şekil 11. Geriye Yayılım Algoritması ile eğitilen model için tüm tahmin değerleri

Şekil 11’de Geriye Yayılım Algoritmasının tüm tahmin değerleri gösterilmektedir. Burada eğitim için tahmin değer 0.79237, doğrulama için tahmin değer 0.91716 ve toplam tahmin değer 0.80206 ‘dır.




Şekil 15. Esnek Yayılm Algoritması ile eğitilen model için tüm tahmin değerleri

Şekil 15’de Esnek Yayılm Algoritmasının tüm tahmin değerleri gösterilmektedir. Burada eğitim için tahmin değeri 0.81273 doğrulama için tahmin değeri 0.66415 ve toplam tahmin değeri 0.79111’dir.



Şekil 16. Powell-Beale Yeniden Başlatma ile Eşlenik Gradyan Geri Yayılmı ile model tahmin değerleri


Dördüncü olarak Powell-Beale Yeniden Başlatma ile Eşlenik Gradyan Geri Yayılmı algoritması ile kurulan model için Şekil 16’ da ağır eğitim ve test tahmin değerleri gösterilmiştir. Bu modelde çıkış verilerimiz, en iyi hedeflenen eğitim tahmin değerine %84 ve test tahmini değerine ise %80 oranında doğrulukla çözüme ulaşmıştır.




Şekil 17. Powell-Beale Yeniden Başlatma ile Eşlenik Gradyan Geri Yayılmı ile eğitilen model için gradyant ve başarısız doğrulamaların çevrim sayısına bağlı değişimi

Şekil 17’ de Powell-Beale Yeniden Başlatma ile Eşlenik Gradyan Geri Yayılmı kullanılarak oluşturduğumuz model için gradyant ve başarısız doğrulamaların çevrim sayısına bağlı değişimi gösterilmiştir. Gradyant (Gradient) 0.10751, başarısız doğrulama (validation fail) 6 ve maksimum çevrim sayısı (epochs) 44’tür.

Şekil 18 ’te çıkış verilerimizin, en iyi hedeflenen eğitim, doğrulama ve tahmin değerinin 0.84 üzerinde bir değerle hesaplandığını göstermektedir. Burada çevrim sayısı arttıkça eğitim ile doğrulama tahmini hata değeri arasındaki fark değişmemektedir. En iyi doğrulama performansı ise 38 çevrim için 0.37437’ dir.



Şekil 18. Powell-Beale Yeniden Başlatma ile Eşlenik Gradyan Geri Yayılımı algoritmasının performansı



Şekil 19. Powell-Beale Yeniden Başlatma ile Eşlenik Gradyan Geri Yayılımı algoritması ile eğitilen model için tüm tahmin değerleri

Şekil 19’da Powell-Beale Yeniden Başlatma ile Eşlenik Gradyan Geri Yayılımı’nın tüm tahmin değerleri gösterilmiştir. Burada eğitim tahmin değeri 0.84726, doğrulama tahmin değeri 0.78624 ve toplam tahmin değeri 0.84067’dir.

Tablo 1. Maksimum ve Minimum hata değerleri, MAE

Eş Değer Gerilme Seviyelerinin En Büyük Değerinin En Büyüğü	Maksimum Hata Değerleri	Minimum Hata Değerleri	MAE
L-M Algoritması	567.3049046	0.0884847	44.9600643
Geriy Yayılım Algoritması	583.7448404	2.6159451	73.6396777
Esnek Yayılım Algoritması	615.5700057	1.1184570	71.5189687
Powell-Beale Yeniden Başlatma ile Eşlenik Gradyan Geri Yayılımı Algoritması	663.3704551	1.3264837	98.5485152

Termo-mekanik analizimiz için belirlediğimiz eş değer gerilmelerin en büyük değerinin en büyüğü ve en küçüğü ile en küçük değerinin en büyüğü ve en küçüğü değerlerine bakılarak maksimum hata, minimum hata, RMSE ve MSE değerleri üzerinde değerlendirilmiştir. Tablo 1’de en büyük değerinin en büyüğü olan değer maksimum hata değeri Powell-Beale Yeniden Başlatma ile Eşlenik Gradyan Geri Yayılımı Algoritması’nda, minimum hata değeri L-M Algoritması’nda gözlemlenmiştir. Hatanın mutlak ortalamasına (Mean Absolute Error (MAE)) L-M Algoritması ulaşmıştır. Bu sonuçlar doğrultusunda en iyi performansı L-M Algoritması göstermiştir.

Tablo 2. Maksimum ve Minimum hata değerleri, MAE

Eş Değer Gerilme Seviyelerinin En Büyük Değerinin En Küçüğü	Maksimum Hata Değerleri	Minimum Hata Değerleri	MAE
L-M Algoritması	0.71700552	0,00008547	0.0438608
Geriy Yayılım Algoritması Algoritması	0.7752295	0.0002169	0.0705915
Esnek Yayılım Algoritması Algoritması	0:6980131	0.0004641	0.0520689
Powell-Beale Yeniden Başlatma ile Eşlenik Gradyan Geri Yayılımı Algoritması	0.7887164	0.0001396	0.653947

Tablo 2’de en büyük değerinin en küçüğü değerlerine bakıldığında maksimum ve minimum hata Powell-Beale Yeniden Başlatma ile Eşlenik Gradyan Geri Yayılımı Algoritması ulaşmıştır. Hatanın mutlak ortalaması (MAE) en iyi değerinin L-M Algoritması’nda olduğu gözlemlenmiştir.

Tablo 3. Maksimum ve Minimum hata değerleri, MAE

Eş Değer Gerilme Seviyelerinin En Küçük Değerinin En Büyüğü	Maksimum Hata Değerleri	Minimum Hata Değerleri	MAE
L-M Algoritması	0.0000338	0.0000002	0.0000113
Geriyeye Yayılım Algoritması	0.0000326	0.0000006	0.0000125
Esnek Yayılım Algoritması	0.0000291	0.0000006	0.0000122
Powell-Beale Yeniden Başlatma ile Eşlenik Gradyan Geri Yayılımı Algoritması	0.0000302	0.0000001	0.0000126

Tablo 3’te en küçük değerinin en büyüğü değerlerine bakıldığında maksimum hata değeri L-M Algoritmasında ve minimum hata değeri Powell-Beale Yeniden Başlatma ile Eşlenik Gradyan Geri Yayılımı Algoritmasında olduğu görülmüştür. Hatanın mutlak ortalaması (MAE) değerine bakıldığında performans olarak en iyi sonuca L-M Algoritması varmıştır. Malzemenin radyal yapısından dolayı nümerik analizde eşdeğer gerilme değerlerinin en küçüğünün en büyüğü değeri tüm kompozisyonel gradyent değerlerinde aynı sonuca ulaşmıştır. YSA’nın çıkış verilerine katkı sağlayacağı için bu değer eğitim algoritmalarında kullanılmıştır. Bu sebepten tüm eğitim algoritmalarında hassasiyet ve performansı yüksektir.

Tablo 4. Maksimum ve Minimum hata değerleri, MAE

Eş Değer Gerilme Seviyelerinin En Küçük Değerinin En Küçüğü	Maksimum Hata Değerleri	Minimum Hata Değerleri	MAE
L-M Algoritması	0.0017451	0.0000014	0.0005324
Geriyeye Yayılım Algoritması	0.0047502	0.0000635	0.0012881
Esnek Yayılım Algoritması	0.0057311	0.0000325	0.0012010
Powell-Beale Yeniden Başlatma ile Eşlenik Gradyan Geri Yayılımı Algoritması	0.0091208	0.0001633	0.0025756

Tablo 4’te en küçük değerinin en küçüğü değerlerine bakıldığında maksimum hatayı Powell-Beale Yeniden Başlatma ile Eşlenik Gradyan Geri Yayılımı, minimum hata değerini L-M Algoritması ve hatanın mutlak ortalaması (MAE) değerinde en iyi performansı L-M Algoritması göstermiştir.

4. Sonuç

Fonksiyonel kademelendirilmiş dairesel plaka için termal yüklemeye altında malzeme davranışını belirlemede önem arz eden eş değer gerilme seviyelerinin, mevcut sınır koşulları altında kompozisyonel gradyent üst değerinin belirlenmesi için YSA ile veri setleri oluşturulmuştur. YSA’da dört farklı eğitim algoritması için oluşturulan modeller ile bu algoritmaların performansı değerlendirilmiştir. Tüm eğitim algoritmalarında iki giriş verisi, dört çıkış verisi, tek katmanlı ve üç nöronlu model kullanılmıştır. Hatanın mutlak ortalaması, minimum hata, maksimum hata değerleri açısından uygulanan modellerin test ve eğitim değerlerine bakıldığında genel anlamda L-M Algoritması uygulanan diğer algoritmalara göre daha başarılı sonuç vermiştir. Dairesel plakada radyal yapıdan dolayı en küçüğünün en büyüğü eşdeğer gerilme değeri hep aynı çıktığı ve tüm eğitim algoritmalarının doğru sonuca ulaşmış olduğu görülmüştür. Buna rağmen eğitim algoritmalarına değer olarak katkı sağlayacağı için çalışmaya dahil edilmiştir. Kurulan modellerde CPU işlem sürelerini azaltılması ve doğru veriye en yakın değerle ulaşılması amaçlanmıştır. Termal gerilme probleminin Sonlu Farklar Metodu ile nümerik çözümü bir n ve m değeri için yaklaşık 2-3 gün sürebilirken, yapılan çalışma ile veri seti oluşturma süresi dahil edilmeksizin bu değere 1 saniyeden kısa sürede ulaşılmaktadır. Belirlediğimiz sınır koşulları altında kurulan model ile FKM’lerin hem üretiminde hem de yapılacak teorik çalışmalarında optimum hacimsel dağılıma ulaşmada fikir verici olacaktır. Yapılan çalışmada kullanılan eğitim algoritmaları için, probleme uyumu ve çözme becerisi ile termal gerilme analizindeki performansları dikkate alınarak daha sonraki çalışmalarda araştırmacılar için referans niteliğinde olacaktır.

Referanslar

- [1] Kakac S., Pramuanjaroenkij A., Zhou X.Y., “A review of numerical modeling of solid oxide fuel cells,” International Journal of Hydrogen Energy, 32(7).761-786, 2007, doi.org/10.1016/j.ijhydene.2006.11.028
- [2] Ruys A., Popov E., Sun D., Russell J., Murray C., “Functionally graded electrical/thermal ceramic systems,” Journal of the European Ceramic Society, 21(10-11). 2025-2029, 2001, doi.org/10.1016/S0955-2219(01)00165-0

- [3] Koizumi M., Niino M., "Overview of FGM research in Japan", *MRS Bulletin*, 20(1).19-21, 1995.
- [4] Cho J.R., Ha D.Y., "Optimal tailoring of 2D volume-fraction distributions for heat-resisting functionally graded materials using FDM." *Computer Methods in Applied Mechanics and Engineering*. 191 (29-30). 3195-3211, 2002. doi: 10.1557/S0883769400048867
- [5] Nemat-Alla M., "Reduction of thermal stresses by developing two-dimensional functionally graded materials," *International Journal of Solids and Structures*, 40(26). 7339-7356, 2003. doi: 10.1016/j.ijsolstr.2003.08.017
- [6] Ootao Y., Tanigawa Y., Nakamura T., "Optimization of material composition of FGM hollow circular cylinder under thermal loading a neural network approach." *Composites Part B: Engineering*. 30(4). 415-422 1999. doi: 10.1016/S1359-8368(99)00003-7
- [7] Khoshnoodi H., Yas M.H., Samadinejad A., "Dynamic Analysis of Multi-Directional Functionally Graded Panels and Comparative Modeling by ANN." *Journal of Solid Mechanics*, 8(3).482-494, 2016. Retrieved from http://jsm.iauarak.ac.ir/article_524265.html
- [8] Xu.Y., You.T., "Minimizing thermal residual stresses in ceramic matrix composites by using Iterative MapReduce guided particle swarm optimization algorithm." *Composite Structures*. 99. 388-396. 2013. doi: 10.1016/j.compstruct.2012.11.027
- [9] Singh A.K., Siddhartha, Hussain S., "Wear peculiarity of TiO₂ filled polyester-based Homogeneous composites and their Functionally Graded Materials using Taguchi methodology and ANN." *Materials Today: Proceedings*. 2. 2718 – 2727, 2015. doi: 10.1016/j.matpr.2015.07.239
- [10] Ghatage P.S., Kar V.R., P., Sudhagara E., "On the numerical modelling and analysis of multi-directional functionally graded composite structures: A review", *Composite Structures*, 236, 111837, 2020. doi.org/10.1016/j.compstruct.2019.111837
- [11] Na K.S., Kim J.H., "Volume fraction optimization for step-formed functionally graded plates considering stress and critical temperature", *Composite Structures*, 92(6):1283-1290, 2010. doi.org/10.1016/j.compstruct.2009.11.004
- [12] Demirbaş M.D., Çakır D., "Thermal stress control in functionally graded plates with artificial neural network." *ISVOS Journal*. 2(1). 39-55, 2018.
- [13] Khayat M., Baghlani A., Najafgholipour M.A., "A hybrid algorithm for modeling and studying of the effect of material and mechanical uncertainties on stability of sandwich FGM materials under thermal shock," *Composite Structures* 293, 115657, 2022. doi.org/10.1016/j.compstruct.2022.115657
- [14] Demirbaş M.D., Çakır D., Ozturk C., Arslan S., "Stress Analysis of 2D-FG Rectangular Plates with Multi-Gene Genetic Programming," *applied sciences*, 12,8198, 2022.
- [15] Demirbaş M.D. "Düzlem içi ısı yüküne maruz iki yönlü işlevsel kademelendirilmiş dikdörtgen ve dairesel plakanın ısı gerilme analizi." *Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Makine Mühendisliği*. 2012.
- [16] Mori, T., Tanaka, K., "Average stress in matrix and average elastic energy of materials with misfittings inclusions." *Acta Metallurgica*, 21(5): 517-574. 1973. doi.org/10.1016/0001-6160(73)90064-3
- [17] Apalak M.K., Demirbaş M.D., "Thermal Residual Stresses İn İn-Plane Functionally Graded Clamped Hollow Circular Plates", *Subjected To An Edge Heat Flux Proceedings Of The Institution Of Mechanical Engineers Part L-Journal Of Materials-Design And Applications*, 229:236-260. 2015. doi.org/10.1177/1464420713509
- [18] Apalak M.K., Demirbaş M.D., "Thermal residual stresses in adhesively bonded in-plane functionally graded clamped circular hollow Plates", *Journal Of Adhesion Science And Technology*, 27:1590-1623, 2013. doi:10.1080/01694243.2012.747732
- [19] Öztürk C. 2011. "Yapay Sinir Ağlarının Yapay Arı Kolonisi Algoritması ile eğitilmesi." *Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği*. 2011.
- [20] Hagan M.T., Menhaj M., "Training feed-forward networks with the Marquardt algorithm", *IEEE Transactions on Neural Networks*, 5(6)989-993. 1994.
- [21] Ümütlü R.C. Fault "Diagnosis of A Power Transmission System Using Artificial Neural Networks," *Dokuz Eylül Ege Üniversitesi Fen Bilimleri Enstitüsü. Yüksek Lisans, İzmir*, 104s. 2016.
- [22] Metrotra K., Mohan C.K., Ranka S., "Elements of artificial neural networks." 1997.
- [23] Haykin. S., "Neural networks". Prentice Hall. New Jersey. 2005.
- [24] MATLAB. Mathematical software, version 2009a, "TheMathWorks." Retrieved from <http://www.mathworks.com>.
- [25] Demirbaş M.D., Çakır D., "Modeling of 2D Functionally Graded Circular Plates with Artificial Neural Network", *ISVOS Journal*, 2020, 4(2): 97-110, 2020.