

# Modelling of One-directional Functionally Graded Circular Plates with Artificial Neural Network

Munise Didem Demirbaş<sup>a1</sup>, Didem Çakır<sup>b</sup>

<sup>a</sup>Erciyes Üniversitesi, Makine Mühendisliği Bölümü, Kayseri, Türkiye

<sup>b</sup>Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Kayseri, Türkiye

## Abstract

In functionally graded materials (FGMs), a combination is provided based on a volume ratio to prevent cracks in the interfaces of components and to prevent irregularities in the material transition region. The volumetric distribution between the components determines the mechanical performance of the FGMs. In this study, the thermo-mechanical behavior of the functionally graded circular plate (FGCPs) was investigated. The thermo-mechanical behavior depends on the equivalent stress values, and the equivalent stress values depend on the volumetric distribution of the components of the material, ie the compositional gradient upper values. Numerical analysis was performed for 60 different compositional gradient peaks in the range [0.01-5], models based on volumetric distribution were established and equivalent stress values were calculated. In the artificial neural network (ANN), three different training algorithms, Levenberg-Marquardt, Gradient Descent With Momentum Backpropagation and Gradient Descent With Adaptive Learning Rate Backpropagation, were created and compared. According to the results of the analysis, Levenberg-Marquardt algorithm showed an average success rate of over 90%. It is thought that the models installed in ANN will provide insight in determining the thermo-mechanical behavior of FGCPs and will save work-time.

**Keywords:** One-Directional Functionally Graded Circular Plates, Artificial Neural Network, Training Algorithms, Finite Difference Method, Termal Stress Analysis

## 1. Giriş

Bilgisayar teknolojisinin ve analiz yöntemlerinin gelişmesine paralel olarak ağır çalışma şartlarına mukavim malzeme üretebilmek için malzeme teknolojisi devamlı surette geliştirilmiştir. Günümüzde de yüksek sıcaklık uygulamalarına dayanıklı ideal malzeme için farklı malzemelerin mekanik özelliklerinden maksimum seviyede faydalanmak adına yeni bir malzeme ortaya çıkartılmış ve buna fonksiyonel kademelendirilmiş malzemeler denmiştir [1-3]. Metal ve seramikten oluşan fonksiyonel kademelendirilmiş malzemeler bir tarafı metal, diğer tarafı seramik ve geçiş bölgesi hacim fonksiyonuna bağlı değişen yapılarıdır. Malzemenin bu şekilde tasarlanması geçiş bölgesindeki malzeme süreksizliğine bağlı uyumsuzlukları ortadan kaldırmıştır. Termo-mekanik davranış FKM'yi oluşturan malzemelerin hacimsel dağılımına bağlıdır. Bu yüzden hacimsel dağılımı belirleyen kompozisyonel gradyant üst değerini belirlemek önem arz etmektedir [4-8].

Literatürde yapılan çalışmaların çoğu FGM'in termo-mekanik davranışlardaki uyumsuzlukları ortadan kaldırmak veya minimum seviyeye indirmek üzerine yoğunlaşmıştır. Bu çalışmalarda farklı sınır şartları altında değerlendirmeye alınmış ve farklı algoritmalarla optimum kompozisyonel gradyant üst değerine ulaşmak amaçlanmıştır. Literatürdeki bazı çalışmalar aşağıda detaylandırılmıştır.

Mantari ve Monge [9] fonksiyonel kademelendirilmiş sandviç plakaların serbest titreşim ve burkulma davranışını araştırdılar. Farklı kalınlıklardaki plakaların optimizasyonu için model oluşturdular ve bu medelin doğruluk oranının yüksek sonuçlara ulaştığını vurguladılar. Nemat-Alla, [10] iki yönlü fonksiyonel kademelendirilmiş malzemelerin termo-mekanik davranışını araştırdı. FGM' de optimum tasarımı elde etmek için sonlu elemanlar yöntemini kullandı. Yu ve Wu [11] kademelendirilmiş boruların gerçek dalga frekansını Legendre Polinomları ile hesapladılar. Oluşturdıkları veri kümesini Yapay sinir ağı (YSA) kullandılar. YSA'da eğitim algoritması olarak Levenberg-Marquardt algoritmasının kullanıp kompozisyonel gradyant üst değerine yüksek doğruluğa ulaştığını vurguladılar. Ootao ve arkadaşları [12] FKM'lerin optimizasyonunda yapay sinir ağı yöntemi ile doğrusal olmayan programlamayı (DOP) kıyasladılar. İki yönteme bakıldığında YSA'nın daha verimli sonuçlara ulaştığını gösterdiler. Ootao ve arkadaşları [13] fonksiyonel kademelendirilmiş içi boş bir kürenin termal gerilme davranışını araştırdılar. YSA yöntemini kullanarak gerilmenin minimizasyonu için optimum hacimsel dağılımı sundular. Nazari ve arkadaşları [14] FKM'lerin çekirdek ve kalınlık üzerindeki doğal frekansını Meshless Local Petrov-Galerkin (MLPG) yönteminde uygulayarak

<sup>1</sup> Sorumlu Yazar. Tel.: +0-90-545-835-84-75.; fax: +0-000-000-0000 .

E-posta adresi: [mddemirbas@erciyes.edu.tr](mailto:mddemirbas@erciyes.edu.tr)

gerçek değerlere ulaşılar. YSA yöntemi ile doğal frekansın optimum değerini araştırdılar. Turteltaub [15] termo-mekanik yük tesirindeki FKM'lerin kompozisyonel gradyant üst değerinin optimizasyonu üzerine çalıştı. Çok amaçlı optimizasyon yöntemini kullanarak kontrol ve yapısal optimizasyonu yaptı ve farklı sınır şartları için yeni bir malzeme kompozisyonu önerdi. Jodaei ve arkadaşları [16] üç boyutlu fonksiyonel kademelendirilmiş halka plakasının analizi için state-space based differential quadrature metodunu kullandılar. Optimizasyon için yapay sinir ağı algoritmasını kullandılar. Cho ve Ha [17] termal yük altındaki, fonksiyonel kademelendirilmiş malzemelerin termo-elastik davranışını, sonlu farklar metodunu kullanarak analiz ettiler. Farklı sınır şartları için iki boyutlu hacimsel dağılımın optimum değerini araştırdılar. Bölge ara yüzlerindeki en yüksek gerilmeyi minimize etmek için yapay sinir ağı algoritmasını kullandılar ve optimum kompozisyonu önerdiler. Na ve Kim [18] fonksiyonel kademelendirilmiş malzemelerde gerilme ve kritik sıcaklık değerlerini optime edecek kompozisyonel gradyant üs değerini araştırdılar. Üç boyutlu fonksiyonel kademelendirilmiş malzemenin sonlu elemanlar metodu ile termo-mekanik burkulma analizi için malzemede oluşan gerilme dağılımını optimum yapacak en uygun hacimsel dağılımı sundular. Cho ve Shin [19] yapay sinir ağı yöntemini kullanarak termal dayanımlı malzeme bileşiminin optimizasyonu üzerine çalıştılar. İç ceza fonksiyonu yöntemi ve altın oran yöntemini optimizasyon teknikleri olarak kullandılar. Sayısal deneyler sonucunda, yapay sinir ağları yönteminin, malzeme optimizasyonunda optimum tasarıma ulaşmada önemli bir yöntem olduğunu vurguladılar.

Apalak ve arkadaşları [20] üç boyutlu ve yapıştırıcıyla birleştirilmiş köşe bağlantısının optimum tasarımını YSA'da ve YSA ile birleştirilmiş Genetik Algoritmada bulmayı amaçladılar. Serbest titreşim analizlerinde ilk on doğal frekansı baz alarak sonlu elemanlar yönteminde YSA'nın eğitim verilerine ulaşılar. Her bir doğal frekans için maksimum doğal frekansın ve minimum modal gerilim enerjisinin optimum geometrik boyutlarını belirlemek için Genetik Algoritma ile YSA'yı birleştirildiler ve optimum tasarımı sundular.


Literatürde benzer sınır şartı ve düzlem boyunca kademelendirilen bir ve iki yönde fonksiyonel kademelendirilmiş dikdörtgen plakaların YSA ile ve Genetik programlama (GP) ile modelleri oluşturulmuştur [21-23]. Ancak bu çalışmalarda problem geometrisi farklıdır. Literatürde FKM ve YSA ile ilgili yapılan çalışmalarda dairesel plakaların düzlem boyunca kademelendirildiği ve sayısal çözüm yöntemi olarak sonlu farklar metodunun kullanıldığı çalışmalara rastlanmamıştır. Dolayısıyla bu çalışmamız literatüre katkı sağlayacak niteliktedir.

Bu çalışmada, plakanın kademelendirmesi düzlem boyunca yapılmış ve belirli ısı ve yapısal şartlara sahip dairesel plakalar için termal gerilme analizi sonuçlarında en önemli parametreler olan eşdeğer gerilme seviyeleri ve kompozisyonel gradyant üst değerleri kullanılarak yapay sinir ağı yöntemi ile verimli eğitilmiş bir model elde edilmiştir. Bu eğitilen model kullanılarak belirlenen aralıktaki kompozisyonel gradyant üst değeri için eşdeğer gerilme seviyelerinin en büyük değerinin en büyüğü, en büyük değerinin en küçüğü en küçük değerinin en büyüğü ve en küçük değerinin en küçüğü değerleri bulunabilmektedir.

## 2. Materyal ve Metot

### 2.1. Fonksiyonel Kademelendirilmiş Malzemeler ve Dairesel Plaka

Geleneksel yöntemlerle üretilen malzemeler ihtiyaçları karşılayamaz hale geldiğinden günümüz şartlarında kullanılacak malzemeleri üretmek amacı ile kademeli malzemeler düşünülmüştür. FKM'ler birden fazla malzemenin bir hacim fonksiyonuna bağlı olarak mikro yapıda birleştirilmesi ile elde edilir. Çünkü geleneksel kompozitlerde katmanlar arasındaki geçiş bölgelerinde malzeme süreksizliklerine bağlı olarak ara yüzey çatlakları meydana gelmektedir. Kademelendirilmiş malzemeler kullanarak ara yüzey geçiş bölgesindeki süreksizlikler ve buna bağlı olarak meydana gelen ara yüzey çatlakları minimum düzeye indirgenebilmiştir. Bu malzemelerde ihtiyaç duyulan özelliklerin sağlanması için kademelendirilmiş malzeme tasarlanırken aynı zamanda malzeme bileşiminde ekonomiklik, fonksiyonellik ve malzemenin elastik sınırlar içerisinde çalışması gibi özellikler gereklidir. Bu sayılan özellikler ancak optimum hacimsel bileşimin yani kompozisyonel gradyant üs değerinin belirlenmesi ile sağlanır. Sınır şartları belirli bir problem için malzemenin hacimsel dağılımını belirlemede kompozisyonel gradyant üs değeri oldukça önemlidir.



Şekil 1. Fonksiyonel kademlendirilmiş dairesel plaka[25]

Fonksiyonel kademlendirilmiş dairesel plakanın kademlendirilmesi Şekil 1’de görüldüğü gibi radyal yönde yapılmıştır [24]. Bu kademlendirilme ise aşağıdaki Seramik malzemenin hacimsel dağılımını gösteren formül ile gerçekleştirilmiştir.

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

Burada  $V_c$ , seramik hacim oranı,  $R_o$  ve  $R_i$  sırasıyla plakanın dış ve iç yarıçapı olup  $l_R=R_o-R_i$ 'dir.  $\bar{r} = r - R_i$  ve  $n$  [0.001-5] aralığındaki kompozisyonel gradyan üst değeridir.


Metal hacimsel dağılımını gösteren formül  $V_m$  olmak üzere;

$$V_m(\bar{r}) = 1 - V_c(\bar{r}) \quad (3)$$

Olarak değişmekte olup, plakanın hacim oranlarına bağlı olarak termal ve mekanik özellikleri Mori-Tanaka [25] şeması esas alınarak belirlenmiştir. İlgili formülasyonlar daha önce yapılan çalışmalarımızda mevcuttur [21-24, 26-28]. Bu çalışmanın temel amacı YSA ile oluşturulan modellerin kullanılması olup bu kısım aşağıda detaylandırılmıştır.

## 2.2. Yapay Sinir Ağı Algoritması

İnsan beyinde yer alan öğrenme, çıkarım yapma, yöntem geliştirme ve karar verme gibi süreçlerin bilgisayar dilinde modellenmesi ile yapay zeka yöntemleri geliştirilmiştir. İnsanda mükemmel bir beyin-zeka gelişimi ancak iyi bir öğrenme veya öğrenme tekniği ile gerçekleşir. Bilgisayar teknolojilerinde öğrenme tekniği en fazla Yapay Sinir Ağı’nda kullanılmaktadır [29].



Şekil 2. Basit Bir Yapay Sinir Hücresi [30]

Literatürdeki uygulamalar incelendiğinde, YSA'ların çok boyutlu, karmaşık, kusurlu, kesin olmayan, eksik vs. veriler olması durumunda program etkin çalışmaya devam eder. Problemi çözmek için matematiksel modelin ve algoritmaların bulunmadığı, sadece veri kümesinin olduğu durumlarda daha çok tercih edildiği görülmektedir.

Şekil 1’de basit bir YSA hücresi sunulmuştur. Hücreye gelen bilgiler ağırlıklı olarak kümülatif toplanır. Daha sonra net girdi hesaplanması için fonksiyona gönderilir. Toplam fonksiyonu denklem 4’de gösterilmiştir. Burada  $x$ ,  $w$  ve  $b$  sırasıyla giriş değeri, ağırlık vektörü ve eşik değeridir.

$$girdi(net) = \sum x_i w_i + b_i \quad (4)$$

Net girdinin hesaplanması için aktivasyon fonksiyonu belirlenir ve bu fonksiyon belirlenirken genellikle doğrusal olmayan fonksiyon tercih edilir. En yaygın kullanılan fonksiyon ise sigmoid fonksiyonu olup aşağıda verilmektedir. Burada  $f$  ve  $e$  sırasıyla sigmoid fonksiyonu ve hata vektörüdür.

$$f = \frac{1}{1 + e^{-x}} \quad (5)$$

Öğrenme, tahmini değerlerin gerçek değerlere yaklaşmasıdır ve bu yaklaşım oranını ölçmek için bir hata fonksiyonu belirlenir. Aşağıda hata fonksiyonu ( $E$ ) verilmektedir. Burada  $y_d$  ve  $y$  sırasıyla programın hedeflenen çıktısı ve programın gerçek çıktı değerleridir.

$$E = \frac{1}{2} \sum_{m=1}^m (y_d - y)^2 \quad (6)$$

Çalışmamızda literatürde yaygın olarak kullanılan ve aşağıda detayları verilen 3 farklı eğitim algoritması ile problemimiz değerlendirilmiştir.

**Levenberg-Marquardt (LM) algoritması** Gauss-Newton algoritmasıyla gradyant azaltma metodunun birleştirilmesiyle ortaya çıkan bir algoritmadır. Bu algoritma Hessani matrisinin hesaplanmasına gerek duyulmadan Gauss-Newton algoritmasına göre daha doğru sonuçlara ulaşmaktadır ve bu matriste ağırlık performansını ikinci dereceden türevleri belirlemektedir. LM algoritması ileri beslemeli ağlarda kullanılan en hızlı öğrenme metodudur [31]. Bu algoritmanın kullanıldığı denklemler aşağıda yer almaktadır. Burada  $H$  Hessani matrisi,  $I$  birim matris,  $\mu$  kombinasyon katsayısıdır.  $J$  Jacobian matrisini göstermektedir.

$$H = J^T J \quad (7)$$

$$g = J^T e \quad (8)$$

$$x_{k+1} = x_k - [J^T J + \mu I]^{-1} J^T e \quad (9)$$

**Momentum Katsayılı Geriye Yayım algoritması (Gradient Descent With Momentum Backpropagation-MGY)** gradyant azaltma tekniği kullanarak geriye yayılım algoritması oluşturulmuştur. Rumelhart geriye yayım algoritmasına momentum katsayısı eklenerek yeni denklem elde etmiştir [32]. Ağırlık fonksiyonu aşağıda detaylandırılmıştır. Denklem 10’da  $\alpha$  momentum ve  $n$  ağırlık katsayısı,  $E$  hata değeridir. Öğrenme katsayısı  $n$  olup, her problem için farklı belirlenir ama genelde 0.1-0.9 arasında seçilir [33].

$$w_t = w_{t-1} + n \left( \frac{\partial E_t}{\partial w_{t-1}} \right) + \alpha \Delta w_{t-1} \quad (10)$$

Geriye yayılım algoritmasına momentum teriminin eklenmesi ile yakınsama hızı artar ve yerel minimuma takılma olasılığı azalır [34].

**Adaptif Geriye Yayım algoritması (Gradient Descent With Adaptive Learning Rate Backpropagation-AGY)** Öğrenmenin güncellenmesi gradyant azaltma yönünde ağırlıkların hata ve hata türevlerinin işlevi olan öğrenme oranı belirler. Denklem 11’de hata fonksiyonu aşağıda detaylandırılmıştır. Burada  $P(E)$ , hata fonksiyonudur [35].

$$w_t = w_{t-1} + p(E) \left( \frac{\varphi_t}{\|\varphi_t\|^2} \right) \quad (11)$$


### 3. PROBLEM TARİFİ VE YSA İLE MODELLEME

#### 3.1. Problemin Tarifi

Tek yönde fonksiyonel kademelendirilmiş dairesel plaka sabit ısı akısına  $200\text{KW/m}^2$  seramik ( $\text{ZrO}_2$ ) ve metal (Ti-6Al-4V) olmak üzere iki farklı malzeme kullanılmıştır. Hacimsel dağılımını belirleyen en önemli ölçüt olan kompozisyonel gradyan üst değerleri göz önünde bulundurularak eşdeğer gerilme değerleri hesaplanmıştır. 60 farklı kompozisyonel gradyan üst değeri için sonlu farklar metodu ile eşdeğer gerilme değerlerine ulaşılmıştır. FKM'lerin termo-mekanik davranışını belirleyen eşdeğer gerilme değerleri en büyük değerinin en büyüğü, en büyük değerinin en küçüğü, en küçük değerinin en büyüğü ve en küçük değerinin en küçüğüdür. Sayısal yöntemde elde edilen değerlere bakıldığında bu eşdeğer gerilme değerlerinin sadece en küçük değerinin en küçüğü farklılık gösterirken diğer değerler farklılık göstermemektedir. Bu durumun dairesel plakanın radyal yapıda olmasından kaynaklanmaktadır. YSA analizlerini ve sayısal yöntem çalışmaları Matlab [36] programlama dilinde oluşturulmuştur.


#### 3.2. YSA ile Modelleme

Yapay sinir ağı modelinde 60 farklı kompozisyonel gradyan üst değeri ile veri kümesi oluşturulmuştur. Bu veri kümelerinin yarısı eğitim seti, yarısı ise test seti olarak kullanılmıştır. Programımızın durdurma kriteri olarak verilerdeki doğrulama oranının %10 olması ve maksimum çevrim sayısının 1000 olması olarak belirlenmiştir. Şekil 3.' de görüldüğü gibi YSA modelimizde 3 farklı eğitim algoritmaları kullanılarak tek giriş, tek çıkış ve üç nörondan oluşan model oluşturulmuştur.



Şekil 3. Tek katmanlı yapay sinir ağı modeli


Eğitim tahmini değerler Şekil 4'te gösterilmektedir. LM algoritması % 99,9 MGY algoritması % 71.389 ve AGY % 40.627 doğrulukla çözüme ulaşmıştır. Üç farklı algoritmanın eğitim işleminin sonlanması ile Levenberg-Marquardt (LM) algoritmasının eğitim performansının daha iyi olduğu görülmüştür.




Şekil 4. Yapay sinir ağının eğitim tahmin değerleri 1) LM, 2) MGY, 3) AGY

Şekil 5'te test kümesi ile analizden çıkan oranlar gösterilmiştir. LM algoritması % 85.6, MGY algoritması % 95.54 ve AGY algoritması % 28.045 oranlarında bulunmuştur. Eğitim algoritmalarının test performanslarına bakıldığında MGY algoritmasının

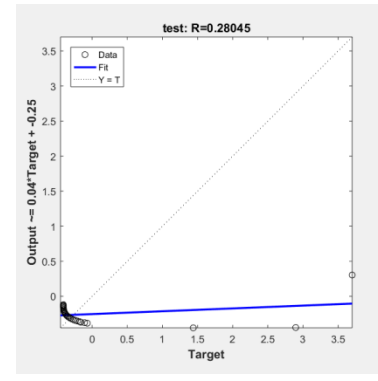
sonuçlara yaklaşımının daha iyi olduğu görülmektedir. Fakat eğitim ve test değerleri aynı anda değerlendirildiğinde Levenberg-Marquart (LM) algoritmasının performansı daha iyi olmuştur.



1




2




3


Şekil 5. Yapay sinir ağının eğitim tahmin değerleri 1) LM, 2) MGY, 3) AGY



1




2




3

Şekil 6. Yapay sinir ağının eğitim tahmin değerleri 1) LM, 2) MGY, 3) AGY

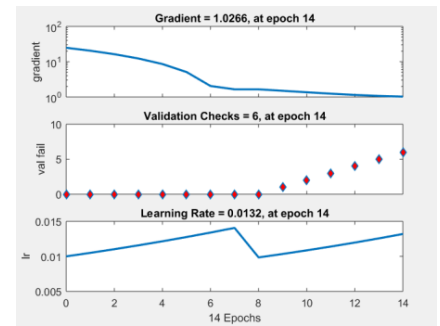
Yapay sinir ağının durdurma kriterleri hata değeri, doğrulama sayısı ve çevrim sayısıdır. Hata fonksiyonu olarak ortalama kareli hata (Mean Square Error (MSE)) formülü tercih edilmiştir. Modellerin en iyi doğrulama performansları Şekil 6'da görülmektedir. Hata değerleri; LM algoritması için 0.0000541, MGY algoritması için 0.0138 ve AGY için 0.0130 olmuştur. Doğrulama performansına en kısa sürede MGY algoritması ulaşmıştır.



1



2



3

Şekil 7. Yapay sinir ağının eğitim tahmin değerleri 1) LM, 2) MGY, 3) AGY

Şekil 7'de gradyant azaltma, gradyant, öğrenme katsayısı ve başarısız doğrulamanın çevrim sayısına bağlı değişimi gösterilmektedir. LM algoritmasının gradyant (Gradient) 0.000042, öğrenme katsayısı (lr) 0.0000001, başarısız doğrulama (validation fail) 6'dır. AGY algoritmasında gradyant (Gradient) 4.0731 ve başarısız doğrulama (validation fail) 6'dır. MGY algoritmasında gradyant (Gradient) 1.0266, öğrenme katsayısı (lr) 0.0132, başarısız doğrulama (validation fail) 6'dır.

**Tablo 1. Momentumlu Geriye Yayılım Algoritmasının hata değerleri**

	GERÇEK	HATA DEĞERLERİ		
	$\sigma_{eqv}$	LM	MGY	AGY
0.02	0.00000073	0.00011868	0.00088002	0.00220730
0.14	0.00004994	0.00003491	0.00097003	0.00166388
0.21	0.00018321	0.00000092	0.00091543	0.00123618
0.34	0.00086962	0.00005821	0.00035938	0.00003883
0.38	0.00122951	0.00013208	0.00003421	0.00046133
0.45	0.00191362	0.00060509	0.00059575	0.00136645
0.50	0.00276940	0.00099957	0.00141785	0.00235998
1.00	0.01418460	0.01230531	0.01262517	0.01442577
1.50	0.03212278	0.00481533	0.03010233	0.03245541
3.00	0.03152172	0.02135955	0.02334842	0.03152999

Tablo 1’de sayısal yöntemle ulaşılan gerçek değerler ile YSA’dan çıkan sonuçlara göre hata değerleri bulunmaktadır. Eğitim algoritmalarının genel olarak durumları incelendiğinde ( $\sigma_{eqv}$ ) eşdeğer gerilmenin en küçük değerinin en küçüğüne LM algoritması ulaşmış olup minimum hata değeri 0.00000092 ve maksimum hata değeri 0.02135955 olmuştur. MGY algoritmasına bakıldığında minimum hata değeri 0.00003421 ve maksimum hata değeri 0.03010233 olmuştur. AGY algoritmasına bakıldığında ise minimum hata değeri 0.00003883 ve maksimum hata değeri 0.03245541 olarak bulunmuştur.

#### 4. Sonuç

Fonksiyonel kademelendirilmiş dairesel plakanın eş değer gerilme analizi tek katmanlı algılayıcı modelde üç farklı eğitim algoritmasında değerlendirilmiştir. Yapılan çalışmada dairesel plakanın [0.01-5] aralığında 60 farklı kompozisyonel gradyant üst değeri için sayısal analiz yapılmış olup sonlu farklar yöntemi ile eş değer gerilme değerleri hesaplanmıştır. Malzemelerin elastik dayanımını belirleyen önemli 4 farklı eşdeğer gerilme değerlerine bakıldığında, dairesel plakanın radyal yapısından kaynaklı en büyük değerinin en büyüğü ve en küçük değerinin en büyüğü birbirine eşit ve sabittir. Çünkü ısı akısı tesirindeki dairesel plaka kararlı ısı transferine geçmiştir. Bundan dolayı her katmandaki sıcaklık [0:2 $\pi$ ] aralığında aynı gözlenmektedir ve maksimum eşdeğer gerilme bileşenleri dış kenar boyunca aynı seviyelerdedir. İç kenara doğru ısı akısının tesir ettiği bölge azalmakta ve buna bağlı olarak farklı büyüklüklerde minimum eşdeğer gerilme seviyeleri gözlenmektedir. Buna bağlı olarak eşdeğer gerilmenin en küçük değerinin en küçüğünün ile en büyük değerinin en küçüğünün büyüklükleri değişkendir. Bu sebeple YSA’da kurulan model başlangıçta tek giriş ve dört çıkışlı olmasına rağmen dairesel plakanın geometrik özelliklerinden dolayı çıkış sayısı azalmıştır.

Üç farklı eğitim algoritmasında yapılan değerlendirme ile hata oranları (MSE) değerleri LM için 0.00354157, MGY için 0.00757823 ve AGY için 0.00821215’dir. Tablo 2’de eğitim algoritmalarının MSE, minimum ve maksimum hata değerleri gösterilmiştir. Genel olarak değerlendirme yapıldığında, fonksiyonel kademelendirilmiş dairesel plakanın belirlediğimiz sınır koşulları altında Levenberg- Marquart Algoritması ile ortalama %90 üstü eğitim ve test değerlerine performansı göstermiştir.

**Tablo 2. MSE, minimum ve maksimum hata değerleri**

	LM	MGY	AGY
MSE	0.00354157	0.00757823	0.00821215
Minimum	0.00000092	0.00003421	0.00003883
Maksimum	0.02135955	0.03010233	0.03245541

#### Referanslar

[1] Ruys A., Popov E., Sun D., Russell J., Murray C., “Functionally graded electrical/thermal ceramic systems”, Journal of the European Ceramic Society, vol. 21, no.10-11, pp.2025-2029, December 2001. Doi: DOI: 10.1016/S0955-2219(01)00165-0

[2] Kakac S., Pramuanjaroenkij A., Zhou X.Y., “A review of numerical modeling of solid oxide fuel cells”, International Journal of Hydrogen Energy, vol.32, no.7, pp.761-786, May, 2007. Doi: 10.1016/j.ijhydene.2006.11.028

- [3] Koizumi M., Niino M., “Overview of FGM research in Japan”, MRS Bulletin, vol.20, no.1, pp.19-21, January, 1995. Available: <https://doi.org/10.1557/S0883769400048867>
- [4] Shabana Y.M., Noda N., “Thermo-elastic-plastic stresses in functionally graded materials subjected to thermal loading taking residual stresses of the fabrication process into consideration”, Composites Part B: Engineering, vol.32, no.2, pp.111-121, 2001. Doi: 10.1016/S0020-7683(97)00253-9
- [5] Praveen G.N., Reddy J.N., “Nonlinear transient thermoelastic analysis of functionally graded ceramic-metal plates. International Journal of Solids and Structures”, vol.35, no.33, pp.4457-4476, November 1998. Doi: 10.1016/S0020-7683(97)00253-9.
- [6] BOĞA C., “Elastic Analysis of an Hollow Cylinder Made from Functionally Graded Material Exposed to Internal Pressure”, ISVOS Journal, 2018, vol:2, no:1, pp: 56 – 66, june 2018, Availble: <https://dergipark.org.tr/bilmes/issue/38611/442417>.
- [7] Boğa C., Yıldırım V. “Direct application of the Complementary Functions Method (CFM) to the static analysis of rotating disks with both parabolic-varying thickness profile and functionally graded (FG) material” Research on Engineering Structures and Materials · January , April 2016 , vol:3, no:1, pp:11-25, DOI: 10.17515/resm2016.36me0129.
- [8] Demirbaş M.D., Recep Ekici R., Apalak M.K., “Thermoelastic analysis of temperature-dependent functionally graded rectangular plates using finite element and finite difference methods”, Mechanics of Advanced Materials and Structures, june 2018, vol:0, no:0, pp:1-18, DOI:10.1080/15376494.2018.1494871.
- [9] Xiang Y., Zhou Y., “A dynamic multi-colony artificial bee colony algorithm for multi-objective optimization”, Applied Soft Computing, vol.35, pp.766-785, October 2015. doi: 10.1016/j.asoc.2015.06.033
- [10] Nemat-Alla M., “Reduction of thermal stresses by developing two-dimensional functionally graded materials”, International Journal of Solids and Structures, vol.40, no.26, pp.7339-7356, December 2003. Doi: 10.1016/j.ijsolstr.2003.08.017
- [11] Ghannadpour S.A.M., Ovesy H.R., Nassirnia M., “Buckling analysis of functionally graded plates under thermal loadings using the finite strip method”, Computers & Structures, vol.108-109, pp.93-99, October 2012. Doi: 10.1016/j.compstruc.2012.02.011
- [12] Ootao Y., Kawamura R., Tanigawa Y., Nakamura T., “Neural network optimization of material composition of a functionally graded material plate at arbitrary temperature range and temperature rise”, Archive of Applied Mechanics, vol.68, no.10, pp. 662-676, 1998. Doi :10.1016/j.compstruc.2012.02.011
- [13] Ootao Y., Kawamura R., Tanigawa Y., Imamura R., “Optimization of material composition of nonhomogeneous hollow sphere for thermal stress relaxation making use of neural network”, Computer Methods in Applied Mechanics and Engineering, no.18, no. 1-2, pp. 185-201, November 1999. Doi : 10.1016/S0045-7825(99)00055-9
- [14] Ali M.M., Khompatporn C., Zabinsky Z.B., “A Numerical Evaluation of Several Stochastic Algorithms on Selected Continuous Global Optimization Test Problems”, Journal of Global Optimization, vol.31, no.4, pp.635-672, 2005. Available: <https://link.springer.com/article/10.1007/s10898-004-9972-2>
- [15] Turteltaub S., “Optimal control and optimization of functionally graded materials for thermomechanical processes”, International Journal of Solids and Structures, vol.39, no.12, pp.3175-3197, June 2002. Doi : 10.1016/S0020-7683(02)00243-3
- [16] Bouchafa A., Benzair A., Tounsi A., Draiche K., Mechab İ., Adda Bedia E.A., “Analytical modelling of thermal residual stresses in exponential functionally graded material system”, Materials & Design, vol.31, no.1, pp.560-563, January 2010. Doi : 10.1016/j.matdes.2009.07.010
- [17] 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, vol.191, no:29-30, pp.3195-3211, 2002. Doi : 10.1016/S0045-7825(02)00256-6
- [18] Na K.S., Kim J.H., “Volume fraction optimization for step-formed functionally graded plates considering stress and critical temperature”, Composite Structures, vol.92, no.6, pp.1283-1290, May 2010. Doi : 10.1016/S0045-7825(02)00256-6
- [19] Cho J.R., Shin S.W., “Material composition optimization for heat-resisting FGMs by artificial neural network”, Composites Part A: Applied Science and Manufacturing, vol.35, no:5, pp.585-594, May 2004. Doi : 10.1016/j.compositesa.2003.12.003



- [20] Apalak M.K, Ekici R., Yildirim M., “Optimal design of an adhesively-bonded corner joint with single support based on the free vibration analysis”, *Journal of Adhesion Science and Technology*, vol:20, no:13, pp:1507-1528, April 2006 DOI: 10.1163/156856106778666426
- [21] Demirbaş M. D., Çakır D. “Thermal Stress Control in Functionally Graded Plates with Artificial Neural Network”, *International Scientific And Vocational Journal*, Vol:2, no:1, pp:39-55, 2018, doi: 10.29137/umagd.485604
- [22] Demirbaş M. D., Çakır D. “Thermal Stress Analysis in Two-Directional Functionally Graded Plates with Artificial Neural Network Training Algorithms”, *International Journal of Engineering Research and Development* cilt.11, no.2, ss 442-450, June 2019. Doi : 10.29137/umagd.485604
- [23] Demirbaş M. D., Çakır D., Arslan S., Öztürk C “Equivalent stress analysis of functionally graded rectangular plates by genetic programming”, *International Scientific and Vocational Studies Journal*, cilt.2, ss.67-80, 2018. Available: <https://dergipark.org.tr/download/article-file/515242>
- [24] Demirbaş M. D., “Düzlem İçi Isıl Yüke Maruz Tek Yönlü İşlevsel Kademelendirilmiş Plaka ve Disk Bağlantılarının Isıl Gerilme Analizi”, *Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Makine Mühendisliği, Yüksek Lisans*, 2009.
- [25] Mori, T., Tanaka, K., 1973. “Average stress in matrix and average elastic energy of materials with misfittings inclusions.” *Acta Metallurgica*, 21(5): 517-574.doi: 10.1016/0001-6160(73)90064-3
- [26] 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*, Cilt.229, Ss.236-260, 2015.doi: 10.1177/1464420713509699
- [27] 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*, Cilt.27, ss.1590-1623, 2013.doi: 10.1080/01694243.2012.747732
- [28] Çakır D ,“Fonksiyonel Kademelendirilmiş Plakalarda Malzeme Kompozisyonunun Yapay Sinir Ağı ve Genetik Programlama İle Belirlenmesi”, *Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Makine Mühendisliği, Yüksek Lisans*, 2018
- [29] Öztürk C., “Yapay Sinir Ağlarının Yapay Arı Kolonisi Algoritması İle eğitilmesi”, *Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği, Ocak*, 2011.
- [30] Mannard M., Kronqvist J., Böling J.M., “Structural learning in artificial neural networks using sparse optimization”, *Neurocomputing*, vol.272, no.10, pp.660-667, 2018.
- [31] Hagan M.T., Menhaj M., “Training feed-forward networks with the Marquardt algorithm”, *IEEE Transactions on Neural Networks*, vol.5, no.6, pp.989-993, 1994.
- [32] Rumelhart D.E., Hinton G.E., Williams R.J., “Learning representations by backpropagation errors”, *Nature*, vol.323, pp.533-536, 1986.
- [33] Metrotra K., Mohan C.K., Ranka S., “Elements of artificial neural networks, 1997.
- [34] Oğuz M., “Yalıtkan malzemelerde elektiriksel dayanımın yapay sinir ağları ile belirlenmesi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, Elektrik Mühendisliği Haziran, 2001.
- [35] Parlos A.G., Muthusami J., Atiya A.F, “Incipient fault detection and identification in progress systems using accelerated neural network learning”, *Nuclear Technology*, vol.105, pp.145, 1994.
- [36] MATLAB. Mathematical software, version 2009a, TheMathWorks.Available: <http://www.mathworks.com.7>