



Yapay Sinir Ağı Eğitim Algoritmaları ile İki Yönlü Fonksiyonel Kademelendirilmiş Plakalarda Termal Gerilme Analizi

Thermal Stress Analysis in Two-Directional Functionally Graded Plates with Artificial Neural Network Training Algorithms

Munise Didem Demirbaş¹ , Didem Çakır² 

¹Erciyes Üniversitesi, Makine Mühendisliği Bölümü, Kayseri, TÜRKİYE

²Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Kayseri, TÜRKİYE

Başvuru/Received: 23/10/2018

Kabul/Accepted: 05/03/2019

Son Versiyon/Final Version: 30/06/2019

Öz

Fonksiyonel kademelendirilmiş malzemelerin (FKM) henüz seri üretiminin yapılmaması nedeniyle hacimsel dağılımının belirlenmesi oldukça önemlidir. Çünkü hacimsel dağılımın belirlenmesi ile malzemenin emniyetli gerilme sınırları belirlenmektedir. FKM yüksek sıcaklık tesirinde kullanılmakta olup termal gerilme sınırları oldukça önemli olmaktadır. Termal gerilme dağılımının ve seviyelerinin hesaplanması için ise sayısal analiz yöntemleri kullanılmaktadır. Bu çalışmada, 2B-FK plakaların ısı akısı tesirindeki termo-mekanik davranışının tespitindeki en önemli parametre olan eşdeğer gerilme seviyeleri için hacimsel dağılıma bağlı modeller sonlu farklar metodu (SFM) kullanılarak oluşturulmuştur. Bu modeller yapay sinir ağına (YSA) üç farklı eğitim algoritması ile elde edilmiştir.

Çalışmamızda, 2B-FK plakaların mevcut şartlar için farklı kompozisyonel gradyant üst değerlerin de eşdeğer gerilme seviyesinin belirlenebileceği modeller sunulmuştur. Bu modeller vasıtasıyla SFM göre 340 kat daha hızlı çözüm elde edilmektedir. Önerilen modeller henüz seri üretimi gerçekleştirilemeyen FKM hem üretiminde hem de yapılacak teorik çalışmalarda optimum hacimsel dağılıma ulaşmak için yol gösterici olacaktır. Yapılan çalışmada farklı eğitim algoritmaları için eğitim aşamaları, performans değerleri ve işlevsellikleri detaylı olarak incelenmiş ve yorumlanmıştır.

Anahtar Kelimeler

“2D-FKP, Yapay Sinir Ağı, Eğitim algoritmaları”

Abstract

It is very important to determine the volumetric distribution because Functionally Graded Materials (FGMs) are not mass-produced at present. By determining the volumetric distribution, the allowable stress limits of the material are also determined. FGMs are used in high temperature effects so thermal stress limits become very important. For the calculation of thermal stress distribution and levels, numerical analysis methods are used. In this study, the models based on volumetric distribution for the equivalent stress levels, which are the most important parameter for the determination of the thermo-mechanical behavior of the 2D-FG plates, were formed by using the finite difference method (FDM). These models were obtained by three different training algorithms in artificial neural network (ANN).

In this study, the models which can determine the equivalent stress level of different composition gradient exponent values for the existing conditions of the 2D-FGs are presented. These models provide 340 times faster solution than the FDM. Suggested models will be the guide to reach the optimum volumetric distribution in both production and theoretical studies of FGMs which cannot be mass-produced yet. In the study, the training stages, performance values and functionality of different training algorithms are examined and interpreted in detail.

Key Words

“2D-FGM, artificial neural network, training algorithms”

1. Giriş

Fonksiyonel kademelendirilmiş malzemeler (FKM) yüksek sıcaklık malzemesi olarak bundan üç dekat önce ortaya çıkmıştır. Bu malzemelerin bir tarafı metal diğer tarafı seramik olmak üzere geçiş bölgesi bir hacimsel fonksiyona bağlı olarak değişmektedir. Bu hacimsel fonksiyon seramikten metale yada metalden seramiğe geçişin hızını belirlemekte olup termo-mekanik performans ile oldukça ilgilidir. Bu sebepten birçok çalışma farklı mekanik tesir altındaki hacim oranının belirlenmesi üzerine yoğunlaşmıştır.

Fonksiyonel kademelendirilmiş malzemeler iki veya daha fazla malzemenin malzeme özelliklerinden faydalanılarak, makro ya da mikro yapıda birleşmesi ile meydana gelir. FKM'lerdeki ara yüzey çatlakları minimum seviyeye indirgenmiştir (Shabana ve Noda, 2001). FKM'lerde hacimsel dağılımın belirlenmesi için kompozisyonel gradyant üst değerinin belirlenmesi gerekir ve literatürde pek çok çalışma bu alanda odaklanmıştır (Koizumi ve Niino, 1995). Literatürdeki fonksiyonel kademelendirilmiş malzemelerin optimum kompozisyonunun belirlenmesi ile ilgili çalışmaların bazıları aşağıda verilmiştir.

Cho ve Ha, (2002) fonksiyonel kademelendirilmiş malzemenin termal yüklemeye altındaki termo-elastik davranışını sonlu farklar metodunu kullanarak incelediler. Farklı sınır şartları için iki boyutlu hacimsel dağılımın optimum değerini bulmayı amaçladılar. Ara yüzeylerdeki en yüksek gerilmeyi minimize etmek için YSA yöntemi ile model sundular. Moitaa ve arkadaşları, (2018). sayısal yöntem olarak sonlu elemanları kullanarak FKM'lerin yapısal dağılımını belirlediler. Analiz sonuçlarını kullanarak YSA'da model oluşturdular. Ootao ve arkadaşları, (1999) içi boş bir kürenin malzeme kompozisyonunun termal yüklemeye altında optimizasyonunu yaptılar. Optimizasyon yöntemi olarak yapay sinir ağı yöntemini kullandılar. YSA'nın doğruluğunu ölçmek için literatürde yaygın olarak kullanılan doğrusal olmayan programlama ile karşılaştırdılar. İlk verileri oluşturduktan sonra YSA'nın optimum sonuca hızlı ulaştığını tespit ettiler. Nemat-Alla, (2003) yüksek sıcaklık uygulamalarında kullanılabilmesi için iki boyutlu fonksiyonel kademelendirilmiş malzemelerin geliştirilmesi için çalıştı. Termal gerilme analizinde sonlu elemanlar yöntemini kullandı. Uza ve havacılık sanayisinde ihtiyacı karşılayacak optimum tasarımı sundu. Xu ve You, (2013) fonksiyonel kademelendirilmiş boruların Legendre yöntemi ile kritik frekansını hesapladılar. Optimizasyon yöntemi olarak YSA'yı kullandılar. Kurdukları modelde eğitim algoritması olarak Levenberg-Marquart algoritmasını kullandılar. Kompozisyonel gradyant üst değerinin gerçek değeri ile tahmini değerlerin oldukça yakın olduğunu ifade ettiler. Jodaei ve arkadaşları,(2012) üç boyutlu fonksiyonel kademelendirilmiş plakalar da sayısal yöntem olarak State-Space Based Differential Quadrature Metodu kullandılar. Optimum malzeme kompozisyonuna ulaşmak için YSA ile model kurdular. Demirbaş ve Çakır, (2018) fonksiyonel kademelendirilmiş plakaların optimum hacim oranını bulmak için YSA yöntemini kullandılar. Kurdukları modelin gerçek değerlere yakın olduğunu vurguladılar. Do ve arkadaşları, (2019) kalınlık yönünde fonksiyonel kademelendirilmiş plakanın burkulma ve serbest titreşim analizini yaptılar. Derin sinir ağı yöntemi ile modifiye simbiyotik organizma arama algoritmasını birleştirerek model kurdular. Yaptıkları çalışmayı izo-geometrik analiz ve modifiye simbiyotik organizma algoritmasında karşılaştırdılar ve kurdukları model ile optimizasyon sürelerinde önemli ölçüde tasarruf sağladılar. Salavati ve arkadaşları, (2015) fonksiyonel kademelendirilmiş yapıların kritik kırılma yükünü bulmayı amaçladılar. Sayısal yaklaşım olarak Strain Energy Density (SED) yöntemini kullandılar. Kritik kırılma yükünü belirlemede YSA yönteminin kullanışlı olduğunu ve iyi sonuçlar elde ettiklerini vurguladılar. Nazari ve arkadaşları, (2015) kompozit fonksiyonel kademelendirilmiş sandviç dikdörtgen plakaların üç boyutlu doğal frekansı üzerine çalıştılar. Çalışmalarında Petrov-Galerkin ve YSA yöntemlerini uyguladılar. YSA yönteminde ise geriye yayılım algoritmasını tercih ettiler. Singh ve arkadaşları, (2015) Kompozit malzemelerin aşınma durumunu incelediler. Onlar kompozit ve fonksiyonel kademelendirilmiş malzemeleri üretmek için mekanik karıştırma ve santrifüj tekniğini kullandılar. Geliştirdikleri malzemeleri Taguchi Yöntemi ve Varyans Analizi (ANOVA) ile analiz ettiler. Verileri doğrulamak için YSA'yı kullandılar. FKM'lerin üretilen tüm kompozitlere göre aşınma dirençlerinin iyi olduğunu buldular. Khsoshnoodi ve arkadaşları, (2016) çok yönlü kademelendirilmiş FKM'nin dinamik analizi için yarı analitik yöntem kullanarak nicel değerlere ulaştılar. SSDQM ile YSA yöntemini karşılaştırdılar. Başlangıçta verilere ulaşma zamanını dikkate almadan YSA'nın daha pratik olduğunu buldular.

2. Malzeme ve Metot


2.1 Fonksiyonel Kademelendirilmiş Malzemeler

Programlama ve bilişim teknolojilerinin ilerlemesi ve analiz yöntemlerinin gelişmesi ile birlikte malzeme teknolojisinde ileri düzeyde inovasyon ve yapısal varyasyon imkanları artmış ve pek çok ihtiyacı karşılayabilecek malzemeler üretilmiştir. Geleneksel malzemelerden farklı olan bu özel malzemelerden biri de fonksiyonel kademelendirilmiş malzemelerdir. Bu malzemeler yüksek sıcaklık tesirinde iyi mekanik dayanıma sahip olacak ve geçiş bölgesinde minimum ısı ve mekanik uyumsuzluk oluşturacaktır. Geleneksel kompozit malzemelerde katmanlar arasındaki geçiş bölgelerinde malzeme süreksizliklerine bağlı olarak ara yüzey çatlakları meydana gelmektedir. Kademelendirilmiş malzemelerle bu sorun ortadan kalkmış ve ara yüzey hataları önlenmiştir. FKM'lerde uygun yapısal özelliğinin sağlanabilmesi için seramikten metale veya metalden seramiğe geçiş bölgesinin hacim oranının yani kompozisyonel gradyant üst değerinin belirlenmesi oldukça önemlidir.

2.2 Yapay Sinir Ağı Algoritması (YSA)

Optimizasyon problemindeki zorluk seviyesi yükseldikçe optimum sonuca ulaşmak güçleşmekte ve zaman almaktadır. Bu sebeple problem çözümündeki zaman faktörünün önemi ve optimizasyon yönteminin yetersizliği gibi nedenlerle farklı optimizasyon teknikleri geliştirilmiştir. Bu nedenle geliştirilen optimizasyon yöntemlerinden biri de yapay sinir ağı algoritmasıdır. Yapay sinir

ağı, insan beyninin çalışma yapısında yer alan öğrenme, bilgi işleme, yöntem geliştirme ve karar verme gibi temel özelliklerin modellenmesi ve bilgisayar diline aktarılması yoluyla geliştirilmiştir (Öztürk, 2011). Yapay sinir ağı bu öğrenme özelliği sayesinde örneklerle ilgili bilgileri toplar ve yeni problem ile karşılaştırılınca öğrendiği bilgileri ağırlık katsayısı ile verilere uygulayarak problemler hakkında karar verir. Bu gelişmiş sinir ağı yöntemi uzay-havacılık sistemleri, askeri uygulamalar, finansal veri işleme, kontrol teknikleri, araştırma uygulamaları gibi birçok alanda kullanılmaktadır.



Şekil 1. Basit bir yapay sinir hücresi

Şekil 1.'de yapay sinir ağı hücresinin basit bir gösterimi çizilmiştir. Şekilde gösterildiği gibi hücreye giriş verileri toplam fonksiyonuna gönderilir. Literatürde birçok toplam fonksiyonu bulunmaktadır. Toplam fonksiyonlarından en çok kullanılan kümülatif toplam fonksiyonudur. Bundan dolayı çalışmamızda bu fonksiyon tercih edilmiştir. Toplam fonksiyonunda x, a ve b sırasıyla giriş değeri, ağırlık vektörü ve eşik değeridir.

$$net = \sum x_i a_i + b_i \quad (I)$$

Toplam fonksiyonundan üretilen değer aktivasyon fonksiyonuna aktarılır ve net girdi değeri üretilir. Literatürde pek çok aktivasyon fonksiyonu kullanılmaktadır ve genellikle doğrusal olmayan sigmoid fonksiyonu tercih edilmiştir. Denklem II'de sigmoid fonksiyonu gösterilmiştir.

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

Öğrenme işlemi ise, üretilen tahmini değerlerle gerçek değerler arasındaki hata değerinin hesaplanması ve bu hata değerinin beklenen hata düzeyine kadar devam etmesi işlemidir. Bu çalışmamızda ortalama kareli hata fonksiyonu, hata değerinin hesaplanması için seçilmiştir. Denklem III'de ise, hata fonksiyonunda (E), tahmini değer (y_d) ve gerçek değer (y) arasındaki fark hesaplanarak belirlenen uygunluk değeri hesaplanmaktadır.

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

Momentum Katsayısı Geriye Yayılım Algoritması (Gradient Descent with Momentum Backpropagation (MGY): Rumelhart ve arkadaşları tarafından geliştirilen bir öğrenme algoritması olan geriye yayılım algoritması nöronlarda gradyan azaltma tekniğini kullanmaktadır (Rumelhart D.E. ve arkadaşları (1986)). Rumelhart'ın bu algoritması geliştirilerek formülüne momentum katsayısı eklenerek momentum katsayılı geriye yayılım algoritmasını geliştirmiştir (Parlos ve arkadaşları, 2017). Denklem IV'de ise, momentum katsayılı geriye yayılım algoritmasının fonksiyonu verilmiştir. Burada α momentum katsayısıdır. Momentum katsayısı genelde $0 < \alpha < 1$ arasında belirlenir. Bu katsayının eklenmesi yakınsama hızını artırır ve yerel minimuma takılma olasılığını azaltır (Haykin. S. (2005)).

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


Adaptif Geriye Yayılım Algoritması (Gradient Descent with Adaptive Learning Rate Backpropagation (AGY): bu algoritma geriye yayılım yönünde ağırlık değerlerini hata ve hata türevlerinin işlevi olan öğrenme oranını güncellemektedir. AGY'de kullanılan hata fonksiyonu aşağıda detaylandırılmıştır. Burada $p(E)$, hata fonksiyonudur (Parlos ve arkadaşları, 2017).

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

Momentumlu Adaptif Geriye Yayılım Algoritması (Gradient Descent with Momentum Adaptive Learning Rate Backpropagation (MAGY): Adaptif Geriye Yayılım Algoritması üzerinde değişiklikler yapılarak Momentumlu Adaptif Geriye Yayılım Algoritması (MAGY) oluşturulmuştur. Algoritmalar arasındaki fark n öğrenme katsayısı gradyanının karesi yerine kendisine bölümünden ibaret olmasıdır. Ayrık zaman aralığında bu algoritmanın, Adaptif Geriye Yayılım Algoritmasına göre daha iyi olduğunu tespit edilmiştir (Haykin, 2005). Denklem VI' de bu algoritmanın ağırlık fonksiyonu görülmektedir. Burada φ ise hata işlevinin ağırlık değerine göre türevidir.

$$w_t = w_{t-1} + n \left(\frac{\varphi_t}{\|\varphi_{t-1}\|} \right) \quad (VI)$$

3. YSA ile modelleme



Şekil 2. İki yönlü fonksiyonel kademelendirilmiş plaka

$$V_s(x, y) = \left(\frac{x}{l} \right)^n \left(\frac{y}{h} \right)^m \quad (VII)$$


$$V_m(x, y) = 1 - V_s(x, y) \quad (VIII)$$

Denklem VII ve VIII'de sırasıyla V_s seramik, V_m metal hacimsel dağılımı temsil etmektedir. Kompozisyonel gradyant üst değerleri ise n ve m olup sırasıyla x - ve y - yönündedir.

Bu çalışmada bir tarafı seramik (ZrO_2) bir tarafı metal (Ti-6Al-4V) olmak üzere iki farklı malzemedan oluşan fonksiyonel kademelendirilmiş dikdörtgen plaka kullanılmıştır. Bir kenarından düzlem içi ısı akısına maruz bırakılmış iki yönlü kademelendirilmiş plakanın termal gerilme analizinin sayısal sonuçları kullanılarak yapay sinir ağı ile hacim oranı için termal gerilme seviyelerini verecek modeller oluşturulmuştur. YSA'nın eğitim verilerine ulaşmak için sayısal bir yöntem olan sonlu farklar metodu ile nicel verilere ulaşılmıştır. Termo-mekanik analizde malzemenin dayanımını belirleyen en önemli kısıt eşdeğer gerilme seviyeleridir. Bundan dolayı eğitim setinde eş değer gerilme değerlerinin en büyüğünün en büyüğü (σ_{eqv})₁, en büyüğünün en küçüğü (σ_{eqv})₂, en küçüğünün en büyüğü (σ_{eqv})₃ en küçüğünün en küçüğü (σ_{eqv})₄ olmak üzere dört farklı gerilme değeri seçilmiştir. [0.0001-1.5] aralığında rastsal olarak seçilen 200 farklı n ve m kompozisyonel gradyant üst değerlerine karşılık gelen (σ_{eqv})₁, (σ_{eqv})₂, (σ_{eqv})₃, (σ_{eqv})₄ eş değer gerilme seviyeleri dikkate alınarak model oluşturulmuştur.


Dört farklı çıktı bulunmaktadır. Şekil 3. kurulan YSA modeline göre çizilmiştir. Çalışmamızda aşağıdaki gibi Şekil 3. ve çıktılar detaylı bir şekilde aşağıda açıklanmıştır.

Tek katmanlı algılayıcı model için üç nöronla kurulan YSA modeli daha iyi performans göstermektedir. Bu sebepten iki giriş (rastsal alınan n ve m değerleri) ve dört (eş değer gerilme) çıkış değeri olan, tek katmanlı ve üç nöronlu oluşan yapay sinir ağı modeli kurulmuştur. Sayısal yöntemde ulaşılan veriler yani data setleri yapay sinir ağının eğitilmesinde kullanılmıştır (Çakır, 2018).




Şekil 3. İki yönlü fonksiyonel kademelendirilmiş plakının tek katmanlı yapay sinir ağı modeli

Programlama dilinde (Matlab,2009a) oluşturulan modelde analiz çalışmaları yapılmıştır. Yapay sinir ağı modelinde 200 verimiz %50 eğitim seti, %50 test seti olarak kullanılmıştır. YSA'nın doğrulama oranı %10 ve maksimum çevrim sayısı 1000 olarak belirlenmiştir.



Şekil 4. Yapay sinir ağının eğitim tahmin değerleri a) MGY, b) AGY, c) MAGY

Şekil 4'te eğitim tahmin değerleri gösterilmektedir. MGY algoritması % 98.381, AGY algoritması % 97.879 ve MAGY % 99.281 doğrulukla çözüme ulaşmışlardır. Üç farklı algoritmanın eğitim işleminin sonlandıktan sonraki dağılımına bakıldığında gerçek değerlerle uyum içerisinde olduğu görülmektedir. Modellerin performans değerleri beklenen değeri karşılamıştır.




Şekil 5. YSA'nın test tahmin değerleri a)MGY, b) AGY, c) MAGY

Eğitilmiş programda test kümesine gönderilen verilerden çıkan sonuçlardaki doğruluk oranı şekil 5'te gösterildiği gibidir. MGY algoritması % 98.137, AGY algoritması % 97.529 ve % 99.097 oranlarında bulunmuştur. Kurulan üç farklı modelin test kümeleri içerisindeki sonuçlarında bakıldığında MAGY diğer algoritmalara göre biraz daha iyi bir performans sergilediği görülmektedir.


Yapay sinir ağının çalışma mantığında durdurma kriterleri doğrulama sayısı, hata değeri ve çevrim sayısıdır. Modellerde literatürde yaygın olarak kullanılan ortalama kareli hata (Mean Square Error (MSE)) formülü tercih edilmiştir. Şekil 6'da modellerin en iyi

doğrulama performansları görülmektedir. Hata değerleri; MGY algoritması için 0.031805, AGY algoritması için 0.050505 ve MAGY için 0.013767'dir. Doğrulama performansına en kısa sürede MGY algoritması ulaşmıştır.

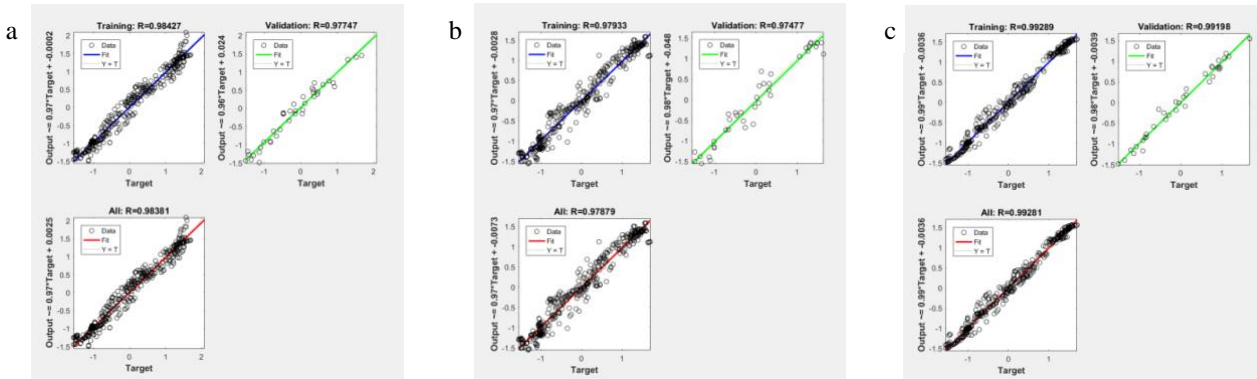


Şekil 6. Algoritmaların doğrulama performansı a)MGY, b) AGY, c) MAGY

YSA'da farklı algoritmalar türetilerek performans değerlendirilmesi yapılmıştır. Bu algoritmaların kuruluş mantığına göre çeşitli ölçütler kullanılmıştır. Şekil 7'de gradyant azaltma, öğrenme katsayısı ve başarısız doğrulamanın çevrim sayısına bağlı değişimi gösterilmektedir. MGY algoritmasının gradyant (Gradient) 0.07156, öğrenme katsayısı (lr) 1.41, başarısız doğrulama (validation fail) 6'dır. AGY algoritmasında gradyant (Gradient) 0.0336 ve başarısız doğrulama (validation fail) 0'dır. MAGY algoritmasında gradyant (Gradient) 0.09, öğrenme katsayısı (lr) 1.89, başarısız doğrulama (validation fail) 6'dır.



Şekil 7. YSA'nın gradyant, öğrenme katsayısı ve başarısız doğrulamanın çevrim sayısına bağlı değişimi a)MGY, b) AGY, c) MAGY



Şekil 8. YSA'nın eğitilen model için tüm tahmin değerleri a)MGY, b) AGY, c) MAGY

Şekil 8 iki yönlü fonksiyonel kademelendirilmiş plakada üç farklı eğitim algoritmasındaki tüm tahmin değerlerini göstermektedir. MGY algoritmasının eğitim için tahmin değeri 0.98427, doğrulama için tahmin değeri 0.97747 ve toplam tahmin değeri 0.98381'dir. AGY algoritmasını eğitim için tahmin değeri 0.97933, doğrulama için tahmin değeri 0.97477 ve toplam tahmin değeri 0.97879'dir. MAGY algoritmasını eğitim için tahmin değeri 0.99289, doğrulama için tahmin değeri 0.99198 ve toplam tahmin değeri 0.99281'dir. Üç algoritmanın sonuç dataları incelendiğinde gerçek değerlerle uyumlu olduğu görülmektedir. YSA'nın sonuçlarının 1'e yakın olması istenir fakat ezberci bir yaklaşımla çözüm anlamına geldiği için 1'e çok yakınsaması istenmez. Ezberci bir mantıkla kurulan YSA'da eğitim ve test veri kümelerinin dışındaki gönderilen verilerde aynı performansı göstermeyebilir. Şekil 8'de MGY ve MAGY algoritmalarının analiz değerlerinin çok iyi olduğu görülmekte fakat MAGY algoritmasının 1'e çok yaklaştığı için ezberci çözüm yaptığı düşünülmektedir.

Tablolarda algoritmaların performansı gerçek değerler ve gerçek değerlere ne kadar yaklaştığını belirten hata değerleri göz önünde bulundurularak oluşturulmuştur.

Tablo 1'de momentumlu geriye yayılım algoritmasının eş değer gerileme değerleri üzerindeki minimum ve maksimum hata değerleri gösterilmektedir. $(\sigma_{eqv})_1$ 'de minimum hata değeri 0.0051 ve maksimum hata değeri 4.036'dir. $(\sigma_{eqv})_2$ 'de minimum hata

değeri 0.0734 ve maksimum hata değeri 8.94'dir. $(\sigma_{\text{eqv}})_3$ 'de minimum hata değeri 0.0094 ve maksimum hata değeri 10.36'dir. $(\sigma_{\text{eqv}})_4$ 'de minimum hata değeri 0.0033 ve maksimum hata değeri 2.74'dir. Tablo 1: Momentumlu geriye yayılım algoritmasının eş değer gerilme değerlerine ulaşma performansına bakıldığında en iyi performansın %0.0012 hata oranı ile $(\sigma_{\text{eqv}})_1$ 'de olduğu görülmektedir.

Tablo 1. Momentumlu Geriye Yayılım Algoritmasının hata değerleri

m	n	Reel değerler				Hata değerleri			
		$(\sigma_{\text{eqv}})_1$ FDM	$(\sigma_{\text{eqv}})_2$ FDM	$(\sigma_{\text{eqv}})_3$ FDM	$(\sigma_{\text{eqv}})_4$ FDM	$(\sigma_{\text{eqv}})_1$ MGY	$(\sigma_{\text{eqv}})_2$ MYG	$(\sigma_{\text{eqv}})_3$ MGY	$(\sigma_{\text{eqv}})_4$ MGY
0.06	0.29	406.197	37.777	155.874	4.174	1.454	8.303	3.484	0.677
0.09	0.98	391.783	86.872	164.698	10.236	0.507	2.757	6.405	2.685
0.65	0.81	392.906	97.370	179.250	18.205	0.771	0.525	10.370	0.967
0.81	0.24	405.750	55.104	157.212	7.740	0.214	2.864	1.839	0.003
0.14	0.48	399.621	57.600	163.747	6.874	0.005	3.047	0.009	0.814
1.02	1.48	388.709	126.925	202.280	28.866	1.326	0.007	1.490	2.748
1.37	0.00	422.252	18.317	101.728	2.031	4.036	1.590	0.085	1.331

Tablo 2'de adaptif geriye yayılım algoritmasının eş değer gerilme değerleri üzerindeki minimum ve maksimum hata değerleri gösterilmektedir. $(\sigma_{\text{eqv}})_1$ 'de minimum hata değeri 0.016 ve maksimum hata değeri 10.63' dir. $(\sigma_{\text{eqv}})_2$ 'de minimum hata değeri 0.11 ve maksimum hata değeri 21.36'dir. $(\sigma_{\text{eqv}})_3$ 'de minimum hata değeri 0.0006 ve maksimum hata değeri 29.51' dir. $(\sigma_{\text{eqv}})_4$ 'de minimum hata değeri 0.018 ve maksimum hata değeri 4.65'dir. Tablo 2: Adaptif geriye yayılım algoritmasının eş değer gerilme değerlerine ulaşma performansına bakıldığında en iyi performansın %0.00002 hata oranı ile $(\sigma_{\text{eqv}})_3$ 'de olduğu görülmektedir.

Tablo 2. Adaptif Geriye Yayılım Algoritmasının hata değerleri

m	n	Reel değerler				Hata değerleri			
		$(\sigma_{\text{eqv}})_1$ FDM	$(\sigma_{\text{eqv}})_2$ FDM	$(\sigma_{\text{eqv}})_3$ FDM	$(\sigma_{\text{eqv}})_4$ FDM	$(\sigma_{\text{eqv}})_1$ AGY	$(\sigma_{\text{eqv}})_2$ AGY	$(\sigma_{\text{eqv}})_3$ AGY	$(\sigma_{\text{eqv}})_4$ AGY
0.120	0.180	411,340	28,599	144,95	3,24	0,0157	4,676	12,045	0,0187
0.090	0.980	391,782	86,872	164,69	10,23	7,384	14,188	2,11	4,65
0.940	0.160	409,346	46,18	147,98	5,808	10,63	18,35	29,50	0,4197
0.480	0.990	391,354	100,28	176,59	17,803	6,23	21,93	5,53	3,589
1.240	1.440	388,824	129,92	210,075	29,29	1,497	0,110	2,91	0,0369
1.390	1.180	389,763	127,058	213,69	27,69	3,125	3,686	0,0006	1,102

Tablo 3'te momentumlu adaptif geriye yayılım algoritmasının eş değer gerilme değerleri üzerindeki minimum ve maksimum hata değerleri gösterilmektedir. $(\sigma_{\text{eqv}})_1$ 'de minimum hata değeri 0.004 ve maksimum hata değeri 0.02'dir. $(\sigma_{\text{eqv}})_2$ 'de minimum hata değeri 4.12 ve maksimum hata değeri 15.76'dir. $(\sigma_{\text{eqv}})_3$ 'de minimum hata değeri 1.76 ve maksimum hata değeri 11.15'dir. $(\sigma_{\text{eqv}})_4$ 'de minimum hata değeri 1.56 ve maksimum hata değeri 26.56'dir. Tablo 3: Momentumlu adaptif geriye yayılım algoritmasının eş değer gerilme değerlerine ulaşma performansına bakıldığında en iyi performansın %0.0001 hata oranı ile $(\sigma_{\text{eqv}})_1$ 'de olduğu görülmektedir.

Tablo 3. Momentumlu Adaptif Geriye Yayılım Algoritmasının hata değerleri

m	n	Reel değerler				Hata değerleri			
		$(\sigma_{\text{eqv}})_1$ FDM	$(\sigma_{\text{eqv}})_2$ FDM	$(\sigma_{\text{eqv}})_3$ FDM	$(\sigma_{\text{eqv}})_4$ FDM	$(\sigma_{\text{eqv}})_1$ AGY	$(\sigma_{\text{eqv}})_2$ AGY	$(\sigma_{\text{eqv}})_3$ AGY	$(\sigma_{\text{eqv}})_4$ AGY
0.5100	0.1300	412.8515	31.7046	139.4998	3.6903	3.3912	2.9426	14.8077	0.2583
0.4700	0.1700	410.5305	36.3780	145.7335	4.4840	2.6650	0.9788	13.8440	0.0117
0.8300	0.1200	412.2739	36.8680	139.1693	4.3723	4.1165	6.4879	13.7991	0.2481
0.0080	0.4700	400.2525	51.5842	162.6774	5.1616	1.4672	14.9157	2.1238	4.2442
0.0090	0.4200	401.6952	47.5085	161.3884	4.7988	1.4903	15.7603	0.1127	4.0595
1.0900	1.3300	389.2060	125.2261	202.6348	28.2247	0.0614	1.7945	5.4586	0.3042
1.2400	1.4400	388.8244	129.9237	210.0759	29.2899	0.0040	0.0307	0.0529	0.3983
1.2800	1.4000	388.9474	129.9201	210.2872	29.1184	0.1152	0.0177	0.2782	0.2313

Tablolarda genel bir değerlendirme yapıldığında MYG ve MAGY algoritmasının $(\sigma_{eqv})_1$ değerleri için daha iyi performans gösterdiği görülmektedir.

4. Sonuç

Yapay sinir ağına tek katmanlı algılayıcı model kurulmuş olup üç farklı eğitim algoritması uygulanarak durumlar incelenmiştir. Kompozisyonel gradyant üst değerlerindeki eş değer gerilme değerlerine bakılarak algoritmalar karşılaştırılmıştır. Dikdörtgen plakanın eş değer gerilme değerlerinin en büyüğünün büyüğüne $(\sigma_{eqv})_1$ bakıldığında ortalama kareli hata hesabına göre minimum hatanın MAGY algoritmasında, maksimum hatanın AGY algoritmasında ve en iyi performansın MAGY algoritmasında olduğu görülmektedir. Eş değer gerilme değerlerinin en büyüğünün en küçüğüne $(\sigma_{eqv})_2$ bakıldığında minimum hatanın MAGY algoritmasında, maksimum hatanın AGY algoritmasında ve en iyi performansın MGY algoritmasının olduğu görülmektedir. En küçüğünün en büyüğünde ise $(\sigma_{eqv})_3$ minimum hata MGY algoritmasında, maksimum hata AGY algoritmasında ve en iyi performans MGY algoritmasında sonuçlanmıştır. En küçüğünün en küçüğü $(\sigma_{eqv})_4$ için ise minimum hata MGY algoritmasında, maksimum hata AGY algoritmasında ve en iyi performans MGY algoritmasında gerçekleşmiştir. Tablo 4'te üç algoritmanın eşdeğer gerilme değerlerindeki minimum, maksimum, ortalama kareli hata değerleri gösterilmiştir. Ayrıca yine Tablo 4'te görüldüğü üzere genel anlamda bakıldığında fonksiyonel kademelendirilmiş plakalarda MGY algoritması diğer algoritmalara göre gerçek değere yakınsamıştır. Hata oranları dikkate alındığında MGY algoritması ile oluşturulan YSA'nın güvenle kullanılabilir olduğunu görülmektedir. Daha sonra yapılacak çalışmalarda YSA ile model oluşturma aşamalarında eğitim algoritması olarak MGY yöntemi tercihen önde olacaktır. Termal gerilme analizinde sonlu farklar metodu ile n ve m kompozisyonel gradyant üst değerlerindeki eş değer gerilme değerlerine ulaşılması yaklaşık 1800 saniye sürmektedir. Her bir değer için bu süre dikkate alındığında optimum hacimsel dağılımdaki kompozisyonel gradyant üst değerini bulmak uzun zaman almaktadır. YSA'da ise veri setini oluşturduktan sonra değerlere yaklaşık 5.30 saniyede ulaşılmaktadır. Kurulan YSA modeli ile sonlu farklar yöntemine göre 340 kat daha hızlı çözüm elde edilmiştir. Kurulan model, belirlediğimiz sınır koşulları altında henüz seri üretimi gerçekleştirilemeyen fonksiyonel kademelendirilmiş malzemelerin hem üretiminde hem yapılacak teorik çalışmalarda optimum hacimsel dağılıma ulaşmak için fikir verici/yol gösterici olacaktır. Literatürde fonksiyonel kademelendirilmiş malzemeler için data setlerinin oluşturulmasında Petrov-Galerkin (MLPG), State-Space Based Differential Method (SSDQM) ve Finite Element Method (FEM) gibi birçok farklı sayısal yöntem kullanılarak optimizasyon çalışmaları yapılmıştır. Fakat fonksiyonel kademelendirilmiş malzemeler için termal gerilme analizinin sonlu farklar metodu ile çözülüp (Finite Difference Method (FDM)) YSA ile değerlendirilmesi yeni bir durumdur.

Tablo 4. MSE, minimum ve maksimum hata değerleri

	EQV	MİN	MAK	MSE
$(\sigma_{eqv})_1$	MGY	0.0051	4.035	1.76
	AGY	0.0157	10.63	14.04
	MAGY	0.004	4.116	1.56
$(\sigma_{eqv})_2$	MGY	0.0073	8.941	11.15
	AGY	0.11	21.94	59.68
	MAGY	0.018	15.76	26.56
$(\sigma_{eqv})_3$	MGY	0.0093	10.37	25.62
	AGY	0.0006	29.51	70.76
	MAGY	0.053	14.8	38.56
$(\sigma_{eqv})_4$	MGY	0.0034	2.748	0.58
	AGY	0.0187	4.65	4.14
	MAGY	0.012	4.244	2.24

Referanslar

Cho J.R., Ha D.Y. (2002). 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.doi: 10.1557/S0883769400048867

Çakır D., (2018). Fonksiyonel kademelendirilmiş plakalarda malzeme kompozisyonunun yapay sinir ağı ve genetik programlama ile belirlenmesi. Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Makine Mühendisliği, 2018.

- Demirbaş M.D, Çakır D., (2018). Thermal stress control in functionally graded plates with artificial neural network. ISVOS Journal. 2(1). 39-55. Retrieved from <http://dergipark.gov.tr/download/article-file/515245>
- Demirbaş M.D. (2012). Düzlem içi ısı yüküne maruz iki yönlü işlevsel kademelendirilmiş dikdörtgen ve dairesel plakanın ısı gerilme analizi. Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Makine Mühendisliği. Aralık 2012.
- Do T.T. D., Lee D., Lee J.(2019). Material optimization of functionally graded plates using deep neural network and modified symbiotic organisms search for eigenvalue problems. Composites: Part B. 159. 300-326.doi: 10.1016/j.compositesb.2018.09.087
- Haykin. S.,2005, Neural networks. Prentice Hall. New Jersey.
- Jodaeei, A. Jalal, M., Yas, M.H. (2012). Free vibration analysis of functionally graded annular plates by state-space based differential quadrature method and comparative modeling by ANN. Composites: Part B. 43(2). 340-353.doi: 10.1007/s12206-012-0860-2
- Khoshnoodi H.,Yas M.H.,Samadinejad A.,(2016) Dynamic Analysis of Multi-Directional Functionally Graded Panels and Comparative Modeling by ANN. Journal of Solid Mechabics, 8(3).482-494. Retrieved from http://jsm.iauarak.ac.ir/article_524265.html
- Koizumi M., Niino M. (1995).Overview of FGM research in Japan, MRS Bulletin. 20(1).19-21.doi: 10.1557/S0883769400048867
- MATLAB.Mathematical software, version 2009a, TheMathWorks. Retrieved from <http://www.mathworks.com>.
- Moitaa J.S., Araújo A.L., Correia F.V., Soaresa C.M.M, Herskovitsc J. (2018). Material distribution and sizing optimization of functionally graded plateshell structures, Composites Part B: Engineering.142. 263-272.doi: 10.1016/j.compositesb.2018.01.023
- Nazari F., Abolbashari M.H. , Hosseini S.M. (2015) Three Dimensional Natural Frequency Analysis of Sandwich Plates with Functionally Graded Core Using Hybrid Meshless Local Petrov-Galerkin Method and Artificial Neural Network. CMES.105(4). 271-299. doi:10.3970/cmcs.2015.105.271
- Nemat-Alla M. (2003). Reduction of thermal stresses by developing two-dimensional functionally graded materials, International Journal of Solids and Structures, 40(26). 7339-7356.doi: 10.1016/j.ijsolstr.2003.08.017
- Ootao Y., Tanigawa Y., Nakamura T., (1999). Optimization of material composition of FGM hollow circular cylinder under thermal loading a neural network approach. Composites Part B: Engineering. 30(4). 415-422.doi: 10.1016/S1359-8368(99)00003-7
- Öztürk C. (2011). Yapay Sinir Ağlarının Yapay Arı Kolonisi Algoritması İle eğitilmesi. Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği. Ocak 2011.
- Parlos A.G., Muthusami J., Atiya A.F. (2017). Incipient fault detection and identification in progress systems using accelerated neural network learning. Nuclear Technology. 105(2). 145-161.doi: 10.13182/NT94-A34919
- Salavati H., Alizadeh Y., Kazemi A., Berto F., (2015) A new expression to evaluate the critical fracture load for bainitic functionally graded steels under mixed mode (I + II) loading. Engineering Failure Analysis 48. 121–136.doi: 10.1016/j.engfailanal.2014.11.005
- Shabana Y.M., Noda N. (2001). 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, 32(2). 111-121.doi:10.1016/S1359-8368(00)00049-4
- Singh A.K., Siddhartha, Hussain S., (2015) 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.doi: 10.1016/j.matpr.2015.07.239
- Xu.Y., You.T. (2013). Minimizing thermal residual stresses in ceramic matrix composites by using Iterative MapReduce guided particle swarm optimization algorithm. Composite Structures. 99. 388-396.doi: 10.1016/j.compstruct.2012.11.027.