

Thermal Stress Control in Functionally Graded Plates with Artificial Neural Network

Munise Didem DEMİRBAŞ^{a*}, Didem ÇAKIR^b

^aErciyes Üniversitesi, Makine Mühendisliği Bölümü, Kayseri, Türkiye

^bErciyes Üniversitesi, Fen Bilimleri Enstitüsü, Kayseri, Türkiye

Abstract

In this study, trained models were obtained by using Artificial Neural Network (ANN) in order to determine the equivalent stress levels of one dimensional functionally graded rectangular plates. In this training set, a single layer sensor model was used according to our linear problem. With ANN, the models were trained by changing parameters the number of different iterations, number of neurons and learning algorithms. and the trained model was tested and its performance was measured.

In our study, thermal stress analyses were performed for different compositional gradient exponents using finite difference method to constitute data sets. The data sets were constructed for the smallest value of the largest value of the equivalent stress levels, the greatest value of the greatest value of the equivalent stress levels, the greatest value of the smallest value of the equivalent stress levels, and the smallest value of the smallest value of the equivalent stress levels. Five different training algorithms were used in our training network: Levenberg-Marquardt, Back Propagation Algorithm, Momentum Coefficient Back Propagation Algorithm, Adaptive Back Propagation Algorithm and Momentive Adaptive Back Propagation Algorithm. The Levenberg-Marquardt algorithm is found to be more efficient than the other algorithms.

With this study, trained models have been developed to provide time and job savings to determine equivalent stress levels in functionally graded plates, which are very important for high temperature applications. These educated models will provide important contributions to the literature and will be a source for the work to be done in this regard.

Keywords: Functionally graded plates, artificial neural network, single layer model, Levenberg-Marquardt algorithm, finite difference method, thermal stress analysis.

1. Giriş

Malzeme bilimi ve teknolojisinde ihtiyaçtan doğan yeni özelliklere sahip malzemeler düşünülmekte ve araştırılmaktadır. Bu amaçla yüksek sıcaklık uygulamaları için düşünülen hem ısı direnci yüksek hem de termal gerilme tesirine dayanıklı malzemeler olarak Fonksiyonel Kademelendirilmiş malzemeler 2 dekat önce düşünülmüştür [1-4]. Bu malzemeler bir tarafı metal, diğer tarafı seramik ve geçiş bölgesi bir hacim fonksiyonuna bağlı olarak tasarlanmıştır. Geçiş bölgesinin fonksiyonel olarak değişmesi ile iki ayrı malzeme yani seramik ve metalin geçiş bölgesinde ısı ve mekanik özelliklerinin uyumsuzluklarından kaynaklanabilecek gerilme süreksizliklerinin oluşması engellenmiştir. Bu özel malzemelerde farklı ısı ve yapısal sınır şartları için gerilme süreksizliklerinin en düşük olduğu malzeme kompozisyonunun yani kompozisyonel gradyant üst değerinin belirlenebilmesi önem arz etmektedir [5-7]. Böylece bu bölgelerde ortaya çıkabilecek ara yüzey çatlakları ve kırılmaların ortadan kaldırılabilir veya minimum seviyeye indirgenebilecektir. Bu amaçla yapılmış literatürde pek çok çalışma vardır. Bu çalışmalarda amaç kimi zaman farklı sınır şartları ve farklı mekanik tesirler için çözüm sunmak iken kimi zaman da farklı algoritmalar ile optimum kompozisyonel gradyant üst değerinin belirlenmesi olmuştur [8]. Bu çalışmalardan bazıları aşağıda detaylandırılmıştır.

Turteltaub [8] zamanın fonksiyonu olan termo-mekanik yük tesirindeki fonksiyonel kademelendirilmiş malzemelerin kompozisyonel gradyant üs değerinin optimizasyonunu yapmıştır. Çok amaçlı optimizasyon kullanarak kontrol ve yapısal optimizasyonu yapmış ve farklı sınır şartları için malzeme kompozisyonu önermiştir. Cho ve Ha [9] termal yükleme altındaki, fonksiyonel kademelendirilmiş malzemenin termo-elastik davranışını, sonlu farklar metodunu kullanarak farklı sınır şartları için iki boyutlu hacimsel dağılımın optimum değerini araştırmışlardır. Bölge ara yüzlerindeki en yüksek gerilmeyi minimize etmek için yapay sinir ağı (YSA) algoritmasını geliştirmişlerdir. Ootao ve arkadaşları [10] termal yük altında fonksiyonel kademelendirilmiş, içi boş bir kürenin malzeme kompozisyonunun optimizasyonunu yapay sinir ağı algoritmasını kullanarak yapmışlardır. Ayrıca yapay sinir ağı ve doğrusal olmayan programlama yöntemi ile elde edilen sonuçları karşılaştırmışlar ve ilk verileri oluşturduktan sonra yapay sinir ağı modelinin optimum sonuca hızlı bir biçimde ulaştığını ifade etmişlerdir. Na ve Kim [11] 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 analizini için gerilme dağılımını optimum yapacak en uygun hacimsel dağılımı ifade ettiler. Mantari ve Monge [12] fonksiyonel kademelendirilmiş sandviç plakanın 3 mekanik yüklem altında serbest titreşim ve burkulma davranışının analizi için hiperbolik bileşik formülasyonunu sundular. Sundukları optimizasyon yöntemini kalınlık oranları farklı olan burkulma problemini çözmek için kullandılar ve tahminlerinde yüksek doğruluk olduğunu vurguladılar. Nemat-Alla, [13] havacılık endüstrisinde iki veya üç yönde değişime sahip yüksek sıcaklıklarda kullanılabilen malzemelere ihtiyaç duyulduğunu belirtti ve iki boyutlu fonksiyonel kademelendirilmiş malzemelerin yüksek sıcaklıklarda ve termal gerilmeye dayanabilecek malzemenin geliştirilmesi üzerine çalıştı. Sonlu elemanlar metodu ile optimum tasarımı sundu. Khoshnoodi ve arkadaşları [14] fonksiyonel kademelendirilmiş plakanın analizi için elastisite teorisine dayanan yarı analitik sayısal yöntemi (YASY) ve YSA algoritmasını seçtiler. Doğal frekansı baz alarak kompozisyonel gradyant üs değerini araştırdılar. Onlar YASY ile YSA'yı karşılatırdılar ve YSA'nın kabul edilebilir verileri bulduğunu vurguladılar. Cho ve Shin [15] yapay sinir ağı (YSA) yöntemini kullanarak ısıya dayanıklı malzeme bileşiminin optimizasyonu üzerine çalıştılar. İç ceza fonksiyonu yöntemi ve altın oran yöntemini optimizasyon teknikleri olarak benimsediler. Sayısal deneyler sonucunda, yapay sinir ağları yönteminin, malzeme optimizasyonundaki tasarım doğruluğunu artırdığını vurguladılar. Nazari ve arkadaşları [16] fonksiyonel kademelendirilmiş dikdörtgen plakanın üç boyutlu doğal frekans analizinde Meshless Local Petrov-Galerkin (MLPG) yöntemini ve YSA'yı kullandılar. FKM'nin çekirdek ve kalınlık üzerindeki doğal frekans etkisinin optimum değerini araştırdılar. Jodaei ve arkadaşları [17] üç boyutlu fonksiyonel kademelendirilmiş halka plakanın analizinde state-space based differential quadrature metodunu (SSDQM) kullandılar. Optimizasyon çalışmasını yapay sinir ağı (YSA) algoritmasında uyguladılar. Fonksiyonel kademelendirilmiş halka plakalarda kabul edilebilir bir tasarıma ulaştılar. Yu ve Wu [18] fonksiyonel kademelendirilmiş malzemeli boruların yönlendirilmiş çevresel dalga dağılım özelliklerini kullanarak yapay sinir ağı algoritmasında test ettiler. Legendre polinom yöntemi ile ileri doğru frekansları hesapladılar. Yapay sinir ağı algoritmasında eğitim aşaması için Levenberg-Marquardt algoritması kullandılar. Kompozisyonel gradyant üs değerinin tatmin değere ulaştığını vurguladılar. Ootao ve arkadaşları [19] fonksiyonel kademelendirilmiş malzemenin kompozisyonel gradyant üs değerinin optimizasyonu için yapay sinir algoritmasını kullandılar. Yaptıkları çalışmada doğrusal olmayan programlama (DOP) ile yapay sinir ağı yöntemini kıyasladılar. YSA nin daha hızlı ve verimli bir şekilde sonuca ulaştığı gösterdiler. Ootao ve arkadaşları [20] fonksiyonel kademelendirilmiş içi boş bir kürede yapay sinir ağı yöntemini uygulayarak termal gerilme dağılımının mininizasyonu için optimum hacimsel dağılımı araştırdılar.

Literatürde pek çok fonksiyonel kademelendirilmiş malzemelerin malzeme kompozisyonunu belirleyen kompozisyonel gradyant üst değerinin optimizasyonu veya tahmini için çalışmalar yapılmıştır. Ancak FKM ve YSA ile ilgili yapılan çalışmalarda plakaların düzlem boyunca kademelendirildiği ve sayısal çözüm yöntemi olarak sonlu farklar methodunun kullanıldığı çalışma yapılmamıştır. Bu yönüyle çalışmamız literatüre önemli katkılar sağlayacaktır.

Bu çalışmada, plakanın kademelendirmesi düzlem boyunca yapılmış ve belirli ısıl ve yapısal şartlara sahip fonksiyonel kademelendirilmiş dikdörtgen plakaların ısıl gerilme analizi sonuçlarında en önemli parametreler olan eşdeğer gerilme seviyeleri ve kompozisyonel gradyant üst değerleri kullanılarak yapay sinir ağı ile verimli eğitilmiş bir model elde edilmiştir. Bu eğitilen model kullanılarak belirlediğimiz 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 bulunabilmektedir.


2. Materyal ve Metot

2.1. Fonksiyonel Kademelendirilmiş Malzemeler

Malzemelerin çalışma şartlarının değişmesi ve maliyet kaleminin önem kazanması gibi etkenler neticesinde ekonomiklik, dayanıklılık, hafiflik gibi malzeme özelliklerini bünyesinde barındırması ihtiyacı doğmuştur. Bilinen alaşımlar, kaplamalar ve tabakalı kompozitler bu ihtiyaçları özellikle de yüksek sıcaklıklar için termal dayanımı karşılayamaz hale gelmiş ve farklı bir malzeme kombinasyonlarına yani FKM teknolojisine yönelinmiştir. FKM, iki veya daha fazla farklı malzemedan oluşan ve bileşimin hacimsel oranı sürekli olarak belirli sınırlar arasındaki bir konum fonksiyonu olarak değişen malzemelerdir. Bu malzemeler yüksek sıcaklık uygulamaları için düşünülmüştür. Çünkü geleneksel kompozitlerde katmanlar arasındaki geçiş bölgelerinde malzeme süreksizliklerine bağlı olarak ara yüzey çatlakları meydana gelmektedir. Kademelendirilmiş malzemeler kullanarak ara yüzey geçiş bölgesindeki süreksizlikler ortadan kaldırılmış ve ara yüzey hataları ve çatlakları önlenmiştir. Bu malzemelerde ihtiyaç duyulan özelliklerin sağlanması için kademelendirilmiş malzeme kullanılırken aynı zamanda malzeme bileşiminde ekonomiklik, fonksiyonellik ve malzemenin elastik sınırlar içerisinde çalışması açısından optimum bileşimin yani kompozisyonel gradyant üs değerinin belirlenmesi gerekliliği ortaya çıkmıştır. Sınır şartları belirli bir problem için malzemenin sınırını belirlemede kompozisyonel gradyantın belirlenmesi oldukça önemli olmaktadır ve bu değer minimize ya da maksimize etmek amacı ile gerçek ya da tamsayı değerlerini tanımlı bir aralıkta seçmek gerekmektedir.

2.2. Yapay Sinir Ağı Algoritması

Hayatımızda oldukça önemli bir yeri olan bilişim teknolojilerinin, karar verme ve öğrenme-gerçekleştirme yeteneklerini kazanması ile kullanım alanları oldukça farklılaşmıştır. Bilişim teknolojilerinde kullanılan yapay zekâ yöntemleri olaylara ve problemlere çözüm üretirken örneklerden ve benzetmelerden faydalanarak öğrenme gerçekleştirmektedir. Bilişim ile öğrenmede en fazla kullanılan yaklaşımlardan biri yapay sinir ağı algoritmasıdır. Yapay sinir ağı, insan beyninin yapısındaki düşünme, bilgi edinme, görme ve karar verme süreçlerini modelleyerek bilgisayar programına aktarılmasıdır. İnsan beyninden esinlenerek, öğrenme sürecinin matematiksel olarak modellenmesi uğraşı sonucu ortaya çıkmıştır [21]. Yapay sinir ağları başta sınıflandırma, modelleme ve tahmin uygulamaları olmak üzere, pek çok alanda kullanılmaktadır [22-23].



Şekil 1. Basit Bir Yapay Sinir Hücresi [24].

Başarılı uygulamalar incelendiğinde, YSA'ların çok boyutlu, gürültülü, karmaşık, kesin olmayan, eksik, kusurlu, hata olasılığı yüksek verilerinin olması ve problemi çözmek için matematiksel modelin ve algoritmaların bulunmadığı, sadece örneklerin var olduğu durumlarda yaygın olarak kullanıldıkları görülmektedir.

Basit bir yapay sinir ağı hücresi Şekil 1.'de gösterilmektedir. Burada hücreye gelen bilgiler ağırlıklı olarak toplanmakta ve net girdi hesaplanmaktadır. Genellikle kümülatif toplam kullanılmakta olup bu toplam fonksiyonu aşağıda yer almaktadır. Burada x , w ve b sırasıyla giriş değeri, ağırlık vektörü ve eşik değeridir.

$$girdi(net) = \sum x_i w_i + b_i \quad (1)$$

Aktivasyon fonksiyonunda ise hücreye net girdiler işlenip bir çıktı oluşturmaktadır. Bu fonksiyonun da farklı türleri vardır ancak genellikle doğrusal olmayan fonksiyonlar tercih edilmektedir. En yaygın kullanılan fonksiyon ise sigmoid fonksiyonu olup aşağıda verilmektedir. Burada f ve e sırasıyla sigmoid fonksiyonudur ve hata vektörüdür.

$$f = \frac{1}{1 + e^{-x}} \quad (2)$$

Öğrenme kuralında yapay sinir ağından çıkan hata oranı Hata fonksiyonu kullanılarak hesaplanır. Yapay sinir ağına gerçekleşen işlemler sonucunda beklenen değerle gerçek değer kıyaslanarak uygunluk değeri belirlenir. Aşağıda hata fonksiyonu (E) verilmektedir. Burada y_d ve y sırasıyla programın hedeflenen çıktısı ve programın gerçek çıktı değerleridir.

$$E = \frac{1}{2} \sum_{m=1}^m (y_d - y)^2 \quad (3)$$

YSA'da literatürde yaygın olarak kullanılan 9 farklı eğitim algoritması bulunmaktadır, çalışmamızda ise bunlardan 5 tanesi eğitim algoritması olarak kullanılmıştır. Kullandığımız eğitim algoritmaları aşağıda detaylandırılmaktadır.

Levenberg-Marquardt (LM) algoritması nöral ağ eğitim uygulaması [26] olup Gauss-Newton algoritmasıyla gradyant azaltma metodunun birleştirilmesiyle ortaya çıkan bir algoritmadır. Bu algoritma Hessani matrisinin hesaplanmasına gerek duymayan Gauss-Newton algoritmasına göre daha doğru sonuçlara ulaşmaktadır ve bu matriste ağın performansını ikinci dereceden türevleri belirlemektedir. LM algoritması ileri beslemeli ağlarda kullanılan en hızlı öğrenme metodudur [3-4]. Bu algoritmanın kullanıldığı denklemler aşağıda yer almaktadır. Burada H Hessani matrisi, I birim matris, μ kombinasyon katsayısıdır. J Jacobian matrisini göstermektedir.

$$H = J^T J \quad (4)$$

$$g = J^T e \quad (5)$$

$$x_{k+1} = x_k - [J^T J + \mu I]^{-1} J^T e \quad (6)$$

Geriye yayım algoritması (Gradient descent backpropagation) yapay sinir ağındaki her nöronda gradyant azaltma tekniğine dayanır. Yapay sinir ağı algoritmasının tarihsel gelişiminde günümüzde bile en yaygın kullanılan model Rumelhart ve arkadaşları tarafından önerilen geriye yayım öğrenme modelidir [22]. Geriye yayım algoritması çıkışta alınan değerler ile beklenen değerlerin durumlarına göre hatayı çıkıştan geriye doğru azaltan yönde işlem gerçekleştirdiği için geriye yayım algoritması adını almıştır [21]. Kullanılan algoritmada hata oranları, ağırlık değerlerinin kısmi türevi üzerinden gerçekleşir. Doğrusal olmayan programda hata oranının türevinin minimum olması hedeflenmektedir. Algoritma gradyant azaltma tabanlı olduğundan ilk koşullara duyarlıdır. Yakınsama hızı yavaştır ve yerel minimuma takılma olasılığı vardır. Eğer ilk atanan ağırlık vektörünün hata düzeyi minimuma çok yakın ve eğimli bir bölgede ise YSA' nın öğrenmesi çok çabuk olacaktır. Bu durumun tam tersi olduğunda sonuca ulaşmak çok zaman alabilir. Öğrenme katsayısı n olup, her problem için farklı belirlenir ama genelde 0.1-0.9 arasında seçilir [27]. Formül 7 ve 8 de hata ve ağırlık fonksiyonları detaylandırılmıştır. Burada n , öğrenme katsayısıdır.

$$e_t = yd_t - y_t \quad (7)$$

$$w_t = w_{t-1} + n \left(\frac{\partial E_t}{\partial w_{t-1}} \right) \quad (8)$$

Momentum Katsayılı Geriye Yayım algoritması (Gradient Descent with Momentum backpropagation) geriye yayım algoritmasına Rumelhart momentum katsayısı eklenerek yeni denklem elde etmiştir [22]. Ağırlık fonksiyonu aşağıda detaylandırılmıştır. Burada α momentum katsayısıdır.

$$w_t = w_{t-1} + n \left(\frac{\partial E_t}{\partial w_{t-1}} \right) + \alpha \Delta w_{t-1} \quad (9)$$

Momentum katsayısı genelde $0 < \alpha < 1$ arasında seçilir. Bu algoritmada momentum teriminin eklenmesi ile yakınsama hızı artar ve yerel minimuma takılma olasılığı azalır [28].

Adaptif Geriye Yayım algoritması (Gradient descent with adaptive learning rate backpropagation) Gradyant azaltma yönünde ağırlık değerlerini hata ve hata türevlerinin işlevi olan öğrenme oranı ile güncellemektedir. Bu algoritmada kullanılan hata fonksiyonu aşağıda detaylandırılmıştır. Burada $P(E)$, hata fonksiyonudur [29].

$$w_t = w_{t-1} + p(E) \left(\frac{\varphi_t}{\|\varphi_t\|^2} \right) \quad (10)$$

Momentumlu Adaptif Geriye Yayım algoritması (Gradient descent with momentum ve adaptive learning rate backpropagation), Adaptif Geriye Yayım algoritması biraz değiştirilerek Momentumlu Adaptif geriye yayım algoritması oluşturulmuştur. Algoritmalar arasındaki fark n öğrenme katsayısı gradyantının karesi yerine kendisine bölümünden ibarettir. Ayırık zaman aralığında bu algoritmanın, Adaptif geriye yayım algoritmasına göre daha iyi olduğunu tespit edilmiştir [28]. Burada φ ise hata işlevinin ağırlık değerine göre türevidir.

$$w_t = w_{t-1} + n \left(\frac{\varphi_t}{\|\varphi_{t-1}\|} \right) \quad (11)$$


3. Problem Tarifi ve YSA ile Modelleme

3.1. Problemin Tarifi

Bu çalışmada tek kenarından düzlem içi ısı akısına maruz bırakılan tek yönde fonksiyonel kademelenmiş dikdörtgen plakaların termo-elastik davranışını belirleyen en önemli parametreler olan eşdeğer gerilme seviyeleri ve kompozisyonel gradyant üst değerleri için yapay sinir ağı ile verimli eğitilmiş bir program elde edilmiştir. Yapay sinir ağı modelimizde 5 farklı eğitim algoritması ile eğitilmiş program elde edilmiş ve analiz sonuçlarını hata oranları ve maksimum çevrim sayıları ile karşılaştırılmıştır. Bu eğitilmiş programlar vasıtasıyla herhangi bir kompozisyonel gradyant üst değeri için eşdeğer gerilmenin maksimumu veya minimum seviyeleri bulunabilmektedir.

Programların eğitilmesinde ve doğrulanmasında kullanılmak üzere sonlu farklar metodu ile ısı transferi ve elastisite denklemlerinin çözümünde elde ettiğimiz [0.001-1,5] aralığındaki rastsal 200 farklı kompozisyonel gradyant üst değerine karşılık

gelen minimum normalize edilmiş maksimum, maksimum normalize edilmiş minimumu, maksimum normalize edilmiş maksimumu, minimum normalize edilmiş minimum eşdeğer gerilme seviyelerinin bulunduğu data setlerimiz oluşturulmuştur. Bu setlerin kullanılacağı tek giriş, dört çıkış ve tek katmanlı yapay sinir ağı modeli oluşturulmuştur. Matlab [30] programlama dilinde oluşturulan modelde 4 farklı nöron sayısı ve nörondaki beş farklı eğitim algoritmasındaki analizler gerçekleştirilmiştir.



Şekil 2. Tek katmanlı yapay sinir ağı modeli

Şekil 2. 'de programların eğitilmesinde kullandığımız YSA modeli yer almaktadır. Burada A ve Q sırasıyla nöronların üzerinde hesaplanan değerlere ait fonksiyonlar ve yapay sinir ağındaki çıkış değerlerinden hesaplanan değerlere ait fonksiyonlardır.

$$\sum (m_i w_i + b_i) = \left(\frac{1}{1 + e^{-m}} \right)^{A_i} \quad (12)$$

$$\sum (A_i a w_{ij} + b_i) = \left(\frac{1}{1 + e^{-m}} \right)^{Q_i} \quad (13)$$

3.2. YSA ile Modelleme


Yapay sinir ağı modelinde 200 verimizden, 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.

YSA modelimizde 5 farklı eğitim algoritmaları ile 4 farklı nöron sayıları ile eğitilmiş program elde edilmiştir. Tablo 1.' de, Eğitim tahmini (regression) değerlerine bakıldığında nöron sayısı artıkça 1 değerine yakınsadığı görülmektedir. Bu durum YSA modelimizin ezberci bir yaklaşım sergilediğini göstermektedir. Ayrıca test tahmininin nöron sayısının artışı ile azaldığı Tablo 1.' de görülmektedir. Bundan dolayı detaylı analizlerimizde nöron sayısı 3 olarak sabit tutulmuştur.

Tablo 1. Tek katmanlı model ve 4 farklı nöron sayılarındaki farklı eğitim algoritmaları için tahmin değerleri.


Eğitim				
Nöron Sayısı	3	5	7	9
Levenberg-Marquardt	0,99533	0,99971	0,99993	0,99998
Gradient descent backpropagation	0,8299	0,99018	0,97095	0,96603
Gradient Descent with Momentum backpropagation	0,97956	0,97470	0,97904	0,96905
Gradient descent with adaptive lr backpropagation	0,98581	0,99562	0,99013	0,99116
Gradient descent w/momentum ve adaptive lr backpropagation	0,99004	0,99671	0,99841	0,785

Test				
Nöron Sayısı	3	5	7	9
Levenberg-Marquardt	0,98682	0,96970	0,96863	0,96746
Gradient descent backpropagation	0,8891	0,98497	0,94998	0,94559
Gradient Descent with Momentum backpropagation	0,97844	0,98162	0,98289	0,9729
Gradient descent with adaptive lr backpropagation	0,98508	0,97558	0,98919	0,991
Gradient descent w/momentum ve adaptive lr backpropagation	0,98816	0,97806	0,97000	0,81924




Şekil 3. Levenberg-Marquardt eğitim algoritması ile model tahmin değerleri

İlk eğitim algoritmamız olan Levenberg-Marquardt kullanılarak oluşturduğumuz model için Şekil 3.' de ağın tahmin değerlerini gösterilmektedir. Burada çıkış değerleri hedeflerine eşit (mükemmel eğitim tahmin oranı) yani tahmin oranı 1 değerine eşit olmaktadır. Bu modelde çıkış verilerimiz en iyi hedeflenen eğitim tahmin değeri olan 0,99 üzerinde bir değerle hesaplanmıştır.



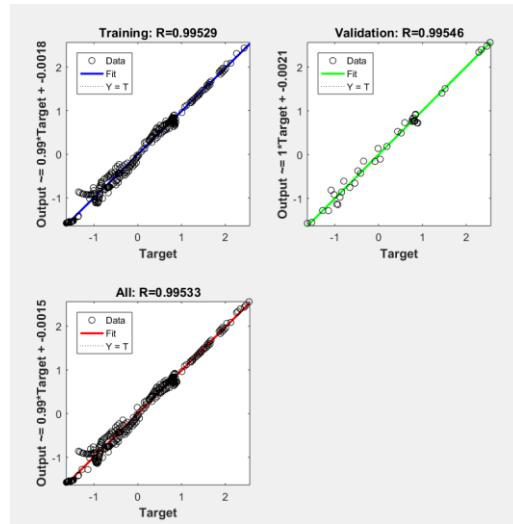
Şekil 4. Levenberg-Marquardt eğitim algoritmasının performansı

Şekil 4. 'te çıkış verilerimizin, en iyi hedeflenen eğitim, doğrulama ve tahmin değerinin 0,99 üzerinde bir değerle hesaplandığını göstermektedir. Burada çevrim sayısı arttıkça eğitim ile doğrulama tahmini hata değeri arasındaki fark değişmemektedir. En iyi doğrulama performansı ise 37 çevrim için 0,011327' tir.



Şekil 5. Levenberg-Marquardt algoritması ile eğitilen model için gradyant, momentum ve başarısız doğrulamanın çevrim sayısına bağlı değişimi

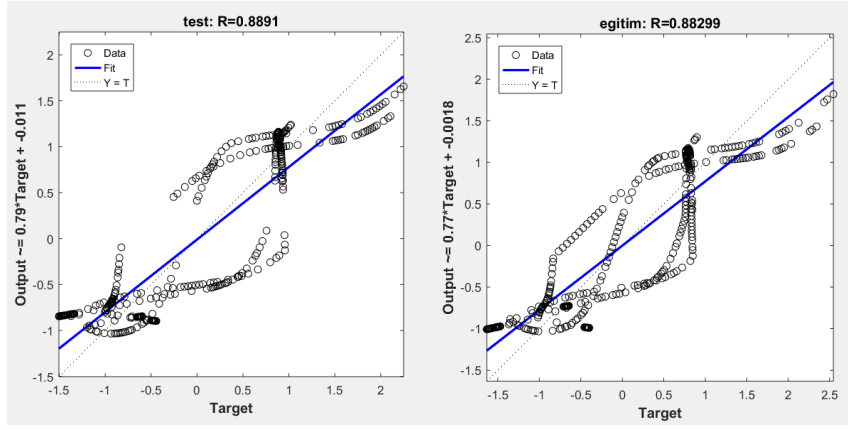
Şekil 5.' de Levenberg-Marquardt eğitim algoritması kullanılarak oluşturduğumuz model için gradyant, momentum ve başarısız doğrulamanın çevrim sayısına bağlı değişimi gösterilmektedir. Gradyant (Gradient) 0,01991, momentum (Mu) 0,00001, başarısız doğrulama (validation fail) 6 değeri maksimum çevrim sayısı (epochs) 43'dür.




Şekil 6. Levenberg-Marquardt eğitim algoritması ile eğitilen model için tüm tahmin değerleri

Şekil 6.'da yapay sinir ağının Levenberg-Marquardt eğitim algoritmasının tüm tahmin değerlerini göstermektedir. Burada eğitim için tahmin değeri 0.99529, doğrulama için tahmin değeri 0.99546 ve toplam tahmin değeri 0.9953 olup mükemmel eğitim tahmin oranı 1 değerine eşit olmaktadır. Bu çalışmada çıkış verilerimize göre, en iyi hedeflenen eğitim değeri, doğrulama değeri ve tüm tahmin değeri 0,99 üzerinde tahmin ile hesaplanmaktadır. Bu durum ağımızın iyi eğitildiğini göstermektedir.

İkinci eğitim algoritmamız olan Geriye Yayım algoritması kullanılarak oluşturduğumuz model için Şekil 7.' de ağın tahmin değerleri gösterilmektedir. Şekil 7. de çıkış verilerimizin en iyi hedeflenen eğitim tahmin değeri 0,88299 olarak, test değerimizin tahmini ise 0.8891 olarak hesaplanmıştır.




Şekil 7. Geriye Yayım algoritması ile eğitilen model için tahmin değerleri



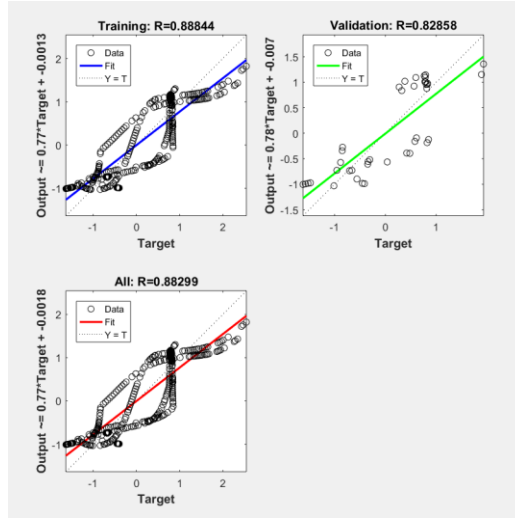
Şekil 8. Geriye Yayım algoritması ile eğitilen model için doğrulama performansı

Şekil 8., yapay sinir ağında Geriye Yayım algoritmasında eğitilmiş modelin en küçük kareler (MSE) yönteminde hesaplanmış minimum hata değerini göstermektedir. Burada çevrim sayısı arttıkça eğitim ile doğrulama tahmininin hata değeri artmaktadır. En iyi doğrulama performansı ise 1000 çevrim için 0,26247' tir.



Şekil 9. Geriye Yayım algoritması ile eğitilen model için gradyant ve başarısız doğrulamanın çevrim sayısına bağlı değişimi

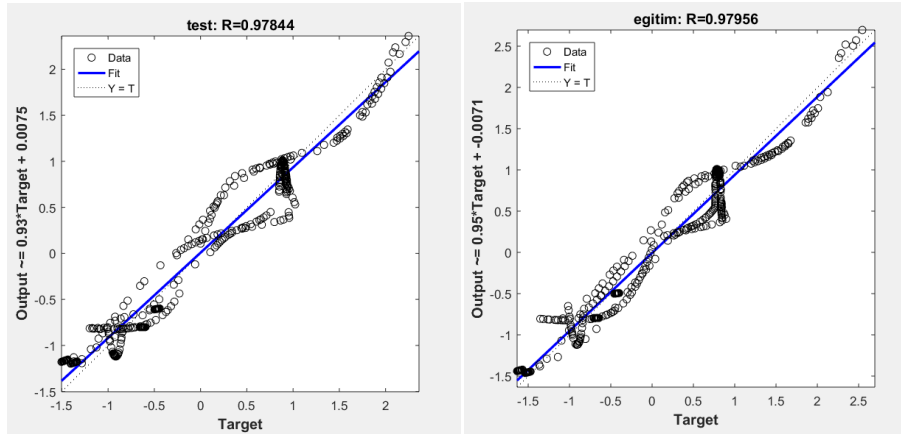
Şekil 9. Geriye Yayım algoritması ile eğitilen model için gradyant ve başarısız doğrulamanın çevrim sayısına bağlı değişimini göstermektedir. Burada maksimum çevrim sayısı 1000 olmak üzere gradyant 0,014311 ve başarısız doğrulama 0'dır.




Şekil 10. Geriye Yayım algoritması ile eğitilen model için tüm tahmin değerleri

Şekil 10., Geriye Yayım algoritması ile eğitilen yapay sinir ağının modelinin tahmin değerlerini göstermektedir. Burada eğitim için tahmin değeri 0.88844, doğrulama için tahmin değeri 0.82858 ve toplam tahmin değeri 0.88299 olup mükemmel eğitim tahmin oranı 1 değerine yaklaşmaktadır. Bu çalışmada çıkış verilerimize göre, en iyi hedeflenen eğitim değeri, doğrulama değeri ve tüm tahmin değeri 0.88 üzerinde tahmin ile hesaplanmaktadır.

Üçüncü eğitim algoritmamız olan Momentum Katsayılı Geriye Yayım algoritması kullanılarak oluşturduğumuz model için Şekil 11.' de ağı tahmin değerleri gösterilmektedir. Bu çalışmadaki çıkış verilerimizin en iyi hedeflenen eğitim tahmin değeri 0,97956 ve test tahmin değeri 0.97844 hesaplanmaktadır. Mükemmel eğitim tahmin oranı '1' olmak üzere sonuçlar bu değere yaklaşmaktadır.




Şekil 11. Momentum Katsayılı Geriye Yayım algoritması ile eğitilen model tahmin değerleri



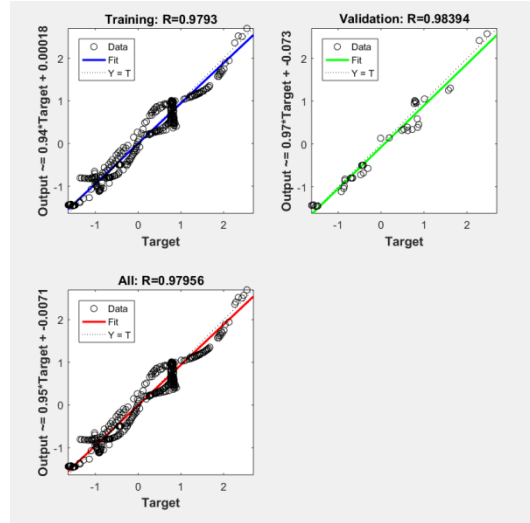
Şekil 12. Momentum Katsayılı Geriye Yayım algoritması ile eğitilen model için doğrulama performansı

Şekil 12.'de Momentum Katsayılı Geriye Yayım algoritması ile eğitilen yapay sinir ağının en küçük kareler (MSE) yönteminde hesaplanmış minimum hata değeri gösterilmektedir. Çevrim sayısı arttıkça eğitim ve doğrulama tahminlerinin hata oranı aynı olmaktadır. En iyi doğrulama performansı ise 1000 çevrim için 0,0411311' tir.

Şekil 13.'de görüldüğü gibi gradyant, maksimum çevrim sayısı 1000 için 0,05392 olmaktadır. Başarısız doğrulama ise 0'dır.




Şekil 13. Momentum Katsayılı Geriye Yayım algoritması ile eğitilen model için gradyant ve başarısız doğrulamanın çevrim sayısına bağlı değişimi



Şekil 14. Momentum Katsayılı Geriye Yayım algoritması ile eğitilen model için tüm tahmin değerleri


Şekil 14. Momentum Katsayılı Geriye Yayım algoritması ile eğitilen model için tüm tahmin değerlerini göstermektedir. Şekil de görüldüğü gibi çıkış verilerimizin tahmininde en iyi hedeflenen eğitim ve doğrulama tahmin değerleri sırasıyla 0,9793 ve 0,98394'dür. Momentum Katsayılı Geriye Yayım algoritması ile eğitilen model de toplam tahmin değeri 0. 97956 olup mükemmel eğitim tahmin oranı 1 değerine yaklaşmaktadır.

Dördüncü eğitim algoritmamız olan Adaptif Geriye Yayım algoritması kullanılarak oluşturduğumuz model için Şekil 15.'de ağın tahmin değerleri gösterilmektedir. Bu çalışmadaki çıkış verilerimizin en iyi eğitim tahmin değeri 0,98581 ve test tahmin değeri 0,98506 olarak hesaplanmaktadır. Mükemmel eğitim tahmin oranı '1' olmak üzere bu eğitim algoritması için sonuçlar bu değere yaklaşmaktadır.




Şekil 15. Adaptif Geriye Yayımla eğitilmiş model için tahmin değerleri

Şekil 16.'da Adaptif Geriye Yayımla eğitim model için en küçük kareler yöntemi ile hesaplanmış minimum hata değerleri gösterilmektedir. Çevrim sayısı arttıkça eğitim ve doğrulama tahmin değerleri için hata oranları artmaktadır. En iyi doğrulama performansı ise 116 çevrim için 0,03609' tir.

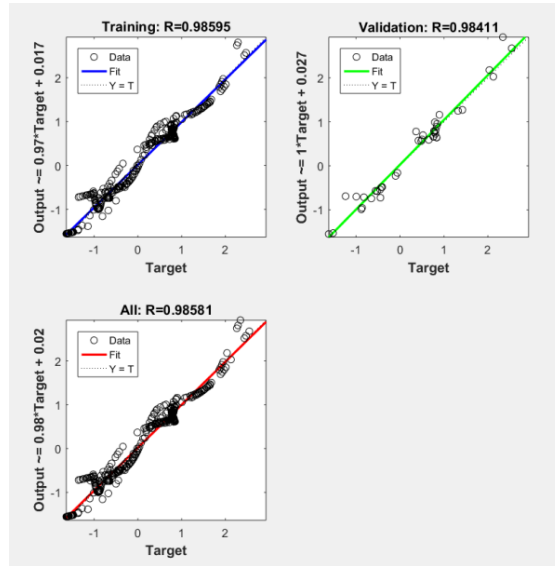


Şekil 16. Adaptif Geriye Yayımla eğitilmiş model için doğrulama performansı



Şekil 17. Adaptif Geriye Yayımla eğitilmiş model için gradyant, başarısız doğrulama ve öğrenme katsayısının (lr) çevrim sayısına bağlı değişimi


Şekil 17., Adaptif Geriye Yayımla eğitilmiş model için gradyant, başarısız doğrulama ve öğrenme katsayısının çevrim sayısına bağlı değişimini göstermektedir. Şekil de görüldüğü gibi Adaptif Geriye Yayımla eğitilmiş modelin çevrim sayısı 122 olmak üzere gradyant 0.19126, başarısız doğrulama sayısı 6 ve öğrenme katsayısı 0.36001 olmaktadır.



Şekil 18. Adaptif Geriye Yayım algoritması ile eğitilen model için tüm tahmin değerleri

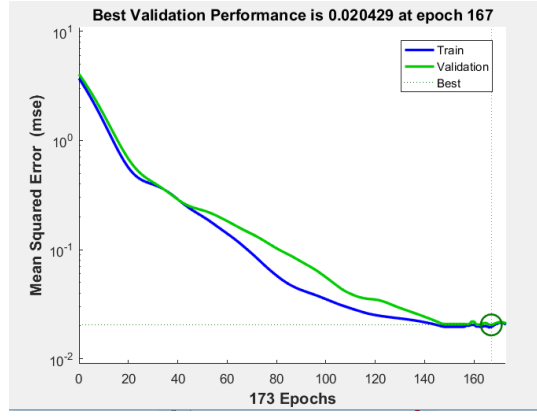
Şekil 18. Adaptif Geriye Yayım algoritması ile eğitilen model için tüm tahmin değerlerini göstermektedir. Bu model için çıkış verilerimizin en iyi eğitim tahmini 0.98595 ve en iyi doğrulama tahmin değeri 0,98411'dir. Adaptif Geriye Yayım algoritması ile eğitilen model de toplam tahmin değeri 0.98581 olup mükemmel eğitim tahmin oranı 1 değerine yaklaşmaktadır.

Beşinci eğitim algoritmamız olan Adaptif Geriye Yayım algoritmasını kullanarak oluşturduğumuz model için Şekil 19.' da eğitim tahmin değerleri gösterilmektedir. Bu çalışmadaki çıkış verilerimizin en iyi eğitim tahmin değeri 0,99004 ve test tahmin değeri 0.98816 olarak hesaplanmaktadır. Mükemmel eğitim tahmin oranı '1' olmak üzere bu eğitim algoritması için tahmin değerleri 0.99 değerinin üzerinde hesaplanmış olup sonuçlar mükemmel eğitim tahmin oranına yaklaşmaktadır.




Şekil 19. Momentumlu Adaptif Geriye Yayım algoritması ile eğitilen model için tahmin değerleri

Şekil 20. 'de Adaptif Geriye Yayım algoritması eğitim algoritmasını ile eğitilen model için en küçük kareler yönteminde hesaplanmış minimum hata oranı verilmektedir. Şekil de görüldüğü gibi çevrim sayısı 167 olmak üzere eğitim ve doğrulama tahmini çevrim sayısı arttıkça hata oranı değişmektedir. En iyi doğrulama performansı ise 167 çevrim için 0,020429' tir.

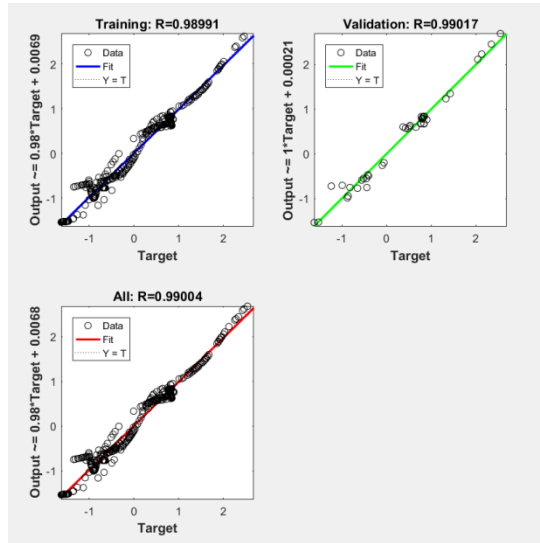


Şekil 20. Momentumlu Adaptif Geriye Yayım algoritması ile eğitilen model için doğrulama performansı



Şekil 21. Adaptif Geriye Yayım algoritması ile eğitilen model için gradyant ve başarısız doğrulamaların çevrim sayısına bağlı değişimi

Şekil 21., Adaptif Geriye Yayım algoritması ile eğitilen model için gradyant ve başarısız doğrulamaların çevrim sayısına bağlı değişimini göstermektedir. Bu model için çevrim sayısı 173 iken gradyant değeri 0,10287, başarısız doğrulama sayısı 6 ve öğrenme katsayısı 0,24162 değerlerini almaktadır.



Şekil 22. Momentumlu Adaptif Geriye Yayım algoritması ile eğitilen model için tüm tahmin değerleri

Momentumlu Adaptif Geriye Yayım algoritması ile eğitilen model için tüm tahmin değerleri Şekil 22.' de gösterilmektedir. Burada en iyi eğitim ve doğrulama tahmin değerleri sırasıyla 0,97738 ve 0.98551 olmaktadır. Bu mode için toplam tahmin değeri ise 0.97801 olup mükemmel eğitim tahmin oranı olan 1 değerine yaklaşmaktadır.

Tablo 2. Tek katmanlı model 5 farklı farklı eğitim algoritmaları için çevrim sayısı

Eğitim Algoritmaları	Çevrim Sayısı
Levenberg-Marquardt (LM)	43
Adaptif Geriye Yayım algoritması (AGY)	116
Momentumlu Adaptif Geriye Yayım algoritması (MAGY)	173
Geriye Yayım algoritması (GY)	1000
Momentum Katsayılı Geriye Yayım algoritması(MGY)	1000

Tablo 2.' de eğitim algoritmalarının maksimum çevrim sayısını gösterilmektedir. Tabloda da görüldüğü gibi Levenberg-Marquardt eğitim algoritması çözüme daha hızlı ulaşmaktadır. [0,0001-1,5] aralığında belirlediğimiz 200 farklı değer arasından en küçük ve en büyük m değerleri dahil edilerek 10 farklı kompozisyonel gradyant üst değeri seçilmiştir. Eğitim algoritmalarından çıkan sonuçlar ile sayısal çözümlenmeden elde edilen gerçek değerler Tablo 3, Tablo 4, Tablo 5., Tablo 6. karşılaştırılmıştır.

Tablo 3. Tek katmanlı model 5 farklı farklı eğitim algoritmaları için 10 adet m değeri için q_1 eş değer gerilmelerin en büyük değerinin en büyüğünü gerçek değerleri ile ağ çıkışların karşılaştırılması ve hata değerleri

m	q_1	LM	GY	MGY	AGY	MAGY	Hata LM	Hata GY	Hata MGY	Hata AGY	Hata MAGY
0,0001	594,91	582,8158	582,6644	584,3530	583,3674	585,259	12,10	12,25	10,56	11,54	9,65
0,005	590,81	582,2859	582,6694	584,4119	582,9044	585,34	8,52	8,14	6,39	7,90	5,47
0,01	586,93	581,7640	582,6747	584,4735	582,4453	585,425	5,17	4,26	2,46	4,49	1,51
0,03	573,82	579,8618	582,6978	584,7338	580,7453	585,796	6,05	8,88	10,92	6,93	11,98
0,5	605,23	597,9040	590,1413	591,7834	597,4507	598,959	7,33	15,09	13,45	7,78	6,27
1	670,55	678,5222	703,8225	703,7456	680,2525	686,606	7,97	33,27	33,20	9,70	16,06
1,15	709,58	709,9078	712,8524	720,1603	710,7040	707,983	0,33	3,28	10,58	1,13	1,59
1,23	729,65	730,3775	716,7568	725,2144	728,5862	723,993	0,73	12,89	4,44	1,07	5,66
1,36	761,17	765,7117	729,1902	738,6745	760,7724	766,153	4,55	31,98	22,49	0,39	4,99
1,45	782,19	786,1208	744,0737	759,6302	784,8564	795,959	3,93	38,12	22,56	2,66	13,76
1,5	793,60	795,5431	752,8684	777,5910	798,3616	807,766	1,94	40,73	16,01	4,76	14,168

Tablo 3. 'de eşdeğer gerilmelerin en büyük değerinin en büyüğü (q_1) gerçek değerleri ile kıyaslandığında hata değeri en düşük 0,33 değeri ile LM algoritması, hata değeri en yüksek olan 40,73 değeri ile GY algoritmasıdır.

Tablo 4. Tek katmanlı model 5 farklı farklı eğitim algoritmaları için 10 adet m değeri için q_2 eş değer gerilmelerin en büyük değerinin en küçüğünü gerçek değerleri ile ağ çıkışların karşılaştırılması ve hata değerleri

m	q_2	LM	GY	MGY	AGY	MAGY	Hata LM	Hata GY	Hata MGY	Hata AGY	Hata MAGY
0,0001	482,13	473,6398	471,4203	470,2803	474,1817	476,0945	8,50	10,71	11,85	7,95	6,04
0,005	478,76	472,3668	471,0865	469,9952	472,9815	475,7677	6,39	7,67	8,77	5,78	2,99
0,01	475,58	471,0977	470,7381	469,6971	471,7793	475,4222	4,49	4,85	5,89	3,81	0,16
0,03	464,91	466,3184	469,2728	468,4388	467,1978	473,9190	1,41	4,36	3,53	2,29	9,01
0,5	456,22	456,0106	457,6716	456,7092	454,7965	451,5310	0,21	1,45	0,49	1,42	4,69
1	549,80	547,9657	555,6126	575,5948	547,9879	557,2142	1,83	5,82	25,80	1,81	7,42
1,15	578,81	578,7303	566,5037	590,7366	578,9740	578,2380	0,08	12,31	11,92	0,16	0,57
1,23	593,10	594,0539	575,0857	592,2434	594,7770	590,1394	0,96	18,01	0,85	1,68	2,96
1,36	614,76	617,5600	608,0223	588,3467	618,8634	618,5326	2,80	6,74	26,42	4,10	3,77
1,45	628,77	633,7404	648,6356	579,3383	634,2447	638,1366	4,97	19,87	49,43	5,48	9,37
1,5	636,21	642,7467	672,7163	571,3434	642,3405	645,8751	6,54	36,51	64,87	6,13	9,66

Tablo 4. 'de eşdeğer gerilmelerin en büyük değerinin en küçüğünü (q_2) gerçek değerleri ile kıyaslandığında en küçük hata değeri 0,08 LM algoritması en büyük hata değeri 64,87 MGY algoritmasıdır. Tablo 5. 'de en küçük değerinin en büyüğünü (q_3) gerçek değerleri 0,21 MGY algoritması 46,64 değeri ile en büyük hata değeri çıkan GY algoritmasıdır.

Tablo 5. Tek katmanlı model 5 farklı farklı eğitim algoritmaları için 10 adet m değeri için q₃ eş değer gerilmelerin en küçük değerinin en büyüğünü gerçek değerleri ile ağ çıkışların karşılaştırılması ve hata değerleri

m	q ₃	LM	GY	MGY	AGY	MAGY	Hata LM	Hata GY	Hata MGY	Hata AGY	Hata MAGY
0,0001	243,97	256,2135	262,2950	248,3865	255,8577	248,8756	12,3	18,33	4,42	11,89	4,91
0,005	250,57	259,3015	264,8596	251,4214	258,9483	250,8596	8,73	14,29	0,85	8,38	0,29
0,01	255,74	262,4189	267,5368	254,5942	262,0743	252,9566	6,68	11,79	1,15	6,33	2,79
0,03	265,20	274,5545	278,8016	267,9924	274,2966	262,0846	9,35	13,60	2,79	9,09	3,12
0,5	451,33	438,5551	418,0279	436,9375	440,1380	443,0264	12,77	33,30	14,39	11,19	8,30
1	467,70	467,0315	464,8338	467,4958	467,2641	464,5076	0,67	2,87	0,21	0,44	3,20
1,15	466,12	464,9530	470,1658	470,2668	465,3808	466,3655	1,17	4,04	4,15	0,74	0,24
1,23	465,57	464,0752	474,6454	469,1927	463,6870	465,8119	1,49	9,08	3,63	1,88	0,24
1,36	466,92	462,5064	492,0594	461,5018	460,3418	462,8645	4,41	25,14	5,41	6,57	4,05
1,45	475,08	459,7863	513,5710	447,7317	457,7887	460,5442	15,29	38,49	27,35	17,29	14,53
1,5	479,69	457,6161	526,3285	435,7624	456,3391	459,6111	22,07	46,64	43,93	23,35	20,08

Tablo 6. Tek katmanlı model 5 farklı farklı eğitim algoritmaları için 10 adet m değeri için q₄ eş değer gerilmelerin en küçük değerinin en küçüğü gerçek değerleri ile ağ çıkışların karşılaştırılması ve hata değerleri

m	q ₄	LM	GY	MGY	AGY	MAGY	Hata LM	Hata GY	Hata MGY	Hata AGY	Hata MAGY
0,0001	127,83	154,1017	138,1839	146,1288	153,3089	144,8129	26,27	10,35	18,30	25,48	16,98
0,005	135,93	158,2185	142,4311	149,8802	157,3511	147,2903	22,29	6,50	13,95	21,42	11,36
0,01	143,99	162,3715	146,8649	153,8020	161,4376	149,9089	18,39	2,88	9,82	17,45	5,92
0,03	173,54	178,5076	165,5203	170,3633	177,3946	161,3068	4,97	8,02	3,17	3,86	12,23
0,5	378,50	386,1963	391,8171	379,1371	385,4663	386,9994	7,70	13,32	0,64	6,97	8,50
1	414,63	406,2164	401,2967	415,3844	407,4458	410,4688	8,41	13,33	0,76	7,18	4,16
1,15	416,62	404,4612	403,6852	419,1978	406,0463	413,2472	12,16	12,94	2,57	10,58	3,38
1,23	417,71	408,4627	407,0207	418,8215	406,9777	413,8929	9,24	10,69	1,12	10,73	3,81
1,36	419,45	418,1821	420,9770	413,9338	412,6790	414,4955	1,26	1,53	5,51	6,77	4,95
1,45	420,63	419,2663	438,3892	404,8793	419,5251	414,747	1,37	17,76	15,75	1,11	5,89
1,5	421,26	417,2653	448,7269	396,9844	423,8724	414,8364	4,00	27,46	24,28	2,61	6,43

Tablo 6. 'da eş değer gerilmelerin en küçük değerinin en küçüğü (q₄) gerçek değerlerinin en küçük hata değeri 0,64 MGY algoritması en büyük hata değeri ise 27,46 değeri üreten GY algoritmasıdır.

4. Sonuçlar

Bu çalışmada tek kenarından düzlem içi ısı akısına maruz bırakılan tek yönde fonksiyonel kademelendirilmiş dikdörtgen plakaların termo-elastik davranışını belirleyen en önemli parametreler olan eşdeğer gerilme seviyeleri ve kompozisyonel gradyant üst değerleri için yapay sinir ağı ile verimli eğitilmiş bir program elde edilmiştir.

Programların eğitilmesinde ve doğrulanmasında kullanılmak üzere sonlu farklar methodunu kullanarak ısı transferi ve elastisite denklemlerinin çözümünde elde ettiğimiz [0.001-1,5] aralığındaki rastsal olarak ürettiğimiz 200 farklı kompozisyonel gradyant üst değerine karşılık gelen eş değer gerilmenin en büyük değerinin en büyüğü, en büyük değerinin en küçüğü, en küçük değerinin en büyüğü ve en küçük değerinin en küçüğü için data setleri hazırlanmıştır. Bu setlerin kullanılacağı tek giriş ve dört çıkış ve tek katmanlı yapay sinir ağı modeli oluşturulmuştur. MATLAB [30] programlama dilinde oluşturulan modelde 4 farklı nörondaki ve beş farklı eğitim algoritması için analizler gerçekleştirilmiştir.

Eğitim ve test data setinin tahmin değeri ve hata oranları dikkate alındığında Levenberg-Maquart algoritması performansının daha iyi olduğu görülmüştür. Levenberg-Maquart algoritması tahmin değerinin %99 verimlilikte ve en az çevrim sayısı ile gerçek değerlere yakın sonuçlar vermiştir.

Bu çalışma ile, yüksek sıcaklık uygulamaları için çok önemli olan fonksiyonel kademelendirilmiş plakalarda eşdeğer gerilme seviyelerini belirlemek için zaman ve iş tasarrufu sağlamak üzere eğitilmiş modeller geliştirilmiştir. Bu eğitilmiş modeller, literatüre önemli katkılar sağlayacak ve bu konuda yapılacak çalışmaların kaynağı olacaktır.

Kaynaklar

- [1] 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, 2007.
- [2] 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, 2001.
- [3] Koizumi M., Niino M., “Overview of FGM research in Japan”, *MRS Bulletin*, vol.20, no.1, pp.19-21, 1995.
- [4] Natali M., Romanato F., Napolitani E., Salvador D.D., Drigo A.V., “Lattice curvature generation in graded InxGAs/GaAs buffer layer”, *Physical Review B*, vol.62, no.16, pp.11054-11062, 2000.
- [5] Noda N., “Thermal Stresses Intensity Factor for Functionally Graded Plate With an Edge Crack”, *International Journal of Thermal Stresses*, vol.22, no.4-5, pp.477-512, 1999.
- [6] 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.
- [7] 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, 1998.
- [8] 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, 2002.
- [9] 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.
- [10] 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*, vol.30, no.4, pp. 415-422, 1999.
- [11] 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.1283-1290:1283-1290, 2010.
- [12] Xiang Y., Zhou Y., “A dynamic multi-colony artificial bee colony algorithm for multi-objective optimization”, *Applied Soft Computing*, vol.35, pp.766-785, 2015.
- [13] 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, 2003.
- [14] Baykasoğlu A., Özbakır L., Tapkan P., “Artificial bee colony algorithm and its application to generalized assignment problem”, *Swarm Intelligence: Focus on Ant and Particle Swarm Optimization*, vol.532, ISBN 978-3-902613-09-7, 2007.
- [15] 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, 2004.
- [16] Ali M.M., Khompatraporn 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.
- [17] 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, 2010.
- [18] 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, 2012.

- [19] 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.
- [20] 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, 1999.
- [21] Öztürk C., “Yapay Sinir Ağlarının Yapay Arı Kolonisi Algoritması İle eğitilmesi”, *Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği, Ocak, 2011.*
- [22] Rumelhart D.E., Hinton G.E., Williams R.J., “Learning representations by backpropagation errors”, *Nature*, vol.323, pp.533-536, 1986.
- [23] Zurada J.M., “Introduction to Artificial Neural Networks”, West Publishing, 1992.
- [24] Manngard M., Kronqvist J., Böling J.M., “Structural learning in artificial neural networks using sparse optimization”, *Neurocomputing*, vol.272, no.10, pp.660-667, 2018.
- [25] Ham F.M., Kostanic I., *Principles of Neurocomputing for Science and Engineering*, 2001
- [26] 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.
- [27] Metrotra K., Mohan C.K., Ranka S., *Elements of artificial neural networks*, 1997.
- [28] Oğuz M., Yalıtkan malzemelerde elektiriksel dayanımın yapay sinir ağları ile belirlenmesi, *İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, Elektrik Mühendisliği Haziran, 2001.*
- [29] 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.
- [30] MATLAB. Mathematical software, version 2009a, TheMathWorks. Available: <http://www.mathworks.com>.