



YAPAY SİNİR AĞLARI KULLANILARAK RAMBERG-OSGOOD PARAMETRELERİNİN TAHMİN EDİLMESİ: GİRDİ PARAMETRELERİ VE NÖRON SAYILARININ TAHMİNLEME DOĞRULUĞU ÜZERİNDEKİ ETKİLERİNİN İNCELENMESİ

Mehmet Alperen SOYER¹, Özler KARAKAŞ^{*2}

¹Pamukkale Üniversitesi, Mühendislik Fakültesi, Makine Mühendisliği, Denizli
ORCID No : <https://orcid.org/0000-0002-7169-0956>

²Pamukkale Üniversitesi, Mühendislik Fakültesi, Makine Mühendisliği, Denizli
ORCID No : <http://orcid.org/0000-0002-6648-7865>

Anahtar Kelimeler

Öz

Ramberg-Osgood, yapay sinir ağları, tahminleme, makine öğrenmesi, yorulma

Bu çalışma kapsamında çeşitli çeliklere ait Ramberg-Osgood parametreleri olan çevrimsel dayanım katsayısı (K') ve çevrimsel uzama sertleşme üsteli (n') yapay sinir ağları (YSA) kullanılarak tahmin edilmiştir. Girdi parametrelerinin ve nöron sayılarının tahminleme doğruluğu üzerindeki etkileri incelenmiştir. YSA yapısında dokuz girdi parametresi, bir gizli katman ve iki çıktı parametresi içermektedir. Parametrelerin tahminleme doğruluğu üzerine etkisini gözlemlemek için önce dokuz girdi parametresine ait sonuçlar bulunmuş sonrasında sırasıyla her bir girdi parametresi tahminleme dışarısına çıkartılıp en sonunda sekiz girdi parametresi kalacak şekilde yeni sonuçlar elde edilmiştir. Bu sonuçlara etki eden diğer bir faktör olan nöron sayısı ise 1-30 aralığında değiştirilerek tahminleme sonuçlarına etkisi gözlemlenmiştir. Tahminleme sonuçlarının rastgeleliğini en aza indirmek için ise her bir parametre için 100 adet replikasyon yapılmıştır. Sonuç olarak çevrimsel dayanım katsayısı (K') tahmin edilirken en iyi nöron sayısı 1, sonuca en çok etki eden parametre akma dayanımı (σ_y) ve en az etki eden parametre ise Brinell sertliği (BHN) olmuştur. Çevrimsel uzama sertleşme üsteli (n') tahmin edilirken en iyi nöron sayısı 17, sonuca en çok etki eden parametre yorulma dayanım üsteli (b) ve en az etki eden parametre ise elastisite modülü (E) olmuştur. Ayrıca, çıktı parametreleri yüksek tahminleme doğruluğu ile tahmin edilmiştir.

* okarakas@pau.edu.tr
doi : 10.46399/muhendismakina.1292022

ESTIMATION OF RAMBERG-OSGOOD PARAMETERS USING ARTIFICIAL NEURAL NETWORKS: INVESTIGATING THE EFFECTS OF INPUT PARAMETERS AND HIDDEN NEURON NUMBERS ON ESTIMATION ACCURACY

Keywords

Ramberg-Osgood, artificial neural networks, estimation, machine learning, fatigue

Abstract

In this study, Ramberg-Osgood parameters, which are the cyclic strength coefficient (K') and the cyclic strain-hardening exponent (n') belonging to various steels, are estimated by means of artificial neural networks (ANN). The effects of input parameters and hidden neuron numbers on estimation accuracy are investigated. The ANN structure consists of nine input parameters, one hidden layer, and two output parameters. In order to investigate the effect of the parameters on the estimation accuracy, first the results for nine input parameters were found, then each input parameter was excluded from the estimation, and finally new results were obtained with eight input parameters. The number of hidden neurons, which is another factor affecting the results was varied in the range of 1-30, and its effect on the estimation results was observed. To reduce the randomization of the estimation results, 100 replications made for each parameter. As a result, while estimating the cyclic strength coefficient (K'), the best neuron number was 1, the most effective parameter on the result was yield strength (σ_y), and the least effective parameter on the result was Brinell hardness (BHN). While estimating the cyclic strain-hardening exponent (n'), the best neuron number was 17, the most effective parameter on the result was fatigue strength exponent (b), and the least effective parameter on the result was Young's modulus (E). Also, the output parameters were estimated with high estimation accuracy.

Araştırma Makalesi

Başvuru Tarihi : 03.05.2023

Kabul Tarihi : 31.07.2023

Research Article

Submission Date : 03.05.2023

Accepted Date : 31.07.2023

Extended Abstract

Introduction/ Background

Fatigue is a serious damage type and can change the material properties of machine components, transportation vehicles, and engineering structures under cyclic loading conditions. Fatigue fracture develops in the internal structure of the material and leaves no trace or evidence until the fatigue damage occurs. 80-85% of the fatigue damage in the machine components is caused by overloading conditions, surface roughness, and notches. Fatigue test requires at least 8-25 specimens and usually requires more than 60 specimens for the stress-strain curves. Plastic deformation is dominant in the low cycle fatigue and the number of cycles to failure is less than 5×10^4 . Estimating the fatigue life and fatigue parameters is vital to prevent the accidents effecting the human life, changing the material before the fatigue failure, and high amount of cost issues.

Ramberg and Osgood (1943) found an equation in order to explain the nonlinear relationship between the stress and strain in materials near to yield strength points and define the stress-strain curves. Traditional equations are used to calculate the fatigue parameters for a long time, but they are inadequate comparing the machine learning methods like artificial neural networks, artificial bee colony, and particle swarm optimization. For these reasons, the Ramberg-Osgood parameters (cyclic strength coefficient and cyclic strain-hardening exponent) are estimated using artificial neural networks.

Objectives/ Research Purpose

In this study, cyclic strength coefficient (K') and cyclic strain-hardening exponent (n') are estimated with the different combinations of input parameters and different number of hidden neurons. Used data in this study is consisted of 49 various steel types and obtained from the studies of Ghajar et al. (2011) and Genel (2004). Larger datasets are increasing the estimation accuracy and learning rate. There are not enough studies and data about the fatigue and fatigue parameters in the literature due to fatigue test is time consuming, knowledge required and high-cost process. Nine different input parameters (BHN, σ_u , σ_y , RA%, E, σ'_f , ϵ'_f , b, and c) were used to estimate the cyclic strength exponent and the strain-hardening exponent. Input parameters were selected to be easily obtained parameters from the basic tensile tests.

Methods/ Methodology

Nine different input parameters were used to estimate the cyclic strength coefficient (K') and cyclic strain-hardening exponent (n') using MATLAB 2022a software. Hyperbolic tangent sigmoid transfer function (tansig) was used in the input layer and output layer. Dataset was normalized with the "mapminmax" function within [-1,1] range. Dataset was divided into 85% learning and 15% testing using "dividerand" function. As a performance criterion, mean square error (MSE) was used. One hidden layer was used, and the hidden neuron numbers were selected within [1-30]. To make result more reliable and robust, replication (100 for this study) was made and average of these replications belonging the used input parameters and hidden neurons were considered. To observe the input parameter effects on the estimation accuracy, firstly all input parameters were used and named as General. Then, all input parameters were excluded from the estimation one by one, leaving eight input parameters, respectively. With excluding the input parameters one by one, their effects on the estimation accuracy will be observed.

Results/ Findings

The best result for the cyclic strength coefficient (K') was obtained with 30 hidden neurons using all input parameters. The effects of the input parameters on estimation accuracy were σ_y , σ_u , b , σ'_f , c , ϵ'_f , E , $RA\%$, and BHN from the most to least, respectively. The highest decrease in the regression values and the highest dependence on the estimation accuracy value were observed when the yield strength parameter was not included situation. Brinell hardness was the least effective parameter on the estimation accuracy. The number of hidden neurons with the best average result was "1" and the worst was "4".

The best result for the cyclic strain-hardening exponent (n') was obtained with 17 hidden neurons and the structure in which the modulus of elasticity parameter was not included in the estimation. The effects of the input parameters on estimation accuracy were b , ϵ'_f , c , σ_u , σ_y , $\%RA$, BHN, σ'_f , and E from the most to least, respectively. The highest decrease in the regression values and the highest dependence on the estimation accuracy value were observed when the fatigue strength exponent (b) parameter was not included situation. Young's modulus was the least effective parameter on the estimation accuracy. The number of hidden neurons with the best average result was "17" and the worst was "1".

As expected, the estimation results are much better when average regression results and replications are not taken into consideration. When looking the individual maximum regression values without the replication, the best structure for cyclic strength coefficient (K') was observed when the Young's modulus (E) parameter was excluded in the estimation and the number of hidden neuron number was 10. For cyclic strain-hardening exponent (n'), the best structure was observed when the reduction of area ($RA\%$) was excluded in the estimation and the number of hidden neuron number was 7.

Discussion and Conclusions

In this study, it is concluded that when estimating the Ramberg-Osgood parameters, a small dataset did not affect the results significantly. At the same time, it has been shown that larger and more complex deep learning structure than the single hidden layer structure is not required, and higher estimation accuracies can be obtained with low hidden neuron numbers without increasing the computational power. Effects of the input parameters on estimation accuracy of the cyclic strength coefficient and cyclic strain-hardening exponent were investigated. Cyclic strength coefficient (K') was highly dependent on yield strength (σ_y) and cyclic strain-hardening exponent (n') was highly dependent on fatigue strength exponent (b). The best hidden neuron number for the cyclic strength coefficient was the "1" and "17" for the cyclic strain-hardening exponent (n'). Considering the maximum regression values without the replication, the best resulting structure for the cyclic strength exponent was 10 hidden neurons without the Young's modulus parameter (E) and for the cyclic strain-hardening exponent was 7 hidden neuron numbers without the reduction of area ($RA\%$).

1. Giriş

Yorulma, tekrarlı yükleme koşulları altında zorlanan çoğunlukla makine elemanları, ulaşım araçları ve mühendislik yapıları olmak üzere malzemenin genel yapısını değiştiren ve sonuçları ciddi boyutlara ulaşabilen bir hasar türüdür. Yorulma kırılması hiçbir iz ve belirti göstermeden malzemenin içyapısında gelişip nihai çatlak oluşumuna kadar fark edilmeden ilerlemektedir ve bu da yorulma hasarını son derece etkili kılmaktadır. Günümüzde makine elemanlarında görülen hasarların %80-85'i aşırı yükleme, yüzey pürüzlülükleri ve çentikler sonucunda meydana gelen yorulma hasarından kaynaklanmaktadır. Yükleme türleri statik ve dinamik olmak üzere farklı koşullarda gerçekleşebilmektedir. Çevrimsel yükleme, statik yüklemeye göre daha tehlikeli ve malzemeyi daha çok hasara uğratabilecek bir yükleme türüdür. Yorulma deneyleri en az 8-15 olmak üzere ve genellikle daha doğru ve güvenilir gerilme-uzama eğrilerinin oluşturulması için 60'ın üzerinde numune ile yapılmaktadır. Literatürde düşük (kısa) çevrimli yorulma çevrim sayısının 5×10^4 'ten küçük olduğu durumlar için kullanılır ve burada plastik deformasyon daha hâkim olan bir büyüklüktür. Malzeme plastik deformasyona uğradıktan sonra deformasyonun geri döndürülmesi mümkün değildir. Malzemede oluşan deformasyonlar yüksek gerilme genliği ve düşük frekansta daha hızlı bir şekilde birikip, malzemenin yorulma ömrünü büyük ölçüde düşürmektedir. Tekrarlı gerilmeler sonucu malzemenin içyapısında oluşan deformasyon sürekli artmakta ve malzemede bir süre sonra yorulma hasarı meydana gelir. Yorulma ömrü ve yorulma parametrelerinin tahmin edilmesi ile malzemede oluşabilecek olumsuz etkilerin önüne geçilmesi, insan sağlığını tehlikeye atacak kazaların önlenmesi, malzemenin nihai hasara uğramadan önce değiştirilmesi ve oluşabilecek yüksek maliyet sorunlarının önüne geçilip önceden önlem almak büyük önem arz etmektedir.

Akma dayanımı noktalarına yakın olan malzemelerdeki gerilme ve uzama arasındaki lineer olmayan ilişkiyi açıklamak ve gerilme-uzama eğrisini tanımlamak için Ramberg-Osgood (Ramberg ve Osgood, 1943) aşağıdaki Eşitlik (1)'i bulmuştur. Özellikle plastik deformasyon ile sertleşebilen ve elastik-plastik bölge arasında yumuşak bir geçişe sahip malzemelerde uygulanabilmektedir (Deolia ve Shaikh, 2016; Baird, Smith, Palermo ve Pampanin, 2014).

$$\varepsilon_t = \frac{\sigma}{E} + \left(\frac{\sigma}{K'}\right)^{\frac{1}{n'}} \quad (1)$$

Eşitlik (1)'de ε_t toplam elastik ve plastik uzama, σ gerilme, E elastisite modülü, K' çevrimsel dayanım katsayısı ve n' çevrimsel uzama sertleşme üstelidir. Yorulma olgusuna ilişkin parametrelerin elde edilmesinde geleneksel yöntemler olarak adlandırılan ampirik bağıntılar (Morrow, 1965; Srivatsan, Soboyejo ve Lederich,

1995; Raske ve Morrow, 1969; Mitchell, 1996; Ong, 1993a ve Ong 1993b; Muralidharan ve Manson, 1988) uzun yıllar boyunca kullanılmıştır. Gerilme-uzama eğrilerini oluştururken gerekli parametreleri elde etmek için çok sayıda deney numunesi, farklı yükleme koşulları, maliyet, zaman ve bilgi birikimi gerekmektedir. Günümüzde formülasyon yöntemi ile elde edilen parametre değerleri, deney sonucunda elde edilen veriler ile karşılaştırıldığında yetersiz kalmaktadır. Bu yüzden makine öğrenmesi yöntemleri ile yorulma parametrelerin tahmin edilmesi günümüzde büyük önem kazanmıştır (Karakaş, Berto ve Hong, 2023). Makine öğrenmesi ve yapay zekâ ile kolaylıkla her türden problemlere ilişkin tahminleme algoritmaları uygulanabilmektedir. Makine öğrenmesi ile kaynaklı ve kaynaksız farklı türden malzemelerin yorulma dayanımı ve yorulma parametrelerinin tahmin edilmesine dair çeşitli çalışmalar bulunmaktadır. Soyer, Kalaycı ve Karakaş (2022), yüksek dayanımlı çeliklerin düşük çevrimli yorulma parametrelerini ve yorulma ömrünü YSA ile yüksek doğrulukta tahmin etmişlerdir. Aynı zamanda farklı öğrenme fonksiyonları, aktivasyon fonksiyonları ve nöron sayıları kullanarak bunların tahminleme üzerine etkilerini incelemişlerdir. Kalaycı, Karagöz ve Karakaş (2019), yapay arı kolonisi algoritması ile magnezyum alaşımlı kaynakların yorulma ömürlerini tahmin etmişlerdir. Ma, Chen ve Shan (2010), havacılık sektöründe kullanılan döndürme karıştırma kaynaklı alüminyum alaşımının yorulma ömrünü genetik algoritma ile yapay sinir ağlarını birlikte kullanarak tahmin etmişlerdir. Yang, Zou ve Deng (2015), gazaltı kaynak yöntemi ile birleştirilmiş çeşitli titanyum alaşımlarının yorulma ömürlerini yapay sinir ağları ve parçacık sürü optimizasyonu ile tahmin etmişlerdir. Karakaş ve Tomasella (2013), kaynaklı magnezyum ve alüminyum alaşımlarının yorulma ömürlerini ve S-N eğrilerini YSA ile tahmin etmişlerdir. Genel (2004), düşük çevrimli yorulma parametrelerini, çekme dayanımı testlerinden elde edilen parametreler ile YSA kullanarak tahmin edip geleneksel denklemler ile elde edilen sonuçlarla karşılaştırmıştır. Ghajar, Naserifar, Sadati ve Alizadeh K. (2011), yaptıkları çalışmada çevrimsel dayanım katsayısı ve çevrimsel uzama sertleşme üsteli parametrelerini YSA ile tahmin etmişlerdir. Ponticelli, Guarino ve Giannini (2020), yaptıkları çalışmada lazerle sertleştirme yöntemi uygulanmış AISI 1040 çeliklerinde optimum işlem parametrelerini hesaplamış ve yorulma ömürlerini genetik algoritma destekli regresyon modeli ile tahmin etmişlerdir. Zhan ve Li (2021), çalışmalarında eklemeli imalat ile üretilmiş 316L paslanmaz çeliğinin üretim parametrelerini göz önüne alarak yorulma ömürlerini yapay sinir ağları, rastgele orman algoritması ve destek vektör makinesi ile eğitilmiş ve sürekli ortam hasar mekaniği ile üretilmiş sonuçlarla tahmin ederek deneysel sonuçlar ile karşılaştırmışlardır. Tomasella, Dsoki, Hanselka ve Kaufmann (2011), çevrimsel malzeme parametrelerini (Manson-Coffin-Basquin ve Ramberg-Osgood) yapay sinir ağları kullanarak tahmin etmişlerdir. Ayrıca ANSLC programı kullanarak yorulma ömürlerini 103-105 çevrim sayısı aralığında başarılı bir şekilde tahmin etmişlerdir. Janežič, Klemenc

ve Fajdiga (2010), yaptıkları çalışmada çevrimsel gerilme-uzama eğrilerini ve yorulma ömürlerini çok katmanlı yapay sinir ağları yaklaşımı kullanarak tahmin etmişlerdir. Ertas (2012), fiber ile güçlendirilmiş laminatlarda farklı lif açılarını optimize etmek için yorulma ömürlerini parçacık sürü optimizasyonu algoritması kullanarak tahmin etmiştir. Ek olarak Kalaycı, Karagöz ve Karakaş (2020), yaptıkları çalışmada yorulma ömürlerini tahmin etmede kullanılan yapay zekâ yöntemlerini araştırıp, yapay sinir ağlarının yorulma ömürlerini tahmin etmede kullanılması sıklığının ezici bir üstünlükte olduğunu vurgulamışlardır.


Bu çalışmada kapsamında çevrimsel dayanım katsayısı ve çevrimsel uzama sertleşme üsteli farklı girdi parametreleri kombinasyonları ve nöron sayıları kullanılarak yapay sinir ağları ile tahmin edilmiştir. Çalışmada kullanılan veriler Gharaj ve diğ. (2011) ve Genel (2004), çalışmalarından alınmıştır ve 49 adet çeşitli çelik gruplarından oluşmaktadır. Veri seti büyüdükçe algoritmanın öğrenme ve tahmin etme kabiliyeti gelişmektedir. Fakat literatürdeki eksiklikler ve yorulma konusunda yapılan çalışmaların uzun zaman alması, maliyetli olması, bilgi birikimi gerektirmesi ve test için gerekli deney numune sayısının fazla olmasından dolayı kullanılan veri seti küçük kalmıştır. Bu gibi durumlarda yapay sinir ağları parametrelerini iyi bilmek, kullanılan veri tipi ve büyüklüğüne göre uygun parametreler seçmek ve probleme göre özelleştirmek tahmin edilen sonuçların doğruluğunu büyük oranda etkileyip performans kriterlerini arttırmaktadır. Çevrimsel dayanım katsayısı (K') ve çevrimsel uzama sertleşme üstelini (n') tahmin etmek için dokuz farklı girdi parametresi kullanılmıştır. Bu parametreler; Brinell sertliği (BHN), çekme dayanımı (σ_u), akma dayanımı (σ_y), alanda yüzdelik azalma (%RA), elastisite modülü (E), yorulma dayanım katsayısı (σ'_f), yorulma süneklik katsayısı (ϵ'_f), yorulma dayanım üsteli (b) ve yorulma süneklik üsteli (c) olarak dikkate alınmıştır. Girdi parametreleri özellikle basit çekme deneyinden elde edilen ve kolayca erişilebilen parametreler olarak seçilmiştir. Bu sayede tahminleme yaparken literatürde bulunması ve deneylerle elde etmesi zor parametreler olmadan da kolaylıkla yüksek regresyon değerleriyle tahminleme yapılabileceği gösterilmiş olacaktır.

2. Yapay Sinir Ağları ve Uygulanması

Yapay sinir ağları tıpkı insan beynindeki sinirler hücrelerine benzeyen yapay nöronlara sahip bir sistemdir. Bu yapay nöronlar birbirleriyle iletişim kurarak elde ettikleri bilgileri bir sonraki katmana aktarırlar. Yapay sinir ağlarında genel olarak üç adet katman vardır ve bu katmanlar sırasıyla girdi katmanı, gizli katman ve çıktı katmanıdır. Girdi ve çıktı katmanının sayısı her zaman birdir ve sadece girdi ve çıktı katmanındaki parametre sayıları artıp azalabilir. Gizli katmanın sayısı ise en az bir olmak şartıyla belirli bir üst sınırı yoktur. Gizli katman sayısının artışı ile yapay sinir ağlarının karmaşıklığı, işlem süresi, derinliği ve tahmin doğruluğu artmaktadır. Gizli katman sayısının artması ile derin yapay sinir ağları

yapısı oluşur. Girdi katmanındaki veriler nöronlar aracılığıyla iletildikten sonra ağırlık değerleri ile çarpılıp bias adı verilen aktivasyon fonksiyonunu sağa veya sola ötelemeye yarayan değerler eklenir. Sonuç olarak tahmin edilen parametre değerleri elde edilir.

Tüm testler MATLAB R2022a yazılımı ile i3-11154G 3.00 GHz CPU, 8 GB DDR4 RAM, 3500-2500 MB/s okuma ve yazma hızlarına sahip NVMe M.2 SSD ve Windows 11 işletim sistemine sahip dizüstü bilgisayarda yapılmıştır. Bu çalışmada kullanılan yapay sinir ağlarının genel yapısı, kullanılan girdi ve çıktı parametreleri ve katmanlar Şekil 1’de verilmiştir.



Şekil 1. Yapay Sinir Ağlarının Yapısı

Gizli katmanda ve çıktı katmanında daha önceki çalışmamızda (Soyer ve diğ., 2022) performansı doğrulanmış olan hiperbolik tanjant sigmoid transfer fonksiyonu “tansig” kullanılmıştır. Öğrenme fonksiyonu olarak Levenberg-Marquardt “trainlm” kullanılmıştır. Veri setinin normalize edilmesi için “mapminmax” fonksiyonu kullanılıp, veriler $[-1,1]$ aralığında normalize edilmiştir. Veriler “diverand” fonksiyonu ile %85 öğrenme ve %15 test etme şeklinde ayrılmıştır. Yapay sinir ağlarında girdi parametreleri ilk önce gizli katmanlara iletilip ardından rastgele üretilmiş ağırlık değerleri ile çarpılıp, aktivasyon fonksiyonunu sağ veya sol yöne kaydırmaya yarayan bias değeri de eklendikten sonra toplam fonksiyonu elde edilmektedir. Toplam fonksiyonu, aktivasyon fonksiyona iletildikten sonra çıktı sonuçları elde edilmektedir. Performans kriteri olarak ortalama hata karesi “MSE” kullanılmıştır. Gizli katman nöron sayıları $[1-30]$ aralığında değişmekte olup tek gizli katman kullanılmıştır. Elde edilen sonuçlar her çalıştırma sonrasında değiştiği için güvenilirliğini ve stabilitesini ölçmek için replikasyon

yöntemi kullanılmıştır. Replikasyon aynı çalıştırma kriterlerini belirlenen sayıda (bu çalışmada 100 olarak belirlendi) tekrarlı bir şekilde çalıştırmaktadır. Tahmin edilen verilerin gerçekteki değerleri ile ne kadar iyi uyum sağladığını belirlemek için regresyon parametresine bakılıp regresyon değeri “1” sayısına ne kadar yakınsa o kadar doğru sonuçlar, “0” sayısına ne kadar yakınsa da sonuçlarda o kadar kötü uyum elde edilmiş anlamına gelmektedir. Regresyon değerleri hem öğrenme hem de test parametrelerini içeren tüm regresyon değerleri dikkate alınmıştır. Çıktı parametreleri tahmin edilirken girdi parametrelerinin tahminlemeye etkilerini incelemek için önce tüm girdi parametreleri ile tahminleme yapılmıştır. Ardından sırasıyla sekiz girdi parametresi kalacak şekilde tüm girdi parametreleri tek tek tahminlemenin dışına alınmıştır. Bu sayede tüm parametreler ile elde edilen tahminleme sonuçları ile çıkartılan parametrenin tahmin etme doğruluğuna etkisi gözlemlenebilecektir.

Bu çalışmada araştırma ve yayın etiğine uyulmuştur.

3. Bulgular ve Tartışma

Bu çalışma kapsamında Ramberg-Osgood gerilme uzama parametreleri yapay sinir ağları yöntemiyle tahmin edilmiştir. Parametreler tahmin edilirken dokuz adet sırasıyla; Brinell sertliği (BHN), çekme dayanımı (σ_u), akma dayanımı (σ_y), alanda yüzdelik azalma (%RA), elastisite modülü (E), yorulma dayanım katsayısı (σ'_f), yorulma süneklik katsayısı (ϵ'_f), yorulma dayanım üsteli (b) ve yorulma süneklik üsteli (c) girdi parametreleri kullanılarak, çevrimsel dayanım katsayısı (K') ve çevrimsel uzama sertleşme üsteli (n') tahmin edilmiştir. Çıktı parametreleri tahmin edilirken girdi parametrelerinin çıktı parametreleri arasındaki ilişki ve tahmin etme doğruluğuna etkileri incelenmiştir. Her iki çıktı parametresi için sırasıyla birinci girdi parametresinden başlayıp sonuncu girdi parametresine kadar tek tek girdi parametreleri, girdi katmanından çıkartılarak tahminlemeler yapılmıştır. Örnek olarak Brinell sertliği girdi katmanından çıkartılarak geri kalan sekiz girdi parametresi ile tahminleme yapılmıştır ve grafiklerde “BHN” olarak belirtilen değerler Brinell sertliğinin dikkate alınmadığı sonuçlardır. Son olarak dokuz girdi parametresi birlikte dikkate alınarak tahminleme yapılmıştır ve grafiklerde tüm girdi parametreleri dikkate alındığı için “Hepsi” olarak adlandırılmıştır.


Elde edilen regresyon sonuçları her bir nöron için 100 adet replikasyonla yapılmış olup 100 replikasyona ait regresyon değerlerinin ortalaması alınarak bulunmuştur. Yapay sinir ağlarının genel yapısında rastgelelik olduğu için her bir çalıştırmada farklı sonuçlar elde edilmektedir. Belirlenen yapıdaki algoritmanın doğruluğunu ve stabilitesini ölçmek için replikasyon yapılması düşük karmaşıklık ve değişken içeren yapılarda zorunludur. Kullanılan algoritmayı tek bir çalıştırma sonucunda 100 replikasyonda elde edilen sonuçlar en kötü sonuç ya da en iyi sonucu verebilmektedir. İşte bu rastgeleliği olabildiğince en aza indirerek

ortalama olarak en iyi sonuçları veren yapay sinir ağları yapısını belirlemek oldukça önemlidir. Çevrimsel dayanım katsayısı (K') için her bir nöron sayısı için elde edilen replikasyonların ortalama regresyon sonuçları Tablo 1'de, çevrimsel uzama sertleşme üsteli (n') için elde edilen sonuçlar ise Tablo 2'de verilmiştir.


Tablo 1. Çevrimsel Dayanım Katsayısında Her Bir Nöron İçin Elde Edilen Ortalama Regresyon Değerleri

Nöron	Tahminlemeye Dahil Edilmeyen Parametreler									
	BHN	σ_u	σ_y	%RA	E	σ'_f	ϵ'_f	b	c	Hepsi
1	0,8373	0,8275	0,7823	0,8685	0,8643	0,8377	0,8537	0,8056	0,7838	0,8278
2	0,7235	0,6775	0,6896	0,6989	0,7649	0,7163	0,7170	0,6991	0,6796	0,6676
3	0,7047	0,6313	0,6911	0,6880	0,7096	0,6639	0,7237	0,6628	0,6426	0,6869
4	0,6687	0,6725	0,6610	0,6760	0,6427	0,6350	0,6179	0,6562	0,6529	0,6293
5	0,6954	0,6963	0,6656	0,7019	0,6836	0,6364	0,7027	0,6482	0,6741	0,6764
6	0,7082	0,6546	0,6574	0,7225	0,7623	0,7299	0,7218	0,7364	0,7295	0,7373
7	0,7067	0,7262	0,6624	0,7245	0,7004	0,7930	0,7494	0,7757	0,7037	0,7681
8	0,7440	0,7778	0,7229	0,7311	0,7383	0,7334	0,7014	0,7445	0,7377	0,7419
9	0,7496	0,7876	0,7662	0,7840	0,7600	0,7623	0,7877	0,7409	0,7415	0,7106
10	0,7498	0,7522	0,7101	0,8020	0,7749	0,6959	0,7969	0,7089	0,7641	0,7489
11	0,8052	0,7248	0,7364	0,7507	0,7864	0,7261	0,8160	0,7728	0,7566	0,8135
12	0,7739	0,7479	0,6802	0,6882	0,8204	0,7960	0,7824	0,7401	0,7918	0,6968
13	0,7933	0,7819	0,7430	0,7653	0,7969	0,7808	0,8203	0,7551	0,7597	0,8295
14	0,7767	0,7668	0,7396	0,7738	0,7770	0,7456	0,8027	0,6887	0,7023	0,8118
15	0,7704	0,7549	0,7855	0,7878	0,7554	0,7514	0,7980	0,7677	0,7616	0,7829
16	0,8729	0,8060	0,8060	0,7539	0,7525	0,7417	0,7824	0,8236	0,7935	0,7859
17	0,7610	0,7500	0,7866	0,7549	0,7961	0,7713	0,8532	0,7728	0,7930	0,8182
18	0,7815	0,7853	0,7474	0,7212	0,7941	0,7908	0,8232	0,7824	0,7297	0,7846
19	0,8040	0,8206	0,7861	0,7401	0,7570	0,7602	0,8100	0,8331	0,7808	0,7794
20	0,7326	0,8054	0,7723	0,8108	0,7583	0,7617	0,8407	0,7613	0,7362	0,7730
21	0,7320	0,7716	0,7424	0,8258	0,8590	0,8043	0,7951	0,7296	0,7754	0,8123
22	0,7835	0,8060	0,6911	0,8459	0,7909	0,7850	0,8239	0,7589	0,7619	0,7440
23	0,7130	0,8178	0,7880	0,7566	0,8253	0,7864	0,8069	0,8231	0,7550	0,8225
24	0,7867	0,8139	0,8242	0,7838	0,8150	0,7492	0,8265	0,7599	0,8439	0,8105
25	0,8158	0,8057	0,7949	0,7863	0,8289	0,7562	0,7956	0,7848	0,7659	0,8120
26	0,8262	0,7995	0,7810	0,8076	0,8193	0,8398	0,8222	0,7631	0,7886	0,7669
27	0,8216	0,8096	0,7989	0,8022	0,8093	0,8116	0,8190	0,7930	0,7757	0,7816
28	0,7990	0,7954	0,7750	0,7937	0,8337	0,8187	0,8541	0,8310	0,8033	0,8213
29	0,8073	0,7571	0,7774	0,7823	0,7881	0,7689	0,7834	0,7930	0,8224	0,8224
30	0,8019	0,8218	0,7796	0,7616	0,8142	0,7683	0,8294	0,8356	0,8266	0,9066

Çevrimsel dayanım katsayısı (K') için en iyi sonuç 30 nöron ve tüm girdi parametrelerinin birlikte kullanıldığı yapıda elde edilmiştir. Girdi parametrelerinin tahminleme sonuçları üzerine etkileri en çoktan en aza doğru sırasıyla; σ_y , σ_u , b , σ'_f , c , ε'_f , E , %RA ve BHN olmuştur. Tahminleme sonucu regresyon değerlerinde en çok azalma ve tahminleme değerine en çok bağımlılık akma dayanımı parametresinin dahil edilmediği durumda gerçekleşmiştir. Tahminlemeye en az etkisi olan parametre ise Brinell sertliği olmuştur. Tüm girdi parametre kombinasyonlarında (dahil edilmeyen ve hepsinin dahil edildiği) Şekil 2'de gösterildiği gibi en iyi ortalama sonuç veren nöron sayısı 1 olup en kötü sonuç veren nöron sayısı ise 4 olmuştur. Aynı zamanda tahminlemeye dahil edilmeyen parametreler ve tüm parametrelerin birlikte kullanıldığı yapılara ait en iyi regresyon sonucu değerleri ise Şekil 3'te verilmiştir.



Şekil 2. Çevrimsel Dayanım Katsayısı (K') İçin Farklı Girdi Kombinasyonlarında Her Bir Nöron Sayısı İçin Elde Edilen Ortalama Regresyon Değerleri



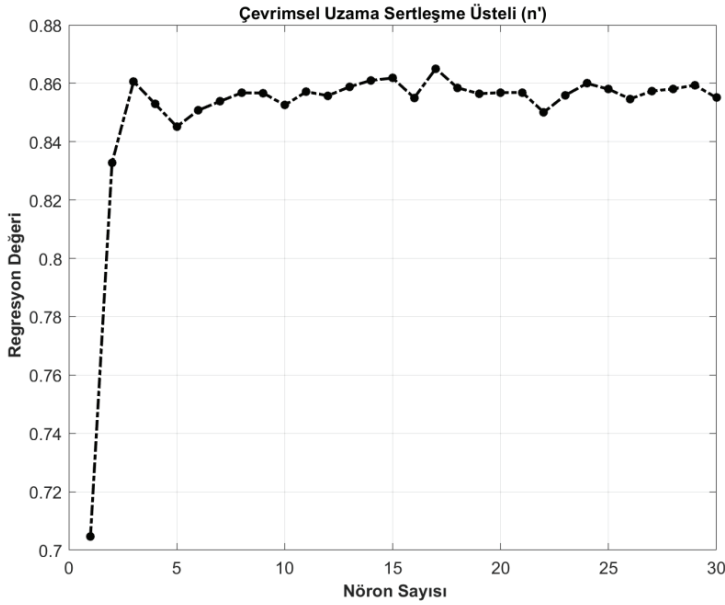
Şekil 3. Çevrimsel Dayanım Katsayısı (K') İçin Tahminlemeye Dahil Edilmeyen Parametreler ve Tüm Parametrelerin Birlikte Kullanıldığı Yapılara Ait En İyi Regresyon Sonuçları

Tablo 2. Çevrimsel Uzama Sertleşme Üstelinde Her Bir Nöron İçin Elde Edilen Ortalama Regresyon Değerleri


Nöron	Tahminlemeye Dahil Edilmeyen Parametreler									
	BHN	σ_u	σ_y	%RA	E	σ'_f	ϵ'_f	b	c	Hepsi
1	0,7123	0,7034	0,7133	0,7056	0,7155	0,7084	0,7168	0,6632	0,6949	0,7122
2	0,8313	0,8379	0,8211	0,8228	0,8351	0,8416	0,8435	0,8183	0,8320	0,8442
3	0,8529	0,8641	0,8529	0,8626	0,8762	0,8635	0,8684	0,8484	0,8691	0,8485
4	0,8461	0,8527	0,8504	0,8624	0,8619	0,8511	0,8456	0,8504	0,8560	0,8525
5	0,8411	0,8401	0,8460	0,8579	0,8533	0,8506	0,8508	0,8328	0,8335	0,8456
6	0,8473	0,8475	0,8572	0,8474	0,8571	0,8643	0,8490	0,8395	0,8559	0,8425
7	0,8513	0,8649	0,8516	0,8646	0,8724	0,8694	0,8336	0,8478	0,8440	0,8388
8	0,8626	0,8644	0,8430	0,8679	0,8600	0,8572	0,8504	0,8394	0,8579	0,8645
9	0,8631	0,8559	0,8547	0,8727	0,8637	0,8705	0,8361	0,8407	0,8457	0,8638
10	0,8600	0,8495	0,8478	0,8604	0,8630	0,8590	0,8500	0,8476	0,8436	0,8444

11	0,8514	0,8647	0,8427	0,8642	0,8695	0,8627	0,8664	0,8421	0,8582	0,8493
12	0,8617	0,8462	0,8572	0,8593	0,8651	0,8637	0,8588	0,8382	0,8475	0,8599
13	0,8569	0,8603	0,8625	0,8691	0,8684	0,8674	0,8450	0,8479	0,8523	0,8583
14	0,8687	0,8542	0,8647	0,8732	0,8749	0,8605	0,8579	0,8420	0,8538	0,8603
15	0,8611	0,8582	0,8632	0,8779	0,8918	0,8550	0,8582	0,8453	0,8426	0,8647
16	0,8587	0,8595	0,8569	0,8614	0,8820	0,8480	0,8537	0,8392	0,8442	0,8470
17	0,8690	0,8637	0,8651	0,8728	0,8823	0,8751	0,8631	0,8611	0,8404	0,8581
18	0,8558	0,8546	0,8497	0,8716	0,8673	0,8660	0,8600	0,8514	0,8488	0,8596
19	0,8642	0,8467	0,8694	0,8637	0,8669	0,8675	0,8427	0,8508	0,8447	0,8478
20	0,8656	0,8628	0,8555	0,8562	0,8539	0,8526	0,8399	0,8586	0,8518	0,8713
21	0,8590	0,8610	0,8488	0,8688	0,8575	0,8705	0,8513	0,8409	0,8535	0,8574
22	0,8646	0,8394	0,8529	0,8680	0,8539	0,8554	0,8405	0,8358	0,8494	0,8410
23	0,8605	0,8571	0,8468	0,8659	0,8582	0,8657	0,8421	0,8431	0,8613	0,8584
24	0,8792	0,8601	0,8604	0,8704	0,8727	0,8801	0,8401	0,8390	0,8386	0,8593
25	0,8583	0,8627	0,8544	0,8598	0,8637	0,8630	0,8472	0,8613	0,8541	0,8557
26	0,8589	0,8360	0,8635	0,8665	0,8749	0,8640	0,8491	0,8436	0,8370	0,8532
27	0,8695	0,8707	0,8589	0,8521	0,8746	0,8560	0,8524	0,8439	0,8423	0,8529
28	0,8624	0,8576	0,8726	0,8661	0,8840	0,8590	0,8409	0,8329	0,8432	0,8625
29	0,8556	0,8709	0,8708	0,8691	0,8759	0,8618	0,8398	0,8552	0,8566	0,8381
30	0,8487	0,8538	0,8541	0,8531	0,8658	0,8633	0,8597	0,8528	0,8444	0,8551

Çevrimsel uzama sertleşme üsteli (n') için en iyi sonuç 17 nöron ve elastisite modülü parametresinin tahminlemeye dahil edilmediği yapıda elde edilmiştir. Girdi parametrelerin tahminleme sonuçları üzerine etkileri en çoktan en aza doğru sırasıyla; b , ϵ'_f , c , σ_w , σ_y , %RA, BHN, σ'_f ve E olmuştur. Tüm parametrelerin birlikte tahmin edildiği koşul ise ortalama bir sonuç vermiştir. Tahminleme sonucu regresyon değerlerinde en çok azalma ve tahminleme değerine en çok bağımlılık yorulma dayanım üsteli (b) parametresi dahil edilmediği durumda gerçekleşmiştir. Tahminlemeye en az etkisi olan parametre ise elastisite modülü (E) olmuştur. Tüm girdi parametre kombinasyonlarında (dahil edilmeyen ve hepsinin dahil edildiği) Şekil 4'te gösterildiği gibi en iyi ortalama sonuç veren nöron sayısı 17 olup en kötü sonuç veren nöron sayısı ise 1 olmuştur. Tahminlemeye dahil edilmeyen parametreler ve tüm parametrelerin birlikte kullanıldığı yapılara ait en iyi regresyon sonucu değerleri ise Şekil 5'te verilmiştir.



Şekil 4. Çevrimsel Uzama Sertleşme Üsteli (n') İçin Farklı Girdi Kombinasyonlarında Her Bir Nöron Sayısı İçin Elde Edilen Ortalama Regresyon Değerleri



Şekil 5. Çevrimsel Uzama Sertleşme Üsteli (n') İçin Tahminlemeye Dahil Edilmeyen Parametreler ve Tüm Parametrelerin Birlikte Kullanıldığı Yapılara Ait En İyi Regresyon Sonuçları

Ortalama regresyon sonuçları ve replikasyonlar dikkate alınmadığı zaman beklediği gibi sonuçlar çok daha yüksek çıkmaktadır. Ortalama regresyon sonuçlarının da alınmasının nedeni çalışılan parametrelerin yazılan kodun verimliliğine ne derece etki ettiğini ve dahil edilip edilmediğinde nasıl sonuçlar verdiğini gözlemlemek içindir. Tek başına replikasyonların ortalaması dahil edilmediğinde çevrimsel dayanım katsayısı ve çevrimsel uzama sertleşme üstelini tahmin ederken dahil edilmeyen parametreler ve tüm parametrelerin dahil edildiği durumlarda elde edilen en yüksek regresyon değerleri ve ortalama kare hataları Tablo 3'te verilmiştir.

Tablo 3. Çevrimsel Dayanım Katsayısı ve Çevrimsel Uzama Sertleşme Üsteli İçin Bulunan En Yüksek Regresyon Değerleri ve Ortalama Kare Hataları

Parametre Yapısı	Çevrimsel Dayanım Katsayısı (K')			Çevrimsel Uzama Sertleşme Üsteli (n')			
	Ortalama Hata Karesi	Regresyon Değeri	Nöron Sayısı	Parametre Yapısı	Ortalama Hata Karesi	Regresyon Değeri	Nöron Sayısı
BHN'siz	9,50E-06	0,9982	25	BHN'siz	1,79E-05	0,9949	21
σ_u 'suz	4,88E-03	0,9981	10	σ_u 'suz	1,92E-05	0,9947	16
σ_y 'suz	4,44E-09	0,9982	30	σ_y 'suz	2,40E-05	0,9948	24
%RA'sız	1,30E-02	0,9880	26	%RA'sız	7,78E-06	0,9977	7
E'siz	1,62E-02	0,9990	10	E'siz	2,11E-05	0,9940	9
σ_f 'suz	8,56E-07	0,9982	29	σ_f 'suz	1,63E-05	0,9953	15
ϵ_f 'suz	1,37E-03	0,9988	14	ϵ_f 'suz	2,75E-05	0,9924	6
b'siz	1,02E-10	0,9979	20	b'siz	4,54E-05	0,9873	18
c'siz	7,31E-04	0,9976	25	c'siz	2,16E-05	0,9937	12
Hepsi	2,27E-02	0,9989	20	Hepsi	3,20E-05	0,9908	18

Tekil maksimum regresyon değerlerine bakıldığında çevrimsel dayanım katsayısı için en iyi sonuç veren yapı, elastisite modülü (E) parametresinin hesaplamaya dahil edilmediği ve 10 nöron sayısı durumunda gözlemlenmiştir. Çevrimsel uzama sertleşme üsteli için ise en iyi sonuç veren yapı, alanda yüzdelik azalma (%RA) parametresinin hesaplamaya dahil edilmediği ve 7 nöron sayısı durumunda gözlemlenmiştir.

Genel olarak yapay sinir ağlarında tahminleme yapılırken kullanılan girdi parametrelerin çokluğundan ziyade niteliği önem taşımaktadır. Yapay sinir ağlarının yapısı kompleks hale gelip daha büyük veri setlerinin kullanılması ile tahminleme doğruluğu artmaktadır. Gelişen teknoloji koşulları ile zamanın verimli kullanılmasının önemi arttıkça yapılan işleri minimum maliyet ve maksimum verimlilik

ile gerçekleştirmek büyük önem taşımaktadır. Bu yüzden yapısal karmaşıklığı en aza indirip araştırmacıların çalışma yapabilmek için gerekli bilgi gereksinimlerini hafifleterek gelecekteki çalışmalar için de büyük kolaylık sağlanmış olacaktır.

4. Sonuç

Bu çalışma kapsamında ϵ -N Wöhler Eğrilerinin oluşturulmasında etkili olan Ramberg-Osgood parametrelerinin (K' ve n') yapay sinir ağları ile tahmin edilmesi ve girdi parametreleri ile nöron sayılarının tahminleme sonuçları üzerine etkileri araştırılmıştır. Dokuz farklı girdi parametresi, tek gizli katman ve iki farklı çıktı parametresi ile YSA yapısı oluşturulmuştur. Girdi parametreleri sekiz adet kalacak şekilde her bir parametre tahminleme dışarısına çıkartılarak tahminleme üzerindeki etkileri araştırılmıştır. Ayrıca her bir çıkartılan parametre için 1'den 30'a kadar farklı nöron sayıları kullanılmıştır. Yapay sinir ağları ile tahminleme yapılırken her bir çalıştırmada farklı sonuçlar elde edilmektedir. Bu rastgeleliği azaltmak ve daha stabil sonuçlar elde etmek adına her bir parametre değeri için 100 adet replikasyon yapılmıştır. Sonuç olarak;

Çevrimsel dayanım katsayısının (K') tahmin edilmesinde en etkili parametre akma dayanımı (σ_y) ve en az etkili parametre ise Brinell sertliği (BHN) olmuştur. En iyi sonuçlar ise tüm parametrelerin dikkate alındığı durumda elde edilmiştir. En iyi tahminlemeyi veren nöron sayısı ise 1 olmuştur. Replikasyonsuz regresyon değerlerinde en iyi sonuç elastisite modülünün (E) dahil edilmediği ve 10 nöron sayısında elde edilmiştir.

Çevrimsel uzama sertleşme üstelinin (n') tahmin edilmesinde en etkili parametre yorulma dayanım üsteli (b) ve en az etkili parametre ise elastisite modülü (E) olmuştur. En iyi tahminlemeyi veren nöron sayısı ise 17 olmuştur. Replikasyonsuz regresyon değerlerinde en iyi sonuç alanda yüzdellik azalma (%RA) parametresinin dahil edilmediği durumda ve 7 nöron sayısında elde edilmiştir.

Tablo 3'ten de görüleceği üzere Ramberg-Osgood parametreleri tahmin edilirken veri seti büyüklüğünün fazla olmaması tahminleme sonuçlarına önemli ölçüde etki etmemiştir. Aynı zamanda tek gizli katmanlı yapıdan daha büyük ve kompleks derin öğrenme yapılarına ihtiyaç duyulmayıp düşük nöron sayıları ile de işlem gücünü arttırmadan yüksek doğrulukta tahminlemelerin yapılabileceği gösterilmiştir.

Simgeler ve Kısaltmalar

%RA Alanda yüzdellik azalma

b Yorulma dayanım üsteli

BHN Brinell Setliği

c	Yorulma süneklik üsteli
E	Elastisite Modülü
K'	Çevrimsel dayanım katsayısı
MSE	Ortalama hata karesi
n'	Çevrimsel uzama sertleşme üsteli
YSA	Yapay sinir ağı
ε'_f	Yorulma süneklik katsayısı
σ'_f	Yorulma dayanım katsayısı
σ_u	Çekme dayanımı
σ_y	Akma dayanımı

Kaynakça

- Baird, A., Smith, T., Palermo, A., & Pampanin, S. (2014, March). Experimental and numerical study of U-shape flexural plate (UFP) dissipators. *In New Zealand Society for Earthquake Engineering 2014 Technical Conference and AGM*. New Zealand Society for Earthquake Engineering Auckland, New Zealand.
- Deolia, P., & Shaikh, F. A. (2016). Finite element analysis to estimate burst pressure of mild steel pressure vessel using Ramberg–Oslo model. *Perspectives in Science*, 8, 733-735. Doi: <https://doi.org/10.1016/j.pisc.2016.06.073>
- Ertas, A. H. (2012). Optimization of fiber reinforced laminates for maximum fatigue life using particle swarm optimization. *Procedia engineering*, 38, 473-478. Doi: <https://doi.org/10.1016/j.proeng.2012.06.058>
- Genel, K. (2004). Application of artificial neural network for predicting strain-life fatigue properties of steels on the basis of tensile tests. *International Journal of Fatigue*, 26(10), 1027-1035. Doi: doi.org/10.1016/j.ijfatigue.2004.03.009
- Ghajar, R., Naserifar, N., Sadati, H., & Alizadeh K, J. (2011). A neural network approach for predicting steel properties characterizing cyclic Ramberg–Oslo equation. *Fatigue & Fracture of Engineering Materials & Structures*, 34(7), 534-544. Doi: <https://doi.org/10.1111/j.1460-2695.2010.01545.x>
- Janežič, M., Klemenc, J., & Fajdiga, M. (2010). A neural-network approach to describe the scatter of cyclic stress–strain curves. *Materials & Design*, 31(1), 438-448. Doi: <https://doi.org/10.1016/j.matdes.2009.05.044>
- Kalayci, C. B., Karagoz, S., & Karakas, Ö. (2020). Soft computing methods for fati-

- gue life estimation: A review of the current state and future trends. *Fatigue & Fracture of Engineering Materials & Structures*, 43(12), 2763-2785. Doi: <https://doi.org/10.1111/ffe.13343>
- Kalayci, C. B., Karagöz, S., & Karakaş, Ö. (2019). Bee colony intelligence in fatigue life estimation of simulated magnesium alloy welds. *International Journal of Fatigue*, 127, 36-44. Doi: doi.org/10.1016/j.ijfatigue.2019.05.032
- Karakaş, Ö., & Tomasella, A. (2013). Fatigue life estimation of non-penetrated butt weldments in light metals by artificial neural network approach. *Materialwissenschaft und Werkstofftechnik*, 44(10), 847-855. Doi: <https://doi.org/10.1002/mawe.201300025>
- Karakaş, Ö., Berto, F., & Hong, Y. (2023). Fatigue & Fracture of Engineering Materials & Structures Virtual Special Issue: Data science and machine learning for fatigue and fracture assessment. *Fatigue & Fracture of Engineering Materials & Structures*. Doi: <https://doi.org/10.1111/ffe.14002>
- Ma, D., Chen, Z. Q., & Shan, X. L. (2010). Forecasting of the fatigue life of metal weld joints based on combined genetic neural network. In *Key Engineering Materials* (Vol. 439, pp. 195-201). Trans Tech Publications Ltd. Doi: <https://doi.org/10.4028/www.scientific.net/KEM.439-440.195>
- Mitchell, M. R. (1996). Fundamentals of modern fatigue analysis for design.
- Morrow, J. (1965, July). Cyclic plastic strain energy and fatigue of metals. In *Internal friction, damping, and cyclic plasticity* (pp. 45-87). ASTM International. Doi: <https://doi.org/10.1520/STP43764S>
- Muralidharan, U., & Manson, S. S. (1988). A modified universal slopes equation for estimation of fatigue characteristics of metals. Doi: <https://doi.org/10.1115/1.3226010>
- Ong, J. H. (1993). An evaluation of existing methods for the prediction of axial fatigue life from tensile data. *International journal of fatigue*, 15(1), 13-19. Doi: [https://doi.org/10.1016/0142-1123\(93\)90071-W](https://doi.org/10.1016/0142-1123(93)90071-W)
- Ong, J. H. (1993). An improved technique for the prediction of axial fatigue life from tensile data. *International journal of fatigue*, 15(3), 213-219. Doi: [https://doi.org/10.1016/0142-1123\(93\)90179-T](https://doi.org/10.1016/0142-1123(93)90179-T)
- Ponticelli, G. S., Guarino, S., & Giannini, O. (2020). An optimal genetic algorithm for fatigue life control of medium carbon steel in laser hardening process. *Applied Sciences*, 10(4), 1401. Doi: <https://doi.org/10.3390/app10041401>
- Ramberg, W., & Osgood, W. R. (1943). *Description of stress-strain curves by three parameters* (No. NACA-TN-902).

- Raske, D. T., & Morrow, J. (1969). Mechanics of materials in low cycle fatigue testing. In *Manual on low cycle fatigue testing*. ASTM International.
- Soyer, M. A., Kalaycı, C. B., & Karakaş, Ö. (2022). Low-cycle fatigue parameters and fatigue life estimation of high-strength steels with artificial neural networks. *Fatigue & Fracture of Engineering Materials & Structures*, 45(12), 3764-3785. Doi: <https://doi.org/10.1111/ffe.13847>
- Srivatsan, T. S., Soboyejo, W. O., & Lederich, R. J. (1995). The cyclic fatigue and fracture behavior of a titanium alloy metal matrix composite. *Engineering fracture mechanics*, 52(3), 467-491. Doi: [https://doi.org/10.1016/0013-7944\(95\)00014-M](https://doi.org/10.1016/0013-7944(95)00014-M)
- Tomasella, A., El Dsoki, C., Hanselka, H., & Kaufmann, H. (2011). A computational estimation of cyclic material properties using artificial neural networks. *Procedia Engineering*, 10, 439-445. Doi: <https://doi.org/10.1016/j.pro-eng.2011.04.075>
- Yang, X., Zou, L., & Deng, W. (2015). Fatigue life prediction for welding components based on hybrid intelligent technique. *Materials Science and Engineering: A*, 642, 253-261. Doi: <https://doi.org/10.1016/j.msea.2015.07.006>
- Zhan, Z., & Li, H. (2021). Machine learning based fatigue life prediction with effects of additive manufacturing process parameters for printed SS 316L. *International Journal of Fatigue*, 142, 105941. Doi: <https://doi.org/10.1016/j.ijfatigue.2020.105941>