

Burak Aydoğdu* Bursa Uludağ Üniversitesi
Fen Bilimleri Enstitüsü
BursaNecmettin Kaya Bursa Uludağ Üniversitesi
Makine Mühendisliği Bölümü
Bursa

Dikdörtgen Kesitli Disk Yayların Yapay Sinir Ağı İle Optimizasyonu

Ürün tasarımında analizlere ayrılan zamanın ve maliyetlerin önemli ölçüde azaltılmasında makine öğrenmesi kilit rol oynamaktadır. Makine öğrenmesi ile gerçekleştirilen optimizasyon çalışması, sonlu elemanlar analizine kıyasla zaman ve maliyet açısından büyük üstünlükler sağlamaktadır. Bu çalışmada, disk yaylar için bir makine öğrenmesi modeli eğitilmiş, eğitilen modelin disk yayların boyut optimizasyonunda kullanılması amaçlanmıştır. Tek ve çok amaçlı optimizasyon yöntemlerinin uygulanabilirliğini göstermek için istenilen yay rijitliğine sahip çeşitli disk yayların optimizasyonu ele alınmış ve Pareto çözümleri sunulmuş çözümler incelenmiştir. Elde edilen tasarım parametreleri ile sonlu elemanlar analizleri gerçekleştirilmiş ve yapay sinir ağı ile sonlu elemanlar sonuçları karşılaştırılmıştır. Yapay sinir ağı kullanımı ile optimizasyon sonucuna 4,5 saniye içerisinde ulaşılabildiği ve elde edilen sonuçların doğruluklarının (%96,16) sinir ağı başarı oranı (%97,67) ile benzer olduğu görülmüştür.

Anahtar Kelimeler: Disk Yay, Sonlu Elemanlar Analizi, Makine Öğrenmesi, Yapay Sinir Ağı, Optimizasyon, Genetik Algoritma

Makale Bilgisi:

Araştırma Makalesi

Gönderilme: 31 Ekim 2022

Kabul: 28 Ocak 2023

*Sorumlu Yazar: Burak AYDOĞDU

Email: aydogdu.burak@outlook.com

DOI:

<https://doi.org/10.56193/matim.1197038>

Atf şekli/How to cite: Aydoğdu B., Kaya N., Dikdörtgen Kesitli Disk Yayların Yapay Sinir Ağı İle Optimizasyonu. Makina Tasarım ve İmalat Dergisi, 2023; 21(1): 1-11.

GİRİŞ

Rekabetin yoğun olarak yaşandığı günümüzde ürünlerin kısa zamanda, düşük maliyetlerde üretilmesi ve tasarım doğrulama analizlerinin yapılması firmaların pazarda yer alabilmesi açısından önem taşımaktadır [1]. Mühendislikte sonlu elemanlar metodu (SEM) veya hesaplamalı akışkanlar dinamiği (HAD) kullanılarak yapılan tasarım doğrulama analizlerinin süreleri modelin karmaşıklığına, ağ yapısına veya kullanılan bilgisayarın yeterliliğine göre farklılık göstermektedir. Bu farklılıklar neticesinde saniyeler ile günler arasında değişen sürelerle ihtiyaç duyulurken optimizasyon gibi yüzlerce kez iterasyon yapılması gerekebilen yöntemler ile süreler daha da uzamaktadır.

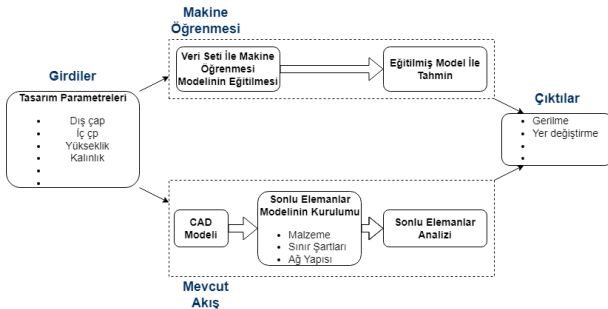
Ürünlerde açığa çıkacak olan gerilme ve yer değiştirmelerin makine öğrenmesi modellerine tahmin ettirilmesi ve optimizasyon problemlerine ayrılan zamanın ve maliyetlerin önemli ölçüde

elemanlar modelinden her iterasyon için gerekli sonuçların alınması çok sayıda iterasyon için çok sayıda sonlu elemanlar çözümü gerektireceğinden hesaplama süreleri açısından uygun olmamaktadır. Bu nedenle genellikle sonlu elemanlar modeli yerine geçen vekil model yaklaşımı kullanılmaktadır.

Bu makalede ise vekil model yerine makine öğrenmesi yaklaşımı kullanılması önerilmiştir. Önerilen yöntemin akış diyagramı Şekil 1'de verilmiştir. Bu yöntemde belirli sayıda sonlu elemanlar analizi ile veri seti oluşturulur. Bu veri seti ile makine öğrenmesi eğitilir. Farklı tasarım girdileri için sonuçlar hızlı bir şekilde makine öğrenmesi modelinden elde edilir.

Analizlerin bir kez yapılarak yeterli sayıda veri ile eğitilmiş başarılı bir makine öğrenmesi modelinin kurulması hem zamanı hem de maliyetleri SEM'e kıyasla önemli ölçüde azaltabilmektedir [2].

Mevcut akışta gereken uzun zamanlardan kaçınmak adına, makine öğrenmesi kullanılarak bir model ve yeni iş akışının geliştirilmesi optimizasyon çalışmasında kullanılması istenen değerlerin saniyeler içerisinde elde edilmesini sağlayabilmektedir. Makine öğrenmesi modellerinin hızlı ve başarılı sonuçlar üretmesi optimizasyon problemlerinde makine öğrenmesi tekniklerinin kullanılmasını ilgi çekici hale getirmektedir.



Şekil 1. SEA ile makine öğrenmesinin örnek bir akış diyagramı

Çalışmada, makine öğrenmesi modelinin sonlu elemanlar modeline kıyasla optimizasyon çalışmalarındaki başarısının (ürün geliştirmeye ayrılan kaynakların azaltılması) ortaya konulması amaçlanmıştır. Bu amaçla örnek olarak, Abaqus [3] yazılımı kullanılıp bir disk yay için sonlu elemanlar modeli kurulması ve veri seti eldesi çalışması gerçekleştirilmiştir. Daha sonra, yapay sinir ağının veri seti üzerindeki başarıları incelenerek başarıyı arttıracak uygun parametreler aranmıştır. Son olarak ise elde edilen model optimizasyon çalışmasında kullanılmış ve istenilen yay rijitliğine sahip disk yay parametrelerine bir genetik algoritma ile ulaşılmaya çalışılmıştır. Pareto çözümleri dahil olmak üzere elde edilen sonuçlar (yay rijitliği, hacim, zaman) incelenmiş ve sonuçlar tartışılmıştır.

LİTERATÜR TARAMASI

Müller vd. [4] yaptıkları çalışmada, kaçınılması mümkün olmayan otomobil kazalarında doğru kararı vermenin insanoğlu için neredeyse imkânsız olduğunu belirterek, birbirine paralel olarak çalışacak iki paralel yol (makine öğrenmesi ve fiziksel olasılık) ile çözüm önerisinde bulunmuşlardır. İlk yol, sonlu elemanlar analizlerinin verileri ile eğitilmiş bir makine öğrenmesi modeli, ikinci yol ise kaza kuvvetlerini ve ivmelerini tahmin eden bir iki-boyutlu kütle-yay-damper modelini içermektedir. Birlikte, her iki yol da aynı kaza senaryosunun iki farklı perspektifini sağlayarak gerçek zamanlı olarak doğru ve güvenilir bir tahmin sonucunu ortaya koymaktadırlar. Yapılan çalışma sonucunda görülmüştür ki, sunulan iki-boyutlu modelin eğişik çarpışmalar da dahil olmak üzere çeşitli

senaryoların hız ve çarpışma kuvveti ilerlemesini tahmin etmede uygundur.

Ma vd. [5], doğrusal olmayan (nonlinear) mafsallı yapılar için giderek artan verimli ve doğru modelleme gereksinimlerini karşılamak için sonlu elemanlar modeline ve derin öğrenme tekniklerine dayanan yeni bir karma modelleme yöntemi sunmuşlardır. Sunulan karma modelleme yönteminin performansı, doğrusal olmayan mafsallara sahip bir konsol plakasına odaklanan bir çalışma ile test edilmiş ve değerlendirilmiştir. Elde edilen sonuçlar, sunulan karma modelin doğrusal olmayan yapıların davranışlarının tahminindeki yeterliliğini göstermektedir.

Qi vd. [6] yaptıkları çalışmada, sonlu elemanlar yöntemi (SEY) ve makine öğrenmesine dayanarak karbon fiberin mekanik özelliklerinin tahminini amaçlamışlardır. Çalışmada karar ağacı algoritması kullanımı uygun görülmüş ve aşırı öğrenmeden (overfitting) kaçınmak için uygun ağaç derinliği aranmıştır. Elastisite ve kayma modülünün tahmini için uygun ağaç derinliği belirtilmiştir.

Karina vd. [7], SEM ve deney sonuçlarından elde ettikleri korozyona uğramış çelik levhaların yüzey ve malzeme özelliklerini kullanarak uygulaması basit, yüksek doğruluk oranına sahip ve maliyetsiz olan bir yapay sinir ağı (YSA) modeli geliştirmişler ve eğitilmiş modeli kullanarak çelik levhanın çekme dayanımını tahmin etmeyi amaçlamışlardır. Çalışmada, 10 farklı malzeme özelliği ağındaki girdisi (feature) olarak belirlenmiş ve girdi sayısı azaltılarak 5 ayrı senaryo için 5 farklı sinir ağı modeli geliştirilmiştir. Modellerin başarılarının değerlendirilmesinde ortalama mutlak hata (mean absolute error-MAE) kullanılmış ve en düşük MEA oranını %3,7 ile 10 parametrenin de ağ girdisi olarak kullanıldığı modelin ürettiği görülmüştür.

Liang vd. [8], makine öğrenmesi tekniklerini kullanarak aorttaki (şahdamarı) gerilme dağılımını doğrudan hesaplayacak bir derin öğrenme modeli geliştirmişlerdir. Model, sonlu elemanlar analizi (SEA) girdilerini derin öğrenme modelinin girdileri olarak alıp, SEA adımlarını es geçerek aort damarındaki gerilme dağılımını çıktı olarak hesaplayacak doğrultuda tasarlanmış ve eğitilmiştir. Eğitilmiş modelin aort damarındaki gerilme dağılımını ortalama %0,492 ile %0,891 hata ile tahmin etme yeteneğine sahip olduğu görülmüştür.

Phellan vd. [2] yaptıkları araştırmada, doğrudan SEY'e dayanan mekanik simülasyonların ciddi derecede zaman gerektirdiğini belirtmiş ve bu durumun gerçek zamanlı sonuç gerektiren uygulamalarda SEY'in kullanımını kısıtladığı


belirtmişlerdir. Yaptıkları arařtırmalar sonucunda 41 adet alıřma incelenmiř ve bunların 32 tanesinde SEY'e dayanan simülasyonlar ile eđitilmiř makine renmesi modeli kullanıldıđı grlmřtr. İncelenen alıřmaların 35'inde ise tercih edilen makine renmesi algoritmasının yapay sinir ađı olduđu belirtilmiřtir. SEY'ne dayanan mekanik simlasyonların makine renimi kullanarak hızlandırılması SEY'nin benimsenmesine ve analiz iin gereken zamanın azalmasına katkı sađladıđı vurgulanmıřtır.

Literatrde makine renmesi kullanılarak gerekleřtirilen optimizasyon alıřmaları az olmakla birlikte geliřen yapay zek teknolojileri sayesinde ilgi ekici hale gelmektedir. alıřmada, yapay sinir ađı kullanılarak bir makine elemanının boyut optimizasyonu gerekleřtirilmiř ve uzun sreler gerektiren SEM yerine hızlı ve bařarılı sonular retme avantajına sahip yapay sinir ađı kullanımının rn geliřtirme alıřmalarına sađlayacađı faydalar sunulmuřtur.

MATERYAL VE YNTEM

Disk Yaylar

Tm makine elemanları dıř yk altında deformasyona uđrarlar; deformasyon elastik blge sınırları iindeyse, yk ortadan kalkınca makine elemanı da bařlangıtaki konumunu alır. Genelde ok kk olan bu deformasyonlar yay adını verdiđimiz zel geometriye sahip elemanlarda olduka yksektir, bu nedenle yaylar elastik elemanlar altında da ifade edilirler [9]. Disk yay da denilen tabak yaylar kesilmiř koni [10] ya da eksenleri ynnde h_0 kadar konikleřmiř halkalardır (řekil 2) [9], [11].



řekil 2. Disk yay tasarım parametreleri [1]

Disk yaylar birbirine sabitlenen iki yzey arasında n ykleme oluřturmak, takım tezgahlarında ve valflerde gergi elemanı olarak, krenlerde ve tařıtlarda titreřim snmleyici olarak uygulama alanı bulmaktadır [9], [10]. Tek yayın gereken yk tařıyamadıđı durumlarda aynı ynde st ste (yay paketi) veya ters ynde st ste (yay stunu) koyarak istenilen zellikte yay elde etmek mmkndr [9]. rnek bir uygulama řekil 3'te gsterilmiřtir.



řekil 3. Disk yayların bir kullanım rneđi [9].

řekil 2'de de grldđ zere disk yaylar drt geometrik parametre ile tanımlanabilir: i (D_i) ve dıř (D_e) ap, kalınlık (t) ve ykseklik (h_0). Konikleřmiř řekilleriyle basit olarak grnen disk yayların aksenal ynlerindeki yk nedeniyle gerilme dađılımı karmařık bir hal almaktadır [11].

Dikdrtgen kesitli disk yaylar, kesitin bir eksen etrafında dndrlmesi ile elde edilebilir. Disk yayın hacminin hesaplanması iin Pappes-Gulden teoremi kullanılırsa hacim ifadesi:

$$V = 0,7854 \sqrt{(D_e + D_i)^2 (D_e^2 - 2D_e D_i + D_i^2 + 4h_0^2)} t^2 \quad (1)$$

řeklinde yazılabilir [1].

Makine renmesi

Yapay zek algoritmalarından biri olan makine renmesi, istediđimiz sonulara basit, hızlı ve ucuz bir yntemle ulařmamızı sađlarken yksek boyutlu karmařık ve lineer olmayan iliřkilerle bařa ıkabilmesi nedeniyle mhendislik problemlerinin zmnde alternatif bir zm yolu sunmaktadır [7], [12]. Makine renmesi sanayide, retim srelerinin planlanması, kalite kontrol, bakım zamanlarının belirlenmesi, lojistik, robotik ve retim hatlarındaki uygulamalarda yer almaktadır [13]. Makine renmesi algoritması geliřtirme sreci 4 temel adımdan oluřur. Bunlar;

1. *Problemin tanımlanması:* Mhendislik probleminin tanımlanıp (bařlangı ve sınır şartları, malzeme zellikleri vb.) bir sonlu elemanlar programında zlerek veri setinin elde edilmesi.
2. *Veri setinin hazırlanması:* Elde edilen veri setinin incelenerek veri n iřlemenin (boyut indirgeme, znitelik seimi, verinin leklendirilmesi vb.) gerekleřtirilmesi.
3. *Model seimi ve eđitimi:* ok sayıda algoritmanın mevcut olması veri setine

uygun modelin belirlenmesini gerekli kılar. Modellerin başarı oranları (R^2 -belirlilik katsayısı, MAE, MSE-mean square error) ve karmaşıklığı (gerekli eğitim süresi, işlem gücü vb.) incelenerek uygun model belirlenmelidir.

4. *Makine öğrenmesinin işleme alınması:* Uygun model belirlendikten sonra ilgili çalışmalar (optimizasyon vb.) için modelin kullanılması [12].

Yapay sinir ağları, canlılardaki biyolojik sinir ağlarından esinlenen bilgi işlem sistemleridir. Yapay sinir ağları, bir karara varmak için birden fazla işlem aşamasını gerçekleştiren doğrusal modellerin genellemeleri olarak görülebilir.


$$\hat{y} = w_0 * x_0 + w_1 * x_1 + \dots + w_n * x_n + b \quad (2)$$

Denklem 2 ile verilen eşitlik bir çoklu doğrusal regresyon denkleminin benzeridir. Burada:

X : Girdiler,

ω : Geri besleme (backpropagation) ile güncellenen ağırlıklandırma,

\hat{y} : Girdilerin ağırlıklandırılmış toplamı, yapay sinir ağının tahmin değeridir [14].



Şekil 4. Girdilerin ve çıktının node (düğüm) olarak gösterildiği bir ağ [10].

Kayıp fonksiyonu, tahminleri (\hat{y}) hedeflerle (y) karşılaştırır ve ağın tahminlerinin beklenenle ne kadar iyi eşleştiğinin bir ölçüsü olan bir kayıp değeri üretir. Optimizasyon fonksiyonu, bu kayıp değerini sinir ağının ağırlıklandırmalarını (ω) güncellemek için kullanır [15].

Optimizasyon

Bir çalışmada en uygun değere ya da en iyi çözüme deneme-yanılma yöntemi yerine optimizasyon ile ulaşmak mümkündür ve optimizasyonun amacı harcanan kaynakları en aza indirerek en yüksek bilgiye ulaşmadır denilebilir [16], [17]. Optimizasyon yöntemleri iki grupta toplanabilir: gradyan tabanlı (gradient-based) ve gradyan tabanlı olmayanlar (non-gradient-based). Gradyan tabanlı optimizasyon tipindeki iki dezavantaj yakınsamanın yavaş gerçekleşmesi ve global optimum sonuca ulaşmanın garanti

edilmemesidir [18]. Başlangıç noktalarının rastgele olarak dağıtıldığı gradyan tabanlı olmayan optimizasyonda (genetik algoritmalar (GAs), benzetimli tavlama (SA) vb.) süreç, yakınsama kriteri karşılanana kadar her bir adımda yeni popülasyon önceki adımdaki örneklerin amaç fonksiyonu ile olan ortalama uyumuna bakılarak edinilen bilgiler doğrultusunda güncellenmesiyle devam eder [18]–[20].

Genetik algoritmalar aynı anda farklı alanlardaki çözümleri inceleyerek sadece yerel minimuma ulaşmayı değil aynı zamanda bir çözüm uzayı, tasarım uzayı bulmayı amaçlar [21], [22]. Bu rastgele dağıtılan noktalar ile farklı alanlardaki çözümleri incelemek yüksek işlem gücü gerektirmesine rağmen yerel bir çözüm yerine global optimum noktanın belirlenebilmesine olanak sağladığından bu gerekliliğe değen bir harcamadır [23]. Genetik algoritmalar adından da anlaşılacağı üzere doğal seçimden, türlerin kökeni teorisinden esinlenilerek geliştirilmiştir ve doğada, güçlü olanın genlerini sonraki nesillere aktarmasına dayanır [17], [21], [23].


Birçok mühendislik problemi maliyeti azaltmak ve performansı arttırmak gibi birden fazla amacı içerisinde barındırır ki, bunlar zorlu ancak gerçekçi problemlerdir. Pareto çözümleri ağırlıklandırılmış toplamlar gibi tek bir sonucun olduğu çözümlere kıyasla daha çok tercih edilir [21]. Pareto çözümlerinin olduğu bir çoklu amaç fonksiyonunda tek bir çözüm yerine her biri kabul edilebilir seviyede olan birden çok çözüm, bir çözüm seti elde etmek amaçlanır [19], [21], [24]. Bir amaç fonksiyonundan feragat edilerek diğerine ağırlık verilebileceği düşünüldüğünde Pareto çözümleri, aranan sonucun amaç fonksiyonları arasında ödün vererek ulaşılmasına olanak sağlar [19], [21].

Gradyan tabanlı olmayan algoritmaların lokal optimuma yakalanmadan global optimumu bulabilme avantajı vardır. Bu nedenle çalışmada, gradyan tabanlı olmayan bir genetik algoritma kullanılmıştır.

Yöntem


Daha önce de belirtildiği üzere kesitin bir eksen etrafında döndürülmesiyle elde edilebilecek olan disk yayların analizleri, Abaqus yazılımı kullanılarak Python programlama dilinde yazılan bir makro ile gerçekleştirilmiştir. Böylece tasarım parametrelerinin el ile tek tek değiştirilip çözülmesi yerine bu işi otomatik olarak yapan bir kod geliştirilmiştir. Ele alınan disk yayların malzeme özellikleri elastisite modülü 210000 N/mm^2 , Poisson oranı 0.3 ve akma gerilmesi 450 N/mm^2 olarak kabul edilmiştir.

Abaqus yazılımında oluşturulan sonlu elemanlar modelinin sınır şartları Şekil 5'te görülebilir. Sınır şartları olarak, alt yüzeye temas eden dairesel bölge üzerindeki düğüm noktalarının düşey (y) doğrultudaki ve üst yüzeydeki dairesel bölge üzerindeki düğüm noktalarının yatay doğrultudaki (x ve z) yer değiştirme serbestlik dereceleri sıfırlanmıştır. Yayın üst kısmındaki yüzey ile referans noktası (RP-1) arasında coupling ilişkisi kurulmuş ve F kuvveti bu referans noktasına uygulanarak tanımlanmıştır.




Şekil 5. Sonlu elemanlar modelinin sınır şartları

Çalışmada kullanılan Abaqus yazılımı öğrenci versiyonu olması nedeni ile düğüm ve eleman sayıları 1000 ile sınırlandırılmıştır. Dolayısıyla çalışmadaki yayların sonlu eleman büyüklükleri kontrol edilerek düğüm noktalarının 800 ile 1000 aralığında kalması sağlanmış ve sonlu eleman tipi hexahedron olarak seçilmiştir. Bu geometri için bu eleman sayılarının uygun olduğu söylenebilir. Şekil 6'da eleman sayılarına bağlı olarak yay rijitliklerindeki değişimler görülmektedir.




Şekil 6. Ağdan bağımsızlık çalışması

Sabit 1222 N [25] kuvvet altında farklı disk yay parametreleri için toplamda 256 adet analiz gerçekleştirilmiş, her bir analiz için elde edilen sonuçlar (gerilme ve yer değiştirme), düğüm noktaları ve hexahedron eleman sayısı tasarım parametreleri de dahil edilerek bir csv (comma-separated values) dosyasında kaydedilmiştir.




Şekil 7. 1222 N yüklemeye karşılık gelen von-Mises mukayese gerilme dağılımı (MPa)




Şekil 8. 1222 N yüklemeye karşılık gelen toplam yer değiştirme dağılımı (mm)

Yapılan 256 adet analiz yan sıra rijitliğini görmek üzere farklı kuvvetler altında 99 adet analiz daha gerçekleştirilmiştir. Elde edilen diyagramlar (Şekil 9 ve 10) incelendiğinde yayların lineer davranış sergilediği görülmektedir.



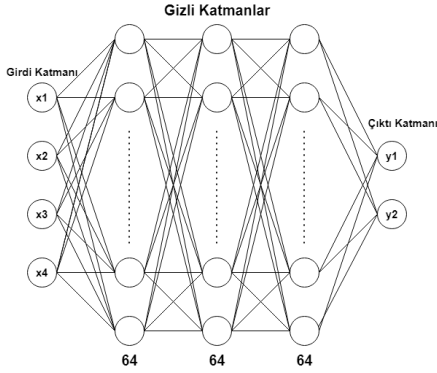
Şekil 9. Yay rijitlikleri



Şekil 10. Yayların gerilme-kuvvet eğrileri

Sonlu elemanlar analizi gerçekleştirilerek elde edilen 256 adet veriden oluşan veri seti kullanılarak (%75 eğitim ve %25 test) yapay sinir ağı ile bir makine öğrenmesi çalışması gerçekleştirilmiştir. Burada, tasarım parametreleri (D_e , D_i , t ve h_0) girdiler, gerilme ve yer değiştirme değerleri çıktılar olarak belirlenmiş, 3 adet gizli katmana sahip yapay sinir ağı farklı epoch sayılarında incelenerek çalışmaya uygun ağ yapısı bulunması amaçlanmıştır.

Çalışmada kurulan yapay sinir ağı 4 adet girdiye sahip bir girdi katmanı, her biri 64 adet düğüm noktasından oluşan 3 gizli katman ve 2 adet çıktı değeriye sahip bir çıktı katmanından oluşmaktadır (Şekil 11). Katmanların aktivasyon fonksiyonu relu (rectified linear unit), optimizasyon fonksiyonu Adam [26], loss fonksiyonu mse ve başarı metriği olarak da mae seçilmiştir.



Şekil 11. Oluşturulan yapay sinir ağı

1222 N yük altında analizi gerçekleştirilen ve sinir ağı eğitilen yayların Şekil 9 ve 10'da belirttiği üzere davranışlarının lineer olması nedeni ile Denklem 3 ve 4 ile verilen eğim denklemleri yayların herhangi bir yük altındaki yer değiştirme ve gerilme değerlerinin hesaplanmasında kullanılabilir.

$$y_y = \frac{y}{1222} F_y \quad (3)$$

$$\sigma_y = \frac{\sigma}{1222} F_y \quad (4)$$

Burada:

\hat{y} : Yapay sinir ağının tahmin ettiği yer değiştirme değeri [mm],

F_y : Tasarım parametreleri aranan yayın yükü [N],

y_y : Hesaplanan yaylanma değeri [mm],

$\hat{\sigma}$: Yapay sinir ağının tahmin ettiği gerilme değeri [N/mm^2],

σ_y : Hesaplanan gerilme değeri [N/mm^2].

Standart bir optimizasyon problemi için tasarım değişkenleri, amaç ve kısıt fonksiyonları tanımlanmalıdır. F_y yükü altında istenen yaylanma miktarına (y) sahip yay için gerçekleştirilecek olan optimizasyon çalışmasına ait eşitlik ve eşitsizlikler aşağıdaki denklemlerde belirtilmiştir.

1. Tasarım Değişkenleri:

$$40 \leq D_e \leq 70 \quad (5)$$

$$14,2 \leq D_i \leq 25,5 \quad (6)$$

$$2,65 \leq h_0 \leq 4,5 \quad (7)$$

$$1,25 \leq t \leq 2,5 \quad (8)$$

2. Amaç Fonksiyonları:

$$\min f_1 = 0,5(y_y - y)^2 \quad (9)$$

$$\min f_2 = V \quad (10)$$

3. Kısıt Fonksiyonları:

$$g_1 = h_0 - y_y \geq 0 \quad (11)$$

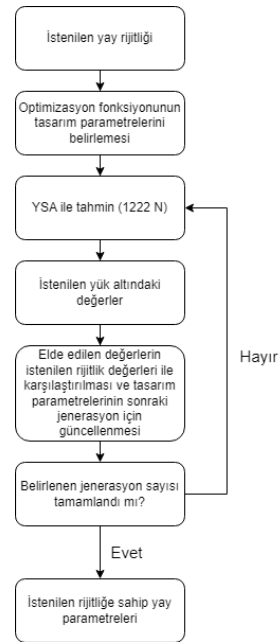
$$g_2 = \sigma_{Akma} - \sigma_y \geq 0 \quad (12)$$

Burada:

y : Tasarım parametreleri aranan yayın yaylanma miktarı [mm],

f_1 : Yapay sinir ağının tahmin ettiği yaylanma miktarı ile istenilen yaylanma miktarı arasındaki uyum, minimize edilecek olan rijitlik fonksiyonu [mm],

f_2 : Denklem 1 ile hesaplanıp minimize edilecek olan hacim fonksiyonu [mm].




Şekil 12. Optimizasyon çalışmasının akış diyagramı

Optimizasyon çalışması için pymoo [27] kütüphanesinde yer alan algoritmalar kullanılmıştır. Tek amaçlı optimizasyon çalışması için GA (Genetic Algorithm) ve çok amaçlı optimizasyon çalışması için NSGA-II (Nondominated Sorting Genetic Algorithms) [24] algoritması tercih edilmiştir. GA kullanılarak elde edilen çözümlerdeki başarılar incelenmiş ve çok amaçlı optimizasyon çalışması ile ulaşılan Pareto çözümleri sunulmuştur.


Veri seti: Veri setine ait minimum, maksimum, ortalama, varyans ve standart sapma değerleri Tablo 1'de; dış çap, iç çap, yükseklik, kalınlık, gerilme ve yer değişiminin veri seti içerisindeki dağılımları Şekil 13, 14, 15, 16, 17 ve 18'de verilmiştir.

Tablo 1. Veri setine ait özellikler


	Minimum	Maksimum	Ortalama	Varyans	Standart Sapma
D_e	40,000	70,000	55,000	125,000	11,180
D_i	14,200	25,500	19,600	16,575	4,071
h_0	2,650	4,500	3,588	0,473	0,688
t	1,250	2,500	1,813	0,230	0,480




Şekil 13. Dış çapın veri setindeki dağılımı




Şekil 14. İç çapın veri setindeki dağılımı




Şekil 15. Yüksekliğin veri setindeki dağılımı



Şekil 16. Kalınlığın veri setindeki dağılımı



Şekil 17. Gerilmenin veri setindeki dağılımı



Şekil 18. Yer değiştirmenin veri setindeki dağılımı

BULGULAR VE TARTIŞMA

Yapay Sinir Ağı

Yapay sinir ağının farklı epoch sayılarındaki başarıları R^2 , MAE ve MSE metrikleri kullanılarak Tablo 2, 3 ve 4'te gösterilmiştir. Başarı oranları incelendiğinde 1500 epoch eğitilen sinir ağının özellikle yer değiştirme değerinin tahmininde %97,67 gibi yüksek R^2 başarı oranı ile öne çıktığı görülmektedir. Tablo 5'te ise yapay sinir ağlarının eğitim süreleri için harcanan zamanlar saniye biriminden belirtilmiştir.

Tablo 2. Sinir ağının R^2 başarı oranı

Epoch	Eğitim Verileri		Test Verileri	
	Gerilme	Yer Değiştirme	Gerilme	Yer Değiştirme
500	%99,74	%67,93	%99,53	%54,86
1000	%99,85	%94,46	%99,80	%90,37
1500	%99,95	%98,39	%99,86	%97,67
2000	%99,93	%86,88	%99,78	%78,18

Tablo 3. Sinir ağının MAE değerleri

Epoch	Eğitim Verileri		Test Verileri	
	Gerilme	Yer Değiştirme	Gerilme	Yer Değiştirme
500	3,3538	0,5838	4,3357	0,4924
1000	2,6545	0,1929	3,0746	0,2191
1500	1,2667	0,0882	2,3387	0,0901
2000	1,3201	0,2882	3,1812	0,2993


Tablo 4. Sinir ağının MSE değerleri

Epoch	Eğitim Verileri		Test Verileri	
	Gerilme	Yer Değişirme	Gerilme	Yer Değişirme
500	20,2933	0,2802	34,918	0,2873
1000	11,6238	0,0466	15,3649	0,0612
1500	3,9237	0,0141	11,1893	0,01481
2000	5,3997	0,1146	16,7854	0,1388

Tablo 5. Sinir ağının eğitimi için gerekli zaman

Epoch	Zaman [s]
500	68,53
1000	138,98
1500	196,62
2000	271,91

1500 epoch için hem eğitim hem de test verilerinde yüksek ve birbirine yakın başarı oranlarının yakalanması, eğitilen modelde underfitting (öğrenememe) ve overfitting (ezberleme) problemi ile karşılaşmadığını göstermektedir. Yapay sinir ağının tahmin ettiği değerler ile gerçek değerlerin karşılaştırması Şekil 19'da görülebilir.



Şekil 19. Test ve tahmin verilerinin karşılaştırılması (1500 Epoch)

Belirtilen başarı metrikleri incelendiğinde 1500 epoch ile eğitilen ağı, optimizasyon çalışmasında gerilme ve yer değiştirme değerlerinin tahmininde kullanılması adına yeterli seviyede başarıya ulaştığı görülmektedir.

Boyut Optimizasyonu

4 farklı çalışma için GA algoritması kullanılarak elde edilen tek amaçlı optimizasyon sonuçları Tablo 6'da verilmiştir. İki adet kısıt fonksiyonuna sahip üç çalışma incelendiğinde istenilen $1200 N - 1,2 mm$ ve $3500 N - 2,8 mm$ yay rijitliği için hata değeri $3E - 08 mm$ 'den daha

küçük olmak üzere son derece başarılı sonuçlar ürettiği görülmektedir. $4000 N - 3,8 mm$ için gerçekleştirilen çalışma optimum sonuca akma sınırına gelerek ($449.999 N/mm^2$) $0,36378 mm$ hata ile ulaşmaktadır. Akma gerilmesine ait g_2 kısıt fonksiyonu kaldırıldığında aynı rijitliğe sahip yaya $7,959E - 09 mm$ hata ve $803,135 N/mm^2$ gerilme ile ulaşabildiği görülmüştür. Dört çalışma için de 100 popülasyon ve 20 jenerasyon parametreleri göz önüne alındığında, optimizasyon çalışması için gereken ortalama 4,5 saniyelik süreler kayda değer zaman ve maliyet kazançları sağlamaktadır.

Tablo 6. Tek amaçlı optimizasyon sonuçları

		Yay 1	Yay 2	Yay 3	Yay 4
İstenilen Yay Rijitliği	$F [N]$	1200	3500	4000	4000
	$y [mm]$	1,2	2,8	3,8	3,8
Algoritma		GA	GA	GA	GA
Amaç Fonksiyonları		f_1	f_1	f_1	f_1
Kısıt Fonksiyonları		g_1, g_2	g_1, g_2	g_1, g_2	g_1
Fonksiyon Değerleri	$f_1 [mm]$	2,4233E-11	2,2980E-08	0,36378	7,9595E-09
$y [mm]$		1,200007	2,79975	2,94702	3,79987
Gerilme [N/mm^2]		316,4189	439,45	449,613	803,135
Hacim [mm^3]		2707,3306	7924,42	9296,67	4569,799
Popülasyon		100	100	100	100
Jenerasyon		20	20	20	20
Tasarım Parametreleri	$D_s [mm]$	53,3488	68,51	69,9791	65,9168
	$D_1 [mm]$	20,0546	24,2796	14,3105	24,697
	$h_0 [mm]$	3,0362	3,16489	4,2397	3,8258
	$t [mm]$	1,38758	2,4336	2,4938	1,5316
Optimizasyon Süresi [s]		4,312	4,244	4,318	2,307

Tablo 6'da belirtilen $2,4233E - 11$ seviyesindeki hata değerinden ödün verilerek tasarımcı için kabul edilebilir $1E - 06$ seviyelerindeki hata seviyesine sahip yayın kullanılması hacimden tasarruf edilmesini olanak sağlayabilir. Bu doğrultuda hacmi ifade edecek ikinci bir amaç fonksiyonu (f_2) ile çok amaçlı optimizasyon çalışması gerekli kılınmaktadır.


Tablo 7'de ise yine 4 farklı yay rijitliği için NSGA-II algoritması ile elde edilen çok amaçlı optimizasyon sonuçları verilmiştir. Elde edilen sonuçlar incelendiğinde NSGA-II algoritmasının GA algoritması kadar başarılı sonuçlar yakalayabildiği görülmektedir. $6,743E - 8 mm$ 'den daha düşük hata değerleri ile tasarım parametrelerine ulaşılan yay rijitlikleri için, çizelgede belirtilen değerler f_1 amaç

fonksiyonunun en küçük hata değerlerine sahip olduğu ve en yüksek hacme sahip sonuçlardır. Tek amaçlı optimizasyonda olduğu gibi çok amaçlı optimizasyon için de gerekli süreler ortalama 4,5 saniyedir.

Tablo 7. Çok amaçlı optimizasyon sonuçları

		Yay 5	Yay 6	Yay 7	Yay 8
İstenilen Yay Rijitliği	$F [N]$	700	1500	2800	3000
	$y [mm]$	0,86	1,5	2,4	1,2
Algoritma		NSGA-II	NSGA-II	NSGA-II	NSGA-II
Amaç Fonksiyonları		f_1, f_2	f_1, f_2	f_1, f_2	f_1, f_2
Kısıt Fonksiyonları		g_1, g_2	g_1, g_2	g_1, g_2	g_1, g_2
Fonksiyon Değerleri	$f_1 [mm]$	4,90E-10	6,31E-10	2,19E-09	6,743E-08
	$f_2 [mm^3]$	3029,009	1953,028	6935,77	2661,916
$y [mm]$		0,86003	1,49996	2,400066	1,19963
Gerilme [N/mm^2]		191,611	439,224	380,3619	437,1704
Hacim [mm^3]		3029,009	1953,03	6935,77	2661,916
Popülasyon		100	100	100	100
Jenerasyon		20	20	20	20
Tasarım Parametreleri	$D_e [mm]$	56,5897	47,445	63,4485	46,6885
	$D_i [mm]$	15,3433	17,825	18,221	24,1731
	$h_0 [mm]$	3,9282	3,2192	3,1424	2,681
	$t [mm]$	1,2769	1,2568	2,368	2,0665
Optimizasyon Süresi [s]		4,336	4,3127	4,371	4,375

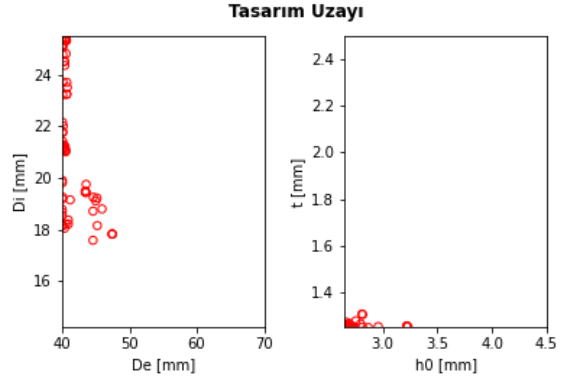
f_1 amaç fonksiyonunun hata değerinin arttığı ancak hacmin beklenildiği üzere azaldığı Pareto çözümleri ve tasarım uzayları bir yay rijitliği için Şekil 20 ve 21'de, çok amaçlı optimizasyon çalışmasında elde edilen çözümlerden birkaçı ise Tablo 8'de verilmiştir.



Şekil 20. 1500 N ve 1,5 mm için Pareto diyagramı

Tablo 8 incelendiğinde f_1 fonksiyonundan ödün verilerek hacmin azaltılabileceği

gözlemlenmektedir. Çözüm 1 ve 2 incelendiğinde, $5,33E - 06 mm$ hataya sahip tasarımın seçilmesi ile hacmin $181,638 mm^3$ azalacağı ve malzemeden $\%9,3$ tasarruf edilebileceği görülmektedir.



Şekil 21. 1500 N ve 1,5 mm için tasarım uzayı

Tablo 8. İstenilen 1500N ve 1,5 mm rijitlik için elde edilen çözümlerden bazıları

		Çözüm 1	Çözüm 2	Çözüm 3	Çözüm 4
Fonksiyon Değerleri	$f_1 [mm]$	6,31E-10	5,33E-06	4,62E-05	5,42E-04
	$f_2 [mm^3]$	1953,028	1771,394	1705,753	1633,66
$y [mm]$		1,49996	1,4967	1,4904	1,46708
Gerilme [N/mm^2]		439,224	443,668	444,412	445,047
Hacim [mm^3]		1953,028	1771,394	1705,75	1633,66
Tasarım Parametreleri	$D_e [mm]$	47,445	45,932	45,006	44,63
	$D_i [mm]$	17,825	18,7936	19,1	19,245
	$h_0 [mm]$	3,2192	2,9579	2,7529	2,8134
	$t [mm]$	1,2568	1,2545	1,2793	1,2521

100 popülasyon ve 20 jenerasyon ile gerçekleştirilen çalışma için 2000 defa yapay sinir ağı çalıştırılarak yapılan tahminler ile gerilme ve yer değiştirme sonuçlarına kısa sürelerde ulaşılması, sonlu elemanlar ile yapılacak olan optimizasyon çalışmasına kıyasla zaman açısından büyük avantajlar sağlamaktadır. Çalışmada elde edilen veri seti (256 adet veri) için yaklaşık 40 dakika harcadığı göz önüne alındığında, 2000 analiz için gerekli olan süre yaklaşık olarak 5 saat olmaktadır. Bu fark, doğrusal olmayan, karmaşık geometrili ve çok sayıda elemandan oluşan modellerde daha fazla olacaktır.

YSA ve SEA Sonuçlarının Karşılaştırılması

Elde edilen optimizasyon sonuçlarının doğruluğu sonlu elemanlar analizi yapılarak değerlendirilmiştir ve Tablo 9'de karşılaştırmalar verilmiştir. Tablo 2 ile belirtilen ve 1500 epoch eğitilen yapay sinir ağı için yer değiştirmedeki $\%2,33$ hata değeri optimizasyon sonuçlarında $\%3,84$

(Tablo 10) olarak karşımıza çıkmaktadır. Gerilme değeri ise yer değiştirmeden daha iyi sonuçlar üretmek için %1'den daha az hata ile hesaplanmıştır (Tablo 10).

Tablo 9. Elde edilen tasarım parametreleri için YSA ile SEA sonuçlarının karşılaştırılması

İstenilen Yay Rijitliği		Yapay Sinir Ağı Sonucu		Sonlu Elemanlar Analizi Sonucu		Yüzde Hata [%]	
F [N]	y [mm]	y [mm]	Gerilme [N/mm ²]	y [mm]	Gerilme [N/mm ²]	y [mm]	Gerilme [N/mm ²]
1200	1,2	1,200007	316,4189	1,39547	322,523	14,007	1,8926
3500	2,8	2,79975	439,45	3,044	441,615	8,024	0,4902
4000	3,8	2,94702	449,613	3,038	448,7981	2,995	-0,1816
4000	3,8	3,79987	803,135	4,1975	764,696	9,473	-5,0267
700	0,86	0,86003	191,611	0,898	197,363	4,228	2,9144
1500	1,5	1,49996	439,224	1,4366	439,522	-4,410	0,0678
2800	2,4	2,400066	380,3619	2,5285	380,261	5,079	-0,0265
3000	1,2	1,19963	437,1704	1,2971	445,02	7,514	1,7639

Optimizasyon çalışmasının yapay sinir ağı kullanılarak gerçekleştirilmesi ile elde edilen sonuçların, yapay sinir ağı başarı oranları ile benzerlik göstermesi gayet doğaldır. Yapay sinir ağı ile gerçekleştirilecek olan optimizasyon çalışmasının başarısının yapay sinir ağının başarısına bağlı olduğu görülmektedir.

Tablo 10. YSA ile SEA sonuçlarının R^2 değerleri

Yer Değiştirme	Gerilme
%96,16	%99,24

SONUÇLAR

Gerçekleştirilen çalışmada, sonlu elemanlar analizleri ile gerçekleştirilecek olan optimizasyon çalışmasının yapay sinir ağı ile gerçekleştirilerek zamandan ve buna bağlı olarak ürün geliştirme maliyetlerinden tasarruf edilmesi amaçlanmıştır. Bu doğrultuda disk yaylar için bir sonlu elemanlar modeli oluşturulmuş ve yapay sinir ağının eğitimi için yeterli sayıda veri toplanmıştır. Eğitilen sinir ağı modeli optimizasyon çalışmasında kullanılarak elde edilen tasarım parametreleri sonlu elemanlar analizi ile karşılaştırılmıştır. Elde edilen sonuçlar neticesinde;

1. Belirlenen sinir ağı modeli için uygun epoch sayısı ile gerilme ve yer değiştirme değerlerinin tahmininde yüksek başarı yakalanabildiği,

2. Hem tek hem de çok amaçlı optimizasyon algoritmalarının yapay sinir ağı ile istenilen tasarım parametrelerine belirtildiği üzere 4,5 saniye gibi kısa süreler içerisinde ulaşabildiği,
3. Özellikle davranışı doğrusal olmayan malzemeler ve karmaşık geometriler ile çok sayıda elemandan oluşan modellerde iki yöntem arasındaki zaman farkının daha fazla olacağı,
4. Elde edilen tasarım parametrelerinin sonlu elemanlar analizi ile karşılaştırılması neticesinde optimizasyon çalışmasının başarısının (%96,16) yapay sinir ağının başarı oranına (%97,67) bağlı olarak değişebileceği,
5. Başarı oranı daha yüksek bir sinir ağı ile daha net ve doğru sonuçlara ulaşmanın mümkün olabileceği gözlemlenmiştir.

OPTIMIZATION OF RECTANGULAR SECTION BELLEVILLE SPRINGS WITH ARTIFICIAL NEURAL NETWORK

Machine learning has a crucial role in significantly reducing the time and costs devoted to analysis in product design. Optimization work with machine learning provides excellent advantages in terms of time and cost compared to finite element analysis. In this study, a machine learning model was trained for Belleville springs and aimed to use the trained model in the size optimization of Belleville springs. To show the applicability of single and multi-purpose optimization methods, the optimization of various Belleville springs with desired spring stiffness is discussed, and Pareto solutions are presented and examined. Finite element analyzes were carried out with the obtained design parameters, and artificial neural network and finite element results were compared. It has been seen that the optimization result can be reached within 4.5 seconds with the artificial neural network, and the accuracy of the obtained results (96.16%) is similar to the neural network success rate (97.67%).

Keywords: Belleville Spring, Finite Element Analysis, Machine Learning, Artificial Neural Network, Optimization, Genetic Algorithm

KAYNAKÇA

1. N. Kaya and F. Öztürk, "Dikdörtgen Kesitli Disk Yayların Optimum Kesit Tasarımı," *Makina Tasarım ve İmalat Dergisi*, vol. 4, no. 3, pp. 140–145, 2002.
2. R. Phellan, B. Hachem, J. Clin, J. M. Mac-Thiong, and L. Duong, "Real-time biomechanics using the finite element method and machine learning: Review and

- perspective,” *Med Phys*, vol. 48, no. 1, pp. 7–18, Jan. 2021.
3. “Abaqus/CAE Student Edition 2020.”
 4. M. Müller, X. Longl, M. Betsch, D. Böhmmländer, and W. Utschick, “Real-Time Crash Severity Estimation with Machine Learning and 2D Mass-Spring-Damper Model,” *IEEE Conference on Intelligent Transportation Systems, Proceedings, ITSC*, vol. 2018–November, pp. 2036–2043, Dec. 2018.
 5. Z. S. Ma, Q. Ding, and Y. J. Zhai, “Hybrid Modeling of Nonlinear-Jointed Structures via Finite-Element Model Reduction and Deep Learning Techniques,” *Journal of Vibration Engineering and Technologies*, vol. 9, no. 4, pp. 575–585, Jun. 2021.
 6. Z. Qi, N. Zhang, Y. Liu, and W. Chen, “Prediction of mechanical properties of carbon fiber based on cross-scale FEM and machine learning,” *Compos Struct*, vol. 212, pp. 199–206, Mar. 2019.
 7. C. N. N. Karina, P. Chun, and K. Okubo, “Tensile Strength Prediction of Corroded Steel Plates by Using Machine Learning Approach,” *Steel and Composite Structures*, vol. 24, no. 5, pp. 635–641, Aug. 2017.
 8. L. Liang, M. Liu, C. Martin, and W. Sun, “A deep learning approach to estimate stress distribution: a fast and accurate surrogate of finite-element analysis,” *J R Soc Interface*, vol. 15, no. 138, Jan. 2018.
 9. F. C. Babalık and K. Çavdar, *Makine Elemanları ve Konstrüksiyon Örnekleri*, 8th ed. Bursa: Dora Yayınları, 2015.
 10. D. L. Venkatesh and H. Zhou, “Designing Belleville Spring Washers,” *Int. J. Eng. Res. Technol*, vol. 7, no. 12, pp. 168–174, 2018.
 11. [11] D. Bhope, S. Tahilyani, and K. Singh, “Effects of Slots on Deflection and Stresses in Belleville Spring,” *The International Journal of Engineering And Science (IJES)*, pp. 2–3, 2013.
 12. X. Liu, C. E. Athanasiou, N. P. Padture, B. W. Sheldon, and H. Gao, “A machine learning approach to fracture mechanics problems,” *Acta Mater*, vol. 190, pp. 105–112, May 2020.
 13. S. Fahle, C. Prinz, and B. Kuhlenkötter, “Systematic review on machine learning (ML) methods for manufacturing processes – Identifying artificial intelligence (AI) methods for field application,” *Procedia CIRP*, vol. 93, pp. 413–418, Jan. 2020.
 14. S. Müller, A., & Guido, *Introduction to Machine Learning with Python*. O’Reilly Media, Inc., 2016.
 15. F. Chollet, *Deep Learning with Python*. Manning Publisher Co., 2018.
 16. N. Gunantara, “A review of multi-objective optimization: Methods and its applications,” *Cogent Eng*, vol. 5, no. 1, pp. 1–16, Jan. 2018.
 17. E. S. Andrabbttir, K. J. Healy, D. H. Withers, B. L. Nelson, Y. Carson, and A. Maria, “Simulation optimization,” *Proceedings of the 29th conference on Winter simulation - WSC ’97*, pp. 118–126, 1997.
 18. I. Ahmadianfar, O. Bozorg-Haddad, and X. Chu, “Gradient-based optimizer: A new metaheuristic optimization algorithm,” *Inf Sci (N Y)*, vol. 540, pp. 131–159, Nov. 2020.
 19. M. Marseguerra, E. Zio, and S. Martorell, “Basics of genetic algorithms optimization for RAMS applications,” *Reliab Eng Syst Saf*, vol. 91, no. 9, pp. 977–991, Sep. 2006.
 20. A. R. Yıldız, N. Öztürk, N. Kaya, and F. Öztürk, “Hybrid multi-objective shape design optimization using Taguchi’s method and genetic algorithm,” *Structural and Multidisciplinary Optimization*, vol. 25, no. 4, pp. 251–260, 2003.
 21. A. Konak, D. W. Coit, and A. E. Smith, “Multi-objective optimization using genetic algorithms: A tutorial,” *Reliab Eng Syst Saf*, vol. 91, pp. 992–1007, 2006.
 22. F. Cappello and A. Mancuso, “A genetic algorithm for combined topology and shape optimisations,” *Computer-Aided Design*, vol. 35, no. 8, pp. 761–769, 2003.
 23. R. T. Marler and J. S. Arora, “Survey of multi-objective optimization methods for engineering,” *Structural and Multidisciplinary Optimization*, vol. 26, no. 6, pp. 369–395, Mar. 2004.
 24. K. Deb, A. Pratap, S. Agarwal, and T. Meyarivan, “A fast and elitist multiobjective genetic algorithm: NSGA-II,” *IEEE Transactions on Evolutionary Computation*, vol. 6, no. 2, pp. 182–197, Apr. 2002.
 25. Belleville Springs Ltd., “Belleville Springs User’s Guide and Catalogue.”
 26. D. P. Kingma and J. L. Ba, “Adam: A Method for Stochastic Optimization,” *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*, Dec. 2014.
 27. J. Blank and K. Deb, “Pymoo: Multi-Objective Optimization in Python,” *IEEE Access*, vol. 8, pp. 89497–89509, 2020.