



## YAPAY ZEKA KULLANILARAK TREN TEKERLEKLERİNİN YORULMA ÖZELLİKLERİNİN VEKİL MODELLENMESİ

Mehran MAHOUTİ<sup>1\*</sup>, Mehmed Sinan KÖMEK<sup>2</sup>, Suat YILMAZ<sup>1</sup>

<sup>1</sup> İstanbul Üniversitesi-Cerrahpaşa, Mühendislik Fakültesi, Metalurji Ve Malzeme Mühendisliği Bölümü, İstanbul, Türkiye

<sup>2</sup> Yıldız Teknik Üniversitesi, Elektrik Elektronik Fakültesi, Elektronik ve Haberleşme Mühendisliği Bölümü, İstanbul, Türkiye

Anahtar Kelimeler	Özet
<i>Yapay Zeka</i> <i>Optimizasyon</i> <i>Vekil modelleme</i> <i>Sonlu elemanlar yöntemi</i>	Sonlu Elemanlar Yöntemi (Finite Element Method, SEY), tren tekerlekleri gibi karmaşık yapıların analiz edilmesi ve tasarlanması için mühendislikte hayati bir araçtır. Tren tekerlekleri, işletme ömürleri boyunca karşılaştıkları aşırı ve değişken yükler nedeniyle yorulmaya maruz kalmaktadır ve bu durum, ömür süresi ve güvenlik üzerindeki etkileri nedeniyle tren tekerleği tasarımında kritik bir endişe kaynağıdır. Ancak, özellikle tren tekerlekleri gibi karmaşık geometrilere sahip büyük ölçekli yapıların modellenmesinde SEY'in geniş hesaplama ihtiyaçları önemli zorluklar sunmaktadır. Doğru yorgunluk analizi için gereken detaylı modelleme, genellikle büyük hesaplama yükleri ve uzun zaman dilimleri ile sonuçlanmakta ve bu durum, hızlı karar verilmesi gereken durumlarda daha az uygulanabilir bir seçenek haline gelmektedir. Bu sınırlamaları ele almak için, Yapay Zeka (Artificial Intelligence, YZ), yenilikçi bir çözüm olarak ortaya çıkmıştır. SEY simülasyonlarından elde edilen veri setleri üzerinde eğitilen YZ modelleri, geleneksel hesaplama maliyeti ve zamanının bir kısmında yorgunluk ömrünü tahmin ederek etkin bir alternatif sunmaktadır. Bu vekil modeller, mühendislik tasarım optimizasyonu süreçleri için gerekli olan hızlı ve doğru tahmini sağlamaktadır. Bu çalışmada YZ tabanlı vekil modelleme yaklaşımı ile tren tekerlekleri optimizasyon problemini geleneksel SEY yaklaşımına kıyas ile nerdeyse %90 oranında hızlandırma başarısına erişilmiştir.

## SURROGATE MODELLING OF TRAIN WHEELS FATIGUE CHARACTERISTICS USING ARTIFICIAL INTELLIGENCE

Keywords	Abstract
<i>Artificial intelligence,</i> <i>Optimization,</i> <i>Surrogate modeling,</i> <i>Finite element method.</i>	The finite element method (FEM) is a vital tool in engineering for analyzing and designing complex structures such as train wheels. Train wheels are subject to fatigue due to the extreme and variable loads they encounter throughout their operating life, and this is a critical concern in train wheel design due to its effects on lifespan and safety. However, the large computational needs of FEM present significant challenges, especially in modeling large-scale structures with complex geometries such as train wheels. The detailed modeling required for accurate fatigue analysis often results in large computational loads and long time periods, making it a less feasible option in situations where rapid decisions must be made. To address these limitations, Artificial Intelligence (AI) has emerged as an innovative solution. AI models trained on data sets obtained from FEM simulations offer an effective alternative by predicting fatigue life at a fraction of the traditional computational cost and time. These surrogate models provide the fast and accurate prediction required for engineering design optimization processes. In this study, the AI-based surrogate modeling approach succeeded in accelerating the train wheels optimization problem by almost 90% compared to the traditional FEM approach.

### Alıntı / Cite

Mahouti, M., Komek, M. S., Yılmaz, S., (2024). Yapay Zeka Kullanılarak Tren Tekerleklerinin Yorulma Özelliklerinin Vekil Modellenmesi, Mühendislik Bilimleri ve Tasarım Dergisi, 12(2), 277-284.

Yazar Kimliği / Author ID (ORCID Number)	Makale Süreci / Article Process
Mehran Mahouti, 0000-0002-6793-6458	<b>Başvuru Tarihi / Submission Date</b> 12.02.2024
Mehmet Sinan Komek, 0009-0000-9391-8053	<b>Revizyon Tarihi / Revision Date</b> 07.03.2024
Suat Yılmaz, 0000-0002-6092-9319	<b>Kabul Tarihi / Accepted Date</b> 17.03.2024
	<b>Yayın Tarihi / Published Date</b> 30.06.2024

\* İlgili yazar / Corresponding author: mahouti@gmail.com, +90-539-610-6523

# SURROGATE MODELLING OF TRAIN WHEELS FATIGUE CHARACTERISTICS USING ARTIFICIAL INTELLIGENCE

Mehran Mahouti<sup>1†</sup>, Mehmed Sinan Kömek<sup>2</sup>, Suat Yılmaz<sup>1</sup>

Istanbul University-Cerrahpaşa, Faculty of Engineering, Department of Metallurgy and Material Engineering, Istanbul, Turkey

Yıldız Technical University, Faculty of Electrical and Electronics, Department of Electronics and Communication Engineering, Istanbul, Turkey

---

## Highlights

- Addressing computational challenges in FEM for train wheel design,
- Enhancing efficiency in structural design processes
- Bridging the gap between simulation detail and computational efficiency

---

## Purpose and Scope

The paper aims to tackle the significant computational demands and challenges associated with using the Finite Element Method (FEM) for the structural design of train wheels. These challenges include high computational costs, extended time frames for simulation, and the need for detailed modelling to accurately capture fatigue characteristics under diverse loading conditions. Also, herein it is aimed to operationalize AI in enhancing the computational efficiency of structural design processes, particularly in the context of train wheel design. By developing a comprehensive 3D model of a train wheel using ANSYS and generating a robust dataset for training AI models, the research seeks to expedite the design optimization process.

## Design/methodology/approach

This study initiates with the development of a comprehensive 3D model of a train wheel using ANSYS. The primary objective is to utilize this detailed 3D model as the basis for generating a robust dataset, encompassing both training and test samples, which will be instrumental in developing and validating a data-driven surrogate model for capturing the intricate behaviours of train wheel fatigue characteristics under various operational conditions. The ultimate aim of this approach is to streamline and expedite the design optimization process for train wheels. By employing the AI based surrogate model, we anticipate a significant reduction in the computational time and resources typically required in FEM analyses. This approach not only promises to be considerably faster than the direct usage of FEM but also opens avenues for exploring a wider range of design variables and conditions, potentially leading to more innovative and optimized train wheel designs.

## Findings

The work found that the application of AI, in the form of surrogate models, has the potential to revolutionize the way fatigue analysis and design optimization of train wheels are conducted. This approach bridges the gap between the need for detailed simulation in FEM and the demand for computational efficiency, marking a significant advancement in the field of structural engineering and design.

## Research limitations/implications

Due to the limited computer hardware capabilities, the 3D model is designed in static form for a wheel at instantaneous time point.

## Originality

The proposed novelty of the work lies in its approach to combining AI with traditional FEM techniques, leading to significant advancements in computational efficiency, design process acceleration, and innovation in train wheel design. This research is valuable to professionals in structural engineering, particularly those focused on railway systems, offering novel methodologies and insights that could substantially improve design and analysis processes in the field.

---

† Corresponding author: mahouti@gmail.com, +90-539-610-6523

## 1. Giriş (Introduction)

Sonlu Elemanlar Yöntemi (SEY), çeşitli yükleme koşulları altında karmaşık yapısal davranışları ve malzeme özelliklerini modelleme yeteneği sayesinde tren tekerleklerinin yorulma analizlerinde vazgeçilmez bir araç olarak ortaya çıkmaktadır [1-2]. SEY, tekerlek malzemesi içindeki gerilim ve deformasyon dağılımını detaylı ve hassas bir şekilde simüle etmeyi sağlar ki bu da yorulma başarısızlığına eğilimli kritik bölgeleri tanımlamak için hayati öneme sahiptir [3]. Karmaşık geometrileri ve çeşitli malzeme özelliklerini, anizotropi ve doğrusal olmayan özellikler dahil, ele alabilme yeteneği, SEY'i tren tekerleği tasarımında gereken çok yönlü analiz için benzersiz bir şekilde uygun kılar. SEY'nin tren tekerleklerinin yorulma analizlerinde kullanılmasının gerekliliği, gerçek dünya koşullarını yüksek sadakatle simüle edebilme yeteneğinden kaynaklanır. Tren tekerlekleri, yorulma ömrünü önemli ölçüde etkileyebilecek çeşitli yükler ve çevresel koşullarla karşılaşır [4-5]. SEY bu koşulları, tekerlek-ray temasını, termal etkileri ve imalat süreçlerinden kaynaklanan artık gerilmeleri dahil olmak üzere doğru bir şekilde modelleyebilir. Bu detaylı modelleme, yorulma çatlaklarının başlangıcını ve yayılımını tahmin etmek için temel olup, sonuç olarak daha güvenilir ve güvenli tekerlek tasarımlarına yol açar [6]. Ayrıca, SEY'nin diğer simülasyon araçlarıyla entegrasyonundaki esnekliği ve malzeme bilimi ile yorulma teorisi alanlarındaki ilerlemeleri dikkate alma yeteneği, tren tekerleklerinin yapısal tasarımında kullanılması gereken bir araç olarak konumunu daha da sağlamlaştırır [7-8]. Mühendislere çeşitli tasarım senaryolarını ve malzeme seçeneklerini simüle etme ve analiz etme imkanı tanıyarak, SEY demiryolu sektöründe yenilik ve verimliliği teşvik eden kritik bir role sahiptir [9-10].

SEY, karmaşık mühendislik sistemlerindeki yapısal tasarımda uzun süredir temel taş olarak kabul edilmektedir [11-13], örneğin tren tekerlekleri gibi [1]. SEY, çeşitli yükleme koşulları altında gerilim [14], deformasyon [15] ve yorulma özelliklerini modellemede eşsiz detay ve hassasiyet sunar [16]. Ancak, sayısız avantajlarına rağmen, SEY, özellikle karmaşık ve büyük ölçekli yapılar uygulandığında önemli hesaplama zorluklarıyla birlikte gelir [17]. SEY'nin yapısal tasarımda kullanılmasının temel zorluklarından biri yüksek hesaplama maliyetidir. Tren tekerlekleri karmaşık geometrilere sahiptir ve geniş bir dinamik yük ve çevresel koşullar yelpazesi altında çalışır [18]. Bu faktörleri SEY modellerinde doğru bir şekilde yakalamak, ince bir ağ ve yüksek detay seviyesi gerektirir, bu da büyük sayıda eleman ve düğümle sonuçlanır [19-20]. Bu tür detaylı modellerin hesaplanması önemli işlem gücü ve bellek talep eder, sıklıkla yüksek performanslı bilgisayar kaynaklarının kullanımını zorunlu kılar. Bu, analizle ilişkili doğrudan maliyetleri artırmakla kalmaz, aynı zamanda simülasyonların tamamlanması için gereken süreyi uzatır ve potansiyel olarak tüm tasarımı ve optimizasyon sürecini yavaşlatabilir. Bir başka zorluk, SEY simülasyonlarının ölçeklenebilirliğidir, bu da model karmaşıklığı ve boyutu ile ilgilidir [21]. Modelin sadakati, fiziksel olayların daha doğru ve detaylı temsillerini yakalamak için arttıkça, hesaplama yükü üssel olarak artar. Bu ölçekleme sorunu, uzun süreler boyunca periyodik yüklemeyi simüle etmenin gerektiği yorulma analizinde daha da belirginleşir, bu da hesaplama taleplerini daha da artırır. Tasarım süreçlerinin tekrarlayıcı doğası, azami kullanılabilir yük miktarını, modelin maliyetini ve ömrünü bulabilmek ve uygulanabilirliğini değerlendirmek için birden fazla simülasyon gerektirir, bu da hesaplama yükünü daha da artırır [22]. Ayrıca, SEY modellerinin karmaşıklığı, gereken uzmanlık ve hata potansiyeli açısından zorluklar oluşturur. SEY kullanımında modelin yapımı, SEY için düzenlenmesi, yazılımda modelin hazırlanması için yöntemlerin özelleştirilmesi, oluşturulan örgünün (mesh) kalitesinin belirlenmesi, yüklerin, destek noktalarının ve eklemlerin doğru şekilde belirlenmesi ve kurulum eğer hareketli ise hareketin doğru tanımlanması için konuya dair mühendislik bilgisinin yeterli olması, yazılıma yeterli hakimiyetinin olması ve sonucun doğruluğuna yakınlığını muhakeme edebilmesi gerekir. Model kurulumunda yapılan yanlış yorumlamalar veya hatalar, sadece hesaplama yoğunluğu açısından değil, aynı zamanda insan hatasına karşı hassasiyet açısından da yanlış sonuçlara yol açabilir [17].

Yapısal tasarımlarda, örneğin tren tekerleklerinde, SEY ile ilişkili hesaplama zorluklarını ele almakta, Yapay Zeka (YZ) uygulaması, dönüştürücü bir çözüm olarak ortaya çıkmıştır. YZ tabanlı vekil modeller, bu yenilikte öncü konumda yer almakta, karmaşık simülasyon genişleyen problemlerin doğruluğunu ve güvenilirliğini korurken, önemli ölçüde daha düşük hesaplama maliyetleri sunmaktadır [23-24]. Yapısal tasarımda vekil modelleme, SEY'nin karmaşık ve yoğun hesaplamalı simülasyonlarını yaklaşık olarak modellemek için YZ algoritmalarının kullanılmasını içerir [25]. Bu YZ modelleri, detaylı SEY simülasyonlarından türetilen bir veri seti üzerinde eğitildikten sonra, stres dağılımları, deformasyon desenleri ve yorulma ömrü gibi çeşitli sonuçları olağanüstü hız ve verimlilikle tahmin edebilir. Temel avantaj, vekil modelin her seferinde tam simülasyonu çalıştırmaya gerek kalmadan SEY çıktılarının hızlı tahminlerini sağlama yeteneğinde yatmaktadır, böylece hesaplama süresi ve kaynak kullanımını önemli ölçüde azaltmaktadır [26-27].


YZ tabanlı vekil modelleme ile elde edilen hesaplama iyileştirmeleri önemlidir. İlk olarak, vekil modeller, tasarım ve analiz sürecini önemli ölçüde hızlandırır. Tren tekerlekleri bağlamında, bu hızlanma, birden fazla tasarım iterasyonunun ve yorulma analizlerinin geleneksel olarak gerekli olan sürenin bir kısmında gerçekleştirilebilmesini sağlar, bu da daha hızlı optimizasyon ve karar verme süreçlerini mümkün kılar. Bu hızlı analiz yeteneği, özellikle tasarımın erken aşamalarında, en umut verici yönleri belirlemek için birçok tasarım alternatifinin değerlendirilmesi gerektiğinde oldukça faydalıdır [28-30]. İkinci olarak, vekil modellemenin içsel

olarak düşük hesaplama yükü, doğrudan SEY simülasyonları ile sıklıkla yüksek maliyetlerinden dolayı yasaklayıcı olan kapsamlı parametrik çalışmaları ve hassasiyet analizlerini yapılabilir hale getirir [31-32]. Bu tür çalışmalar, tren tekerleklerinin değişken işletim koşulları altında davranışlarını anlamak ve yorulma ömrünü etkileyen kritik tasarım parametrelerini belirlemek için gereklidir [33-34]. Dahası, vekil modeller, analize daha karmaşık fenomenleri ve daha ince detayları, karşılık gelen bir hesaplama maliyeti artışı olmadan entegre etme yeteneğine sahiptir. Bu entegrasyon, model karmaşıklığı arttığında doğrudan SEY simülasyonları ile olduğu gibi, vekil model çalıştırmanın hesaplama karmaşıklığının aynı şekilde artmaması sayesinde mümkündür.

Yapısal tasarım süreçlerinin verimliliğini artırmada YZ potansiyelini operasyonel hale getirmek için bu çalışma, mühendislik simülasyonlarında yaygın olarak tanınan bir araç olan ANSYS [35] kullanılarak kapsamlı bir 3D tren tekerleği modeli geliştirmekle başlar. Temel amaç, bu detaylı 3D modeli, hem eğitim hem de test örneklerini kapsayan güçlü bir veri seti oluşturmak için bir temel olarak kullanmak ve bu veri seti, YZ tekniklerine dayanan veri odaklı bir vekil model geliştirmek ve doğrulamak için önemli olacaktır. Bu vekil model, SEY tarafından üretilen verilerde yer alan karmaşık desenlerden ve ilişkilerden öğrenmek üzere tasarlanmıştır ve çeşitli işletim koşulları altında tren tekerleğinin yorulma karakteristiklerinin karmaşık davranışlarını yakalamaktadır. Modeli, 3D ANSYS simülasyonlarından türetilen çeşitli senaryolar üzerinde eğiterek, her tasarım iterasyonunda kapsamlı SEY hesaplamalarına gerek kalmadan hızla yorulma ömrünü ve stres dağılımlarını tahmin edebilme yeteneği geliştirecektir. Bu yaklaşımın nihai amacı, tren tekerlekleri için tasarım optimizasyon sürecini akıcılaştırmak ve hızlandırmaktır. YZ'ye dayalı vekil modeli kullanarak, tipik olarak SEY analizlerinde gerekli olan hesaplama süresi ve kaynaklarında önemli bir azalma bekliyoruz. Modelin, yorulma özelliklerinin hızlı ancak son derece doğru tahminlerini sağlayarak daha dinamik ve yinelemeli bir tasarım sürecini mümkün kılması beklenmektedir. Bu yaklaşım, sadece doğrudan SEY kullanımından önemli ölçüde daha hızlı olmakla kalmayacak, aynı zamanda daha yenilikçi ve optimize edilmiş tren tekerleği tasarımlarına yol açabilecek geniş bir tasarım değişkenleri ve koşulları yelpazesi keşfetme fırsatları da sunacaktır. Özünde, bu araştırma, geleneksel SEY yaklaşımlarının hesaplama sınırlarını aşmada YZ'nin gücünü kullanmayı amaçlamaktadır. Detaylı simülasyon ile hesaplama verimliliği arasındaki boşluğu kapatmak suretiyle önerilen vekil model, tren tekerleklerinin yorulma analizi ve tasarım optimizasyonu şeklini devrim niteliğinde değiştirmeyi vaat etmekte ve yapısal mühendislik ve tasarım alanında önemli bir ilerleme işaret etmektedir.

## 2. Problem Tanımı

Çalışmanın bu bölümünde, Şekil 1'de sunulmuş olan örnek bir tren tekerinin 3B ve şematik görselidir. Tekere 2 kuvvet etki etmektedir. Milden tekere yatak kuvveti ve tekerle ray arasında sürtünme kuvvetidir. Teker ile rayın temas ettiği yüzey tekerin dış yüzüne dik değil yaklaşık 87.5 derece tayin edilmiştir. Teker tasarımında kullanılan parametreler: (i) Teker yarıçapı  $TekerR$ , (ii) Tekerin kalınlık  $MilW$ , (iii) Mil yarıçapı  $MilR$ , (iv) Yatak kuvveti  $F$ . Bu parametrelerin değişimine göre alınan sonuç ise En düşük Güvenlik Katsayısı ( $GK$ ).



Şekil 1. Ele alınan tren tekerinin (a) 3B ANSYS modeli, (b) şematik görseli. ((a) 3D ANSYS model, (b) schematic image of the considered train wheel.)

Şekilde verilen değişkenlerin (geometrik, uygulanan güç vs.) Tablo 1’de verilen aralıklar içerisindeki limitler içerisinde YZ modelleri için gerekli olan eğitim verileri oluşturulacaktır analizleri yapılmıştır. Bu eğitim verilerinin her birinin yaklaşık aldığı süre ise tasarımın mesh ve kullanılan bilgisayar sistemine ciddi anlamda bağlıdır. Bu çalışmada kullanılan bilgisayar altyapısına ve tasarımın mesh ayarına göre simülasyon maliyeti Tablo 2 de sunulmuştur.

**Tablo 1.** Tasarımda ele alınacak olan değişkenler ve aralıkları (Variables and their ranges to be considered in design)

Parametre	Alt değer	Üst Değer
<i>TekerR</i> [cm]	400	500
<i>MilR</i> [cm]	70	100
<i>MilW</i> [cm]	100	150
<i>F</i> [KN]	400	500

**Tablo 2.** Ele alınan problemin simülasyon süre maliyet tablosu (Simulation time cost table of the considered problem)

Bilgisayar Sistemi	Model Ayarı	Simülasyon süresi [dakika]
AMD Ryzen 7 3700X 8-Core Processor 3.59 GHz, 48 GB Ram Windows 10 64 bit	Mesh element sayısı 60 [mm], varsa başka bilgiler	46.6
	Mesh element boyutu 50 [mm], varsa başka bilgiler	55.1
	Mesh element boyutu 35 [mm], varsa başka bilgiler	91.5
	Mesh element boyutu 15 [mm], varsa başka bilgiler	736.6

Tablo 2’den de görüleceği üzere, ele alınan problemde yüksek sayıdaki değişkenlerinden dolayı ve her bir değişkenin incelenen karakteristiğe olan lineer olmayan etkisinden kaynaklı, ele alınacak bir tasarım optimizasyon problemi için en basit yöntemlerde bile en az 1500-2000 fonksiyon değerlendirmesi gerektiren (örneğin, 50 nüfus büyüklüğü ve 40 iterasyonlu Parçacık Sürü Optimizasyonu gibi) bir sürece ihtiyaç uyulmaktadır. Bu tipte olan bir problemin genel optimizasyonunun her bir çalışma durumu için doğrudan SEY’e dayalı bir optimizasyon yaklaşımı kullanılarak neredeyse 90000 dakika (2000×45 (toplam fonksiyon değerlendirme× ortalama simülasyon süresi)) sürdüğü anlamına gelir. Burada üç farklı tasarım durumuna ihtiyacınız olduğunu varsayalım, böylece 3 farklı durum için toplam süre yaklaşık 270000 dakika (3×90000) olur. Bu çalışma kapsamında optimizasyon sürecinin olabildiğince kısaltma ve hesaplama verimliliğini artırmak için direk SEY tabanlı bir optimizasyon yerine YZ tabanlı bir vekil model geliştirilmesi ve optimizasyonun bu vekil model aracılığı ile yapılması hedeflenmiştir.

Bu amaç için öncelik ile vekil modele geliştirecek eğitim ve test verilerinin oluşturulması gerekmektedir. Ele alınan problem için, 4 tasarım değişkeniyle veriye dayalı bir vekil model oluşturulması, eğitim ve test örneklerinin dikkatlice düşünülmesini gerektirir. Bu örneklerin önemi, vekil modeli geliştirmede, doğrulamada ve modelin doğruluğunu sağlamada yattığı için önemlidir. Eğitim örnekleri vekil modeli oluşturmak için kullanılır. Modelin girdi değişkenleri (tasarım değişkenleri) ile çıktı arasındaki ilişkileri öğrenmesi için gerekli verileri sağlarlar. Bu örneklerin çeşitliliği ve temsilciliği ciddi öneme sahiptir. Modelin genelleştirebilmesini ve yeni, görülmemiş veriler için doğru tahmin yapabildiğini sağlamak için tasarım alanı içinde olası senaryoları geniş bir yelpazede kapsamalılar. Test örnekleri ise modeli doğrulamak için hayati öneme sahiptir. Eğitim aşamasında kullanılmazlar ve bağımsız bir şekilde modelin tahmin doğruluğunu değerlendirmek için hizmet ederler. Modelin bu test örneklerindeki tahminlerini gerçek sonuçlarla karşılaştırarak, modelin altta yatan desenleri etkin bir şekilde öğrenip öğrenmediğini veya sadece eğitim verilerini ezberleyip ezberlemediğini (aşırı uyum) anlayabiliriz. Dolayısı ile eğitim ve test örnekleri modelin geliştirilmesinde ciddi bir rol almaktadırlar. Yalnız, detaylı bir eğitim veri seti oluşturmak için, her bir değişkenden lineer örnekleme yöntemi ile 10 adet örnek alınması toplamda 1 milyon (10<sup>6</sup>) adet veri örneğine denk gelecektir. Böylesine büyük bir veri setini hazırlamak ciddi anlamda bir süreye ve maliyete ihtiyacı vardır ki birçok problemde bu denli bir kaynağın kullanımı verimlilik açısından uygun bir çözüm değildir, özellikle SEY gibi veri üretim süresininin ciddi zaman aldığı uygulamalarda.

Bu tarz yüksek sayıda değişkene sahip problemlerde, pratik ve verimli model eğitimi için, Latin Hiperküp Örnekleme (LHÖ), Deney Tasarımı veya adaptif örnekleme yöntemleri gibi alternatif örnekleme yöntemleri tercih edilir. Bu yöntemler, üssel olarak büyük bir veri setine ihtiyaç duymadan tasarım alanı hakkında en fazla bilgiyi yakalamayı amaçlar ve her değişkenin aralığını etkili bir şekilde kapsamaya odaklanır. Bu çalışma kapsamında ise, LHÖ [36] yöntemi kullanılarak 800 adet eğitim ve 50 adet test verisi ANSYS modeli yardımı ile oluşturulmuştur. Bu sayede geliştirecek olan modelin genelleme yeteneğinin doğru bir şekilde incelenmesi hedeflenmiştir.

### 3. Yapay Zeka Tabanlı Vekil Modelleme (Artificial Intelligence Based Surrogate Modelling)

Veriye dayalı vekil modelleme, geleneksel ve genellikle yoğun hesaplama gerektiren simülasyon yöntemlerine pratik ve etkin bir alternatif olarak ortaya çıkan ileri düzey bir hesaplama tekniğidir. Mühendislik ve bilimsel araştırmalarda, vekil modeller, ampirik verilere dayanarak karmaşık sistemlerin davranışını taklit etmek için tasarlanmıştır. Bir vekil modelin temel amacı, yapısal analizdeki SEY simülasyonları gibi daha karmaşık veya zaman alıcı bir sürecin yaklaşık ancak yüksek derecede doğru bir temsilini sağlamaktır. Veriye dayalı vekil modellemenin özü, var olan veri kümelerinden öğrenme ve yeni giriş verileri setleri için sonuçlar tahmin etme yeteneğindedir. Bu yaklaşım, tam ölçekli simülasyonların maliyetli veya zaman alıcı olduğu senaryolarda özellikle faydalıdır. Tren tekerleklerinin yorgunluk analizinde, vekil modeller, önceki simülasyon sonuçlarına dayanarak stres, gerilme ve yorgunluk ömrünü tahmin edebilir, bu da ayrıntılı simülasyonların tekrarlanmasının gerekliliğini önemli ölçüde azaltır.

Tren tekerleklerinin yorgunluk özelliklerinin vekil modellemesinde, YZ, doğrusal olmayan stres-gerinme ilişkilerini ve çeşitli yorgunluğa neden olan faktörleri doğru bir şekilde yakalayabilir. Bu ağlar, farklı yüklemeye ve/veya tasarım değişkenlerinin koşulları altında tren tekerleklerinin kapsamlı SEY simülasyonlarından elde edilen veri kümeleri üzerinde eğitilebilir. Bir kez eğitildiklerinde, YZ'ler tren tekerleklerinin yorgunluk ömrünü ve güvenlik katsayısını hızla tahmin edebilir, bu da her yeni tasarım veya senaryo için yoğun hesaplama gerektiren SEY simülasyonlarını etkili bir şekilde atlatır. Bu bağlamda YZ'lerin kullanımı, sadece tahmin sürecini hızlandırmakla kalmaz, aynı zamanda yüksek doğruluk ve güvenilirlik sağlar, tren tekerlekleri gibi güvenlik kritik bileşenler için hayati öneme sahiptir. Bu bölümde, tasarımın girdi ve çıktıları arasındaki eşleşmeyi sağlayacak bir vekil model oluşturmak için çeşitli ileri düzey ve yaygın kullanılan regresyon teknikleri kullanılmıştır. Vekil modelleri geliştirmek için aşağıdaki yöntemler potansiyel adaylar olarak seçilmiştir: (i) Çok Katmanlı Algılayıcı (ÇKA) [37], (ii) Destek Vektör Regresyon Makinesi (DVRM) [38], (iii) Topluluk Öğrenmesi (TÖ) [39], (iv) Gauss Süreci Regresyonu (GSR) [40-41]. Her modelin hiper-parametreleri, Ortalama Mutlak Hata (OMH) metriği (Denklem 1) kullanılarak k-katlamalı (k=3) çapraz doğrulama (K-ÇD) yöntemi ile izgara-arama optimizasyon yöntemi kullanılarak elde edilmiştir. Bu vekil modellerin karşılaştırmalı performansı Tablo 3'te ayrıntılı olarak verilmiştir. Bulgular, YZ algoritmalarından en bilineni olan GSR yönteminin diğer algoritmalarla kıyasla verimlilik açısından daha iyi performans gösterdiğini göstermektedir. Bu nedenle, tekerleğin tasarım optimizasyon süreci için birincil vekil model olarak GSR modeli benimsenecektir.

$$OMH = \frac{1}{N} \sum_{i=1}^N |H_i - T_i| \quad (1)$$

$$ROMH = \frac{1}{N} \sum_{i=1}^N \frac{|H_i - T_i|}{|H_i|} \quad (2)$$

Burada,  $T_i$ , i'inci örneğin vekil model tarafından tahmin edilen değer,  $H_i$ , ise i'inci örneğin hedeflenen değeridir,  $N$  ise toplam test kümesindeki veri sayısını ifade eder.

**Tablo 3.** Çeşitli yapay zeka modellerinin OMH performans sonuçları (MAE performance results of various AI models)

Model	Hiper-Parametreler	OMH	ROMH [%]
ÇKA	İki katmanlı, 5 ve 10 nöron; tansig	0.29	12.4
DVRM	Box Constraint 66.3, Kernel Gaussian, Kernel Scale 1.97	0.42	17.9
TÖ	Max split 366, type Tree, # learner 249 Method type Bag	0.33	14.5
GSR	Rational Quadratic, fit method Exact	0.11	5.9

GSR tabanlı vekil modeli aşağıda verilen maliyet fonksiyonu ve Bal Arısı çiftleşme optimizasyonu [42] algoritması kullanılarak bir tren tekerinin istenilen kuvvet (F) altında güvenlik faktörünü sağlayacak optimum değişkenleri  $\mathbf{x} = [TekerR, MilR, MilW]$  elde etmesi hedeflenmiştir. Tablo 4 de 4 farklı senaryo için optimizasyon sonuçları sunulmuştur.

$$Maliyet(\mathbf{x}) = \max \{ F = \text{istenilen} : GK(\mathbf{x}) \} \quad (3)$$

**Tablo 4.** Optimum elde edilmiş değişken değerleri (Optimally obtained design values)

Senaryo #	Hedef Kuvvet [KN]	Parametre [TekerR, MilR, MilW]	GSR+BÇO ile elde edilen / ANSYS ile elde edilen GK değeri
1	-410	492.18 ; 89.89 ; 148.0	6.03 / 5.85
2	-430	496.80 ; 80.52 ; 144.5	5.64 / 5.37
3	-450	480.29 ; 80.95 ; 133.1	5.74 / 5.36
4	-480	479.85 ; 77.24 ; 148.7	5.71 / 5.84

Burada dikkat edilmesi gereken husus önerilen GSR tabanlı vekil model yaklaşımı ile, sadece 850 örnek kullanılarak (800 (eğitim) + 50 (test)) model oluşturmak için gereken toplam süre yaklaşık 38250 dakika (850×45) olacaktır. Ancak model oluşturulduktan sonra vekil modelin yanıt süresi 0.001 saniyeden kısadır (Tablo 2de kullanılan bilgisayar ile). Ele alınan problem için elde edilen hızlandırmayı kısaca özetlemek gerekirse, incelenen tekerin 4 farklı tasarım durumu için tasarım optimizasyonu, önerilen yaklaşım kullanılarak toplam gerekli süre, veri üretimine eğitim (637.5 saat = 38250 dakika) ve optimizasyon süreci (4 saniye = 4×1000×0.001 saniye) dahil olmak üzere 638 saatten fazla değildir, oysa doğrudan SEY optimizasyon yaklaşımı 40 iterasyon ve 50 popülasyonu 4 farklı problem için 6000 (2000×4×45) saat gerektirir. Böylece tasarımın genel hesaplama maliyeti neredeyse %90 azaltılmış olur.

#### 4. Sonuç ve Tartışma (Result and Discussion)

Bu çalışmada, geometrik tasarım değişkenleri, uygulanan kuvvet ve tasarımın yorulma özellikleri arasında bir haritalama oluşturmak için yüksek doğrulukta, hızlı ve güvenilir bir veri tabanlı vekil model elde etmek için ÇKA, DVRM, TÖ, GSR gibi yaygın kullanılan ve son teknoloji yapay zeka algoritmaları kullanılarak bir tren tekerleğinin tasarım optimizasyonu verimli bir şekilde incelenmiştir. Veri tabanlı vekil modelin oluşturulması için veri setinin boyutunun mümkün olduğunca düşük olması gerektiğinden, hesaplamalı olarak verimli bir yaklaşım için 850 farklı tasarım örneği vekil modellerin eğitimi ve performans doğrulaması için kullanılmış ve sonuç olarak GSR modelinin seçilen problem için en umut verici çözüm olduğu bulunmuştur. Bundan sonra, dört farklı çalışma durumu tasarımı optimizasyon problemi olarak ele alınmış ve bu çalışma durumları için HBMO ve GSR tabanlı vekil model kullanılmıştır. Bu dört çalışma durumundan elde edilen simüle sonuçlara dayanarak, önerilen Vekil Modelleme yaklaşımı yorulma özellikleri analizleri için son derece doğru bir tahmin başarısı göstermiştir. Tekrar belirtmek gerekirse, çalışmanın ana amacı, yüksek performanslı bir tekerlek tasarımı önermek yerine, tren tekerlek tasarımlarının yorulma özellikleri gibi Sonlu Eleman Yöntemi ile simülasyon gerektiren problemler için düşük hesaplamalı maliyetli, hızlı ve doğru tasarım optimizasyonu çözümü olarak kullanılacak yeni bir veri tabanlı vekil modelleme yaklaşımını tanıtmaktır. Gelecekteki çalışmalarda, yazarlar çalıştıkları problemin tasarım değişkenlerini dinamik 3D modeller ve daha karmaşık tasarımlar için ek tasarım değişkenleri ile genişletmeyi hedeflemektedirler.

#### Çıkar Çatışması (Conflict of Interest)

Yazarlar tarafından herhangi bir çıkar çatışması beyan edilmemiştir. No conflict of interest was declared by the authors.

#### Kaynaklar (References)

- Adriano, V. S. R., Martínez, J. M. G., Ferreira, J. L. A., Araújo, J. A., & Da Silva, C. R. M. (2018). The influence of the fatigue process zone size on fatigue life estimations performed on aluminum wires containing geometric discontinuities using the Theory of Critical Distances. *Theoretical and Applied Fracture Mechanics*, 97, 265-278.
- Andújar, Rabindranath, Jaume Roset, and Vojko Kilar. "Beyond FEM: overview on physics simulation tools for structural engineers." *Technics Technologies Education Management* 6, no. 3 (2011): 555-571.
- Ansys, <https://www.ansys.com/>. Available on (24.11.2023)
- Bhat, S., and R. Patibandla. "Metal fatigue and basic theoretical models: a review." *Alloy steel-properties and use* 22 (2011).
- Bian, Jian, Yuantong Gu, and Martin Howard Murray. "A dynamic wheel-rail impact analysis of railway track under wheel flat by finite element analysis." *Vehicle System Dynamics* 51, no. 6 (2013): 784-797.
- Bracamonte, A. J., Mercado-Puche, V., Martínez-Arguelles, G., Pumarejo, L. F., Ortiz, A. R., & Herazo, L. C. S. (2023). Effect of Finite Element Method (FEM) Mesh Size on the Estimation of Concrete Stress-Strain Parameters. *Applied Sciences*, 13(4), 2352.
- Cwik, Tom, Daniel S. Katz, and Jean Patterson. "Scalable solutions to integral-equation and finite-element simulations." *IEEE Transactions on Antennas and Propagation* 45, no. 3 (1997): 544-555.
- de Gooijer, B. M., Havinga, J., Geijselaers, H. J., & van den Boogaard, A. H. (2021). Evaluation of POD based surrogate models of fields resulting from nonlinear FEM simulations. *Advanced Modeling and Simulation in Engineering Sciences*, 8(1), 1-33.
- Drucker, H., Burges, C. J., Kaufman, L., Smola, A., & Vapnik, V. (1996). Support vector regression machines. *Advances in neural information processing systems*, 9.
- Du, X., He, P., & Martins, J. R. (2021). Rapid airfoil design optimization via neural networks-based parameterization and surrogate modeling. *Aerospace Science and Technology*, 113, 106701.
- Efthimeros, G. A., D. I. Photeinos, Z. G. Diamantis, and D. T. Tsahalis. "Vibration/noise optimization of a FEM railway wheel model." *Engineering Computations* 19, no. 8 (2002): 922-931.
- Feather, W. G., Lim, H., & Knezevic, M. (2021). A numerical study into element type and mesh resolution for crystal plasticity finite element modeling of explicit grain structures. *Computational Mechanics*, 67, 33-55.
- Gardner, M. W., & Dorling, S. R. (1998). Artificial neural networks (the multilayer perceptron)—a review of applications in the atmospheric sciences. *Atmospheric environment*, 32(14-15), 2627-2636.
- Ghiasi, R., Ghasemi, M. R., & Noori, M. (2018). Comparative studies of metamodelling and AI-Based techniques in damage detection of structures. *Advances in Engineering Software*, 125, 101-112.

- Güneş, F., Demirel, S., & Mahouti, P. (2016). A simple and efficient honey bee mating optimization approach to performance characterization of a microwave transistor for the maximum power delivery and required noise. *International Journal of Numerical Modelling: Electronic Networks, Devices and Fields*, 29(1), 4-20.
- Koziel, S., Belen, M. A., Çalışkan, A., & Mahouti, P. (2023). Rapid Design of 3D Reflectarray Antennas by Inverse Surrogate Modeling and Regularization. *IEEE Access*, 11, 24175-24184.
- Kraus, M. A., Bischof, R., Kaufmann, W., & Thoma, K. (2022). Artificial intelligence-finite element method-hybrids for efficient nonlinear analysis of concrete structures. *Acta Polytechnica CTU Proceedings*, 36, 99-108.
- Kudela, J., & Matousek, R. (2022). Recent advances and applications of surrogate models for finite element method computations: A review. *Soft Computing*, 26(24), 13709-13733.
- Kukulski, J., Jacyna, M., & Gołębiowski, P. (2019). Finite element method in assessing strength properties of a railway surface and its elements. *Symmetry*, 11(8), 1014.
- Li, Yang, Mi Zhao, Cheng-shun Xu, Xiu-li Du, and Zheng Li. "Earthquake input for finite element analysis of soil-structure interaction on rigid bedrock." *Tunnelling and Underground Space Technology* 79 (2018): 250-262.
- Liu, Kai, and Lin Jing. "A finite element analysis-based study on the dynamic wheel-rail contact behaviour caused by wheel polygonization." *Proceedings of the Institution of Mechanical Engineers, Part F: Journal of Rail and Rapid Transit* 234, no. 10 (2020): 1285-1298.
- Liu, Yongming, Liming Liu, and Sankaran Mahadevan. "Analysis of subsurface crack propagation under rolling contact loading in railroad wheels using FEM." *Engineering fracture mechanics* 74, no. 17 (2007): 2659-2674.
- Loh, W. L. (1996). On Latin hypercube sampling. *The annals of statistics*, 24(5), 2058-2080.
- Long, Y. Q., Cen, S., & Long, Z. F. (2009). *Advanced finite element method in structural engineering* (pp. 495-586). Beijing: Tsinghua University Press.
- Mendes-Moreira, J., Soares, C., Jorge, A. M., & Sousa, J. F. D. (2012). Ensemble approaches for regression: A survey. *Acm computing surveys (csur)*, 45(1), 1-40.
- Naboulsi, S., & Mall, S. (2003). Fretting fatigue crack initiation behavior using process volume approach and finite element analysis. *Tribology international*, 36(2), 121-131.
- Okereke, M., Keates, S., Okereke, M., & Keates, S. (2018). Finite element mesh generation. *Finite Element Applications: A Practical Guide to the FEM Process*, 165-186.
- Patel, Sunil, Veerendra Kumar, and Raji Nareliya. "Fatigue analysis of rail joint using finite element method." *International Journal of Research in Engineering and Technology* 2, no. 1 (2013): 80-84.
- Plevris, V., & Tsiatas, G. C. (2018). Computational structural engineering: Past achievements and future challenges. *Frontiers in Built Environment*, 4, 21.
- Saneie, Hamid, Ramin Alipour-Sarabi, Zahra Nasiri-Gheidari, and Farid Tootoonchian. "Challenges of finite element analysis of resolvers." *IEEE Transactions on Energy Conversion* 34, no. 2 (2018): 973-983.
- Schulz, E., Speekenbrink, M., & Krause, A. (2018). A tutorial on Gaussian process regression: Modelling, exploring, and exploiting functions. *Journal of Mathematical Psychology*, 85, 1-16.
- Sun, G., & Wang, S. (2019). A review of the artificial neural network surrogate modeling in aerodynamic design. *Proceedings of the Institution of Mechanical Engineers, Part G: Journal of Aerospace Engineering*, 233(16), 5863-5872.
- Swiler, L. P., Gulian, M., Frankel, A. L., Safta, C., & Jakeman, J. D. (2020). A survey of constrained Gaussian process regression: Approaches and implementation challenges. *Journal of Machine Learning for Modeling and Computing*, 1(2).
- Szabó, B., & Babuška, I. (2021). *Finite Element Analysis: Method, Verification and Validation*.
- Wang, J., Jiang, H., Chen, G., Wang, H., Lu, L., Liu, J., & Xing, L. (2023). Integration of multi-physics and machine learning-based surrogate modelling approaches for multi-objective optimization of deformed GDL of PEM fuel cells. *Energy and AI*, 14, 100261.
- Wu, S. W., Wan, D. T., Jiang, C., Liu, X., Liu, K., & Liu, G. R. (2023). A finite strain model for multi-material, multi-component biomechanical analysis with total Lagrangian smoothed finite element method. *International Journal of Mechanical Sciences*, 243, 108017.
- Yang, X. S., Koziel, S., & Leifsson, L. (2014). Computational optimization, modelling and simulation: Past, present and future. *Procedia Computer Science*, 29, 754-758.
- Yao, J., Ye, Z., & Wang, Y. (2014). An efficient SRAM yield analysis and optimization method with adaptive online surrogate modeling. *IEEE Transactions on Very Large Scale Integration (VLSI) Systems*, 23(7), 1245-1253.
- Zahavi, E. (2019). *Fatigue design: life expectancy of machine parts*. CRC press.
- Zhang, Guanzhen, and Ruiming Ren. "Study on typical failure forms and causes of high-speed railway wheels." *Engineering Failure Analysis* 105 (2019): 1287-1295.
- Zhou, M., Mei, G., & Xu, N. (2023). Enhancing Computational Accuracy in Surrogate Modeling for Elastic-Plastic Problems by Coupling S-FEM and Physics-Informed Deep Learning. *Mathematics*, 11(9), 2016.
- Zhu, Yi, Wenjian Wang, Roger Lewis, Wenyi Yan, Stephen R. Lewis, and Haohao Ding. "A review on wear between railway wheels and rails under environmental conditions." *Journal of Tribology* 141, no. 12 (2019): 120801.