

**OPTİMİZASYON TEKNİKLERİ VE SİNİRSEL AĞLAR
KULLANILARAK ARAÇ ALAŞIM JANTLARININ
TASARIMI VE TASARIM DOĞRULAMASI**

Anıl TOPALOĞLU



T.C.
BURSA ULUDAĞ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**OPTİMİZASYON TEKNİKLERİ VE SİNİRSEL AĞLAR KULLANILARAK
ARAÇ ALAŞIM JANTLARININ TASARIMI VE TASARIM DOĞRULAMASI**

Anıl TOPALOĞLU
0000-0002-0462-1360

Prof. Dr. Ferruh ÖZTÜRK
(Danışman)

DOKTORA TEZİ
OTOMOTİV MÜHENDİSLİĞİ ANABİLİM DALI

BURSA – 2022
Her Hakkı Saklıdır

TEZ ONAYI

Anıl TOPALOĞLU tarafından hazırlanan “Optimizasyon teknikleri ve sinirsel ağlar kullanılarak araç alaşım jantlarının tasarımı ve tasarım doğrulaması” adlı tez çalışması aşağıdaki jüri tarafından oy birliği ile Bursa Uludağ Üniversitesi Fen Bilimleri Enstitüsü Otomotiv Mühendisliği Anabilim Dalı’nda **DOKTORA TEZİ** olarak kabul edilmiştir.

Danışman: Prof Dr. Ferruh ÖZTÜRK

Başkan	:	Prof. Dr. Ferruh ÖZTÜRK 0000-0001-5767-8312 Bursa Uludağ Üniversitesi Mühendislik Fakültesi, Otomotiv Mühendisliği Anabilim Dalı	İmza
Üye	:	Prof. Dr. Necmettin KAYA 0000-0002-8297-0777 Bursa Uludağ Üniversitesi Mühendislik Fakültesi, Makine Mühendisliği Anabilim Dalı	İmza
Üye	:	Prof. Dr. Rukiye ERTAN 0000-0002-9631-4607 Bursa Uludağ Üniversitesi Mühendislik Fakültesi, Otomotiv Mühendisliği Anabilim Dalı	İmza
Üye	:	Dr. Öğr. Üyesi İsmail ÖZTÜRK 0000-0003-2641-5880 Pamukkale Üniversitesi, Teknoloji Fakültesi, Otomotiv Mühendisliği Anabilim Dalı	İmza
Üye	:	Dr. Öğr. Üyesi Halil BAYRAM 0000-0002-4664-3883 Amasya Üniversitesi, Mühendislik Fakültesi, Makine Mühendisliği Anabilim Dalı	İmza

Yukarıdaki sonucu onaylarım

Prof. Dr. Hüseyin Aksel EREN
Enstitü Müdürü

.././....

B.U.Ü. Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

20/07/2022

Anıl TOPALOĞLU

TEZ YAYINLANMA FİKRİ MÜLKİYET HAKLARI BEYANI

Enstitü tarafından onaylanan lisansüstü tezin/raporun tamamını veya herhangi bir kısmını, basılı (kâğıt) ve elektronik formatta arşivleme ve aşağıda verilen koşullarla kullanıma açma izni Bursa Uludağ Üniversitesi'ne aittir. Bu izinle Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet hakları ile tezin tamamının ya da bir bölümünün gelecekteki çalışmalarda (makale, kitap, lisans ve patent vb.) kullanım hakları tarafımıza ait olacaktır. Tezde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanılması zorunlu metinlerin yazılı izin alınarak kullandığımı ve istenildiğinde suretlerini Üniversiteye teslim etmeyi taahhüt ederiz.

Yükseköğretim Kurulu tarafından yayınlanan “**Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge**” kapsamında, yönerge tarafından belirtilen kısıtlamalar olmadığı takdirde tezin YÖK Ulusal Tez Merkezi / B.U.Ü. Kütüphanesi Açık Erişim Sistemi ve üye olunan diğer veri tabanlarının (Proquest veri tabanı gibi) erişimine açılması uygundur.

Danışman Adı-Soyadı
Tarih

Öğrencinin Adı-Soyadı
Tarih

İmza

Bu bölüme kişinin kendi el yazısı ile okudum
anladım yazmalı ve imzalanmalıdır.

İmza

Bu bölüme kişinin kendi el yazısı ile okudum
anladım yazmalı ve imzalanmalıdır.

ÖZET

Doktora Tezi

OPTİMİZASYON TEKNİKLERİ VE SİNİRSEL AĞLAR KULLANILARAK ARAÇ ALAŞIM JANTLARININ TASARIMI VE TASARIM DOĞRULAMASI

Anıl TOPALOĞLU

Bursa Uludağ Üniversitesi
Fen Bilimleri Enstitüsü
Otomotiv Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Ferruh ÖZTÜRK

Her alanda karşımıza çıkan optimizasyon problemlerinin çözümü için geliştirilmiş çok çeşitli optimizasyon metotları mevcuttur. Özellikle otomotiv sektöründe zorlu hedefler ve her gün artan rekabet dolayısıyla ürün geliştirme ve tasarım süreçlerindeki optimizasyon yöntemlerinin kullanımı günden güne daha çok önem kazanmaktadır. Araç tasarım süreçlerinin giderek kısaltılması ve daha az kaynakla tasarım parametrelerinin global optimum sonuçlarına daha yakın değerlere ulaşılması amacıyla birçok optimizasyon metodu geliştirilmekte ve uygulanmaktadır.

Alüminyum alaşımlı jantların doğal frekans değerleri ve ağırlık değerleri doğrudan aracın sürüş konforunu etkileyen parametrelerdir. Jant tasarım sürecinde jantın 1. mod doğal frekans değerinin diğer araç parçalarının frekans değerleriyle çakışmasının engellenmesi aracın gürültü performansını doğrudan etkilerken, jant ağırlığının azaltılması ise aracın yakıt tüketimi, emisyon ve yol tutuşu gibi parametrelerini etkilemektedir. Bu kapsamda önerilen çalışma ile yeni bir yaklaşım ile yapay sinir ağı (ANN) temelli parametre tahmin metodu ve parametrik tasarım optimizasyon yöntemi jant tasarım sürecini iyileştirmek amacıyla uygulanmıştır. Deney tasarımı modeli ve sonlu elemanlar analizi aracılığıyla başlangıç veri seti elde edilmiştir. Elde edilen başlangıç veri seti çoklu lineer regresyon (MLR) ve ANN modellerinin eğitilmesinde kullanılmış ve eğitilen her iki model de çok amaçlı genetik algoritma (MOGA) optimizasyonu sürecinde vekil model olarak kullanılarak uygulanmıştır. ANN ve MLR tabanlı tahmin metodlarıyla gerçekleştirilen optimizasyonun 1. mod frekans ve ağırlık parametreleri optimizasyon sonuçları ortaya koyulmuştur.

Önerilen yeni yöntemin literatürde en iyi bilinen jant tasarım optimizasyonu metodlarıyla karşılaştırıldığında hedeflenen değerler açısından daha başarılı sonuçlar elde edildiği ve global optimum sonuçlara daha yakın değerler ortaya koyduğu görülmüştür.

Anahtar Kelimeler: Optimizasyon, alaşımlı jant, yapay sinir ağı, genetik algoritma, sonlu elemanlar analizi, jant ağırlık azaltma

2022, xiv + 100 sayfa.

ABSTRACT

PhD Thesis

DESIGN AND DESIGN VALIDATION OF VEHICLE ALLOY WHEELS USING OPTIMISATION TECHNIQUES AND NEURAL NETWORKS

Anıl TOPALOĞLU

Bursa Uludağ University
Graduate School of Natural and Applied Sciences
Department of Automotive Engineering

Supervisor: Prof. Dr. Ferruh ÖZTÜRK

There are various optimization methods developed for the solution of optimization problems in various disciplines. Especially in the automotive sector, the use of optimization methods in product development and design processes is having more importance day by day due to challenging targets and increasing competition. Many optimization methods are being developed and applied in order to shorten the vehicle design processes and to reach values closer to the global optimum design results with less resources.

Natural frequency and weight values of aluminium alloy wheels are the parameters that directly affect the driving comfort of the vehicle. In the rim design process, preventing overlap of the rim's 1st mode natural frequency value with the frequency values of other vehicle parts directly affects the noise performance of the vehicle. Besides, reducing the rim weight improves the vehicle's parameters such as fuel consumption, emissions and road holding. In this context, with the proposed study, a new approach and artificial neural network (ANN) based parameter estimation method and parametric design optimization method were applied to improve the rim design process. The initial data set was obtained through finite element analysis with the experimental design model. The initial data set obtained was used in the training of multiple linear regression (MLR) and ANN models, and both trained models were applied as a surrogate model in the multi-objective genetic algorithm (MOGA) optimization process. Optimization results of 1st mode frequency and weight parameters of the optimization performed with ANN and MLR based estimation methods are revealed.

When the proposed new method is compared with the well-known wheel design optimization methods in the literature, it is seen that more successful results are obtained in terms of target values and values closer to the global optimum results.

Key words: Optimization, alloy wheel, neural network, genetic algorithm, finite element analysis, wheel weight reduction

2022, xiv + 100 pages.

TEŐEKKÜR

Tez alıőmam sırasında deęerli bilgileri ve tecrübeleri ile bana her aıdan yol gsteren tez danıőmanım ve kıymetli hocam Prof. Dr. Ferruh ZTÜRK'e teőekkürlerimi sunarım.

Tüm hayatım boyunca hep yanımda olan ve her türlü desteklerini benden esirgemeyen anne ve babama ayrıca desteęini hep hissettięim kardeőime teőekkürlerimi sunarım.

Tez alıőmam nedeniyle kendisine zaman ayıramadıęım eőime gösterdięi anlayıő, sabır ve her türlü destekleri için teőekkür ederim.

Anıl TOPALOęLU
20/07/2022

İÇİNDEKİLER

	Sayfa
ÖZET.....	vi
ABSTRACT.....	vii
TEŞEKKÜR.....	viii
SİMGELER ve KISALTMALAR DİZİNİ	x
ŞEKİLLER DİZİNİ.....	xii
ÇİZELGELER DİZİNİ	xiv
1. GİRİŞ.....	1
2. KAYNAK ARAŞTIRMASI	6
2.1 Alüminyum Alaşımli Jantların Tasarım ve Performans Parametreleri	6
2.2 Alüminyum Alaşımli Jantların Tasarım Parametrelerini Tahmin Etme ve Optimizasyon Teknikleri.....	10
2.3 Yapısal Tasarım Çalışmalarında ve Jantlarda Kullanılan Yapay Sinir Ağı Metodu Tabanlı Algoritmalar	17
2.4 Yapay Sinir Ağı Tabanlı Çok Amaçlı Genetik Algoritmanın Seçimi	19
3. MATERYAL ve YÖNTEM.....	20
3.1 Müşteri Odaklı Otomotiv Ürün Geliştirme Süreci.....	20
3.2 Alüminyum Alaşımli Jant Tasarım ve Analiz Süreci	23
3.2.1 Jantın modal analizi ve deneysel doğrulaması	26
3.2.2 Jantın dinamik viraj yorulma analiz ve testi	31
3.3 Parametre Tahmin Sürecinde Kullanılan Metotlar	37
3.3.1 Deney tasarım metodu (DOE).....	40
3.3.2 Çoklu lineer regresyon (MLR).....	45
3.3.3 Yapay sinir ağı (ANN).....	50
3.3.4 Yapay sinir ağı Levenberg-Marquardt metodu (YSA-LM).....	52
3.3.5 Yapay sinir ağı Fletcher-Reeves metodu (ANN-FR).....	56
4. BULGULAR	63
4.1 Yapay Sinir Ağı Parametre Tahmin Metodunun Performans Testleri.....	63
4.1.1 Parametre tahmin metotlarının performans sonuçları	63
4.2 Tasarım Uzayı Dışındaki Tasarım Değişken Değerleri için Performans Sonuçları ..	67
4.3 Önerilen Yapay Sinir Ağı Yöntemi ile Jant Modeli Optimizasyonu	73
4.3.1 Çok amaçlı genetik optimizasyon algoritması	73
4.3.1 Bayes optimizasyonu	85
5. TARTIŞMA ve SONUÇ.....	91
5.1 Önerilen Yapay Sinir Ağı Tabanlı Çok Amaçlı Genetik Algoritma Optimizasyon etodunun Güçlü Yönleri ve Katkıları	91
5.1 Gelecek Çalışmalar	93
KAYNAKLAR	94
ÖZGEÇMİŞ	100

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler	Açıklama
b_0	Kesme noktası
b_k	Regresyon vektör katsayısı
d	Jantın ofset değeri
e_i	Rastlantısal olarak ölçümlenen hata değeri
F_L	Statik yanal teker yükü
F_R	Statik radyal teker yükü
g	Gradyan
$g(x)$	Gradyan vektörü
H	Hessian matrisi
I	Birim matrisi
J	Ağırlık ve sapma değerlerine göre hata vektörünün birinci türevini içeren bir Jacobian matrisi
K	Kütle matrisi
M	Kütle matrisi
M_o	Janta etkiyen eğilme momenti değeri
n	Tüm başlangıç veri seti içerisindeki satır sayısı
p_{i+1}	Formülün vektör yönü
R_w	Lastiğin dinamik radyus değeri
S	Hizmet faktörü
$\ddot{x}(t)$	İvme vektörü
$x(t)$	Yer değiştirme vektörü
$x_{i,k}$	Bağımsız değişken
X_k	Ağırlık ve bias sapma faktörü
y_i	Bağımlı değişken
y_{pi}	Başlangıç veri seti içerisinde her bir satırda tahmin edilen sonuç değeri
y_{si}	Başlangıç veri setinde aynı satırlardaki FEA sonucunda elde edilen değeri
μ	Lastik ile yol yüzeyin arasında oluşan sürünme katsayısı değeri

Kısaltmalar	Açıklama
AI	Artificial Intelligence
ANN	Artificial Neural Network
ANN-FR	artificial Neural Network Fletcher-Reeves
ANN-LM	Artificial Neural Network Levenberg-Marquardt
BO	Bayes Optimizasyonu
BP	Back-Propagation
CAD	Computer-Aided Design
DOE	Design of Experiment
ETRTO	European Tyre and Rim Technical Organisation
FEA	Finite Element Analysis
FEM	Finite Element Model
FR	Fletcher-Reeves

FRF	Frekans Cevap Fonksiyonu
GA	Genetik Algoritma
GO	Genetik Optimizasyon
GP	Gaussian Process
HSS	Hammersley Sampling
LHS	Latin Hypercube Sampling
LM	Levenberg-Marquardt
MLP	Multi-layer Perseptron
MLR	Multiple Linear Regression
MOGA	Multi Objective Genetic Algorithm
NVH	Noise, Vibration and Harshness
RMSE	Root Mean Square Error
SEM	Sonlu Elemanlar Modeli
SNN	Sequential Neural Network
TD-1	Tasarım Değişkeni 1
TD-2	Tasarım Değişkeni 2
TD-3	Tasarım Değişkeni 3
TD-4	Tasarım Değişkeni 4
TD-5	Tasarım Değişkeni 5
TD-6	Tasarım Değişkeni 6

ŞEKİLLER DİZİNİ

Sayfa

Şekil 2.1.	Jant NVH performansı ve 1. mod frekans değerinin araç seviyesinde performans etkisi (Masri vd. 2013)	9
Şekil 2.2.	Jant topoloji optimizasyon örneği öncesi ve sonrası (Prasad vd. 2013)	11
Şekil 2.3.	Topoloji optimizasyon tasarım boşluğu modeli (Das vd. 2013)	11
Şekil 2.4.	Parametrik jant optimizasyon modeli (Özaydın vd. 2018)	12
Şekil 2.5.	Ağırlık azaltımı için oluşturulmuş cep tasarımı (Hsu vd. 2001)	14
Şekil 3.1.	Otomotiv tasarım akışı (Pischinger and Seiffert 2016)	20
Şekil 3.2.	Hedef belirleme V-modeli (Yadav ve Goel 2008)	21
Şekil 3.3.	Hedef belirleme aşamasında bilgi akış şeması (Yadav ve Goel 2008)	22
Şekil 3.4.	Jant kesiti ve tasarım parametreleri detayı	25
Şekil 3.5.	Modal analiz FEM geometrisi sabitlenmiş bijon bölgeleri	27
Şekil 3.6.	Sonlu elemanlar modal analiz 1. mod arkadan görünüm	28
Şekil 3.7.	Sonlu elemanlar modal analiz 1. mod yandan görünüm	29
Şekil 3.8.	Modal analiz a.) 2. mod b.) 3. mod arkadan görünüm	29
Şekil 3.9.	Modal analiz a.) 2. mod b.) 3. mod yandan görünüm	30
Şekil 3.10.	Deneysel modal test	31
Şekil 3.11.	Dinamik viraj yorulma sonlu elemanlar modeli	33
Şekil 3.12.	Dinamik viraj yorulma analiz sonuçları önden görünüm	33
Şekil 3.13.	Dinamik viraj yorulma analiz sonuçları arkadan görünüm	33
Şekil 3.14.	Dinamik viraj yorulma analiz sonuçları maksimum yer değiştirme önden görünüm	34
Şekil 3.15.	Dinamik viraj yorulma analiz sonuçları maksimum yer değiştirme arkadan görünüm	35
Şekil 3.16.	Dinamik viraj yorulma test bankosu kesiti (SAE 2009)	36
Şekil 3.17.	Jant viraj yorulma test bankosu	37
Şekil 3.18.	Jant tasarım değişkenleri	39
Şekil 3.19.	Jant modeli üzerinde biçim değiştirme parametreleri	41
Şekil 3.20.	Örnek latin hiperküp örnekleme matrisi	43
Şekil 3.21.	MLP ve FEA değerlerinin yanıt parametreleri için karşılaştırılması	50
Şekil 3.22.	ANN model yapısı	56
Şekil 3.23.	ANN modelleri için RMSE değerleri karşılaştırması a) ANN-LM b) ANN-FR	61
Şekil 3.24.	ANN modelinde kullanılan metodoloji akış şeması	62
Şekil 4.1.	MLR ve ANN modellerin RMSE değerlerinin karşılaştırılması	67
Şekil 4.2.	Model-2 3 boyutlu görseli	71
Şekil 4.3.	ANN-IV tahmin modelinin FEA sonuçlarıyla karşılaştırması (a) 1. mod frekans (b) Ağırlık (c) Maks. yer değiştirme	73
Şekil 4.4.	MLR+MOGA modeli optimizasyon sonucunda elde edilen optimum noktalar	79
Şekil 4.5.	MLR+MOGA modeli optimizasyon sonucunda elde edilen optimum noktaların tasarım değişken değeri	80

Şekil 4.6.	ANN-IV+MOGA modeli optimizasyon sonucunda elde edilen optimum noktalar	81
Şekil 4.7.	ANN-IV+MOGA modeli optimizasyon sonucunda elde edilen optimum noktaların tasarım değişken değeri	82
Şekil 4.8.	MOGA sonucunda elde edilen Pareto diyagram	83
Şekil 4.9.	Tasarım değişkenleri ve yanıt değerleri için hassasiyet analizi a) 1. mod frekans b) Ağırlık c) Maks. yer değiştirme	85
Şekil 4.10.	Bayes optimizasyon metodu akış şeması (Motoyama vd. 2022)	87
Şekil 4.11.	Bayes optimizasyon algoritması	88
Şekil 4.12.	BO iterasyon ve 1. mod frekans optimizasyonu	89
Şekil 4.13.	BO iterasyon ve ağırlık optimizasyonu	90

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 2.1. Jant tasarımında karşılaşılan parametre tahmin ve optimizasyon metotları	15
Çizelge 3.1. E.T.R.T.O. standardı kapsamında jant spesifikasyonları (ETRTO 2021)	24
Çizelge 3.2. Jant AlSi7Mg malzeme özellikleri (Lipiński 2020)	26
Çizelge 3.3. Jant AlSi7Mg malzeme mekanik özellikleri (Sushant vd. 2015) .	27
Çizelge 3.4. Jantın modal analiz frekans değerleri	28
Çizelge 3.5. Jant modları FEM ve deneysel sonuçların karşılaştırılması	31
Çizelge 3.6. Tasarım değişkenlerinin alt/üst limitleri	40
Çizelge 3.7. Latin Hiperküp örnekleme metoduyla elde edilen 100 satırlık veri seti	44
Çizelge 3.8. Hammersley sıralı örnekleme metoduyla elde edilen 32 satırlık veri seti	45
Çizelge 3.9. Çoklu lineer regresyon test veri seti analiz ve tahmin sonuçları karşılaştırma	49
Çizelge 3.10. ANN-LM metodu gizli katman nöron sayısına göre RMSE değerleri	55
Çizelge 3.11. ANN-FR metodu gizli katman nöron sayısına göre RMSE değerleri	59
Çizelge 3.12. ANN model yapıları	63
Çizelge 4.1. MLR ve ANN modellerinin RMSE değerleri karşılaştırması	65
Çizelge 4.2. Belirlenen tasarım uzayı dışında örnek modellerin tasarım değişkeni değerleri	69
Çizelge 4.3. Örnek modellerin sonuç değerleri	69
Çizelge 4.4. FEA, MLR ve ANN-IV modellerinin tasarım uzayı dışında tahmin hata seviyeleri	70
Çizelge 4.5. Çok amaçlı optimizasyon modeli ana parametreleri	76
Çizelge 4.6. MLR ve ANN-IV tahmin modelleri ile MOGA optimizasyon sonuçları	76
Çizelge 4.7. MLR parametre tahmin ve MOGA optimizasyon metodu sonucu optimum değerler	77
Çizelge 4.8. ANN-IV parametre tahmin ve MOGA optimizasyon metodu sonucu optimum değerler	78
Çizelge 4.9. Farklı optimizasyon metotlarının sonuçlarının ve başlangıç modelinin karşılaştırmalı olarak analizi	91
Çizelge 4.10. Optimum değerleri veren tasarım değişken değerleri	91

1. GİRİŞ

Otomotiv sektöründe birçok alanda gelişmeler yaşanmakta ve teknolojinin en son imkanları kullanarak otomotiv şirketleri birbirleri arasında rekabet etmek için çaba sarf etmektedirler. Firmalar hem müşterilerin isteklerine uygun ürünler ortaya koymaya çalışmakta, hem de diğer markaların ürünlerine göre fark yaratmak için çaba göstermektedir. Firmaların tüm bu çabalarıyla aracın performans anlamında diğer firmaların ürünlerinden daha iyi özelliklere sahip olunması amaçlanmaktadır. Dolayısıyla araç üretici firmalar araç tasarım süreçlerine öncelikle müşteri isteklerini belirleyerek başlar.

Firmalar müşteri isteklerine uygun olarak araç özelliklerini genel anlamda ve araç özelinde belirleyerek bu hedeflere ulaşabilmek için araçtan komponente bir tasarım yaklaşımı sergilemektedirler. Bu yaklaşım dahilinde müşteri isteklerini karşılayacak özelliklere sahip araç için sistem ve komponent bazlı hedefler oluştururlar. Sistem ve komponent bazlı belirlenen bu hedefler kapsamında komponent ve sistem tasarımları bu hedefleri karşılayacak şekilde tasarlanarak simülasyonları gerçekleştirilmeli, test edilmeli ve istenen performansı sağladığından emin olunmalıdır.

Günümüzde otomotiv sektöründe artan rekabet ile birlikte jantlarda araç üzerinde en iyi performansa ulaşabilmek ve aracın yakıt tüketimi, gürültü, titreşim performansını maksimize edebilmek adına konfor ve ağırlık azaltımı üzerine çalışmalar oldukça önem kazanmıştır. Jantlar araç üzerindeki konumları gereği aracın yaysız kütlesi sınıfında yer almaktadır. Teker üzerinde oluşturduğu atalet kuvveti sebebiyle yaysız kütle aracın performans, direksiyon kabiliyeti ve yakıt verimliliği üzerinde, yaylı kütlelerin (gövde vb. komponentler) etkilerine kıyasla daha yüksek bir etkiye sahiptir.

Jant tasarım aşamasında da araç seviyesinde ve süspansiyon sistemi seviyesinde belirlenen araç hedefleri doğrultusunda stil, ağırlık, dayanım, konfor, ses ve gürültü (NVH) gibi parametreler irdelenerek performans hedefleri belirlenir. Belirlenen bu hedeflere uygun jant tasarımı gerçekleştirebilmek adına entegre ürün geliştirme sürecinin

bir parçası olan ürün özelliklerinin erken tahmini yaklaşımı metodu kullanılır. Jantın stil geometrisine uygun olarak jant üzerinde optimizasyon çalışmaları gerçekleştirilir. Optimizasyon çalışmaları gerçekleştirilirken ağırlık, dayanım ve konfor anlamında uygun hedefleri sağlayabilmek amacıyla jantların performans parametreleri de göz önünde bulundurulmaktadır. Bu parametreler göz önünde bulundurularak jant tasarımı ve simülasyonları gerçekleştirilir. Son aşamada ise tüm sanal doğrulama süreçlerinden geçen jant tasarımı üretimi yapılarak, üretimden çıkan ilk jantlar tekil parça bazlı doğrulamalara tabi tutulur ve araç üzerinde testlerde doğrulanarak seri üretim aşamasına geçiş sağlanır.

Araç üzerindeki birçok komponentte olduğu gibi alüminyum jantın üretim ve doğrulama aşamaları oldukça yüksek maliyetler ve uzun zamanlar gerektirmektedir. Araç üretici firmalar ürün özelliklerini erken tahmin edebilmek ve bu sayede ürün geliştirme süreçlerini kısaltmak için simülasyon bazlı çalışmalar gerçekleştirir. Bu nedenle optimum tasarım parametrelerinin belirlenmesi ve jantın üretim öncesi doğrulanması hem mühendislik eforu hem de geliştirme zaman ve maliyetleri açısından günden güne önem kazanmaktadır.

Otomotiv sektöründe ürün geliştirme süreçlerinde, kullanımı gün geçtikçe artan simülasyon ve optimizasyon metotlarının geliştirilmesi ve yeni metotların tasarım süreçlerinde uygulanması araştırmacılar için en önemli motivasyon kaynaklarından. Geliştirilen yeni yöntemler sayesinde tasarım ve ürün geliştirme süreçlerini kısaltmak, optimizasyon probleminin çözüm süresini azaltmak ve daha az mühendislik kaynağı kullanarak optimizasyon işlemini gerçekleştirebilmek amaçlanmaktadır.

Bu çalışmada öncelikle jant tasarım süreçlerinde jantın doğal frekans değeri, ağırlık ve yorulma performans parametrelerinin neden önemli olduğu ve bu parametrelerin araç üzerinde ne gibi etkilerinin olduğu konuları ortaya konulmuştur. Örnek bir jant modelinin Hyperworks paket programı üzerinde sonlu elemanlar modeli (FEM) oluşturulmuştur. Oluşturulan sonlu elemanlar modeli üzerinden modal analiz (Modal analysis), darbe testi (Impact analysis) ve yorulma analizi (Cornering fatigue analysis) gerçekleştirilerek jantın performans parametreleriyle ilgili sonlu elemanlar analizleri (FEA) yapılmıştır. Ayrıca

örnek jantın üretilen bir prototipi üzerinden modal testi (free to free) gerçekleştirilerek FEA sonuçları ile jantın deneysel test performansının korelasyonu sağlanmıştır.

Jant modelinde performans parametrelerinin iyileştirilmesi için tasarım geometrisi belirlenmesi gerekmektedir. Günümüzde jantların göbek, stil bölgesi denilen kısımların tasarım kısıtları stil departmanları tarafından belirlenmektedir. Doğrudan aracın dış görünümü üzerinde etkisi olduğundan bu alanlarda majör değişiklikler arzu edilmemektedir. Bu nedenle çalışma kapsamında jantın lastik ile temasta olan ve dış kısmını oluşturan “rim” olarak adlandırılan çember bölgesinde tasarım parametreleri belirlenmiştir. Jantın çevre kısmında altı farklı tasarım değişkeni belirlenerek bu değişkenlerin optimizasyonun gerçekleştirilmesi amaçlanmıştır.

Korelasyonu sağlanan ve oluşturulan sonlu elemanlar modelleri ile birlikte Hyperstudy paket programı üzerinde jantın belirlenen altı farklı tasarım değişkeni için jant tasarım standartları ve regülasyonları dikkate alınarak sınır şartları belirlenmiş ve şekil dönüştürme (Morph) modeli oluşturulmuştur. Oluşturulan şekil değiştirme modeli üzerinden örneklem sayısını arttırabilmek için tasarım değişkenleri ve analiz sonuçlarının bulunduğu örneklem verisi elde edebilecek şekilde deney tasarım modeli (DOE) oluşturulmuştur. Oluşturulan deney tasarım modeli ile Latin Hiperküp (Latin Hypercube Sampling) ve Hammersley örnekleme metotları kullanılarak tasarım değişkenleri alt ve üst limitleri içerisinde farklı tasarım değişkeni değerleri için uygun olarak deney setleri elde edilmiştir.

Deney tasarım metoduyla elde edilen deney setleri, tasarım parametrelerinin tahminlenmesi için uygun yüzey uydurma, regresyon ve önerilen yapay sinir ağları metotlarında eğitim deney setleri olarak kullanılmıştır. Çalışma kapsamında Çoklu Lineer Regresyon (MLR), yapay sinir ağı (ANN) Levenberg-Marquardt (ANN-LM), ANN Fletcher-Reeves (ANN-FR) yüzey uydurma metotları kullanılarak ilgili metotların Hataların Ortalama Karekökü (RMSE) değerleri birbirleriyle kıyaslanarak metotların doğruluğu karşılaştırılmıştır. Ayrıca ANN modelleri içerisinde ağırlık, bias gibi parametreleri Genetik Algoritma (GA) ile optimize edilerek en düşük hata değerine sahip

parametreler, eğitim veri oranları ve sayıları belirlenmiş ve en uygun metot seçilmiştir. Seçilen en uygun ve en az hata değerine sahip model kullanılarak jantın ağırlık değerini minimize edecek, birinci mod frekans değerini maksimize eden ve yorulma sınır değerini sağlayacak kısıt ve amaç fonksiyonlarına sahip Çok Amaçlı Genetik Optimizasyon (MOGA) işlemi gerçekleştirilmiştir. Kullanılan optimizasyon metodu Baskın Olmayan Sıralama Genetik Algoritması (Non-dominated Sorting Genetic Algorithm - NSGA-II)'dir.

Gerçekleştirilen genetik optimizasyon işlemi sayesinde jant üzerinde ilk mod frekans değerinde 16 Hz'lik bir iyileşme sağlanmış ve jant başına 0,53 kg'lık ağırlık azaltımı sağlanmıştır. Birinci mod frekans değerinin iyileşmesi jantın mod frekans değerinin araçtaki diğer motor komponentleriyle frekans pikleri oluşturmasının önüne geçmekte ve bu sayede de araç gürültü hedefinin sağlanmasına katkıda bulunmaktadır. Ayrıca otomotiv sektöründe yakıt tüketimi ve emisyon değerlerinin azaltılması öncelikleri düşünülerek, önerilen metodun kullanımıyla jantta gerçekleştirilen bu ağırlık azaltımının aracın yaysız kütlede 2.12 kg'lık bir iyileşme sağlamıştır. Bu sayede yakıt tüketimi ve emisyon iyileşmelerinin yanında ayrıca sürüş konforunu da iyileştirmektedir.

Bu tez çalışmasında otomotiv ve jant ürün geliştirme aşamasında avantaj ortaya koyacak oldukça güçlü bir optimizasyon metodu geliştirilmiştir. Literatürde jant tasarım süreçleri için topoloji ve parametre tabanlı regresyon metotları kullanılarak gerçekleştirilen alüminyum alaşımlı jant optimizasyon metotları bulunmaktadır. Bu yöntem literatürde mevcut çalışmalardan farklı olarak jant tasarım ve optimizasyon sürecine jant tasarım parametrelerinin derin öğrenme ve ANN metotlarının entegre edilmesi ile jant tasarım sürecinde oldukça verimli sonuçlar ortaya koymaktadır. Ayrıca çalışmada farklı metotlar örnek bir jant modeli üzerinde uygulanarak doğruluk, kolaylık ve optimizasyon performansı gibi birçok açıdan değerlendirilmiştir. Yapılan karşılaştırmalar sonucunda derin öğrenme ve ANN tabanlı metot, mevcut optimizasyon metotlarına kıyasla performans anlamında en iyi olan metot olarak seçilmiştir.

Geliştirilen ve optimizasyon sürecine parametre tahminlenmesinde entegre edilen metot, otomotiv ürün geliştirme süreçlerinde önemli bir yere sahip olan jant tasarım sürecinde kullanılmıştır. Elde edilen sonuçlar hem doğruluk açısından çoklu doğrusal regresyon gibi konvansiyonel metotlar ile kıyaslanmıştır. Geliştirilen derin öğrenme tabanlı metodun diğer metotlara kıyasla daha yüksek doğruluk göstermesi ve optimizasyon sonucunda daha iyi sonuçlar ortaya koyması hem metodun jant tasarım sürecinde başarısını kanıtlamış, hem de jant tasarım sürecinde tecrübeye dayalı hesaplama ve tasarım önerilerini elimine ederek hesaplama sürelerini kısaltmış ve literatüre yeni bir yaklaşım kazandırmıştır.

2. KAYNAK ARAŞTIRMASI

Alüminyum alaşımlı jantların optimizasyonu için derin öğrenme tabanlı bir optimizasyon çalışması gerçekleştirilmesi için yapılan literatür araştırması aşağıda belirtilen üç başlık altında incelenmiştir.

- Alüminyum Alaşımlı Jantların Tasarım ve Performans Parametreleri
- Alüminyum Alaşımlı Jantların Tasarım Parametrelerini Tahmin Etme ve Optimizasyon Teknikleri
- Yapısal Tasarım Çalışmalarında ve Jantlarda Kullanılan Yapay Sinir Ağı Metodu Tabanlı Algoritmalar

2.1 Alüminyum Alaşımlı Jantların Tasarım ve Performans Parametreleri

Otomotiv sektöründe artan rekabet nedeniyle araç ağırlığını hafifletecek malzemelerin kullanımı günden güne önem kazanmaktadır. Ağırlık azaltımı özellikle aracın yakıt tüketimi, emisyon ve sürüş konforu gibi parametrelerini doğrudan etkilemektedir. Bu nedenle günümüzde alüminyum alaşımlı malzemelerin otomotiv sektöründe kullanımı günden güne artmaktadır. Miller vd. (2000), Alüminyum ve magnezyum alaşımlı jantlar hem yolcu hem de ticari araçlarda kullanılmaktadır. Tipik olarak konvansiyonel jantlara kıyasla aynı dayanım ile çok daha hafif olmalarına ek olarak yüksek ısı iletimine ve gelişmiş kozmetik dış görünüşe sahiptirler (Jape vd. 2016).

Jant otomobilin en önemli komponentlerinden biridir. Jantlar rulman, porya, akson gibi parçalarla birlikte aracın tüm yüklerini taşımaktadır. Ayrıca dikey yüklerin yanı sıra aracın sürüşünden, frenleme, virajlama ve hatta yoldan tümsek vb. etkilerden gelen darbeler gibi düzensiz yüklerden de etkilenmektedir. Yüksek hızlarda rotasyondan kaynaklı olarak jantın kalitesi aracın stabilite, yol tutuşu ve diğer benzer karakteristikleri üzerinde yüksek etkilere sahiptir (Prasad vd. 2013), (Hamidian vd. 2017).

Araç tasarım ve imalat tekniklerinde son yıllarda teknolojinin çok farklı alanlarındaki uygulamalar sayesinde araçlarda çevreye uyumluluk ve güvenlik konularında yeni

gelişmeler yaşanmaktadır. Hibrit, elektrikli ve otonom araçlar ile ilgili çalışmalar önümüzdeki yıllarda çok daha fazla önem kazanacaktır. Bu gelişmeler çerçevesinde araç yapısal elemanlarının tasarım değerlendirilmelerinde de yeni yaklaşımlar uygulanması gerekmektedir. Araçlarda çevreye duyarlılık, sürdürülebilirlik, güvenlik ve konfor gibi karakteristikler ile ilgili çeşitli çalışmalar yapılmaktadır.

Alaşımli jantların üretimleri alüminyum, magnezyum alaşımli veya her ikisinin alaşımı şeklinde malzemeler kullanılarak yapılabilir. Bu tip jantlar konvansiyonel çelik jantlara kıyasla düşük ağırlıkları ile ön plana çıkar. Bu sayede jantlar daha hafif tasarlanır ve aracın toplam yaysız kütesini azaltır. Yaysız kütledeki azalmayla birlikte araçların direksiyon ve hızlanma kabiliyetleri artar ve eş zamanlı olarak aracın yakıt tüketim değerleri de düşer. Ayrıca alaşımli malzemenin ısı iletimi iyidir. Bu sayede frenlerin soğumasına da katkıda bulunarak, frenlerde oluşabilecek hataların mevcut model üzerinden toplanan veriler ve tersine mühendislik ile analiz edilmesine ve minimize edilmesine olanak sağlar. Günümüzde alaşımli jantların tasarım sürecinde dayanım, yorulma ve NVH özellikleri göz önünde bulundurularak ağırlık azaltma amaçlı tasarım değişimi önerileri verilerek değerlendirilir (Sathe vd. 2015).

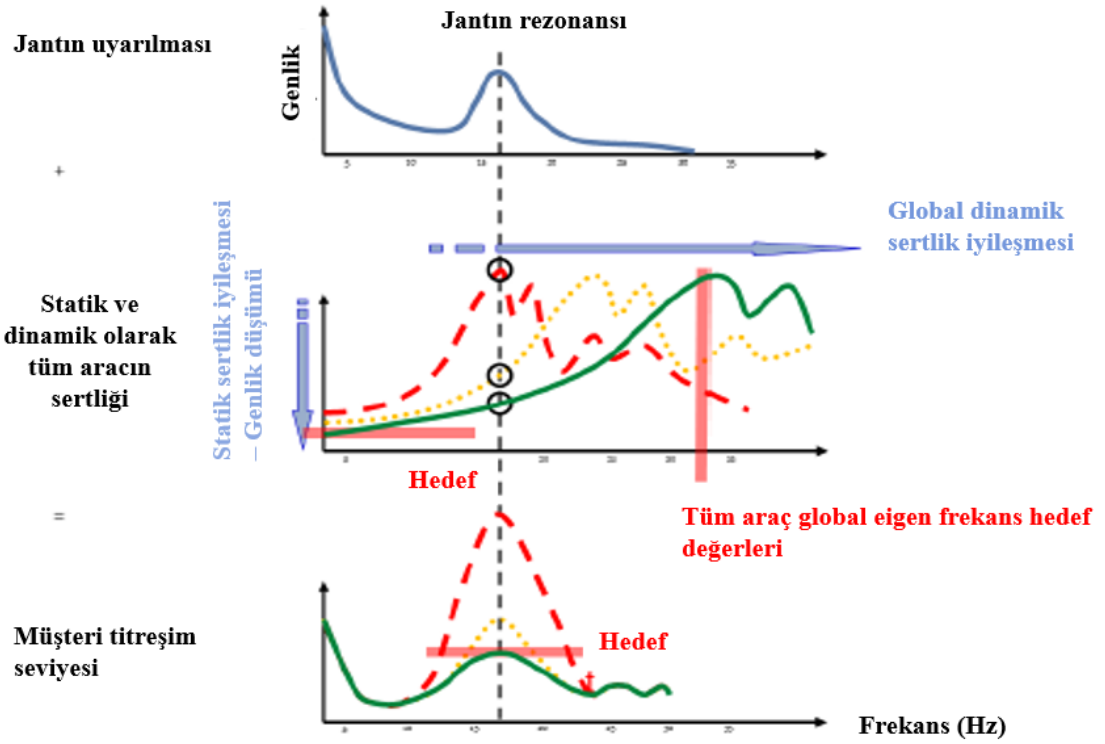
Lastik ve jant, yoldan gelen tüm etkileri yoldan aracın gövdesine taşıdığı için araç tasarım sürecinde oldukça kritik parçalardır. Jantların doğal frekans değerlerinin önceden belirlenmesi ve aracın diğer gövde (BIW) bileşenleriyle rezonans frekanslarının kesişmeyeceği şekilde tasarım gerçekleştirilmesi hem aracın yapısal dinamik performansı açısından önem arz etmekte hem de üretim maliyetlerini azaltmaktadır (Farahani vd. 2017), (Yi vd. 2019). Jant aracın güvenlik ve konfor performansında kritik bir öneme sahiptir. Jant aracın yaysız kütle grubunda yer alan ve dönen bir kütle olduğundan araç üzerinde bir atalet momenti oluşturmakta ve jant ağırlığında gerçekleştirilen iyileşme aracın diğer parçalarına kıyasla yakıt tüketimi ve yol tutuşu anlamında daha büyük etkiye ve öneme sahiptir (Mohammadi vd. 2018).

Bir jant tasarımı ve malzeme özellikleriyle tasarlandığı araç üzerinde gerekli mukavemeti ve aracın ses, titreşim gerekliliklerini sağlayacak özelliklerde seçilmeli ve

tasarlanmalıdır. Jantın bu özellikleri sağlayıp sağlamadığı üretim öncesi sonlu elemanlar modelinde 13° darbe analizi, jant yorulma analizi & modal analiz frekans cevap fonksiyonu (FRF) yapılarak doğrulanır ve bu analizlerin standartlarına uygun minimum ağırlık değerini sağlayan bir tasarım gerçekleştirilir. Üretim sonrasında ise jantın performansını doğrulamak amacıyla malzeme, 13° darbe testi, FRF testi ve yorulma testleri yapılarak jantın son seviye fiziksel doğrulaması yapılır.

Ürün geliştirme sürecinde araç NVH performans hedefleri belirlenirken öncelikle tüm sistem ve parçaların doğal frekans değerleri değerlendirilir. Her bir sistem ve komponent için farklı bir doğal frekans değeri hedefi verilerek ayrıştırılma yapılmaya çalışılır. Nitekim sistemlerin doğal frekans değerlerinin çakışması ve pik oluşturması doğrudan rezonansa sebep olabileceğinden bu ayrışma oldukça önemlidir. Bu nedenle otomotiv ürün geliştirme sürecinde tüm sistemlerin doğal frekans hedefleri belirlenirken, jantlar için de pik oluşturmayacak ve diğer sistemlerden ayrışan hedefler verilir (Kim vd. 2022). Özellikle jantların 1. mod frekans değerleri diğer motor ve transmisyon komponentleri ile frekans olarak çakışma ve pik oluşturma riskine sahiptir. Bu nedenle jantlarda genellikle 1. mod frekans değeri dikkate alınır ve hedef olarak belirlenir.

Masri vd. (2013), jantın doğal frekans modlarının aracın diğer sistemlerinin frekans mod değerleriyle çakışması durumunda oluşan frekans pikleri ve bu frekans piklerinin müşteri titreşim ve araç NVH seviyesi üzerinde olan etkisini değerlendirmek üzere bir çalışma gerçekleştirmişlerdir. Çalışma sonucunda elde ettikleri örnek bir frekans pik eğrisi Şekil 2.1’de verilmiştir. Jantın frekans modlarının daha yüksek değerlere ötelenmesinin aracın sertlik değerini iyileştirdiği ve araç NVH performansına olumlu katkı sağladığı görülmektedir. Bu nedenle araştırmacılar jant tasarım süreçlerinde 1. mod doğal frekans değerini daha yüksek değerlere ötelemek adına çalışmalar ortaya koymuşlardır (Kim vd. 2022).



Şekil 2.1 Jant NVH performansı ve 1. mod frekans değerinin araç seviyesinde performans etkisi (Masri vd. 2013)

Somayaji vd. (2022), farklı alaşımlı jant malzeme tipleri üzerinde modal analiz gerçekleştirmiştir. Bu kapsamda aynı geometrideki jantın farklı malzeme opsiyonları için ilk on doğal frekans değerini bulmuş ve karşılaştırmıştır. Tüm analizler sonucunda ise AL7079 + 8% CF (8% karbon fiber ile güçlendirilmiş) malzemenin modal analizde en iyi performansı sergilediği görülmüştür.

Bae vd. (2015), jantlarda kullanılan malzeme özellikleri de jantın karakteristik özellikleri üzerinde önemli etkilere sahiptir. Kompozit hibrit bir jantın lastik ile temasta olan çevre bölgesi üzerine sönümleyici malzeme entegre etmişlerdir. Geliştirilmiş ve entegre malzeme ile jantın NVH ve rezonans karakteristiklerindeki iyileşme sonlu elemanlar metoduyla analiz edilmiştir. Jantın 1. mod frekans değerinin 37 Hz iyileştiği görülmüştür. Bu iyileşme kabin içerisindeki ses anlamında ölçümlendiğinde ise kabin içerisinde 0,1 – 1,1 dB'lik bir iyileşme sağlandığı görülmüştür. Ayrıca sönümleyici malzeme, jantın sönümleme oranında ise 325% 'lik bir iyileşme göstermiştir.

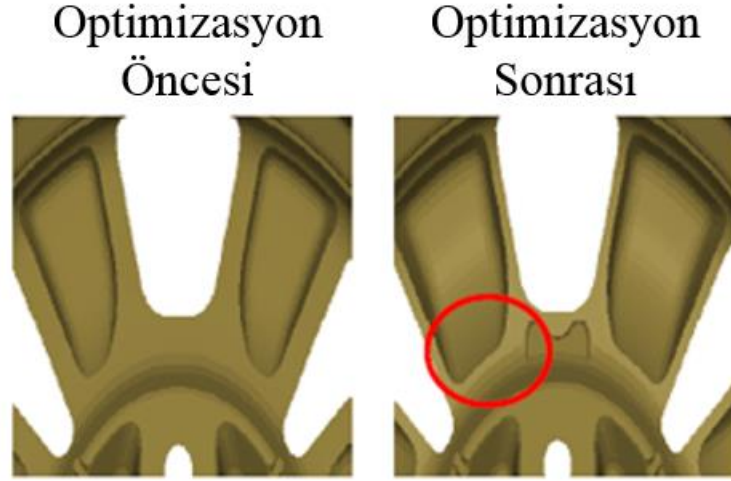
2.2 Alüminyum Alaşımli Jantların Tasarım Parametrelerini Tahmin Etme ve Optimizasyon Teknikleri

Günümüzde jantlarda ağırlık azaltma çalışmaları, ağırlıklı olarak topoloji optimizasyon metodu veya mekanik dayanım kısıtları göz önünde bulundurularak deneysel metotlara dayanan tasarım değişikliği önerileriyle gerçekleştirilmektedir. Son yıllarda ayrıca parametrik şekil optimizasyonu, DOE yöntemleri de kullanılmaya başlanmış ve bazı araştırmacılar tarafından regresyon metotlarıyla güncel optimizasyon yöntemleri kullanılarak jant tasarım süreçlerinin iyileştirilmeye çalışıldığı görülmektedir.

Zhang vd. (2012), alüminyum alaşımli jantın ağırlık hedefini minimize edecek amaç fonksiyonu belirlenmiş, maksimum Von-mises gerilmesi ve radyal yorulma dayanımını kısıt şartları olarak topoloji optimizasyonu gerçekleştirilmiştir. Optimizasyon sonucunda 40%’lik bir ağırlık azaltımı ile 7,76 kg’lık bir jant tasarımıyla hedef gerilme ve dayanım değerlerine ulaşılmıştır.


Prasad vd. (2013), alüminyum alaşımli bir jantta topoloji optimizasyonu gerçekleştirilerek NVH performansı ve mekanik dayanımları kısıt olarak alınmış ve jantta hedeflenen 5%’lik ağırlık azaltımı sağlanmıştır. Ayrıca bu optimizasyon ile jantın modal analizi yapılarak performansı tekrar sınır içerisinde olarak değerlendirilmiştir. Örnek model karşılaştırmalı olarak Şekil 2.2’de verilmiştir.

Zhang vd. (2021), alüminyum alaşımli jant üzerinde entegre çok amaçlı topoloji optimizasyon metodu uygulaması gerçekleştirmiştir. Jantın çevre bölgesinde tasarım alanını belirleyerek, ilgili bölgede topoloji optimizasyonu sonucu NVH gerekliliklerini sağlayan frekans değerlerine sahip ve 13° darbe testine uygun jant tasarımı önerilmiştir.



Şekil 2.2 Jant topoloji optimizasyon örneği öncesi ve sonrası (Prasad vd. 2013)

Das vd. (2013), katı taslak model olarak alınan bir jantın tasarım alanı üzerinde topoloji optimizasyonu çalışması gerçekleştirmiştir. Optimizasyon yapılan jantın üzerinde radyal ve yanal yükleme durumları için sanal analizleri gerçekleştirilerek jantın doğrulaması sağlanmıştır. Ağırlık optimizasyonu yapılmıştır. Topoloji optimizasyonu tasarım uzayı ve şekil tasarım yüzeyleri örnek jant modeli üzerinde Şekil 2.3'te verilmiştir.




Şekil 2.3 Topoloji optimizasyon tasarım boşluğu modeli (Das vd. 2013)

Jiang vd. (2019), magnezyum alaşımlı bir jantın feder arkasındaki bölge üzerinde parametrik çok amaçlı şekil optimizasyonu gerçekleştirilerek jantın ağırlığının ve Von-

misses, gerilmesi deęerinin optimizasyonunu saęlanmıřtır. alıřma sonunda 4% aęırlık ve gerilme deęerinde ayrıca 4,5% iyileřtirme gerekleřtirilmiřtir.

Iřık vd. (2018), farklı jant byklkleri, bijon sayıları ve PCD (Bijon evreleme apı) deęerleri iin maksimum gerilme zerinde parametrik bir alıřma yapılarak bu parametrelerin jantın zerinde oluřan gerilmeye etkileri deęerlendirilmiřtir.

zaydın vd. (2018), bir alminyum jantın feder arkasında bulunan geometrisi parametrik olarak modellenerek jantın maksimum gerilme ve deformasyon deęerleri kısıt fonksiyon olarak belirlenmiř ve jantın aęırlık azaltımı alıřması yapılarak jantta yaklařık 0,387 kg hafifletme saęlanmıřtır. Ayrıca bu alıřma ierisinde sadece stil arkasında bulunan yzeye modifikasyon uygulanarak jantın stil grnm zerinde bir etki oluřturmadan optimizasyon alıřması tamamlanmıřtır. Kullanılan parametrik jant tasarım grselleri, kesitleri ve belirlenen tasarım deęiřken parametreleri Őekil 2.4'te verilmiřtir.



Őekil 2.4 Parametrik jant optimizasyon modeli (zaydın vd. 2018)


Yaman vd. (2014), alaşımlı bir ticari araç jantının FRF analizi yapılarak modları belirlenmiştir. Belirlenen modlar deneysel çalışmayla doğrulanmıştır. Çalışmanın sonucunda deney tabanlı tasarım değişim önerisi verilmiştir ve verilen bu öneriyle jantın frekans değeri optimize edilerek jant başına 200 gr ağırlık kazanımı sağlanmıştır.

Farahani vd. (2018), gürültü ve titreşim müşteriler tarafından daima şikâyet konusu olduğundan otomotiv sektöründe hep en zorlu konulardan biri olmuştur. Tipik bir otomotiv jantı aracın ve araç gövdesinin NVH performansını optimize etmekte önemli bir role sahiptir. Araç lastiği yol ile doğrudan temas halinde olan birincil komponenttir. Eğer lastiğin yapısal dinamiği optimize edilirse yoldan araç kabinine aktarılan gürültü ve titreşim büyük ölçüde azaltılabilir. Bu çalışma içerisinde jant ve lastik modelleri FRF analizleri yapılarak rezonansa girme durumunu önlemek adına jantın üzerinde modifikasyonlar gerçekleştirilmiş ve jantın 7. rezonans frekansı noktası 250 Hz üzerine ötelenmiş, bu sayede ise jantın frekans değerinin diğer komponentlerle birlikte pik oluşturmasının önüne geçilerek aracın ses ve gürültü performansında bir iyileşme sağlanmıştır.

Ye vd. (2014), bir alüminyum alaşımlı jant için faktör analizi gerçekleştirmek için 8 şekil parametresi belirlenmiş ve bu parametre değişimlerinin jantın mekanik özellikleri üzerine etkisini belirlemek amaçlanmıştır. Bu amaçla parametreleri ve performans değerlerini belirlemek için Ridge regresyon metodu uygulanmış ve parametrelerin jant üzerindeki performans etkileri belirlenerek alüminyum jant tasarım sürecinin iyileştirilmesi amaçlanmıştır.

Mayen vd. (2017), Al 6061 T6 alüminyum alaşımının mikro yapısını çoklu lineer regresyon metodunu kullanarak belirlemeyi ve malzemede çatlak ilerleme durumunu tahmin edebilmeyi amaçlamışlardır. Gerçekleştirdikleri regresyon sonucunda malzeme üzerinde gerilim yoğunluğunun çatlak oluşumu ve çatlağın malzeme üzerinde ilerlemesi üzerine etkisi olduğunu tespit etmişlerdir.

Hsu vd. (2001), alüminyum alaşımlı bir jantın stil bölgesinde federlerin arka kısmında bulunan iki tasarım değişkeni belirlenmiş ve bu tasarım değişkenlerinin jantta yarattığı yorulma performansına dair birkaç deneysel sonuç kullanılarak model sıralı yapay sinir ağıyla (SNN) eğitilmiştir. İlgili modelin üzerinden hassasiyet değerleri hesaplanmış ve jantın yorulma gerekliliklerini karşılayan optimum ağırlık değeri hesaplanarak jant tasarımında iyileştirme gerçekleştirilmiştir. Ağırlık azaltımı için tasarım değişkenlerinin belirlendiği jant modeli Şekil 2.5'te gösterilmiştir.



Şekil 2.5 Ağırlık azaltımı için oluşturulmuş cep tasarımı (Hsu vd. 2001)

Borecki vd. (2021), bir jantı balans makinesinin üzerine ivme ölçer ve titreşim oluşturucu ile birlikte yerleştirerek jant üzerinden titreşim verileri toplamışlardır. Topladıkları verileri çok katmanlı perseptron (MLP) metoduyla modeli eğitmekte kullanmışlardır. Bu sayede ANN sınıflandırma yöntemini kullanarak jantın durumunu tahmin etme ve sınıflandırmayı sağlayan bir model oluşturmuşlardır.

Park ve Dang (2010), araç komponentleri için yapısal optimizasyon yöntemi önermişlerdir. Parametre tahminini sağlamak için yanıt yüzeyi ve radyal tabanlı fonksiyon metotlarını kullanarak FEA ihtiyaç duymadan farklı tasarım parametreleri için yanıt fonksiyonun sonuçlarına ulaşacak bir metot ile optimizasyon işlemini

birleştirmişlerdir. Bu sayede hesaplama maliyetlerini düşüren ve optimizasyon sürecini iyileştiren otomatik ve özelleştirilebilir bir optimizasyon gerçekleştirmişlerdir. Geliştirdikleri metodu bir araç jantı üzerinde de uygulayarak süreci iyileştirdiklerini ortaya koymuşlardır.

Jantlar için kullanılan optimizasyon yöntemlerinde gerçekleştirilen literatür araştırması sonucunda, jant performans parametrelerini analiz edebilmek için FEA ve jant tasarım sürecini iyileştirmek için genel olarak topoloji ve şekil optimizasyonlarının gerçekleştirildiği görülmüştür. Bu optimizasyon çalışmaları gerçekleştirilirken araştırmacılar genellikle optimizasyonun her bir tekrar ve hesaplama aşamasında uzun hesaplama zamanı alan FEA gerçekleştirmişlerdir. Jantın stil geometrisi içermesi ve kompleks geometrisi dolayısıyla analizler çok uzun sürmekte ve hem zaman kaybı hem de maliyet oluşturmaktadır. Bu süreyi kısaltabilecek yeni hesaplama ve regresyon metotlarının optimizasyon metotlarıyla entegre edilmeye ve hesaplama süresi zorluğunu aşmaya yönelik çalışmalar olduğu görülmektedir. Bu noktada yüksek doğrulukla jant performans parametrelerinin regresyonu ve tahmininin jant tasarım sürecini iyileştirmek adına kullanılması, tasarım sürecinin iyileşmesine oldukça önemli bir katkı sağlayacaktır.

Jant tasarım sürecinde literatürde yapılan araştırmalar kapsamında, jantın 1. mod frekans değeriyle NVH performansını, ağırlığını, darbe performansını ve maksimum yer değiştirme yani yorulma değerlerini optimize etmek amaçlı gerçekleştirilen çok sayıda çalışmaya rastlanmıştır. Bu çalışmalar incelendiğinde literatürde farklı optimizasyon ve parametre tahmin teknikleri kullanıldığı görülmüştür.

Geçmişte daha çok topoloji ve şekil optimizasyonun, jantların tasarım alanının optimize edilmesi ve uygun jant şeklinin sağlanması için kullanıldığı görülmektedir. Topoloji optimizasyonu hesaplamaya dayalı bir metottur. Dolayısıyla topoloji optimizasyonu çalışmalarında jantın performans parametrelerinin FEA ile hesaplandığı görülmektedir.

Çizelge 2.1 Jant tasarımında karşılaşılan parametre tahmin ve optimizasyon metotları

No	Tahmin/Hesaplama Metodu	Optimizasyon Metodu	Değişken	Amaç Fonksiyonu	Referans Kaynak
1	Yanıt Yüzey Modeli	-	Spoke bölgesi kesit ölçüleri	Maks. Yer Değiştirme (Yorulma)	(Hamidian vd. 2017)
2	Sonlu Elemanlar Analizi	Topoloji ve Şekil Optimizasyonu	Stil bölgesi tasarım şekli	1. mod Frekans (NVH)	(Kim vd. 2022)
3	Sonlu Elemanlar Analizi	Şekil optimizasyonu	Spoke arkası kesit ölçüleri	Maks. Gerilim (Darbe), Ağırlık	(Jiang vd. 2019)
4	Sonlu Elemanlar Analizi	Çok Amaçlı Topoloji Optimizasyonu	Stil bölgesi tasarım şekli	Ağırlık	(Zhang vd. 2021)
5	Sonlu Elemanlar Analizi	DeneySEL Optimizasyon	Rim ve disk kalınlık ölçüleri	1. Mod Frekans (NVH), Ağırlık	(Yaman vd. 2014)
6	ANN (Sınıflandırma)	Parametrik Şekil Optimizasyonu	Spoke bölgesi kesit ölçüleri	Maks. Yer Değiştirme (Yorulma), Ağırlık	(Hsu vd. 2001)
7	Ridge Regresyon	Faktör Analizi	Spoke bölgesi radyus ve uzunluk ölçüleri	Üretim Kısıtları	(Ye vd. 2014)
8	Çoklu Lineer Regresyon	-	Çatlak uzunluğu	Üretim Kısıtları	(Mayen vd. 2017)
9	Sonlu Elemanlar Analizi	Topoloji Optimizasyonu	Spoke bölgesi kesit ölçüleri	1. Mod Frekans (NVH), Ağırlık	(Prasad vd. 2013)
10	Radyal Tabanlı Modelleme ve Regresyon	Yapısal Optimizasyon	Spoke bölgesi kesit ölçüleri	Maks. Yer Değiştirme (Yorulma)	(Park vd. 2010)

Son yıllarda ise parametrik optimizasyon, şekil optimizasyonu ve faktör analizi tabanlı daha çok hesaplamalı optimizasyon tekniklerinin ön plana çıktığı göze çarpmaktadır. Bu metotlar belirli değişken parametreler için elde edilen çıktı değerlere göre optimizasyon işlemini gerçekleştirdiğinden ve hesaplamalı olarak çok sayıda farklı değişken kombinasyonu için sonuç hesaplanması gerektiğinden çıktı değerlerini hesaplamak için meta modellerin kullanımı söz konusudur.

Jant tasarımında kullanılan, jant tasarım parametreleri tahmin ve optimizasyon problemleri için amaç fonksiyonları, değişkenler, kullanılan optimizasyon ve tahmin metotları Çizelge 2.1’de verilmiştir.

Özellikle optimizasyon yöntemleri uygulanırken sanal analiz işlemleri çok uzun zamanlar alabilmektedir. Bu da optimizasyon sürecinin etkinliğinde azalmayı oluşturur. Bu hesaplama sürelerinin uzunluğu problemini çözebilmek ve optimizasyon sürecinin verimliliğini arttırabilmek adına vekil tabanlı optimizasyon metotları kullanılır. Vekil tabanlı optimizasyon metotları özellikle FEA’ların uzun süreler aldığı ve prototip üreterek test maliyetlerinin yüksek olduğu durumlarda oldukça önemli bir role sahiptir.

FEA metoduyla böylesine kompleks bir geometride hesaplama süreleri çok fazla hesaplama zamanı ve mühendislik eforu alabilmektedir. Bu nedenle araştırmacıların DOE, Regresyon ve ANN gibi verilen parametreler için sonuçları tahmin eden metotlar kullandıkları görülmektedir.

2.3 Yapısal Tasarım Çalışmalarında ve Jantlarda Kullanılan Yapay Sinir Ağı Metodu Tabanlı Algoritmalar

YouLiang vd. (2010), ANN’nin geri yayılım (BP) metodunu kullanarak belirli girdi parametreleri ile süspansiyon sisteminin frekans modlarının tahmin edilmesi için bir yöntem uygulamışlardır. Bu sayede süspansiyon sisteminin modal frekans değerini tahmin ederek, uygun sistem geliştirilmesi için öneriler ortaya koymuşlardır.

Ghosal vd. (2016), ANN metodunun tahmin işleminde verimliliğini arttırmak için Fletcher-Reeves (FR) yöntemini ANN metoduyla birlikte kullanmışlardır. Ayrıca bu metodun diğer tahmin metodlarına kıyasla hatalarını karekök metoduyla karşılaştırmalı hesaplamışlardır.

Kong vd. (2019), otomobil yayları için ANN-MLP metodunu kullanarak aracın titreşimi ve süspansiyon sisteminin doğal frekans değerlerinden yayların yorulma ömrünü tahmin amacıyla kullanmışlardır. Metodun uygulanması sonucunda araç tasarımında yayların yorulma ömürlerini 0.58 karekök ortalama hata derecesiyle tespit etmeyi başarmışlardır.

Lin (2012), alüminyum boru ve flanşların birbirleriyle lehimleme sürecini optimize etmek için Taguchi, ANN ve GA metodlarını kullanmıştır. Taguchi metoduyla elde edilen başlangıç veri setini yapay sinir ağını eğitmek için kullanmış ve son olarak da proses optimizasyonu için GA metodunu kullanarak optimizasyon işlemini gerçekleştirmiş ve çekme gerilmesi değerini 48 kgf iyileştirmişlerdir.

Marzbanrad vd. (2011), araç kaza performansını ve enerji absorbe etme yeteneğini arttırmak için araçta kullanılan alüminyum boruların optimizasyonunu gerçekleştirmişlerdir. 5 farklı tasarım parametresi için FEA ile elde edilen sonuçlar ile ANN modelini eğitmiş ve MOGA metodunu kullanarak darbe ve enerji sönmeme performansını 39% oranında iyileştirmeyi sağlamışlardır.

Baykasoğlu vd. (2020), araç darbe emiş değerini yükseltmek için kullanılan ince cidarlı alüminyum tüplerin FEA sonucunda elde edilen veriler ile ANN modeli eğitilmiş ve en yüksek çarpma kuvveti değerini tahmin prosesinde kullanılmıştır. Ayrıca en yüksek çarpma kuvveti değerini optimize etmek amacıyla MOGA işlemi gerçekleştirilmiş ve amaç fonksiyonu değerini 29% ile 51% arasındaki aralarda iyileştirmişlerdir.

2.4 Yapay Sinir Ağı Tabanlı Çok Amaçlı Genetik Algoritmanın Seçimi

Tez çalışması için ANN tabanlı MOGA seçilmiştir. Literatürde ANN metoduyla amaç fonksiyonu ve parametre tahmini yaparak GO gerçekleştirilen çok az sayıda çalışma olması bu konuda çalışmanın motivasyonunu oluşturmaktadır. Ayrıca jant tasarım sürecinde ANN'nin optimizasyon işlemlerinde parametre tahmin sürecinde kullanıldığı bir çalışmanın bulunmaması ve böylesine yeni ve etkin bir metodun yapısal tasarım alanında uygulanmasının jant tasarım sürecinde farklı bir yaklaşım sağlayarak süreci iyileştireceğinin görülmesi de bu seçimde etkili olmuştur.

3. MATERYAL ve YÖNTEM

Tez çalışmasının bu bölümünde otomotivde müşteri odaklı ürün geliştirme süreci ve bu süreci iyileştirecek jant tasarım sürecinde ANN temelli tahmin modeli ve MOGA metodu hakkında detaylı bilgilendirmeler yapılacaktır.

Bu bölüm aşağıdaki kısımları içermektedir:

- Müşteri Odaklı Otomotiv Ürün Geliştirme Süreci
- Alüminyum Alaşım Jant Tasarım ve Analiz Süreci
- Parametre Tahmin Sürecinde Kullanılan Metotlar

3.1 Müşteri Odaklı Otomotiv Ürün Geliştirme Süreci

Otomotiv firmaları son dönemde artan rekabet ile araç kalitesini ve ürün geliştirme süreçlerini iyileştirmek için zorluklarla karşılaşmaktadırlar. Özellikle ürün geliştirme süreçlerinin iyileştirilmesi ve sürelerinin kısaltılması, müşteri isteklerini karşılayan yüksek kaliteli ürünün daha az kaynakla ve daha kısa sürede müşterilere sunulabilmesi için çalışmalar yapılmaktadır (Fürst and Vietor 2019). Otomotiv ürün geliştirme sürecinde tasarım sürecinin akışı Şekil 3.1’de verilmiştir.

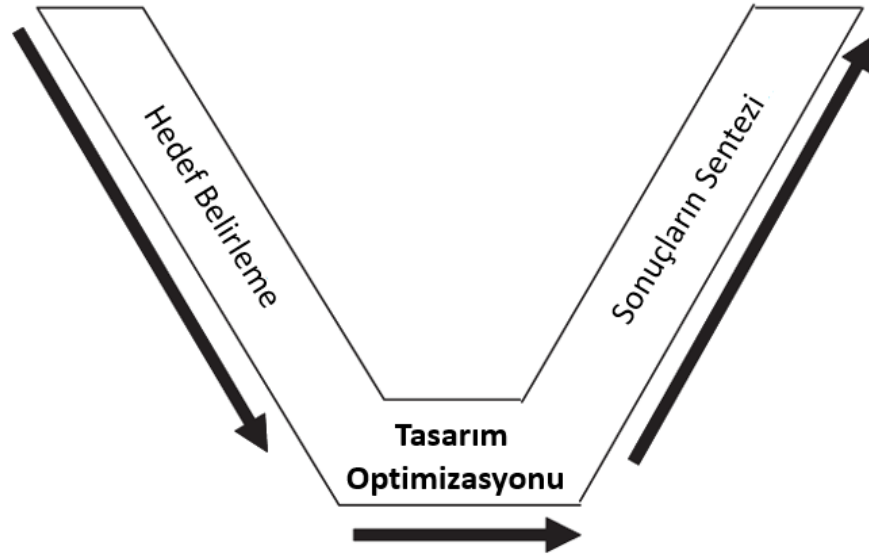


Şekil 3.1 Otomotiv tasarım akışı (Pischinger and Seiffert 2016)

Ürün geliştirme sürecinde müşteri isteklerini karşılayacak ürünü ortaya koyabilmek ve ürün geliştirme sürecini verimli kullanabilmek adına hedef belirleme işleminin öncelikli olarak yapılması gerekmektedir. Araç özelinde sürdürülebilir bir ürün ve marka oluşturulması için emisyon, ağırlık ve yasal zorunlulukları sağlamak gibi birçok hedef

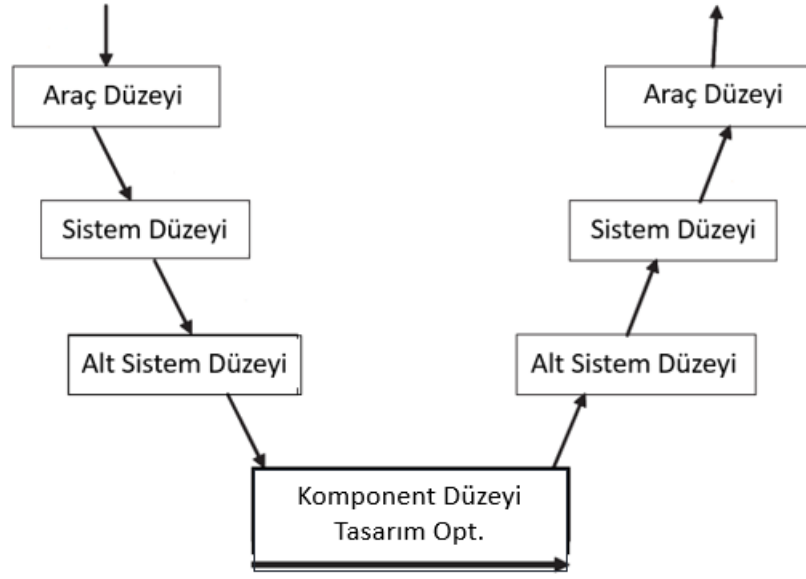
verilir. (Wolff vd. 2020). Aracın bu hedefleri karşılayacak şekilde ürün geliştirme süreci tasarlanır (İbrahim vd. 2021).

Bu süreçte genel olarak yaklaşım müşteri istekleri ve hedefleri doğrultusunda araç bazında hedefin belirlenmesidir. Sonraki aşamada ise araç bazında belirlenen hedefler mühendislik hesaplarına ve komponent bazında hedeflere dönüştürülerek ürün bazlı geliştirme süreci başlatılır. Otomotiv ürün geliştirme sürecinde kullanılan birçok yaklaşım mevcut olmakla birlikte hedef bazlı olarak en yaygın kullanımı olan metot V modeli olarak geçmektedir (Yadav ve Goel 2008).



Şekil 3.2 Hedef belirleme V-modeli (Yadav ve Goel 2008)

V-modeli akış şeması Şekil 3.2’de verilmiştir. V – modeli hedef belirleme, komponent bazlı tasarım optimizasyon süreci ve sonuçların sentezi olmak üzere 3 aşamadan oluşmaktadır. Bu süreç aslında sanal ürün geliştirme süreci olarak da adlandırılmaktadır. Sanal ürün geliştirme süreci yüksek maliyetli prototip ve kalıp üretiminin yapılmasının önüne geçmektedir.



Şekil 3.3 Hedef belirleme aşamasında bilgi akış şeması (Yadav ve Goel 2008)

Dong vd. (2019), araç düzeyinde gürültü, titreşim ve sertlik yani NVH hedeflerini belirlemek, tasarım sentezi ve hedefe ulaşma süreçlerini kapsayan ve hedef belirlemede kullanılan bir bilgisayar destekli mühendislik metodu ortaya koymuşlardır.

Araç bazında hedef belirleme süreci belirli bir akışa göre gerçekleştirilmektedir. Araç düzeyinden başlayarak sırasıyla sistem, alt sistem ve komponent düzeyi tasarım optimizasyon süreçleri gerçekleştirilir. Sonrasında ise akış komponent düzeyinden araç düzeyine doğru gerçekleştirilmektedir. Hedef belirleme aşamasında bilgi akış şeması Şekil 3.3'te verilmiştir.

Ancak günümüzde ürün geliştirme süreçlerinde tüm bu süreçlerin birbiriyle iç içe olduğunu ve entegre bir şekilde gerçekleştirilebileceğini söylemek mümkündür (Goelke vd. 2017). Ayrıca hesaplamalı olarak farklı yaklaşımlar geliştirilerek otomotiv ürün geliştirme sürecinin yeni yaklaşımlarla iyileştirilebileceği görülmektedir.

Son dönemde ise ürün geliştirme sürecine entegre bir şekilde kullanılan ve optimizasyon süreçleri için farklı parametre ayarlarıyla tekrarlanan FEA'larının önüne geçmek ve analizler esnasında oluşacak uzun hesaplama maliyetlerini engellemek için vekil tabanlı

radyal temelli fonksiyon, regresyon ve yanıt yüzeyi modeli gibi metotlar kullanılmaktadır (Park vd. 2010).

Otomotiv ürün geliştirme süreçlerinde meta model tabanlı multidisipliner tasarım optimizasyon süreci uygulanabilir ve bu uygulamalar sayesinde araç ağırlık, NVH ve kaza performans optimizasyon işlemleri gerçekleştirilebilir. Ayrıca güncel metotların kullanımıyla tahmin doğruluğu yüksek bir meta model oluşturulabilir ve bu sayede otomotiv ürün geliştirmede optimizasyon süreçleri hem daha esnek, daha hızlı ve daha az mühendislik eforuyla gerçekleştirilebilir. Tasarım değişiklik önerileri çok küçük hesaplama eforlarıyla tamamlanabilir ve ürün performansını iyileştirecek tasarım uygulamaları ürün tasarım aşamasının başındayken uygulanabilir (Ryberg vd. 2015).

3.2 Alüminyum Alaşımli Jant Tasarım ve Analiz Süreci

Stearns vd. (2013), tekerlek eski zamanların en önemli buluşudur. Bugünün arkeologları ve tarihçileri tekerleğin icadını eski uygarlığın gerçek doğuşu olarak tanımlamaktadır. Tekerleğin gelişimi eski çağlarda büyük ebatlarda tekerleklerin kullanımdan başlayarak orta ebatlı jantlara dönüşmüş ve modern transport araçlarının entegre bir parçası haline gelmiştir. Günümüzde araç üreticileri tarafından jantlarda çelik, magnezyum ve alüminyum gibi sofistike malzemeler kullanılmaktadır. Otomobil jantları yıllar içerisinde çelik ve tahtadan bugünün modern araçlarında kullanılan preslenmiş çelik ve modern döküm ve dövme alüminyum alaşımli jantlara evrilmiştir.

Rahul vd. (2016), alüminyum ve magnezyum alaşımli jantlar hem binek hem de ticari araçlarda kullanılmaktadır. Tipik olarak konvansiyonel jantlara kıyasla aynı dayanım ile çok daha hafif olmalarına ek olarak yüksek ısı iletimine ve gelişmiş kozmetik dış görünüşe sahiptirler.

Prasad vd. (2013), jant otomobilin en önemli komponentlerinden biridir. Jantlar rulman, porya akson gibi parçalarla birlikte aracın tüm yüklerini taşımaktadır. Ayrıca dikey yüklerin yanı sıra aracın sürüşünden, frenleme, viraj dönme ve hatta yoldan tümsek vb.

etkilerden gelen darbeler gibi düzensiz yüklerden de etkilenmektedir. Yüksek hızlarda rotasyondan kaynaklı olarak jantın kalitesi aracın stabilite, yol tutuşu ve diğer benzer karakteristikleri üzerinde yüksek etkilere sahiptir.

Çizelge 3.1 E.T.R.T.O. standardı kapsamında jant spesifikasyonları (ETRTO 2021)

	Parametre	Açıklama	Birim
6.5 J X 16 ET 36 5x110	6,5	Anma Genişliği	Inch
	J	Flanş Tipi	-
	16	Anma Çapı	Inch
	ET36	Ofset Uzunluğu	mm
	5	Bijon Sayısı	Adet
	110	Bijon Çevreleme Çapı	mm

Jantlarda bulunan parametreler E.T.R.T.O. (European Tyre and Rim Technical Organisation) tarafından uluslararası olarak standardize edilmiştir. Tasarım yapılırken aracın geometrisine, aks ağırlığına, kullanılacak lastik tipine, jant ebadına, çevre fren komponentleriyle olan ilişkiye ve bijon yerleşimlerine göre jantın teknik özellikleri bu standartlar kapsamında seçilir. ETRTO standardının içerisinde anma çapı 10” - 22” ve anma genişliği 4” - 10” arasında değişen ölçüler için uygun jant ebatları bulunmaktadır (ETRTO 2021).

Bu çalışma kapsamında ele alınacak olan örnek jantın 6.5 J x 16 x ET 36.5 5 x 110 ölçüleri ve parametreleri Çizelge 3.1 üzerinde verilmiştir.

Bir jantın temel ölçüleri ve ölçülerin anlamlılıkları detaylandırılmış ve temel bir janta ait kesit üzerinde detayları Şekil 3.4 üzerinde gösterilmiştir. Jantın tasarım parametrelerinin temel olarak açıklamaları aşağıda verilmiştir (ETRTO 2021).

- 1. Jant:** Genel olarak bir disk ve lastik kesiti kısımlarından oluşur.
- 2. Lastik Kesiti:** Jant ile lastiğin temas halinde bulunduğu kısımdır.

3. **Disk:** Jantın porya ve aks ile bağlantısının sağlandığı, bijon bağlantılarının bulunduğu ve dışarıdan görünen kısmıdır.
4. **Ofset:** Jantın orta simetri merkezi ile porya temas yüzeyi arasındaki mesafedir.
5. **Flanş:** Lastiği dış kısımdan jant ile temas halinde tutan kısımdır.
6. **Yanak Oturma Yüzeyi:** Lastik yanağının radyal yönde hareketini kısıtlayan yuvadır.
7. **Hump:** Yanak oturma yüzeyi üzerinde lastiğin araç hareket halindeyken jant flanşından dışarı hareketini sınırlayan çıkıntıdır.
8. **Kanal:** Lastik kesiti üzerinde hem derinlik hem de genişliği ile lastiğin jantın üzerine olan montajını kolaylaştıran bölgedir.



Şekil 3.4 Jant kesiti ve tasarım parametreleri detayı

Araç tasarım ve imalat tekniklerinde son yıllarda teknolojinin çok farklı alanlarda uygulamaları ile araçlarda çevreye uyumluluk ve güvenlik konularında yeni gelişmeler yaşanmaktadır. Hibrit, elektrikli ve otonom araçlar ile ilgili çalışmalar önümüzdeki yıllarda çok daha fazla önem kazanacaktır. Bu gelişmeler çerçevesinde araç yapısal elemanlarının tasarım değerlendirilmelerinde de yeni yaklaşımlar uygulanması

gerekmektedir. Araçlarda çevreye duyarlılık, sürdürülebilirlik, güvenlik ve konfor gibi karakteristikler ile ilgili çeşitli çalışmalar yapılmaktadır.

Bir jant tasarımı ile ve malzeme özellikleriyle tasarlandığı araç üzerinde gerekli mukavemeti ve aracın ses, titreşim gerekliliklerini sağlayacak özelliklerde seçilmeli ve tasarlanmalıdır. Jantın bu özellikleri sağlayıp sağlamadığı üretim öncesi sonlu elemanlar modelinde 13° darbe analizi, jant yorulma analizi & modal analiz yapılarak doğrulanır ve bu analizlerin spesifikasyonlarına uygun minimum ağırlık değerini sağlayan bir tasarım gerçekleştirilir. Üretim sonrasında ise performansını doğrulamak amacıyla malzeme, darbe testi 13°, FRF testi ve yorulma testleri yapılarak jantın son seviye fiziksel doğrulaması yapılır.

3.2.1 Jantın modal analizi ve deneysel doğrulaması

Seçilen jantın Altair Hypermesh paket programı üzerinde sonlu elemanlar modeli (FEM) oluşturulmuştur. Tetra element tipinde 5 mm büyüklüğünde 193.228 element kullanılarak FEM oluşturulmuştur. Jantın malzeme bilgisi ise alüminyum alaşımli jantlarda en sık kullanılan AlSi7Mg olarak belirlenmiş ve gerçekleştirilecek tüm analizler bu kapsamda gerçekleştirilmiştir.

Çizelge 3.2 Jant AlSi7Mg malzeme özellikleri (Lipiński 2020)


Element	Si	Mg	Ti	Fe	Cu	Zn	Mg	Al
Oranı	6,5-7,5	0,25- 0,45	0,08- 0,20	<0,2	<0,1	<0,1	<0,1	Diğer

Jant tasarımı için seçilen ve en sık kullanılan malzeme olan AlSi7Mg malzeme tipinin alaşım ve malzeme içeriği detayları Çizelge 3.2’de verilmiştir. Oluşturulan FEM modelde de bu özellikler tanımlanmıştır. Ayrıca analiz aşamasında tanımlanan jant malzeme özellikleri ise Çizelge 3.3’te verilmiştir.

Çizelge 3.3 Jant AlSi7Mg malzeme mekanik özellikleri (Sushant vd. 2015)

AlSi7Mg	Yoğunluk(d)Kg/m ³	Youngs Modülü (E) Pa	Poissons Oranı (1/m)
	2,71	7,10E+10	0,33

Tasarım aşamasında bulunan jantta FRF karakteristiklerini belirlemek adına sonlu elemanlar modeli üzerinde modal analiz gerçekleştirilir. Modal analiz gerçekleştirilirken model üzerinde jantın çalışma şartlarında tekere bağlı olması nedeniyle jantlar bijon bölgelerinden bijon temasının gerçekleştiği bijon ve jantın geometrisine uygun olarak sabitlenir. Sabitlenen model Şekil 3.5’te verilmiştir. Bu jant modeli üzerinden analiz işlemleri gerçekleştirilir.



Şekil 3.5 Modal analiz FEM geometrisi sabitlenmiş bijon bölgeleri


Jantın doğal frekansının tespiti için sistemin serbest titreşim değerleri eşitlik 3.1 üzerinde gösterildiği gibi referans alınarak hesaplanır. $\ddot{x}(t)$ ivme vektörü ve $x(t)$ ise yer değiştirme vektörüdür. M kütle matrisidir (Deng vd. 2022).

$$Kx(t) + M\ddot{x}(t) = 0 \quad (3.1)$$

Çizelge 3.4 Jantın modal analiz frekans değerleri


Mod	Frekans
1. Mod	340 Hz
2. Mod	389 Hz
3. Mod	797 Hz
4. Mod	1300 Hz

Gerçekleştirilen modal FEA sonucunda jantın elde edilen ilk dört doğal frekans değeri Çizelge 3.4’te gösterilmiştir.



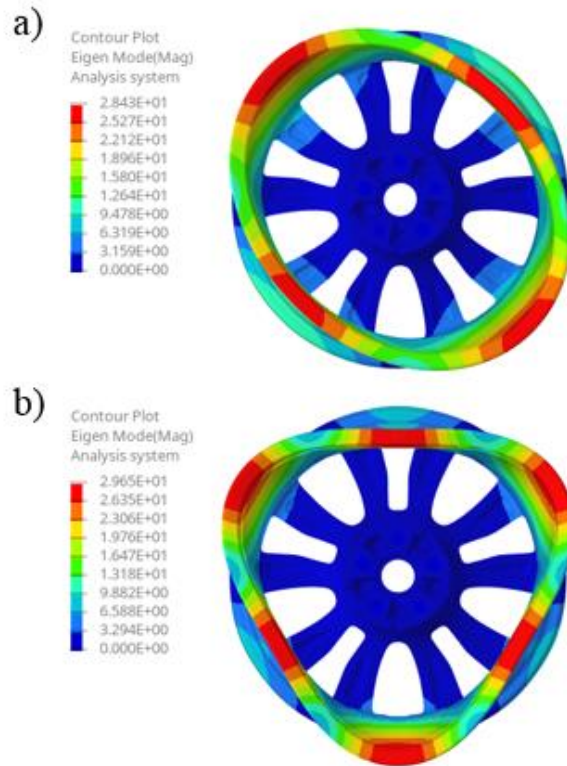
Şekil 3.6 Sonlu elemanlar modal analiz 1. mod arkadan görünüm

Jantın göbek bölgesinden bijon bağlantı noktalarının sabitlenmesiyle gerçekleştirilen modal analiz sonrası jantın ilk modunun arkadan ve yandan şekilleri Şekil 3.6 ve Şekil 3.7’de verilmiştir.

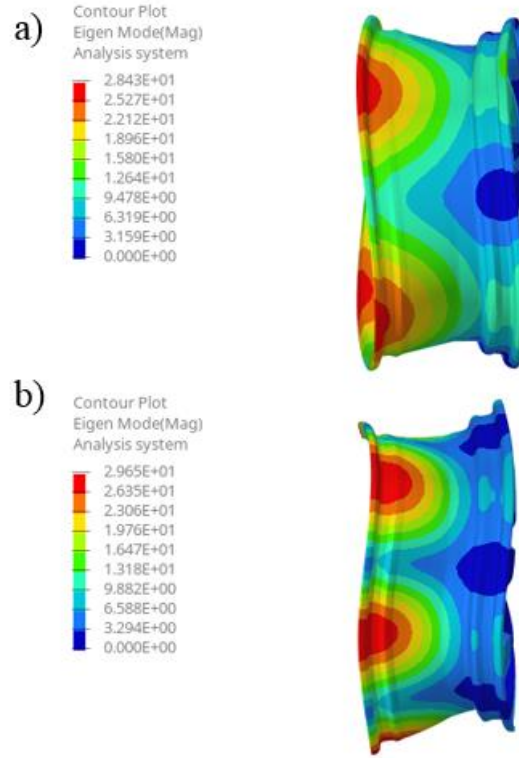


Şekil 3.7 Sonlu elemanlar modal analiz 1. mod yandan görünüm

Ayrıca modal analiz sonucunda elde edilen jant frekans analizinin iki, üçüncü modlarının şekilleri Şekil 3.8 ve Şekil 3.9’da verilmiştir.



Şekil 3.8 Modal analiz a.) 2. mod b.) 3. mod arkadan görünüm



Şekil 3.9 Modal analiz a.) 2. mod b.) 3. mod yandan görünüm

Jantın modal performansının deneysel olarak ölçülmesi için deneysel modal testi gerçekleştirilir. Modal test kapsamında jantın üzerine yerleştirilen yük yükselticiler aracılığıyla janttan veri toplanarak frekans modları ve sönümleme oranları ile zaman verileri elde edilir (Deng vd. 2022).

Örnek alınan jant modeli banko üzerine Şekil 3.10’da gösterildiği haliyle sabitlenmiş ve FEA sonuçlarının deney sonuçlarıyla doğrulanması amacıyla test edilmiştir. Jant bankoya bijonlar aracılığıyla sabitlenmiş ve jantın üzerinde çevre bölgesine ivme ölçerler yerleştirilmiştir. Test prosedürüne göre janta bir kuvvet çekiciyle vurularak ilk tahrik verilmiştir. Yük yükselticiler aracılığıyla veri toplama işlemi gerçekleştirilmiş ve bu veriyi işleyerek jantın modları ve doğal frekansları çıkarılmıştır.



Şekil 3.10 Deneysel modal test

FEM ve deneysel modal performans ölçümleri sonrası jantın FEM ve deneysel performans sonuçları Çizelge 3.5'te karşılaştırılmış ve FEM sonuçları ile deneysel sonuçların paralel olduğu görülerek kurulan model doğrulanmıştır.

Çizelge 3.5 Jant modları FEM ve deneysel sonuçların karşılaştırılması

Mod	FEM	Deneysel Test	Hata %
1. Mod	340.5 Hz	339.1 Hz	0.43%
2. Mod	389.6 Hz	390.2 Hz	0.16%
3. Mod	797.8 Hz	801.2 Hz	0.42%

3.2.2 Jantın dinamik viraj yorulma analiz ve testi

Bu çalışmada jantın dinamik viraj yorulma analiz ve deneysel testi gerçekleştirilerek analiz ve deneysel sonuçların korelasyonu sağlanmış olup, jantın yorulma performans gerekliliğini karşılayıp karşılamadığı kontrol edilmiştir. Jantın dinamik yorulma performansı iki şekilde kontrol edilebilir. Birinci metot jantın lastik ile kontak halinde olan dış rim ve flanş bölgesinin kelepçe ile sabitlenmesi ve jantın göbek aks montajı

yapılan bölgesine bağlanan bir moment koluyla dönme kuvveti uygulanması ile jantın üzerinde moment oluşturulmasıdır. İkinci metot ise jantın dönen bir plakaya sabitlenerek göbek bölgesine bağlanan bir moment koluyla jantta dönme kuvveti ve moment oluşturulmasıdır (Das vd. 2020). Bu çalışmada ikinci metot kullanılmıştır.

Jiang vd. (2018), jantın virajda dinamik eğilme yüküne karşı gösterdiği dayanım jantın dinamik yorulma ömrünü belirleyen faktördür. Jantın üzerine etkiyen eğilme momenti eşitlik 3.2'e göre hesaplanır. Etkiyen bu moment üzerinden hesaplamalar gerçekleştirilir.

$$M_o = (F_R \cdot d + F_L \cdot R_w)S \quad (3.2)$$

$$F_L = \mu \cdot F_R \quad (3.3)$$

$$M_o = (\mu \cdot R_w + d)F_R S \quad (3.4)$$

M_o → Janta etkiyen eğilme momenti değeri (N.m)

μ → Lastik ile yol yüzeyin arasında oluşan sürünme katsayısı değeri (0.7)

R_w → Lastiğin dinamik radyus değeri (m)


d → Jantın ofset değeri (m)

F_R → Statik radyal teker yükü (N)


F_L → Statik yanal teker yükü (N)

S → Hizmet faktörü


Jantın dinamik viraj yorulma analizini gerçekleştirebilmek için SAE jant yorulma test prosedürüne uygun bir FEM oluşturulmuştur. Jant ve araç aks yükleri değerlerine göre jantın göbek bölgesine eklenen bir moment kolu üzerinden janta yük uygulanmıştır. Kurulan analiz modeli ve uygulanan yük Şekil 3.11'de verilmiştir. Uygulanan yük sonrası jantta oluşan maksimum gerilme ve yer değiştirme değerleri incelenmiştir.



Şekil 3.11 Dinamik viraj yorulma sonlu elemanlar modeli




Şekil 3.12 Dinamik viraj yorulma analiz sonuçları önden görünüm



Şekil 3.13 Dinamik viraj yorulma analiz sonuçları arkadan görünüm

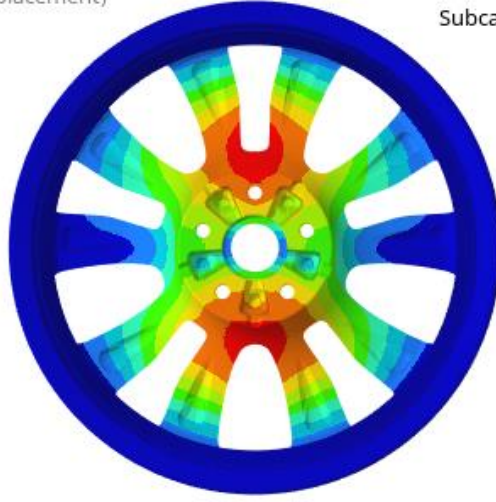

Jantta kurulan FEM üzerinde gerçekleştirilen dinamik viraj yorulma analizi sonucunda maksimum gerilme değeri Şekil 3.12 ve Şekil 3.13'te gösterildiği gibi 93 MPa olarak elde edilmiştir. Ayrıca analiz sonucunda elde edilen janttaki maksimum yer değiştirme değeri ise Şekil 3.14 ve Şekil 3.15'te verildiği gibi 0,264 mm olarak hesaplanmıştır. Jantın maksimum yer değiştirme değeri için izin verilen değer 0,27 mm olarak dinamik viraj yorulma testi sınırı belirlenmiştir. Jantın gerçekleştirilen analiz sonucunda bu değeri sağladığı görülmektedir. Maksimum yer değiştirme değerinin sınır değer içerisinde olması jantın yorulma dayanımının beklenen şekilde ve uygun olarak değerlendirildiği söylenebilir.



Şekil 3.14 Dinamik viraj yorulma analiz sonuçları maksimum yer değiştirme önden görünüm


Jantın üzerinde gerçekleştirilen deneysel dinamik viraj yorulma testi ise SAE test standardına uygun olarak gerçekleştirilmiştir (SAE 2009). İlgili standarda göre Şekil 3.16'da gösterildiği şekilde, jant göbek bölgesinden bijonlar aracılığıyla test bankosu üzerine sabitlenmiş ve jantta moment oluşturmak üzere rulman üzerinden yük moment koluna uygulanmıştır. Jant üzerinde formülde belirtilen şekilde araç spesifikasyonlarına göre hesaplamaları yapılan F_R ve F_L yükleri uygulanmıştır (Wang 2010). Bu yükler altında jantın 400.000 çevrim sonrası herhangi bir deformasyon oluşmaması beklenmektedir.

Fatigue Analysis (Displacement)



1:1
Subcase 1 (loadstep1) : Static Analysis : Frame 0


Şekil 3.15 Dinamik viraj yorulma analiz sonuçları maksimum yer değiştirme arkadan görünüm



Şekil 3.16 Dinamik viraj yorulma test bankosu kesiti (SAE 2009)

Şekil 3.17 üzerinde gösterilen banko aracılığıyla gerçekleştirilmiştir. Test sonucunda jant 400.000 çevrimi herhangi bir deformasyon görülmeden tamamlamış ve test sonucunda yorulma ile ilgili herhangi bir risk görülmeden testi tamamlamıştır. Daha önce

gerçekleştirilen FEA sonuçlarında da jantın moment kolu aracılığı ile uygulanan yük altında maksimum deformasyon değeri 0.264 mm olarak bulunmuş ve sınır değer olarak belirlenen 0.27 mm değerinin altında olduğundan jantın dinamik viraj yorulma performansı pozitif olarak değerlendirilmiştir. Bu çerçevede FEA ve deneysel test sonuçlarının korelasyonunun yapıldığı ve FEA sonucunda yorulma standartlarını sağlayan jantın deneysel olarak da yorulma performansının uygun olduğunu ve test sonuçları ile analiz sonuçlarının birbirini doğruladığını söyleyebiliriz.



Şekil 3.17 Jant viraj yorulma test bankosu

3.3 Parametre Tahmin Sürecinde Kullanılan Metotlar

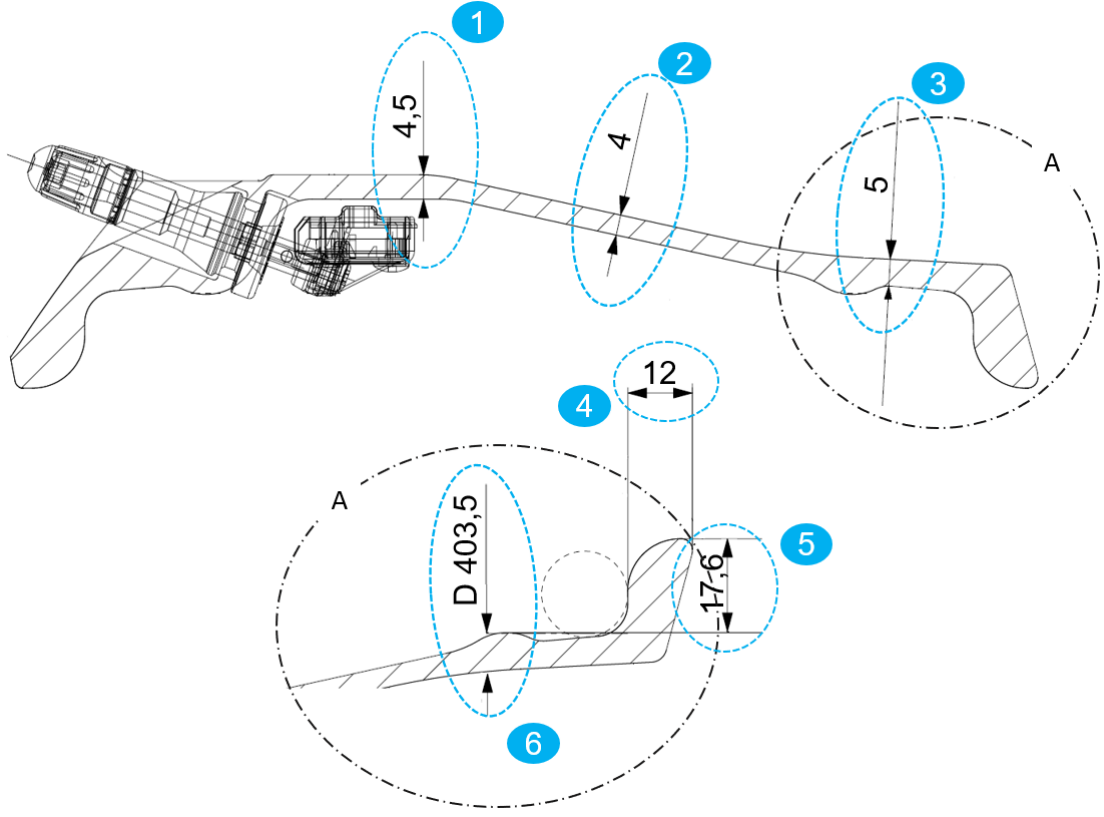
Parametre tahmin sürecinde modelin eğitilmesinde kullanılacak başlangıç veri setlerinin FEM aracılığıyla elde edilmesi ve elde edilen veriler ile farklı veki tabanlı yöntemler kullanarak modelin eğitilmesi sağlanmış ve eğitilen modeller ile çıktı parametrelerin tahmin edilmesi sağlanmıştır. Ayrıca her bir farklı tahmin modelinin doğruluğu ve performansı değerlendirilmiştir. Bu bölüm aşağıdaki metotların kullanımını ve uygulamasını içermektedir.

- Deneysel Tasarım Metodu
- Çoklu Lineer Regresyon Metodu
- ANN
- ANN Levenberg-Marquardt Metodu
- ANN Fletcher-Reeves Metodu

Jant ile gerçekleştirilecek optimizasyon çalışması için öncelikli olarak jant üzerinde optimize edilecek ilgili değişken parametrelerin belirlenmesi gerekmektedir. Jant üzerinde Şekil 3.4'te belirtilen stil yüzeyi aracın dış görünüşüne doğrudan etki ettiğinden ve müşteri algısını belirleyen önemli bir parametre olduğundan dolayı araç tasarım sürecinde genellikle stil departmanları tarafından belirlenir. Jantın stil alanı üzerinde özellikle dış kısımda değişim istenmez. Ancak jantın çevre ve lastik temas bölgesi üzerinde jant tasarım standartları içerisinde bazı değişiklikler mümkün olabilmektedir. Bu nedenle çalışma kapsamında tasarım değişkenleri jantın çeper bölgesinden belirlenmiştir. Belirlenen parametreler jant tasarım standartlarına ve E.T.R.T.O.'da belirtilen jant ölçüsel standartlarına uygun olacak şekilde seçilmiştir.

Bu çalışma kapsamında jantın çeper bölgesi üzerinde 6 farklı tasarım değişkeni belirlenmiş ve bu tasarım değişkenleri Şekil 3.18 üzerindeki gibi verilmiştir. Çalışmanın ilerleyen kısmında bu tasarım değişkenleri için farklı değerlerde jantın 1. mod frekans (Hz), ağırlık (kg) ve viraj yorulma testi maksimum yer değiştirme (mm) değerleri

hesaplanarak tahmin modeli eğitilecek ve uygulanacak çok amaçlı GO metoduyla ilgili girdi parametreler için optimum değerler elde edilecektir.



Şekil 3.18 Jant tasarım değişkenleri

Belirlenen 6 tasarım değişkeni için jant tasarım standartlarına uygun olarak belirli minimum ve maksimum tolerans değerleri vardır. Bu değerler jantın lastik ile uygun şekilde birleşmesi ve yasal düzenlemeleri karşılması amacıyla gereklidir. Örnek jantın tasarım parametreleri için alt/üst limitler ve her bir parametrenin minimum, maksimum değerleri Çizelge 3.6'da gösterilmiştir.

Belirlenen tasarım parametreleri için farklı girdi değerlerinde yanıt değerlerinin tahmin edilebilmesi ve optimizasyon işleminin gerçekleştirilmesi için tahmin modellerini eğitebilecek giriş veri setlerine ihtiyaç vardır. Giriş veri setleri doğrulanan FEM üzerinden FEA sonuçlarıyla elde edilebilir. Ancak birden çok farklı kombinasyon için tek tek FEM oluşturulması ve oluşturulan her bir model için analizlerin gerçekleştirilmesi hem ciddi bir mühendislik eforu hem de hesaplama zamanı gerektirecektir. Bu noktada

kurulan tek bir ana model üzerinden sadece gerekli parametrelerin uygun şekilde değiştirilerek analiz işleminin tekrarlanabileceği biçim değiştirme, morph modeli oluşturulması verilerin elde edilmesi için ciddi anlamda kolaylık, mühendislik zamanı tasarrufu ve hesaplama zamanı kazandıracaktır.


Çizelge 3.6 Tasarım değişkenlerinin alt/üst limitleri

Tasarım Değişkeni	Alt/Üst Limit	Minimum (mm)	Nominal (mm)	Maksimum (mm)
1	(+2.5/-1.5)	3.0	4.5	6.0
2	(+2/-1.5)	2.5	4.0	5.5
3	(+/-2)	3.0	5.0	7.0
4	(+3/-1)	11.0	12.0	15.0
5	(+2/-1)	16.6	17.6	19.6
6	(+/-0.5)	403	403.5	404

Biçim Değiştirme metodu bir şeklin veya tasarım parametresinin bir başka şekle dönüştürülmesi için mevcut FEM üzerinde bulunan düğümlerin koordinatlarının uygun şekilde değiştirilmesini sağlayan bir metottur. Şekil parametresiyle ilişkili bir düğüm koordinatının değiştirilmesi şekil vektörü olarak anılmaktadır. Biçim Değiştirme metodu şekil parametreleri üzerinde sonsuz küçük değişimler için oldukça uygun bir yöntemdir (Kaya vd. 2010). Bu metot özellikle şekil değişiminin küçük olduğu ve değişikliklerinin uygulanmasının uzun zaman alacağı modeller üzerinde kullanılabilir (Oh vd. 2018). Kompleks geometriler üzerinde her bir parametre için şekil değişimi ve ölçüsel değişim yapılması oldukça uzun mühendislik zamanı alabilmektedir. Biçim Değiştirme metodu bu zaman kaybının önüne geçmekte ve aynı FEA'sını çok sayıda farklı tasarım değişkeni değeri için hızlı bir şekilde tekrarlamaya ve zaman tasarrufuna önemli katkı sağlamaktadır (Balla vd. 2018).

Çalışma kapsamında oluşturulan, modal analiz ve viraj yorulma analizi gerçekleştirilen modeller, Hypermorph paket programı üzerinde biçim değiştirme metoduyla şekil vektörleri ve değişkenleri tanımlanarak farklı parametre değerleri için ilgili analizlerin

tekrarlanabileceği bir model oluşturulmuştur. Oluşturulan parametreler Şekil 3.19’da gösterilmiştir. Bu sayede öğrenme modeline girdi sağlayacak başlangıç veri setinin elde edilmesi için bir kolaylık sağlanması ve çok sayıda verinin daha kısa sürede elde edilebilmesi amaçlanmıştır.



Şekil 3.19 Jant modeli üzerinde biçim değiştirme parametreleri

3.3.1 Deney tasarım metodu (DOE)

Geleneksel yaklaşım ile tasarım değişken parametreleri iterasyon yaklaşımı ile kademeli olarak değiştirilerek en iyi nokta aranmaktadır. Ancak deney tasarım metodu ile girdi ve çıktı değerler arasında bir bağlantı geliştirerek tasarım değişkenleri için belirlenen aralıkta tüm değişkenleri temsil edebilen bir vekil yüzeyi bulunur. Vekil model oluşturularak farklı tasarım değişken değerleri için çıktı değerler oluşturulabilmekte ve her bir girdi değerinin çıktı değerlere etkileri belirlenebilmektedir. Ayrıca tüm bunlar sayesinde yanıt

değerlerin üzerinde tasarım değişken etkileri detaylı incelenebilmekte ve yanıt değerleri tahmin edilebilmektedir. Yanıt değerleri az sayıda veriyle bile yüksek doğrulukla belirlenebilmektedir (Park vd. 2010).

Vekil yönteminin kullanılabilmesi ve modelin eğitilebilmesi için uygun sayıda bir örnek giriş veri setinin oluşturulmasına ihtiyaç vardır. Bu veri setinin deneysel yöntemler ve analiz yöntemleriyle elde edilmesi oldukça uzun süre alabilir. Bu noktada Biçim Değiştirme metodu uygulanan model üzerinde farklı değerler için deney tasarım modeli oluşturulması ve veri örnekleme metotlarıyla veri elde edilmesi gerekmektedir. Bu çalışma kapsamında Latin Hiperküp (LHS) ve Hammersley Sıralı Örnekleme (HSS) metotları kullanılmıştır.

	1	2	3	4	5	6	7	8
1	■							
2					■			
3		■						
4							■	
5						■		
6				■				
7								■
8			■					

Şekil 3.20 Örnek latin hiperküp örnekleme matrisi

LHS metodu bir katmanlı Monte Carlo örnekleme metodudur. Bu metot kapsamında tasarım uzayı kutu adı verilen eşit olasılıklı bölgelere ayrılmaktadır. Eğer dağılım doğru ve düzgün yapılırsa eşit olasılıklı ve eşit büyüklükte n boyutlu hiperküpler oluşturulur. Kutular tamamen rastgele seçilen bir şekilde noktalarla doldurulur. Bu sayede her boyutta yalnızca bir kutunun doldurulması sağlanmaktadır. Dolayısıyla doldurulan bir kutu ile

aynı satır ve sütunda yer alan herhangi bir bölge tekrar doldurulmaz. Böylece marjinal bir dağılım elde edilir. Her bir değişken için kutular doldurulana kadar işlem tekrarlanır. İşlem sonunda Latin Hiperküp tasarımına ait bir matris elde edilir (Tang vd. 1993). Örnek bir LHS örnekleme matrisi Şekil 3.20’de boyut ve kutuların doldurulma dağılımına göre gösterilmiştir.

Latin Hiperküp metodu özellikle dağılımı üniform olmayan ve düşük adette örneklem ile olasılık dağılımını elde etmek noktasında ve analiz süreleri uzun süren modellerde dağılımı vermede oldukça kuvvetli bir metottur (Bogoclu vd. 2021).

Çalışma kapsamında Altair Hyperstudy 2019.1 paket programı üzerinde oluşturulan Biçim Değiştirme modeli üzerinden gerçekleştirilmiştir. Hyperstudy üzerinde oluşturulan model için hem modal analiz modeli hem de viraj yorulma analiz modeli entegre edilmiş ve tek bir paket içerisinde örnekleme metotları için farklı tasarım değişken değerleriyle 1. mod frekans (Hz), ağırlık (kg), yorulma analizi maksimum yer değiştirme (mm) değerleri elde edilmiştir.

Latin Hiperküp metoduyla 100 farklı değişik tasarım değişkeni için yanıt değerleri oluşturulan model üzerinden tekrarlı FEA’larının yapılması sonucunda elde edilmiştir. Elde edilen veriler Çizelge 3.7’de verilmiştir. Çalışmada belirlenen tasarım değişkenleri 1’den 6’ya kadar TD-1, TD-2, TD-3, TD-4, TD-5 ve TD-6 olarak numaralandırılmıştır.

Ayrıca tablo üzerinde her bir tasarım değişken varyasyonu için elde edilen 1. mod frekans, ağırlık ve maksimum yer değiştirme sonuçları da paylaşılmıştır.

Çalışma kapsamında ilerleyen parametre tahmin süreçlerinde vekil modelleri eğitmek ve farklı eğitim veri setleriyle modellerin performanslarını karşılaştırmak adına Latin Hiperküp metoduna ek olarak Hammersley Sıralı Örnekleme metoduyla da örnekleme işlemi yapılmıştır. Ayrıca elde edilen bu örneklem metotlarıyla elde edilen veriler ile eğitilen parametre tahmin modelleriyle jantın optimizasyon işlemleri de gerçekleştirilecektir.

Çizelge 3.7 Latin Hiperküp örnekleme metoduyla elde edilen 100 satırlık veri seti

No	TD-1	TD-2	TD-3	TD-4	TD-5	TD-6	1. Mod Frekans	Ağırlık	Maks. Yer Değişirme
1	6.280	4.380	5.952	13.780	16.108	403.242	347.423	9.856	0.263
2	3.642	4.479	4.618	11.142	17.210	403.730	339.021	9.934	0.269
3	4.097	4.030	6.146	11.597	16.292	403.125	346.670	9.720	0.267
4	3.956	3.381	6.834	11.456	18.496	403.869	333.232	10.245	0.264
5	3.612	4.241	3.534	11.112	18.684	403.749	335.396	10.164	0.267
6	4.485	4.840	4.563	11.985	17.066	403.029	343.336	9.899	0.264
7	4.755	4.640	4.125	12.255	19.087	403.325	334.518	10.330	0.259
8	5.260	3.585	6.591	12.760	17.121	403.467	340.986	10.028	0.264
9	4.372	3.938	3.718	11.872	18.622	403.640	336.559	10.197	0.264
10	6.006	6.766	5.971	13.506	17.590	403.214	333.282	10.313	0.261
.
.
.
98	4.449	5.128	6.072	11.949	17.720	403.157	337.970	10.095	0.261
99	3.341	5.715	3.619	10.841	19.533	403.032	328.622	10.390	0.267
100	3.860	4.732	4.778	11.360	19.419	403.183	329.865	10.402	0.264

Hammersley Sıralı Örnekleme metodu ise yarı Monte Carlo metodunun bir varyantı olarak değerlendirilen bir metottur. Bu metodun hata sınırları diğer metotlar ile karşılaştırıldığında oldukça düşüktür. Özellikle düşük sayıda örneklem ele alındığında Hammersley Sıralı Örnekleme metodu kullanıldığında iki boyutlu tasarım uzayında nümerik entegrasyonu diğer Monte Carlo metotlarına kıyasla daha yüksek bir örneklem oluşturulmaktadır (Wojtkiewicz vd. 2003).

Çizelge 3.8 Hammersley sıralı örnekleme metoduyla elde edilen 32 satırlık veri seti

N o	TD-1	TD-2	TD-3	TD-4	TD-5	TD-6	1. Mod Frekans	Ağırlık	Maks. Y.Değ.
1	3.800	3.000	4.333	13.000	16.648	403.091	347.718	9.700	0.265
2	4.600	3.500	5.667	12.000	16.745	403.182	344.076	9.903	0.262
3	5.400	4.000	3.444	14.000	16.842	403.273	340.777	10.081	0.260
4	6.200	4.500	4.778	11.500	16.939	403.364	340.229	10.210	0.259
5	3.160	5.000	6.111	13.500	17.035	403.455	331.388	10.228	0.265
6	3.960	5.500	3.889	12.500	17.132	403.545	334.400	10.266	0.262
7	4.760	2.571	5.222	14.500	17.229	403.636	343.654	9.824	0.266
8	5.560	3.071	6.556	11.250	17.326	403.727	344.700	9.923	0.263
9	6.360	3.571	3.148	13.250	17.423	403.818	343.441	10.045	0.262
10	3.320	4.071	4.481	12.250	17.519	403.909	340.794	9.920	0.268
11	4.120	4.571	5.815	14.250	17.616	403.008	331.939	10.253	0.264
12	4.920	5.071	3.593	11.750	17.713	403.099	337.862	10.216	0.263
13	5.720	5.571	4.926	13.750	17.810	403.190	328.535	10.564	0.260
14	6.520	2.643	6.259	12.750	17.906	403.281	343.099	9.980	0.266
15	3.480	3.143	4.037	14.750	18.003	403.372	340.344	9.844	0.271
16	4.280	3.643	5.370	11.125	18.100	403.463	343.110	9.907	0.264
17	5.080	4.143	6.704	13.125	18.197	403.554	333.454	10.253	0.263
18	5.880	4.643	3.296	12.125	18.294	403.645	338.342	10.232	0.261
19	6.680	5.143	4.630	14.125	18.390	403.736	328.725	10.585	0.259
20	3.640	5.643	5.963	11.625	18.487	403.826	329.263	10.383	0.266
21	4.440	2.714	3.741	13.625	18.584	403.917	344.310	9.787	0.271
22	5.240	3.214	5.074	12.625	18.681	403.017	341.502	9.971	0.266
23	6.040	3.714	6.407	14.625	18.777	403.107	331.826	10.320	0.262
24	6.840	4.214	4.185	11.375	18.874	403.198	339.414	10.236	0.260
25	3.032	4.714	5.519	13.375	18.971	403.289	330.302	10.204	0.266
26	3.832	5.214	6.852	12.375	19.068	403.380	327.650	10.399	0.265
27	4.632	5.714	3.049	14.375	19.165	403.471	326.731	10.523	0.263
28	5.432	2.786	4.383	11.875	19.261	403.562	345.541	9.846	0.268
29	6.232	3.286	5.716	13.875	19.358	403.653	335.215	10.202	0.263
30	3.192	3.786	3.494	12.875	19.455	403.744	338.795	9.911	0.270
31	3.992	4.286	4.827	14.875	19.552	403.835	329.266	10.269	0.266
32	7.000	6.000	7.000	15.000	19.600	404.000	317.048	11.018	0.257

HSS metodu kullanılarak Altair Hyperstudy model üzerinde 32 adet farklı tasarım deęişken deęeri için yanıt deęerleri belirlenmiştir. Elde edilen bu veriler düşük adette örneklem ile tasarım yüzeyini temsil etmekte oldukça güçlü bir veri setidir.

HSS metoduyla elde edilen 32 adet farklı tasarım deęişken parametresi için FEA sonucunda elde edilen yanıt deęerleri her bir veri grubu için Çizelge 3.8’de verilmiştir.

Sonuç olarak, deney tasarım yöntemi ile LHS metodu ile 100 adet başlangıç veri seti elde edilmiş ve HSS metodu ile de 32 adetlik başlangıç veri seti oluşturulmuştur. Bu veri setleri ilerleyen kısımlarda parametre tahmin modellerinin eğitiminde kullanılacak ve farklı modellerin tahmin doğruluęu farklı başlangıç veri setine ait kombinasyonlar ile irdelenecektir.

3.3.2 Çoklu lineer regresyon (MLR)

Belirli tasarım parametreleri ile sonuç deęerler arasında ilişkinin tespit edilebilmesi ve bu ilişkiyle bağlantılı olarak sonuç deęerlerinin veya tasarım parametrelerinin tahmin edilebilmesi için birçok meta model kullanılmaktadır. Girdi ve çıktı deęerleri arasındaki ilişkinin tespit edilebilmesi için kullanılan metotlardan bir tanesi de çoklu lineer regresyon metodudur. Bu çalışmada belirlenen tasarım parametreleri ile sonuç deęerleri arasındaki ilişkiyi belirlemek için ilk olarak çoklu regresyon metodu kullanılmıştır (Abrougui vd. 2019).

Çoklu regresyon metodu (MLR) belirlenen tasarım parametreleri ile yanıt deęişkenleri arasındaki ilişkiyi tespit etmek ve kullanılan başlangıç veri setinin lineer denkleme baęlı olarak girdi ve çıktı deęerleri arasındaki korelasyon modelini oluşturan bir istatistik metodudur. Çoklu regresyon metodu modelinin formülasyonu eşitlik 3.5 ile tanımlanmaktadır.

$$y_i = b_0 + b_1 \cdot x_{i,1} + \dots + b_k \cdot x_{i,k} + e_i \quad (3.1)$$

y_i bağımlı değişken iken, $x_{i,k}$ bağımsız değişkendir. b_k regresyon vektör katsayısıdır. b_0 ise kesme noktası olarak adlandırılmaktadır. e_i ise rastlantısal olarak ölçümlenen hata değeridir (Abrougui vd. 2019).

Çoklu regresyon modelini oluşturmak için öncelikle bağımlı ve bağımsız değişkenlerin tanımlanması gerekmektedir. Bu çalışma kapsamında 1. Mod frekans değeri, ağırlık ve maksimum yer değiştirme sonuç değerleri bağımlı değişkenler olarak tanımlanmıştır. Ayrıca Şekil 3.18’de belirlenen 6 jant tasarım parametresi ise bağımsız değişkenler olarak modele tanımlanmıştır. Çoklu regresyon modeli deney tasarım metoduyla elde edilen başlangıç veri seti ile oluşturulur.

Çoklu regresyon yönteminde en önemli noktalardan bir tanesi ise modelin başlangıç veri seti ile girdi ve çıktı parametreler arasındaki ilişkiyi aşırı öğrenmesi durumudur. Modelin tam olarak tahmin yapmak yerine başlangıç veri değerlerini tamamen kopyalaması ve eğitim verisi üzerinde en alt kırılıma kadar tüm sonuçları ezberlemesi durumudur. Bu da modelin sadece başlangıç veri setinin üzerinde başarı sağlayacağını göstermektedir. Farklı bir tasarım değişkeni veya sonuç değerinin tahmin edilmesi sürecinde modelin performansı oldukça düşük olacak ve çok yüksek hata değerlerine sahip olacaktır. Bu nedenle tahmin işlemini yüksek doğrulukla gerçekleştirmek için kurulan modelin mutlaka aşırı öğrenmeye karşı kontrol edilmesi gerekmektedir (Tusar vd. 2017).

Aşırı öğrenme durumunu kontrol etmek amacıyla çapraz doğrulama tekniği uygulanması mümkündür. Bu teknik ile başlangıç veri seti öğrenme ve test veri seti olarak belirli bir oranda ikiye bölünür. Model sadece eğitim veri setiyle eğitilir (Tusar vd. 2017).

Bu çalışma kapsamında da DOE ile elde edilen başlangıç veri seti belirli oranlarda ikiye bölünerek eğitim ve test veri seti olarak belirlenmiştir. MLR modelinin öğrenme sürecinde sadece eğitim veri seti kullanılmış ve sonrasında modelin doğrulama işlemleri yapılabilmesi için test veri seti kullanılmıştır. Eğitim veri setiyle eğitilen modelin aşırı

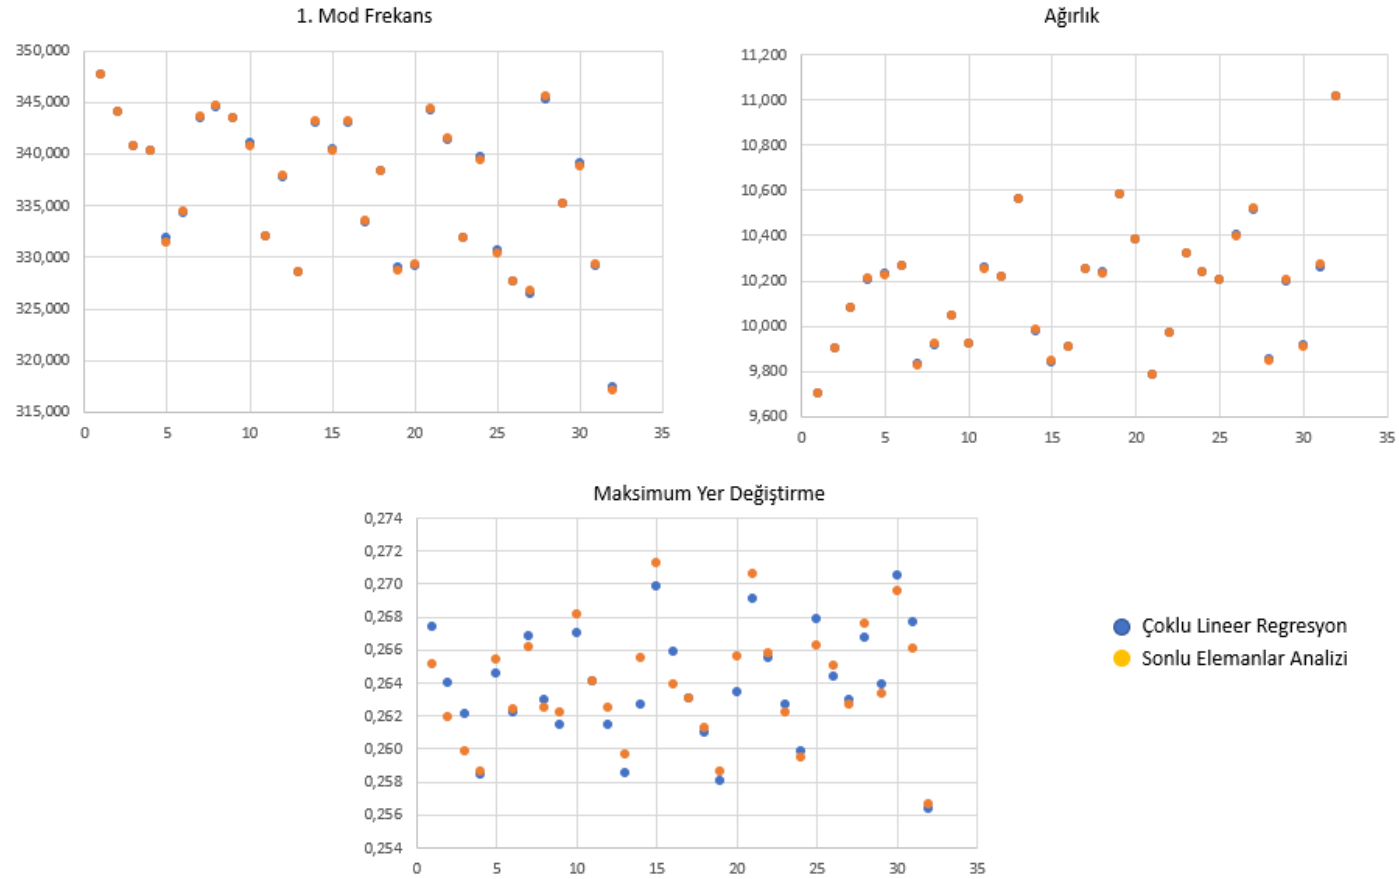
öğrenme davranışı gösterip göstermediğini kontrol etmek amacıyla test veri setindeki belirli parametreler için yanıt değerleri irdelenmiş ve modelin aşırı öğrenme yani ezberleme davranışı sergilemediği doğrulanmıştır.

Model farklı eğitim ve test veri seti oranları ve farklı başlangıç veri seti değerleriyle tekrarlı olarak eğitilmiş ve modelin performansı, tahmin sürecindeki hata değeri değerlendirilerek çalışmanın bundan sonraki kısmı için en yüksek doğruluğa sahip çoklu lineer regresyon modeli belirlenmiş ve kullanılmıştır. Belirlenen ve kullanılan çoklu lineer regresyon modelinin başlangıç veri seti, eğitim ve test veri oranları ve hata değeri ilerleyen bölümlerde karşılaştırmalı olarak ayrıca verilmiştir.

Çalışma kapsamında oluşturulan çoklu lineer regresyon modeli ile tahmin edilen sonuçlar ve analiz sonuçları her bir parametre için karşılaştırmalı olarak Çizelge 3.9'da verilmiştir. Ayrıca test veri seti ile birlikte her bir farklı tasarım değişkeni parametresi değeri için hem MLR hem de FEA sonucunda elde edilen değerler karşılaştırmalı olarak Şekil 3.21'de verilmiştir.

Çizelge 3.9 Çoklu lineer regresyon test veri seti analiz ve tahmin sonuçları karşılaştırma

No	TD-1	TD-2	TD-3	TD-4	TD-5	TD-6	MLR	Analiz	MLR	Analiz	MLR	Analiz
							1. Mod Frekans (Hz)	1. Mod Frekans (Hz)	Ağırlık (kg)	Ağırlık (kg)	Maks Yer Değiştirme (mm)	Maks Yer Değiştirme (mm)
1	3.800	3.000	4.333	13.000	16.548	403.091	347.732	347.718	9.700	9.700	0.267	0.2651
2	4.600	3.500	5.667	12.000	16.645	403.182	344.015	344.076	9.898	9.903	0.264	0.2619
3	5.400	4.000	3.444	14.000	16.742	403.273	340.718	340.777	10.082	10.081	0.262	0.2599
4	6.200	4.500	4.778	11.500	16.839	403.364	340.300	340.229	10.204	10.210	0.258	0.2587
5	3.160	5.000	6.111	13.500	16.935	403.455	331.842	331.388	10.231	10.228	0.265	0.2654
6	3.960	5.500	3.889	12.500	17.032	403.545	334.240	334.400	10.265	10.266	0.262	0.2624
7	4.760	2.571	5.222	14.500	17.129	403.636	343.490	343.654	9.829	9.824	0.267	0.2662
8	5.560	3.071	6.556	11.250	17.226	403.727	344.467	344.700	9.913	9.923	0.263	0.2625
9	6.360	3.571	3.148	13.250	17.323	403.818	343.488	343.441	10.044	10.045	0.261	0.2622
10	3.320	4.071	4.481	12.250	17.419	403.909	341.011	340.794	9.920	9.920	0.267	0.2682
11	4.120	4.571	5.815	14.250	17.516	403.008	332.060	331.939	10.258	10.253	0.264	0.2641
12	4.920	5.071	3.593	11.750	17.613	403.099	337.765	337.862	10.217	10.216	0.261	0.2625
13	5.720	5.571	4.926	13.750	17.710	403.190	328.520	328.535	10.565	10.564	0.259	0.2597
14	6.520	2.643	6.259	12.750	17.806	403.281	343.047	343.099	9.978	9.980	0.263	0.2655
15	3.480	3.143	4.037	14.750	17.903	403.372	340.398	340.344	9.842	9.844	0.270	0.2713
16	4.280	3.643	5.370	11.125	18.000	403.463	342.958	343.110	9.907	9.907	0.266	0.2639



Şekil 3.21 MLP ve FEA değerlerinin yanıt parametreleri için karşılaştırılması

3.3.3 Yapay sinir ağı (ANN)

ANN yapay zekâ (AI) metodunun öğrenme sürecini temsil eden basitleştirilmiş, küçük beyin sinir sistemidir. ANN modelleri bir başlangıç veri seti aracılığıyla eğitilerek belirli girdi parametreler için spesifik yanıt değerlerini elde etmeyi sağlayabilirler. ANN'leri birbirine bağlı girdi, çıktı ve gizli katmanlardan meydana gelmektedirler. ANN modeli yapısında birden fazla gizli katman mevcut olabilir. ANN modeli girdi verisi, bias ve ağırlık değerlerini kullanarak çıktı değerleri üretilmesine olanak sağlar. ANN'leri gizli katmanların bağlantı tiplerine bağlı olarak ileri-beslemeli ve geri beslemeli olarak iki farklı tiptedir (Ghosal ve Gupta 2016).

Çok katmanlı algılayıcılar (MLP), nümerik simülasyonlar sonucunda elde edilen veriler aracılığıyla nümerik fonksiyonu doğrulukla tahmin etmek için kullanılan bir metottur. Çok katmanlı algılayıcılar birçok farklı metoda sahip olup, belirli bir başlangıç veri seti ile eğitilerek, girdi ve çıktı parametreler arasındaki ilişkiyi tahmin etme konusunda oldukça başarılı metottur (Park vd. 2021).

Bu çalışma kapsamında ANN parametre tahmin sürecinde kullanılmıştır. ANN metotlarından parametre tahmin sürecinde kullanılan MLP kullanılmıştır. MLP'ler birçok farklı metoda sahip olup bu çalışma kapsamında Levenberg-Marquardt (LM) ve Fletcher-Reeves (FR) metotları kullanılmış ve her iki metodun doğrulukları farklı eğitim veri seti ve parametreler ile irdelenmiştir. Ayrıca her iki metot için de model eğitim sürecinde bias ve ağırlık gibi parametreler genetik optimizasyon (GO) metodu ile optimize edilerek en yüksek doğruluk ile tahmin edilecek modellerin oluşturulması amaçlanmıştır. Çalışma kapsamında ANN LM ve ANN FR modelleri ve optimizasyon modeli MATLAB 2019a paket programı üzerinde oluşturulmuş ve çözümlenmiştir (Beale vd. 2010).

MLR, ANN-LM ve ANN-FR gibi oluşturulan tüm tahmin modellerinin parametre optimizasyonları yapıldıktan sonra her bir modelin tahmin doğruluğu farklı başlangıç veri seti oranları ve değerleri için incelenmiş ve karekök ortalama hata (RMSE) metoduyla karşılaştırılarak, en uygun ve en yüksek doğruluğa sahip tahmin modelinin belirlenmesi ve optimizasyon işlemlerinin belirlenen doğruluğu en yüksek modele göre

gerçekleştirilmesi amaçlanmıştır. Ayrıca bu metotların jant tasarım sürecindeki tahmin performansları irdelenmiş olup, bundan sonraki jant tasarım süreçlerinde kullanılması uygun metot için öneri verilmiştir.

Oluşturulan ANN-LM, ANN-FR ve MLR modelleri tahmin sonucunda elde edilen sonuç 1. Mod frekans, ağırlık ve maksimum yer değiştirme değerleri ile deney tasarım metodu sonucunda elde edilen değerler modellerin geçerliliğini doğrulamak için karşılaştırılmıştır. Modellerin doğruluklarının analizi için yaygın olarak kullanılan RMSE metodu kullanılmış her bir model için değerler karşılaştırmalı olarak incelenmiştir. RMSE değerinin hesaplanması için kullanılan denklem eşitlik 3.6'da verilmiştir.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_{pi} - Y_{si})^2}{n}} \quad (3.2)$$

Y_{pi} başlangıç veri seti içerisinde her bir satırda tahmin edilen sonuç değerini, Y_{si} ise başlangıç veri setinde aynı satırlardaki FEA sonucunda elde edilen değeri belirtmektedir. n ise tüm başlangıç veri seti içerisindeki satır sayısına tekabül etmektedir (Siavash vd. 2021).

Kurulan tahmin modelinde 1. Mod frekans (Hz), ağırlık (kg) ve yer değiştirme (mm) değerleri yanıt değerleri olarak tanımlanmıştır. Kurulan ANN modellerinde öğrenme sürecine etki eden ve modelin doğruluğunu direkt olarak etkileyen bias ve ağırlık değerleri ise seçilen eğitim algoritmasına bağlı olarak belirlenmiştir. Bias ve ağırlık değerleri tekrarlayan öğrenme modellerinde bire bir aynı algoritma uygulanması durumunda bile değişiklik gösterebilmekte ve modelin tahmin doğruluğunu doğrudan etkileyebilmektedir. Bu nedenle eğitim modeline ait bu parametrelerin eğitim algoritmasına bağlı olarak optimize edilmesi doğruluğu yüksek bir model oluşturabilmek için oldukça önemlidir (Park vd. 2021).

Kurulan ANN modeli 3 adımda tasarlanmıştır:

Adım 1: Öğrenme için başlangıç veri setinin oluşturulması

Adım 2: Modelin LM ve FR eğitim algoritmaları ile ayrı ayrı eğitilmesi ve her bir modelin en uygun gizli katman sayısı ve gizli katmandaki nöron sayısının belirlenerek, modellerin optimum gizli katman ve nöron sayısı için eğitilmesi.

Adım 3: Her iki model için de bias ve ağırlık değerlerinin optimize edilmesi ve oluşturulan modellerde aşırı öğrenme yani ezberleme durumunun meydana gelip gelmediğinin kontrol edilmesi.

3.3.4 Yapay sinir ağı Levenberg-Marquardt metodu (YSA-LM)

Levenberg-Marquardt algoritması Hessian matrisi tabanlı bir metottur. LM Hessian matris yaklaşımı ile doğrusal olmayan en küçük kareler optimizasyonu için kullanılmaktadır. Hessian matrisi eşitlik 3.7’de belirtilen şekilde yakınsamaktadır (Hagan ve Menjah 1994).

$$H = J^T J \quad (3.3)$$

J, ağırlık ve sapma değerlerine göre hata vektörünün birinci türevini içeren bir Jacobian matrisidir. Gradyan ise eşitlik 3.8.’de verilmiştir.

$$g = J^T e \quad (3.4)$$

g gradyan değeri ve e ise ağırlık hata vektörüdür. LM eğitim algoritmasının uygulama sürecinde modelin bias ve ağırlık değerleri H ve g değerlerine bağlı olarak LM algoritması tarafından belirlenmektedir (Huda ve Taib 2014).

μ , öğrenme oranı, I birim matrisi ve X_k ise ağırlık ve bias değerlerinin sapma vektörüdür. Model bias ve ağırlık değerlerini eşitlik 3.9.’a göre gerçekleştirmektedir.

$$X_{k+1} = X_k + [H + \mu I]^{-1} g \quad (3.5)$$

Newton yaklaşımına göre μ sıfırdır. Eğer μ değeri sıfırdan yüksek bir değer ise gradyan inişi küçük adım boyutuna sahiptir ve μ her bir iterasyondan sonra ANN modelin performansını iyileştirmek için azalmaktadır (Hagan ve Menjah 1994).

Çalışma kapsamında oluşturulan ANN modeli TD-1'den TD-6'ya kadar olmak üzere 6 farklı tasarım değişkenine ve 1. Mod frekansı, ağırlık ve maksimum yer değiştirme parametreleri olmak üzere 3 yanıt değerine sahip olduğundan, ANN modelinde girdi katmanında 6 adet nöron ve çıktı katmanında ise 3 adet nöron bulunmaktadır. Modelin gizli katman sayısı ve gizli katmanda bulunan nöron sayısı ise ağırlık hata değerinin analizine göre karar verilmiştir. Gizli katman sayısı ve gizli katmandaki nöron sayısı modelin tahmin doğruluğuna etki etmektedir. Eğer modelde çok fazla gizli katman var ise modelde aşırı öğrenme durumu meydana gelebilir ve modelin yakınsaması artan hesaplama karmaşıklığından dolayı yavaşlar. Eğer modelde optimumdan düşük sayıda gizli katman ve nöron var ise model genelleme yapar ve başlangıç veri setinde bulunan şablonları iyi öğrenemez (Kalogirou 2003).


Bu çalışmada LM modelin gizli katman sayısı ve gizli katmandaki nöron sayısına ANN-LM modeli gizli katmandaki nöron sayısı 1'den 60'a kadar her bir nöron sayısı için ayrı ayrı eğitecek bir kod dizisi oluşturularak farklı nöron sayısı değerleri için modelin RMSE değerleri karşılaştırılmış ve en uygun RMSE değerine sahip model belirlenmiştir. ANN-LM model LHS deney tasarım metodu sonucu elde edilen 100 adetlik başlangıç veri setiyle farklı nöron sayılarıyla eğitilmiş ve her bir eğitim sonucunda modellerin RMSE değerleri Çizelge 3.10'da verilmiştir.

Çalışmada oluşturulan ve eğitilen ANN-LM modelin yapısı Şekil 3.22'de gösterilmiştir. Modelin eğitimi sırasında başlangıç veri setinin 70%'i eğitim verisi olarak seçilmiş olup. 30% ise modelin doğruluk oranını ver aşırı öğrenme durumu olup olmadığını teyit etmek amacıyla doğrulama verisi olarak kullanılmıştır.

Çizelge 3.10 ANN-LM metodu gizli katman nöron sayısına göre RMSE değerleri

ANN-LM			DOĞRULAMA VERİ SETİ		
Girdi Katmanı Nöron Sayısı	Çıktı Katmanı Nöron Sayısı	Gizli Katman Nöron Sayısı	RMSE (1. Mod Frekans)	RMSE (Ağırlık)	RMSE (Maks. Yer Değiştirme)
6	3	1	1.6298	0.0461	0.0029
6	3	2	0.2609	0.0067	0.0014
6	3	3	0.2059	0.0052	0.0012
6	3	4	0.2550	0.0054	0.0011
6	3	5	0.1476	0.0022	0.0011
6	3	6	0.0873	0.0020	0.0009
6	3	7	0.1488	0.0028	0.0008
6	3	8	0.0996	0.0025	0.0009
6	3	9	0.3564	0.0072	0.0013
6	3	10	0.1096	0.0026	0.0010
6	3	11	0.1466	0.0041	0.0012
6	3	12	0.1371	0.0039	0.0009
6	3	13	0.0929	0.0024	0.0008
6	3	14	0.3291	0.0070	0.0015
6	3	15	0.1704	0.0046	0.0010
6	3
6	3
6	3
6	3	60	11.0784	0.3620	0.0060

Çapraz doğrulama metodu, başlangıç eğitim veri setindeki verilerin belirli bir oranda ikiye bölünmesi ve bir kısmının modeli eğitmek bir kısmının ise modeli doğrulamak amacıyla kullanılan bir istatistik metodudur. Çapraz doğrulama metodu modelin aşırı öğrenme/ezberleme durumunu kontrol etmek ve modelin performansını arttırmak amacıyla kullanılmaktadır. Çalışmada hold-out tekniği kullanılmış ve çapraz doğrulama gerçekleştirilmiştir.



Şekil 3.22 ANN model yapısı

Çalışmada kurulan ANN-LM modelin hata oranları incelendiğinde RMSE değerlerine göre en yüksek doğruluğu veren modelin gizli katman nöron sayısı 6 olarak bulunmuştur. Bu nedenle öğrenme 6 gizli katman nöron sayısı ile gerçekleştirilmiştir. Bias ve ağırlık değerleri ilk olarak rastgele verilmiş ancak sonrasında RMSE değerini iyileştirecek şekilde ayarlanmış ve optimizasyonu yapılmıştır. Son oluşturulan ANN-LM modelinde 1. mod frekans için RMSE değeri 0.0399, ağırlık için 0.0019 ve maksimum yer değiştirme için ise 0.0006 olarak bulunmuştur.

İkinci aşama olarak ise modelde 1. modelde 70% olan eğitim veri seti oranı 2. modelde 80% olarak alınmış ve eğitim veri seti oranının ANN-LM modelinin doğruluğu üzerinde olan etkisi incelenmiştir. İkinci modelde 1. mod frekans için RMSE değeri 0.0319 olarak elde edilmiş ve 3. bir model olarak 100 adet LHS sonucunda elde edilmiş veri setine ek olarak 32 adetlik Hammersley metoduyla elde edilen 32 adetlik veri seti de kullanılmış ve 132 adetlik başlangıç veri seti kullanılarak model eğitilmiştir. Sonuç olarak 1. mod frekans RMSE değeri olarak 0.0318, ağırlık için 0.0012 ve maksimum yer değiştirme için ise 0.0006 elde edilmiştir.

Ayrıca ANN-LM metoduyla eğitimi tamamlanan modellerin doğruluğundan ve aşırı öğrenme/ezberleme durumu oluşup oluşmadığından emin olmak amacıyla ek bir 20 satırlık veri seti ile eğitim modelinin doğruluğu tekrar kontrol edilmiştir. Kontrol sonucunda herhangi bir ezberleme durumu olmadığı görülmüş ve modellerin RMSE değerlerinin uygun olduğu değerlendirilmiştir.

3.3.5 Yapay sinir ağı Fletcher-Reeves metodu (ANN-FR)

Fletcher ve Reeves çok değişkenli bir fonksiyona sahip modelin yerel minimum değerini bulmak için yeni bir gradyan yöntemi geliştirmişlerdir (Fletcher and Reeves 1964). ANN-FR modeli geri beslemeli ağ eğitim algoritmasıdır. Öğrenme sırasında bias ve ağırlık değerlerini yenilemek için eşlenik gradyan metodunu kullanmaktadır. Bu tip eşlenik gradyan metodunu kullanan algoritmalar genellikle değişken öğrenme oranını kullanan eğitim algoritmalarından daha hızlı metotlardır. Konvansiyonel eğitim metotları ile kıyaslandığında eşlenik gradyan metodu daha yüksek bir işlem hacmi kullanmaktadır. Ancak bu tip metotlar genellikle çok sayıda ağırlık değerine sahip olan ağlarda kullanıldıklarında oldukça faydalı metotlardır (Rafae and Ali 2015).

$$g_0 = g(x_0) \quad (3.6)$$

$$p_0 = -g_0 \quad (3.7)$$

$g(x)$ gradyan vektörüdür. p_{i+1} ise Eşitlik 3.13'de gösterildiği gibi formülün yönünü göstermektedir. Eşitlik 12'de gösterildiği gibi. g_{i+1} 'in bir lineer kombinasyonudur.

$$g_{i+1} = g(x_{i+1}) \quad (3.8)$$

$$p_{i+1} = -g_{i+1} + \beta_i p_i \quad (3.9)$$

$$\beta_k = \frac{\|g_k\|^2}{\|g_{k-1}\|^2} \quad (3.10)$$

İlgili FR metodunda üretilen p_{i+1} vektörü fonksiyonun yerel ikinci dereceden yaklaşımı ile bağlantılı gerçekleşir. Fonksiyonun yakınsaması Eşitlik 3.14'te gösterildiği gibi yanıtın her bir iterasyonda yerel yaklaşımına bağlı olarak gerçekleşmektedir.

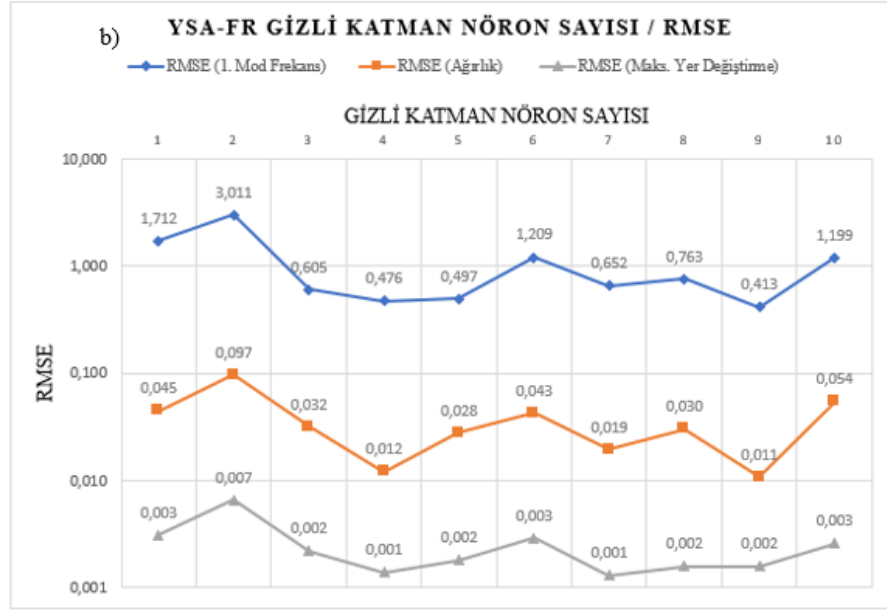

Çalışma kapsamında ANN-LM algoritmasıyla uygulanan ilk modelin eğitiminde kullanılan veri setinin kullanılmasıyla ANN-FR eşlenik gradyan eğitim algoritması aracılığıyla da gerçekleştirilmiştir. LM modelinde olduğu gibi FR metoduyla da modelin eğitilmesi amacıyla benzer yaklaşım kullanılmış olup, 6 tasarım değişkeniyle, girdi nöron sayısı 6 adet, 1. mod frekans, ağırlık ve maksimum yer değiştirme çıktı parametreleriyle çıktı nöron sayısı 3 adet olarak uygulanmış ve modelin gizli katmanında bulunan nöron sayısı 1'den 60'a kadar farklı modeller oluşturulmuş ve her bir modelin hata oranları ayrıca hesaplanabileceği bir kod dizisi oluşturulmuştur. Oluşturulan modellerin her birinin RMSE değerleri birbirleriyle karşılaştırılmıştır. ANN-FR modeli de ANN-LR modeli gibi LHS sonucunda elde edilmiş olan 100 adetlik başlangıç veri seti kullanılarak oluşturulmuştur. İlk aşamada 70% eğitim veri set oranı ile başlangıç veri setinin içerisinden rastlantısal olarak 70% veri setinin rastlantısal olarak seçimiyle model eğitilmiş ve 30% 'luk veri seti ise doğrulama veri seti olarak belirlenmiştir.

Çalışma kapsamında kurulan ANN-FR modelinin 1'den 60'a kadar farklı gizli katman nöron sayısı ile elde edilen RMSE değerleri ve modelin özellikleri Çizelge 3.11'de verilmiştir. Her iki ANN-LM ve ANN-FR modelinde de en iyi doğruluk oranının gizli katman nöron sayısı 1-10 arasındaki modellerde olduğu görülmektedir. ANN-FR modelinde en iyi performansı gösteren model gizli katman nöron sayısı 9 adet olan modeldir.

Çizelge 3.11 ANN-FR metodu gizli katman nöron sayısına göre RMSE değerleri


ANN-FR			DOĞRULAMA VERİ SETİ		
Girdi Katmanı Nöron Sayısı	Çıktı Katmanı Nöron Sayısı	Gizli Katman Nöron Sayısı	RMSE (1. Mod Frekans)	RMSE (Ağırlık)	RMSE (Maks. Yer Değiştirme)
6	3	1	1.711	0.045	0.003
6	3	2	3.0108	0.097	0.007
6	3	3	0.605	0.032	0.002
6	3	4	0.476	0.012	0.001
6	3	5	0.497	0.028	0.002
6	3	6	12.088	0.043	0.003
6	3	7	0.652	0.019	0.001
6	3	8	0.763	0.030	0.002
6	3	9	0.413	0.011	0.002
6	3	10	11.992	0.054	0.003
6	3
6	3
6	3
6	3	60	11.892	0.376	0.014

Bu çalışma kapsamında oluşturulan ANN-LM ve ANN-FR modellerinin gizli katman nöron sayısının 1 ile 10 arasında olduğu her bir model için 1. mod frekans (Hz), ağırlık (kg) ve maksimum yer değiştirme (mm) değerleri için RMSE değerleri karşılaştırmalı olarak Şekil 3.23’de verilmiştir. RMSE değerleri ve modellerin performanslarının daha iyi anlaşılabilmesi için ilgili grafik logaritmik skalada verilmiştir. Bu eğriden görüldüğü üzere ANN-LM modelinde en iyi performans gizli katman nöron sayısı 6 ve ANN-FR modelinde ise gizli katman nöron sayısı 9 olduğunda ortaya çıkmaktadır. Bu nedenle çalışmanın bundan sonraki kısımlarında ANN-LM ve ANN-FR eğitim modelleri bu gizli katman nöron sayıları kullanılarak oluşturulacaktır.



Şekil 3.23 ANN modelleri için RMSE değerleri karşılaştırması a) ANN-LM b) ANN-FR

Alüminyum alaşımlı jant tasarım sürecini iyileştirmek için kullanılan ANN modelinde farklı bir yaklaşım kullanılarak jant tasarım sürecinde parametre ve sonuç değerlerine etkisinin tahmin edilme sürecinin iyileştirilmesi ve yüksek doğruluk değeriyle tahmin sürecinin geliştirilerek, optimizasyon ve jant tasarım sürecine katkı sağlaması amaçlanmıştır. Kullanılan metodolojinin akış şeması Şekil 3.24’te verilmiştir.



Şekil 3.24 ANN modelinde kullanılan metodoloji akış şeması

Oluşturulan kod dizisi belirli bir optimizasyon bakış çerçevesinde oluşturulmuş ve MATLAB üzerinde çalıştırılmıştır. Kullanılan algoritma kapsamında ilk aşamada başlangıç veri setinin elde edilmesi ve ANN modelinin optimum gizli katman nöron sayısının belirlenmesi, ikinci aşamada ise optimum gizli katman nöron sayısı ile rastgele belirlenen ağırlık ve bias değerlerinin optimizasyonunu GA ile gerçekleştirilmiştir. Elde edil optimum bias ve ağırlık değerleriyle ANN modeli eğitilmiştir.

Çalışma kapsamında kullanılan ANN-LM ve ANN-FR eğitim algoritmaları ve eğitim algoritmalarının parametreleri Çizelge 3.12’de verilmiştir. Başlangıç veri seti olarak LHS sonucunda elde edilen 100 adetlik veri seti ve Hammersley metoduyla elde edilen 32 adetlik veri seti kullanılmıştır. Başlangıç veri setinin büyüklüğünün ANN modelin öğrenme performansına olan etkilerini irdelemek üzere modeller arasında farklı sayıda başlangıç veri setleri kullanılarak doğruluklarının kontrolü amaçlanmıştır. Ayrıca başlangıç veri setinin içerisinde rastgele belirlenecek eğitim ve doğrulama veri set oranları da farklılaştırılarak birden çok model eğitilmiştir. Bu sayede eğitim ve doğrulama veri setlerinin oranlarındaki değişikliklerin modellerin eğitim performansları üzerine olan etkisi irdelenmiştir.

Çizelge 3.12 ANN model yapıları

Metot	Eğitim Algoritması	Ağırlık ve Bias	Eğitim/Doğrulama Veri Set Oranları	Başlangıç Veri Seti Satır Sayısı
ANN-I	LM	Rastgele	70%–30%	100
ANN-II	LM	Optimum	70%–30%	100
ANN-III	LM	Optimum	80%–20%	100
ANN-IV	LM	Optimum	80%–20%	132
ANN-V	FR	Rastgele	70%–30%	100
ANN-VI	FR	Optimum	70%–30%	100
ANN-VIII	FR	Optimum	80%–20%	100
ANN-VIII	FR	Optimum	80%–20%	132

Ayrıca ilk modelde rastgele ve eğitim algoritmasının yapısına göre belirlenen bias ve ağırlık değerleri, GA yardımıyla optimize edilmiş ve her bir metot için bir sonraki

modelde optimize edilen deęerler kullanarak doęruluęu iyileřtirilmiř modeller oluřturulması saęlanmıřtır. Oluřturulan bu model ve kullanılan bu metot ile jant tasarım sũrecine ve ANN parametre tahmin metoduna farklı bir yaklařım geliřtirilmiřtir.

4. BULGULAR

Bu bölümde bir önceki bölümde geliştirilen tasarım parametrelerinin tahmin metotlarının tahmin doğruluğu için performans testlerinden elde edilen sonuçlar raporlanmıştır. Önerilen metodun jant tasarım parametreleri tahmin ve jant tasarım optimizasyon sürecindeki performansı diğer tahmin ve jant optimizasyon metotlarıyla karşılaştırmalı olarak verilmiştir. Tasarım uzayı dışında ve belirlenen parametrelerin dışındaki değerlerin tahmininde önerilen ANN modelinin parametre tahmin performansı MLR metodu ile karşılaştırmalı olarak değerlendirilmiştir. Ayrıca ileride tasarım uzayı dışında oluşabilecek farklı tasarım değişken değeri durumları için önerilen model FEA sonuçlarıyla da kıyaslanmıştır. Ardından ise seçilen algoritma ile örnek jantın tasarım optimizasyonu çok amaçlı GA (MOGA) optimizasyon metodu kullanılarak uygulanmış ve ANN-LM ve MOGA metotlarıyla gerçekleştirilen optimizasyon sonuçları MLR ve MOGA metoduyla uygulanan optimizasyon sonuçlarıyla karşılaştırmalı olarak verilmiştir.

4.1 Yapay Sinir Ağı Parametre Tahmin Metodunun Performans Testleri

Kurulan parametre tahmin modellerinin RMSE doğruluk değerleri karşılaştırılmış ve jant tasarım sürecinde en uygun parametre tahmin metodunun belirlenmesi sağlanmıştır. Ayrıca tasarım uzayı dışındaki değerler için modellerin tahmin doğrulukları gerçek değerler üzerinden FEA sonuçlarına göre irdelenmiştir. Bu bölüm aşağıdaki başlıklar altında incelenmiştir.

- Parametre tahmin metotlarının performans sonuçları
- Tasarım uzayı dışındaki tasarım değişken değerleri için performans sonuçları

4.1.1 Parametre tahmin metotlarının performans sonuçları

Kurulan ANN-LM ve ANN-FR modelleri Çizelge 3.12’de verilen detaylara göre farklı başlangıç veri seti ve parametre değerleri kullanılarak oluşturulmuştur. Jant tasarım sürecinde ANN kullanımının optimizasyon sürecine olan etkisi ve jant tasarımına en uygun metodun belirlenmesi amacıyla 8 farklı ANN modeli oluşturulmuştur ve

performansı değerlendirilmiştir. Oluşturulan modellerden NN-IV modeli ise başlangıç veri setinin 100 satırdan 132 satıra çıkarılması durumunda modelin performansını tespit etmek amacıyla oluşturulmuştur.

Çalışma kapsamında kurulan parametre tahmin modellerinin, yanıt değerlerini tahmin hata seviyesine göre karşılaştırması Çizelge 4.1’de verilmiştir. Her bir modelin parametre bazında RMSE değerleri hesaplanarak karşılaştırılmıştır.

Çizelge 4.1 MLR ve ANN modellerinin RMSE değerleri karşılaştırması

Model	1. Mod Frekans RMSE	Ağırlık RMSE	Maks. Yer Değiştirme RMSE
MLR	0.1938	0.0041	0.0012
ANN-I	0.0873	0.0020	0.0009
ANN-II	0.0399	0.0019	0.0006
ANN-III	0.0319	0.0017	0.0006
ANN-IV	0.0318	0.0012	0.0006
ANN-V	0.4130	0.0110	0.0016
ANN-VI	0.2203	0.0067	0.0012
ANN-VII	0.1981	0.0084	0.0013
ANN-VIII	0.1490	0.0066	0.0012

MLR metodunun uygulamasıyla 1. mod frekans değeri için 0.1938, ağırlık için 0.0041 ve maksimum yer değiştirme için ise 0.0012’lik RMSE değerleri elde edilmiştir. ANN-I modelinde ise 1. mod frekans değeri için 0.0873, ağırlık için 0.0020 ve maksimum yer değiştirme değerinde ise 0.0006 RMSE değeri elde edilmiştir. ANN-LM ve ANN-FR modellerinde bias ve ağırlık değerleri dışarıdan bir müdahale olmadığı sürece rastgele belirlenmektedir. ANN-I ve ANN-V modellerinde rastgele atanan ağırlık ve bias değerleri kullanılmıştır. Ağırlık ve bias değerlerinin iyileştirilmesi ve optimize edilmesi ile modelin doğruluk performansı iyileştirilebilir. Bu nedenle tüm parametreleri ANN-I ile aynı olan ANN-II ve yine tüm parametreleri ANN-V ile aynı olan ANN-VI modelleri sadece ağırlık ve bias değerleri için GA ile optimizasyon işlemi gerçekleştirilerek öğrenme modeli kurulmuştur. Sonuç olarak ANN-II ve ANN-VI modellerinin ANN-I ve ANN-V modellerinden daha yüksek doğruluğa sahip olduğu görülmektedir. Bu durumda

bias ve ağırlık değerlerinin GA ile optimizasyonunun ANN modelin doğruluk performansını iyileştirildiği görülmüştür.


ANN-II ve ANN-III modelleri karşılaştırıldığında, model yapısında sadece eğitim ve doğrulama veri oranları arasındaki fark olduğu, ANN-II modelinde başlangıç veri setinin 70%'inin eğitim veri seti olarak kullanılmasına rağmen ANN-III modelinde başlangıç veri setinin 80%'inin eğitim veri seti olarak kullanıldığı görülmektedir. ANN-III modelinin RMSE değeri ANN-II modelinden daha düşük elde edilmiştir. Ayrıca ANN-VI ve ANN-VII modelleri arasındaki tek fark da eğitim/doğrulama veri seti oranının 70%'e karşılık 80% olduğu ve ANN-VII modelinin RMSE değerinin ANN-VI modeline göre daha düşük olduğu görülmüştür. Bu durumda ANN modelinin eğitim veri setindeki artışın modelin doğruluğu üzerinde olumlu etkisi olduğu görülmektedir.

Ayrıca ANN modelinin doğruluk performansı başlangıç veri setinin veri adedinden de doğrudan etkilenmektedir. ANN-III modelinde sadece LHS'den elde edilen 100 adetlik veri seti kullanılırken ANN-IV modelinde farklı olarak LHS'den elde edilen 100 veri seti ve Hammersley metodundan elde edilen 32 adetlik veri de dahil edilerek 132 adetlik veri seti kullanılmıştır. ANN-IV modelinin RMSE değerleri ANN-III modeline göre daha düşüktür. Ayrıca benzer durum ANN-VII ve ANN-VIII modellerinde de mevcut olup 132 adetlik başlangıç veri setine sahip olan ANN-VIII modelinin RMSE değeri ANN-VII'ye göre daha düşük olarak elde edilmiştir. Bu durumda başlangıç veri setinde daha fazla sayıda veri bulunmasının ANN modelinin doğruluğu üzerinde olumlu bir etkisinin olduğu görülmektedir.

Çalışma kapsamında MLR, ANN-LM ve ANN-FR eğitim algoritmaları optimum tasarım parametrelerinin tahmin edilmesi ve jant tasarım parametrelerinin optimum değerlerinin bulunması ve gerekli jant tasarım parametrelerinin sağlanması için kullanılmıştır. Kurulan MLR ve ANN tahmin modellerinin doğrulaması yapılmış ve RMSE değerlerinin karşılaştırmaları Şekil 4.1'de verilmiştir.

Kullanılan tahmin metotlarının tahmin doğruluk değerleri değerlendirildiğinde en iyi RMSE değerini ANN-LM metodunun 1. mod frekans yanıt değeri için 0.0318, ağırlık

için 0.0012 ve maksimum yer değiştirme yanıt değeri için ise 0.0006 RMSE değerleriyle sağladığı görülmektedir.



Şekil 4.1 MLR ve ANN modellerin RMSE değerlerinin karşılaştırması

Gerçekleştirilen ve kurulmuş olan farklı tahmin modelleri içerisinde en yüksek doğrulukla tasarım parametrelerinin tahmin edilmesini sağlayan öğrenme modeli sırasıyla ANN-IV, ANN-III, ANN-II, ANN-I, ANN-VIII, MLR, ANN-VII, ANN-VI, ANN-V modelleridir. Genel olarak tahmin metotları değerlendirildiğinde ise ANN bias ve ağırlık değerleri optimize edilmiş modellerin, rastgele seçilen modellere göre her iki ANN-LM ve ANN-FR daha iyi sonuç verdiği görülmüştür. Ayrıca veri seti içerisinde eğitim-doğrulama veri setinin 80% olduğu örnekler 70% olan modellere kıyasla daha yüksek doğrulukla sonuç vermektedir. Ayrıca başlangıç veri setinin 100'den 132'ye çıkarılması her iki ANN-LM ve ANN-FR metotlarında da tahmin doğruluğunun yükseldiği görülmektedir. Genel itibariyle eğitim algoritmaları arasında bir kıyaslama yapıldığında ise en yüksek tahmin doğruluk değerini sağlayan metotlar sırasıyla ANN-LM, ANN-FR ve MLR modelleridir. Sonuç olarak en yüksek doğruluk değerini sağlayan parametre tahmin modeli ise ANN-IV modelidir.

4.2 Tasarım Uzayı Dışındaki Tasarım Değişken Değerleri için Performans Sonuçları

Jant tasarım sürecinde tasarım ve yanıt parametrelerin tahmin performansı değerlendirilmesi hata oranlarına göre yapılmıştır. Jant tasarım sürecinde başlangıçta belirlenen tasarım uzayının dışında oluşabilecek gereklilikler durumunu ve önerilen metodun tasarım uzayı ve biçim değiştirme tolerans değerleri dışarısında da tahmin doğruluğunu değerlendirmek için tasarım uzayı dışarısında seçilen tasarım değişkenleri için yanıt parametrelerinin en iyi performansı gösteren ANN-LM (ANN-IV) modeli ve MLR modeliyle elde edilmesi sağlanmış ve tahmin edilen değerler belirlenen tasarım parametreleri için gerçekleştirilen FEA sonuçlarıyla kıyaslanmıştır. Bu sayede çalışmada önerilen ANN-LM metodunun etkinliği kanıtlanmıştır.

Önerilen modelin tasarım uzayı dışında performansını değerlendirmek amacıyla Çizelge 3.6 üzerinde belirtilen tasarım değişken sınırları dışarısında tasarım değişkeni değerlerine sahip 2 farklı model oluşturulmuştur. 1. model daha önce oluşturulan biçim değiştirme modeli tasarım değişken sınırları dışarısında seçilmiş olup, 2. model ise hem biçim değiştirme modeli hem de tasarım uzayı tasarım değişken sınırları dışarısında seçilmiştir. Oluşturulan 2 modelin seçilen tasarım değişken değerleri Çizelge 4.2’de verilmiştir. Her iki model için de önerilen ANN modeli, MLR modeli ve FEA sonuç değerleri hesaplanmış ve sonuçlar karşılaştırmalı olarak değerlendirilmiştir.

Çizelge 4.2 Belirlenen tasarım uzayı dışında örnek modellerin tasarım değişkeni değerleri

Model	TD-1	TD-2	TD-3	TD-4	TD-5	TD-6
Model-1	2.5	2.0	2.5	17	21	405
Model-2	11	2	1.5	36	6	404

Belirlenen tasarım değişkenleri için her iki modelin de yanıt değerleri ANN-IV ve MLR metotlarıyla tahmin edilmiş ve her iki modelin de FEA gerçekleştirilmiştir. Sonuçta elde edilen değerler Çizelge 4.3’te verilmiştir.

Çizelge 4.3 Örnek modellerin sonuç değerleri

Model	Metot	1. Mod Frekans (Hz)	Ağırlık(kg)	Maksimum Yer Değiştirme (mm)
Model-1	FEA	334.2021	9.7473	0.2793
	MLR	335.2309	9.6877	0.2790
	ANN-IV	333.8167	9.7938	0.2791
Model-2	FEA	343.8160	10.1892	0.2539
	MLR	353.9210	10.6467	0.2434
	ANN-IV	347.1684	9.8956	0.2576

Önerilen metodun tasarım uzayı ve biçim değiştirme modeli sınırları dışında performansının doğrulanması amacıyla oluşturulan 2 model üzerinde elde edilen sonuçlar değerlendirilmiştir. Ayrıca her bir modelin yanıt değerlerinin FEA sonuçlarıyla kıyaslamalı olarak değerlendirilebilmesi amacıyla hata seviyeleri hesaplanarak Çizelge 4.4'te verilmiştir.

Çizelge 4.4 FEA, MLR ve ANN-IV modellerinin tasarım uzayı dışında tahmin hata seviyeleri

Model	Metot	1. Mod Frekans (Hz)	Ağırlık (kg)	Maksimum Yer Değiştirme (mm)
Model-1	FEA-ANN-IV	0.115%	0.477%	0.087%
	FEA-MLR	0.308%	0.611%	0.123%
Model-2	FEA-ANN-IV	0.975%	2.881%	1.457%
	FEA-MLR	2.939%	4.490%	4.135%

Biçim değiştirme modeli tasarım sınırları dışında seçilen Model-1 özelinde değerlendirildiğinde: 1. mod frekans değerinde FEA sonucunda 334.2 Hz'lik değer elde edilirken, MLR 335.2 Hz ve ANN-IV modeli 333.8 Hz değerlerini vermiştir. MLR tahmin modeli 0.308%'lik hata seviyesine sahipken, ANN-IV tahmin modeli 0.115%'lik hata seviyesine sahiptir. Ağırlık değerinde ise FEA sonucunda 9.7473 kg değeri elde edilirken MLR modeli ile 9.6877 kg ve ANN-IV modeliyle 9.7938 kg değerine

ulaşmıştır. MLR modeli ağırlık parametresini tahmin performansında 0.611% hata seviyesine sahipken ANN-IV modeli ise 0.477% hata seviyesine sahiptir. Maksimum yer değiştirme parametresi için ise FEA sonucunda 0.2793 mm elde edilirken, MLR modelinde 0.2790 mm ve ANN-IV modelinde ise 0.2791 mm değeri elde edilmiştir. Bu yanıt parametresi için ise MLR modeli 0.123% hata seviyesine sahipken, ANN-IV modeli ise 0.123%'lük hata değerine sahiptir. Biçim değiştirme modeli tasarım sınırları dışında modellerin tahmin performansı değerlendirildiğinde ANN-IV modelinin MLR modeline göre hem değerlerin FEA sonuçlarına yakınlığı hem de hata seviyeleri anlamında daha uygun bir model olduğu görülmektedir.

Hem biçim değiştirme modeli hem de jant tasarım uzayı sınır değerleri dışında belirlenen Model-2'nin 3 boyutlu bilgisayar destekli tasarım (CAD) modeli Şekil 4.2'de verilmiştir. Model-2 için bir değerlendirme yapıldığında ise, 1. mod frekans değeri FEA sonucunda 343.8 Hz bulunurken, MLR modeli aynı model için 353.9 Hz, ANN-IV modeli ise 347.2 Hz değerlerine ulaşmıştır. MLR modelinin 2.939%'lik hata seviyesine karşılık ANN-IV modeli 0.975%'lik hata seviyesine sahiptir. Ağırlık yanıt parametresi için ise FEA sonucunda 10.1892 kg değeri elde edilirken, MLR sonucunda 10.6467 kg ve ANN-IV sonucunda ise 9.8956 kg değeri elde edilmiştir. MLR modeli ağırlık değerinde 4.490%'lik hata seviyesine sahipken, ANN-IV modeli 2.881% olarak hesaplanmıştır. Son olarak maksimum yer değiştirme değeri olarak FEA ile 0.2539 mm değeri hesaplanırken, MLR modeli tahminiyle 0.2434 mm değerine ulaşmış ve ANN-IV modeli ile ise 0.2576 mm değeri tahmin edilmiştir. ANN-IV modeli hata seviyesi 1.457% iken, MLR modeli 4.135% olarak elde edilmiştir. Tasarım uzayı dışında belirlenen tasarım değişkenleri için bir analiz gerçekleştirilmiş olup ANN-IV modelinin hem elde ettiği sonuçlarda FEA değerlerine yakınlık hem de hata seviyeleri olarak MLR modeline göre üstünlüğü gösterilmiştir.




Şekil 4.2 Model-2 3 boyutlu görseli

Hem biçim değiştirme modeli tasarım sınırları dışarısında hem de jant tasarım uzayı dışında belirlenen jant tasarım değişken değerlerine sahip 2 farklı modelin FEA sonuç değerleriyle çalışma dahilinde önerilen metot ANN-IV ve konvansiyonel MLR metodunun sonuçları kıyaslanmıştır. Biçim değiştirme sınırları dışında tasarım parametreleri belirlenmiş Model-1’de ANN-IV’ün MLR modeline göre daha üstün olduğu gösterilmiştir. Ancak benzer karşılaştırma jant tasarım uzayı dışında tasarım değişkenleri belirlenen Model-2’de gerçekleştirildiğinde ANN-IV’ün tahmin performansında MLR’a kıyasla olan üstünlüğü çok daha belirgin olarak ortaya çıkmıştır.

Sonuç olarak, çalışmada önerilen ANN parametre tahmin metodu jant tasarım parametrelerinin optimizasyon sürecinde, mevcutta sıklıkla uygulanan tecrübeye dayalı konvansiyonel metotlar yerine hesaplamalı olarak en iyi performans parametrelerine ulaşmak amacıyla kolaylıkla uygulanabilir bir metottur. Hesaplamalı metotlar arasında ise geleneksel MLR metodu ANN tabanlı tahmin modellerine göre daha yüksek RMSE değerlerine sahiptir. Yapılan çalışmada, ANN metodunun geçmiş vaka ve verilerden öğrenbilme yeteneği sayesinde MLR ve regresyon tabanlı metotlara göre daha yüksek

doğruluk değerine sahip olduğu görülmüştür. En yüksek başlangıç veri setine sahip (132 adet) ve en yüksek eğitim-doğrulama veri oranına (80%) sahip ANN-IV tahmin modelinin diğer daha düşük başlangıç veri seti ve eğitim-doğrulama veri oranına sahip metotlara kıyasla daha verimli parametre tahmin işlemi gerçekleştirildiği sonucuna ulaşılmıştır.

Ayrıca ANN-IV modeli parametre tahmini ve FEA sonucunda elde edilen yanıt değerlerinin daha iyi karşılaştırılabilmesi amacıyla her bir yanıt parametresi değerinin 1. mod frekans (Hz), ağırlık (kg) ve maksimum yer değiştirme (mm) sonuçları Şekil 4.3'te pareto diyagramı olarak verilmiştir. Her bir diyagram üzerinde x eksenine FEA sonucunda elde edilen değeri gösterirken, y eksenindeki değerler ise ANN-IV metoduyla gerçekleştirilen ve elde edilen tahmin değerlerini göstermektedir. Dolayısıyla her bir diyagram üzerindeki noktalar $y=x$ eksenine ne kadar yakın ise modelin tahmin doğruluğunun o kadar yüksek olduğu söylenebilir.



Şekil 4.3 ANN-IV tahmin modelinin FEA sonuçlarıyla karşılaştırması (a) 1. mod frekans (b) Ağırlık (c) Maks. yer deęiřtirme

4.3 Önerilen Yapay Sinir Ağı Yöntemi ile Jant Modeli Optimizasyonu

Çalışma kapsamında araç tasarım süreçlerinde V-modeli esas alınarak araç seviyesinde belirlenen performans hedefleri sistem, alt sistem ve komponent seviyesine indirgenmiştir. İndirgenen performans hedeflerine göre tekil parça bazında hedefler ortaya çıkarılmıştır. Jant tasarım sürecinde hem tasarım süresini kısaltmak hem de hesaplama sürecinde zaman kazanmak adına parametre tahmin metotları ve vekil modeller kullanılmıştır. Bir sonraki adımda ise kullanılan vekil modeller üzerinden jant tasarım optimizasyonu gerçekleştirilerek jantın araç performans hedeflerine ulaşacak bir tasarıma kavuşturulması amaçlanmıştır. Tüm bunları yaparken de literatüre farklı bir metot ve yöntem kazandırılmıştır.

Çalışma dahilinde jant üzerindeki optimizasyon çalışması kurulan ANN-IV ve MLR vekil modelleri kullanılarak gerçekleştirilmiştir. Kurulan optimizasyon algoritmalarıyla vekil modeller adapte edilerek birer optimizasyon modeli oluşturulmuştur. Farklı tahmin modellerinin ve optimizasyon metotlarının aynı tasarım şartları için uygulanması sonucunda optimizasyon sonuçları elde edilmiştir. Çalışmada çok amaçlı genetik optimizasyon yani MOGA metodu ve alternatif bir metot olarak ise Bayes optimizasyon (BO) metotları kullanılarak optimizasyon işlemleri gerçekleştirilmiştir. Her iki metot ile elde edilen sonuçlar karşılaştırmalı olarak değerlendirilmiştir.

4.3.1 Çok amaçlı genetik optimizasyon algoritması

MOGA metodu genellikle birden fazla amaç fonksiyonu bulunduğunda ve bu amaç fonksiyonlarının maksimum veya minimum değerlerinin bulunması söz konusu olduğunda kullanılan bir metottur. MOGO farklı amaç fonksiyonları için optimum çözümleri bulmak amacıyla kullanılmaktadır. Algoritma optimum çözümü ararken aynı zamanda problemin limitleri ve kısıtlarının da tanımlanması gerekmektedir. Metot optimum çözüme ulaşmak için çalışırken, aynı zamanda problemin kısıtlarını da dikkate alarak sonuçlar üretmeyi sağlamaktadır. Amaç fonksiyonları arasında bu tip dengenin sağlandığı ve optimum çözüme ulaşmanın amaçlandığı bu tip çözümler pareto çözümler olarak adlandırılır (Anvari vd. 2021), (Ge vd. 2021).

Bu çalışma kapsamında alüminyum alaşımlı jant tasarım optimizasyonu probleminde optimum çözümü bulmak için basın olmayan sıralama genetik algoritması (NSGA-II) metodu kullanılmıştır. Kurulan MOGA modeliyle 2 adet amaç fonksiyonu tanımlanmıştır. 1. amaç fonksiyonu, jantın 1. mod frekans (Hz) değerinin maksimize edilmesi ve 2. amaç fonksiyonu ise jantın ağırlık (kg) değerinin minimize edilmesi olarak tanımlanmıştır. Ayrıca optimizasyon işlemi gerçekleştirilirken jantın yorulma performansının garanti edilmesi amacıyla kısıt fonksiyonu olarak jantın maksimum yer değiştirme (mm) değerinin 0.27 mm değerinden küçük olması kısıt fonksiyonu olarak tanımlanmıştır. Tanımlanan amaç ve kısıt fonksiyonları Çizelge 3.6'da verilen tasarım değişken sınır değerleri kullanılarak belirlenmiştir.

Çalışma kapsamında optimizasyon sürecinde parametre tahmin işleminde kullanılması amacıyla en iyi RMSE değerini veren ve en yüksek doğruluğa sahip olan ANN-IV tahmin modeli kullanılmıştır.

MOGA metodu başlangıç popülasyonunu rastgele oluşturan bir genetik algoritmadır. Optimizasyon işlemindeki amaç ve kısıt fonksiyonlarına dayalı olarak geliştirilen uygunluk fonksiyonu, ilk popülasyonun çaprazlamasının uygunluğuna bağlı olarak başlangıç değerlerinin uygunluğunu belirlemek için kullanılmıştır. MOGA kapsamında mutasyon ise yeni jenerasyonlar üretmek amacıyla uygulanmıştır. Bu işlem popülasyon yakınsayana veya maksimum jenerasyon sayısına ulaşıncaya kadar tekrarlı olarak devam eden bir işlemdir (Chaiyaratana vd. 2007).

Çizelge 4.5 Çok amaçlı optimizasyon modeli ana parametreleri

Parametre	Değer
Popülasyon Büyüklüğü	180
Jenerasyon	50
Pareto Oranı	0.35
Çaprazlama Oranı	0.8
Göç Oranı	0.2

Çalışma kapsamında uygulanan MOGA NSGA-II optimizasyon sürecinin ana parametreleri Çizelge 4.5'te verilmiştir. Çalışma kapsamında gerçekleştirilen her iki optimizasyon sürecinde de belirtilen parametreler kullanılmıştır.

Önerilen metotla tahmin edilen tasarım ve yanıt parametrelerinin optimizasyonu ile jant tasarım optimizasyonu gerçekleştirebilmek adına MOGA uygulaması yapılmıştır. GA hem ANN-IV hem de MLR tahmin metotları kullanılarak optimum jant tasarım parametrelerinin maksimum doğrulukla hesaplanması amaçlanmıştır. Kurulan ANN-IV ve MLR ile MOGA modelleri için optimizasyon sonuçları Çizelge 4.6'da verilmiştir.

Çizelge 4.6 MLR ve ANN-IV tahmin modelleri ile MOGA optimizasyon sonuçları

Metot	1. Mod Frekans (Hz)	Ağırlık (kg)	Maksimum Yer Değiştirme (mm)
MLR + MOGA	354.462	9.461	0.269
ANN-IV+MOGA	356.373	9.419	0.268
Başlangıç Model	340.542	10.014	0.264

Kullanılan jant tasarımının ilk halinde uygulanan sanal analizler sonucunda 1. mod frekans değeri 340.542, ağırlık 10.014 kg ve maksimum yer değiştirme değeri 0.264 mm olarak elde edilmiştir. Gerçekleştirilen MOGA optimizasyon çalışmaları sonucunda MLR+MOGA metodunun birlikte kullanılması sonucunda 354.462 Hz 1. mod frekans değeri 9.461 kg ağırlık ve 0.269 mm maksimum yer değiştirme değeri elde edilirken, ANN-IV+MOGA metodunun kullanımında 1. mod frekans değeri 356.373, ağırlık 9.419 ve maksimum yer değiştirme değeri ise 0.264 mm olarak elde edilmiştir. Optimizasyon sonucunda en yüksek 1. mod frekans değeri ve minimum ağırlık değeri ANN-IV+MOGA metodunun kullanımıyla elde edilmiştir.

MATLAB paket programı ile gerçekleştirilen MLR+MOGA ve ANN-IV+MOGA jant optimizasyon modelleri geliştirilen kod dizisi aracılığıyla oluşturulmuş ve optimizasyon işlemi uygulanmıştır. Her iki metotla gerçekleştirilen iterasyonlar sonucunda en iyi değerler elde edilmiştir. Elde edilen en iyi 15 değer her iki metot için de Çizelge 4.7 ve Çizelge 4.8'de verilmiştir.

Çizelge 4.7 MLR parametre tahmin ve MOGA optimizasyon metodu sonucu optimum değerler

N o	TD-1	TD-2	TD-3	TD-4	TD-5	TD-6	1. Mod Frekan s (Hz)	Ağırlık (kg)	Maks. Yer Değişirm e (mm)
1	3.228	2.598	3.310	11.372	17.197	403.638	354.462	9.461	0.270
2	3.396	2.624	3.404	11.196	17.408	403.589	354.140	9.484	0.270
3	3.519	2.588	3.410	11.410	17.350	403.629	353.938	9.496	0.270
4	3.753	2.575	3.939	11.250	17.198	403.585	353.633	9.524	0.269
5	3.218	2.721	3.351	11.444	17.297	403.641	353.254	9.498	0.270
6	4.035	2.609	3.443	11.603	17.440	403.661	353.080	9.559	0.269
7	3.218	2.777	3.340	11.442	17.279	403.642	352.982	9.509	0.270
8	4.373	2.611	3.591	11.791	17.462	403.663	352.233	9.605	0.269
9	4.259	2.631	4.114	11.300	17.588	403.709	351.963	9.606	0.268
10	3.866	2.726	3.382	12.207	17.207	403.599	351.576	9.589	0.269
11	3.792	2.700	3.735	11.516	17.808	403.677	351.396	9.583	0.270
12	4.146	2.660	4.197	11.700	17.411	403.651	351.067	9.620	0.268
13	5.643	2.887	3.587	11.557	17.498	403.719	350.711	9.766	0.265
14	3.458	2.659	3.786	12.098	17.691	403.648	350.365	9.573	0.271
15	4.859	2.837	3.603	11.991	17.707	403.722	349.778	9.719	0.267


Elde edilen 15 farklı değer içerisinde maksimum 1. mod frekans ve minimum ağırlık değerini sağlayan uygun değerler optimum tasarım parametreleri olarak belirlenmiştir. MLR tahmin modeli kullanılarak bulunan optimum sonuç değeri TD-1 3.228, TD-2 2.598, TD-3 3.310, TD-4 11.372, TD-5 17.197 TD-6 403.638, değerlerine sahip jant tasarımı için elde edilmiştir. ANN-IV tahmin modeli kullanılarak bulunan optimum jant tasarım parametreleri ise TD-1 4.062, TD-2 2.577, TD-3 3.048, TD-4 11.147, TD-5 16.656, TD-6 403.312'dir.

Optimizasyon işlemleri sonucunda elde edilen optimum 15 değere ek olarak her bir model için elde edilen tüm optimum sonuçlar Şekil 4.4 ve Şekil 4.6 pareto diyagramlarında verilmiştir. Ayrıca her bir iterasyon sonucunda belirlenen tasarım değişkenleri ise Şekil 4.5 ve Şekil 4.7'de gösterilmiştir.

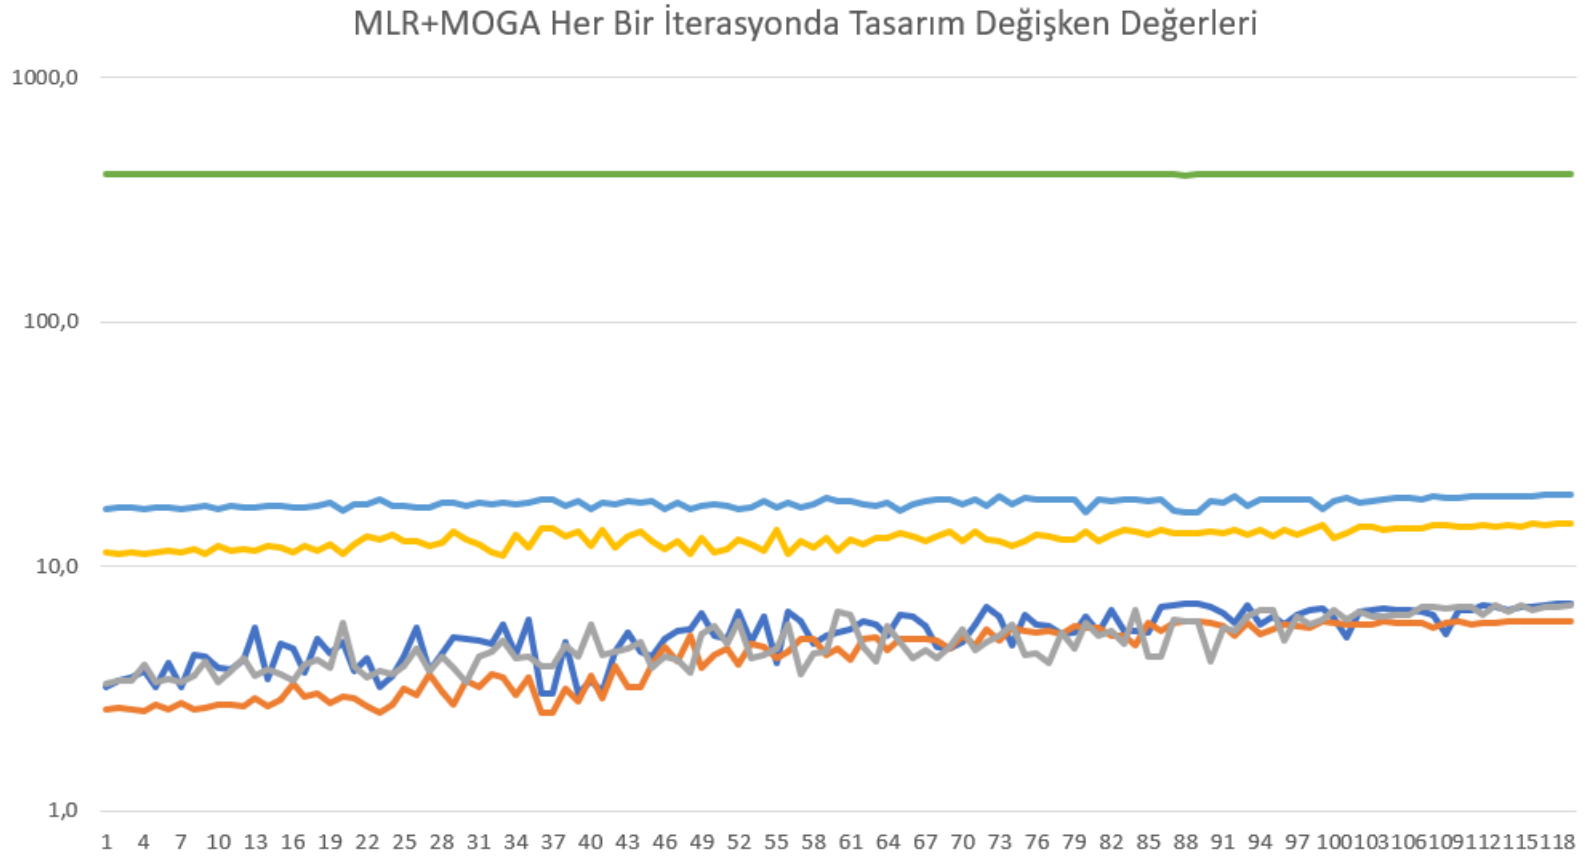
Çizelge 4.8 ANN-IV parametre tahmin ve MOGA optimizasyon metodu sonucu optimum değerler

N o	TD-1	TD-2	TD-3	TD-4	TD-5	TD-6	1. Mod Frekan s (Hz)	Ağırlık (kg)	Maks. Yer Değiştirm e (mm)
1	4.062	2.577	3.048	11.147	16.656	403.312	356.373	9.418	0.268
2	3.734	2.569	3.120	11.167	16.652	403.296	356.443	9.463	0.268
3	3.710	2.568	3.184	11.199	16.651	403.223	356.285	9.465	0.268
4	3.585	2.568	3.184	11.199	16.651	403.223	356.189	9.460	0.268
5	3.101	2.564	3.101	11.232	16.648	403.014	355.863	9.441	0.269
6	3.070	2.585	3.131	11.234	16.670	403.032	355.682	9.443	0.269
7	3.748	2.578	3.188	11.473	16.718	403.255	355.551	9.482	0.268
8	4.023	2.577	3.612	11.347	16.685	403.305	355.305	9.505	0.267
9	3.999	2.574	3.662	11.451	16.693	403.293	354.985	9.510	0.267
10	3.754	2.613	3.141	11.684	16.741	403.255	354.973	9.496	0.268
11	3.320	2.583	3.168	11.345	17.150	403.045	354.766	9.473	0.269
12	4.147	2.734	3.515	11.364	16.757	403.347	354.559	9.541	0.267
13	3.759	2.708	3.152	11.884	16.666	403.253	354.234	9.519	0.268
14	3.952	2.632	3.212	11.761	16.989	403.322	354.194	9.525	0.268
15	4.496	2.767	3.524	11.541	16.823	403.193	353.928	9.580	0.266


MLR+MOGA Optimizasyon Sonucu




Şekil 4.4 MLR+MOGA modeli optimizasyon sonucunda elde edilen optimum noktalar



Şekil 4.5 MLR+MOGA modeli optimizasyon sonucunda elde edilen optimum noktaların tasarım değişken değeri

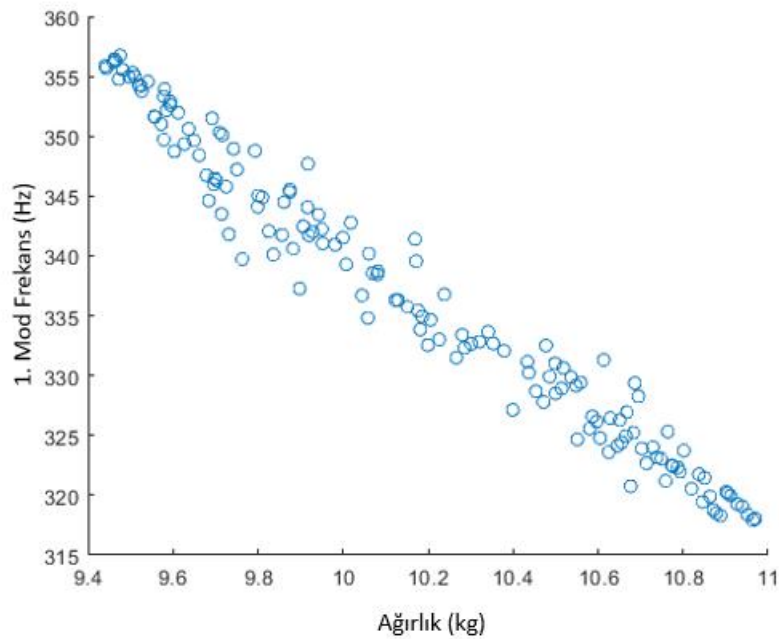


Şekil 4.6 ANN-IV+MOGA modeli optimizasyon sonucunda elde edilen optimum noktalar



Şekil 4.7 ANN-IV+MOGA modeli optimizasyon sonucunda elde edilen optimum noktaların tasarım değişken değeri

Gerçekleştirilen jant tasarım optimizasyon çalışması sonuçlarına göre ANN+MOGA modeli 0.27 mm maksimum yer değiştirme değerini sağlarken, 1. mod frekans değerinde MLR+MOGA modeline kıyasla +2 Hz daha yüksek değer ve ağırlık olarak ise -0.04 kg daha düşük değer sağlamaktadır. Önerilen ANN+MOGA modeli jant tasarım sürecinde 1. mod frekans değeri için 14% (+2 Hz) ve ağırlık değeri için ise 8% (-0.16 kg/araç) daha düşük ağırlık değeri sağlamaktadır. Bu da ANN tahmin modeli kullanılan optimizasyon çalışmasının MLR modeline kıyasla daha iyi optimizasyon sonuçları verdiğini göstermektedir.



Şekil 4.8 MOGA sonucunda elde edilen Pareto diyagramı


Çalışma kapsamında kurulan optimizasyon modelinde 2 amaç fonksiyonu olduğundan dolayı elde edilen sonuçlar sadece 1. mod frekans ve ağırlık fonksiyonları için değerlendirilmiştir. Maksimum yer değiştirme parametresi ise kısıt şartı olarak alındığından kısıt şartı olan maksimum yer değiştirme değeri için 0.27 mm'den küçük değerini optimizasyon modelinin her durumda sağlaması gerektiğinden pareto diyagramı sadece 2 amaç fonksiyonu için oluşturulmuştur. 6 tasarım değişkeni ve ANN-IV ve MOGA modelini referans alarak oluşturulan optimizasyon modeli sonuçları 2 amaç fonksiyonu değeri için Şekil 4.8'de verilmiştir. Optimizasyon süreci hedefleri göz önünde bulundurulduğunda verilen pareto diyagramı üzerindeki her bir nokta optimum nokta

olarak değerlendirilebilir. Optimizasyon işlemi sonucunda kısıt fonksiyonunu sağlayan optimum amaç fonksiyonu değerleri ANN-IV tahmin modeli ve MOGA optimizasyon metodu kullanılarak elde edilmiş olup, problemin optimum çözümü 1. mod frekans değeri için 356.373 Hz. ağırlık için 9.419 ve maksimum yer değiştirme değeri için ise 0.269 olarak belirlenmiştir.

Optimizasyon işlemi gerçekleştirilen alüminyum alaşımlı jant tasarımında belirlenen parametreler TD-1'den TD-6'ya kadar numaralandırılarak Şekil 3.18'deki gibi gösterilmiştir. Ayrıca jant tasarım parametrelerinden hedef yanıt değerleri üzerinde en yüksek etkiye sahip olan parametreleri belirlemek amacıyla hassasiyet analizi gerçekleştirilmiştir. Hassasiyet analizi aynı zamanda duyarlılık analizi olarak da literatürde yer almaktadır (Liu vd. 2022).

Çalışma kapsamında gerçekleştirilen hassasiyet analizinin sonuçları her bir yanıt parametresi için Şekil 4.8'deki gibi verilmiştir. Jantın flanş yüksekliği değerinin (TD-5) 1. mod frekans ve ağırlık parametre değerlerinin üzerinde en yüksek etkiye sahip olmasına rağmen jantın flanş (TD-4) genişliğinin jant maksimum yer değiştirme değeri üzerinde en yüksek etkiye sahip olduğu görülmektedir. Bu nedenle TD-4 ve TD-5 tasarım parametrelerinin araç ağırlık ve performansı üzerinde en yüksek etkiye sahip parametreler olduğu gösterilmiştir.

Önerilen metot jantın optimizasyon işlemini gerçekleştirerek, 1. mod frekans değerini arttırarak, diğer araç parçaları ve fonksiyonları ile frekans çakışmasının önüne geçmeyi sağlamaktadır. Bu sayede aracın gürültü karakteristiğine de doğrudan olumlu olarak etki etmektedir (Cremers vd. 2013). Ayrıca çalışma sonucunda aracın yaysız kütle adın verilen ağırlığı 2.38 kg azaltılarak aracın konfor performansında da iyileşme sağlanmıştır. Jantın dayanım ve yorulma hedeflerini sağlaması ayrıca aracın viraj denge yeteneğini de geliştirmektedir (Gobbi and Mastinu 2000).



Şekil 4.9 Tasarım değişkenleri ve yanıt değerleri için hassasiyet analizi a) 1. mod frekans b) Ağırlık c) Maks. yer değiştirme

Kurulan model üzerinde tasarım deęişkenleri ve yanıt deęerlerinin birbirleri arasındaki iliřkileri, etki oranları ve hassasiyet oranları yüzdesel olarak ve kümülatif olarak Şekil 4.9'da verilmiştir.

Genel olarak önerilen jant parametre tahmin modeli olan ANN-LM ve MLR metoduyla jant parametreleri ve yanıt deęerlerinin tahmin edilmesi sağlanarak jant tasarım optimizasyonunda 1. mod frekans ve ağırlık deęerleri MOGA metodu kullanılarak optimizasyon modelleri oluşturulmuş ve global optimum deęere en yakın deęeri veren metod belirlenmiştir. Önerilen ANN-LM metodunun dięer metoda kıyasla daha optimum deęerler verdięi sonucu gösterilmiştir. Ayrıca elde edilen sonuçlar üzerinden hassasiyet analizi gerçekleştirilmiş ve her bir tasarım deęişkeninin yanıt deęerleri üzerindeki etkileri tekil olarak incelenmiştir.

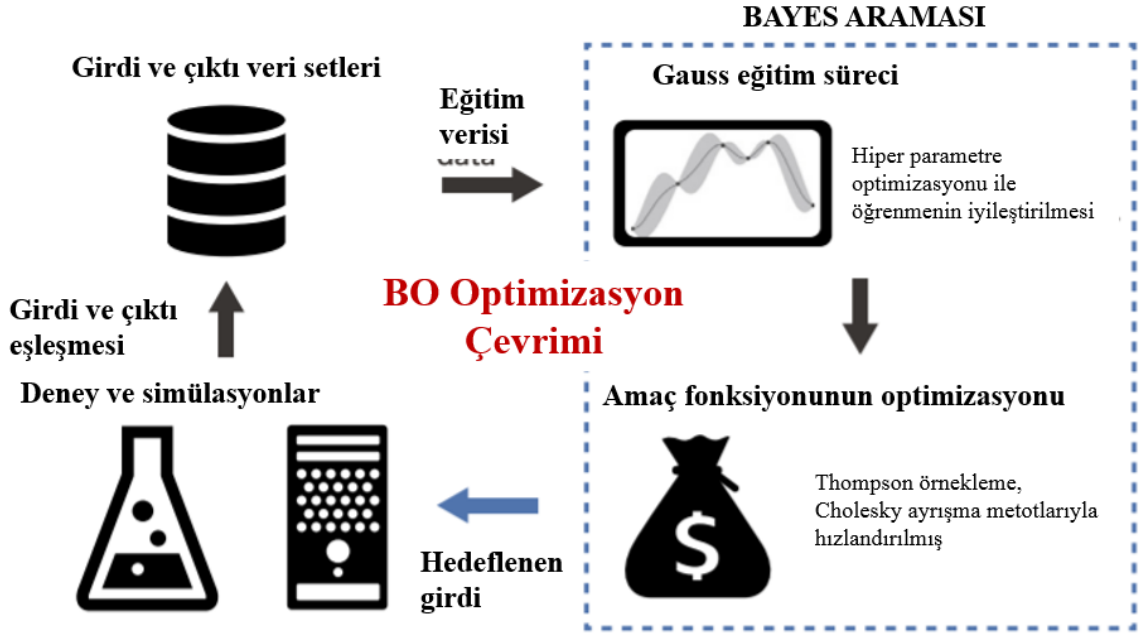
4.3.1 Bayes optimizasyonu

Temel fizik ve bilimde optimizasyon problemleri en sık karşılaşılan problemlerdendir. Genellikle en iyi çıktı deęerlerini elde edebilmek amacıyla uygun girdi veya parametre deęerlerinin bulunması optimizasyon sürecinin temelini oluşturmaktadır. Gauss sürecine (GP) dayanan bayes optimizasyon metodu, başlangıç bir veri setine sahip olunan ve makine öğrenimi yardımıyla parametre tahmin işleminin yardımıyla girdi parametre uzayında daha iyi çıktı sonuçları veren girdi parametreleri bulmak için kullanılabilir (Quinero-Candela vd. 2005).

Bayes optimizasyonu araçların lithium-ion bataryalarında hızlı şarja uygun tasarım optimizasyonu için (Jiang vd. 2022), yarı aktif süspansiyon sistemi tasarımı (Savaia vd. 2020) ve araçta sensor yerleşim probleminin optimizasyonu (He vd. 2019) gibi otomotiv sektöründe birçok optimizasyon probleminin çözümünde sıkça kullanılmaktadır. Ayrıca BO metodu derin öğrenme metodunun kullanıldığı yapay sinir ağı tahmin modelinde hiper parametre optimizasyonu gibi problemler için de kullanılmaktadır (Shin vd. 2020).


BO metodunda, daha önceden belirlenen deneysel bir çalışma veya analiz sonucu elde edilmiş olan bir veri seti kullanılarak eğitilen bir Gauss yöntemi aracılığıyla hedeflenen

çıkı değerleri ve bu değerlerin varyans değerleri tahmin edilir. Bir sonraki aşamada ise öğrenme işlemi tamamlanmış GP, hedef fonksiyonuna bağlı olarak daha iyi ve optimuma daha yakın yanıt değerlerini elde etme olasılığı en yüksek olan girdi değerlerini seçer. BO algoritması bu işlemleri her döngüde tekrar ederek optimum girdi ve çıkı değerlerine ulaşana kadar döngünün devam etmesini sağlar (Tran vd. 2019).



Şekil 4.10 Bayes optimizasyon metodu akış şeması (Motoyama vd. 2022)

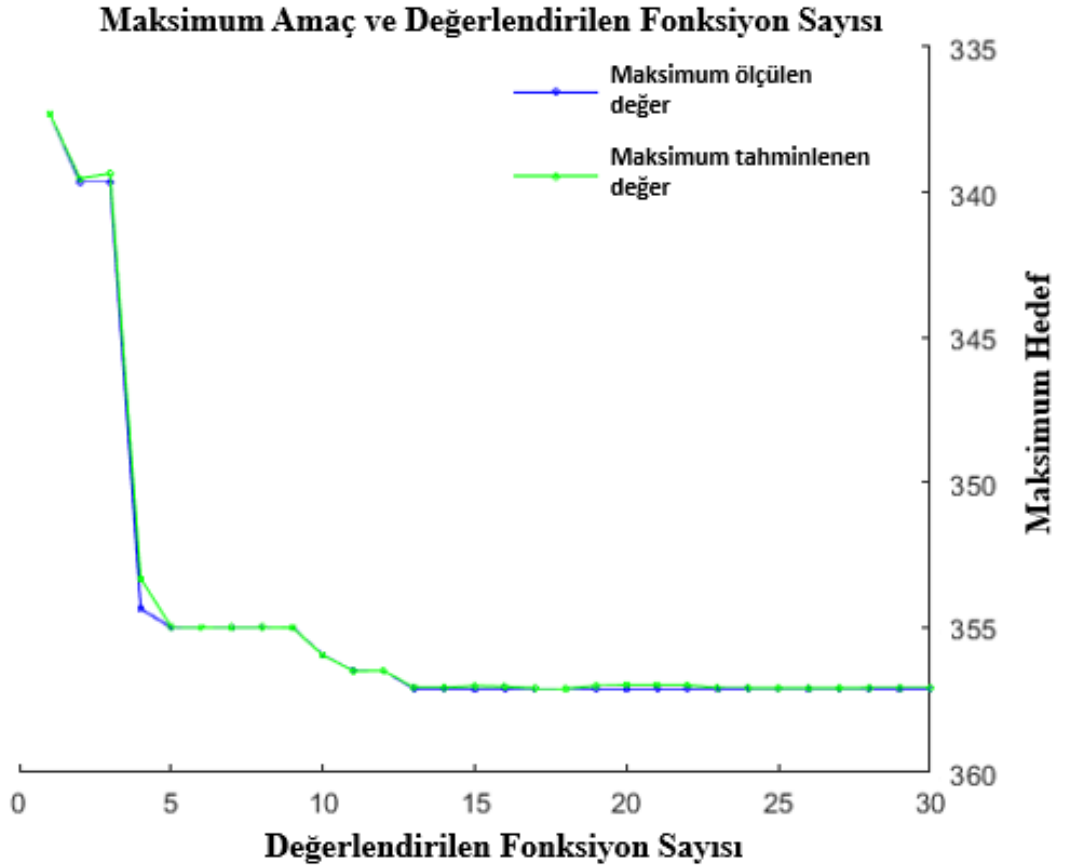
BO sürecinde en uygun yanıt değerlerini sağlayan ve global optimum değere en yakın yanıt değerlerini veren girdi yani tasarım değişken değerleri elde edilirken kullanılan akış diyagramı Şekil 4.10'da verilmiştir. BO süreci bu akış diyagramına uygun olarak en uygun sonuçlar elde edilinceye kadar devam eder. Süreç içerisinde eğitim ve hiper parametre optimizasyonu gibi aşamalar da bulunmaktadır. Bu çevrim sonucunda optimum sonuç değerleri elde edilir ve optimizasyon işlemi tamamlanır. BO özellikle eğitim veri seti bulunan ve derin öğrenme tabanlı parametre tahmin metodlarının kullanıldığı optimizasyon problemlerinde sıkça kullanılmaktadır (Tran vd. 2019).



Şekil 4.11 Bayes optimizasyon algoritması

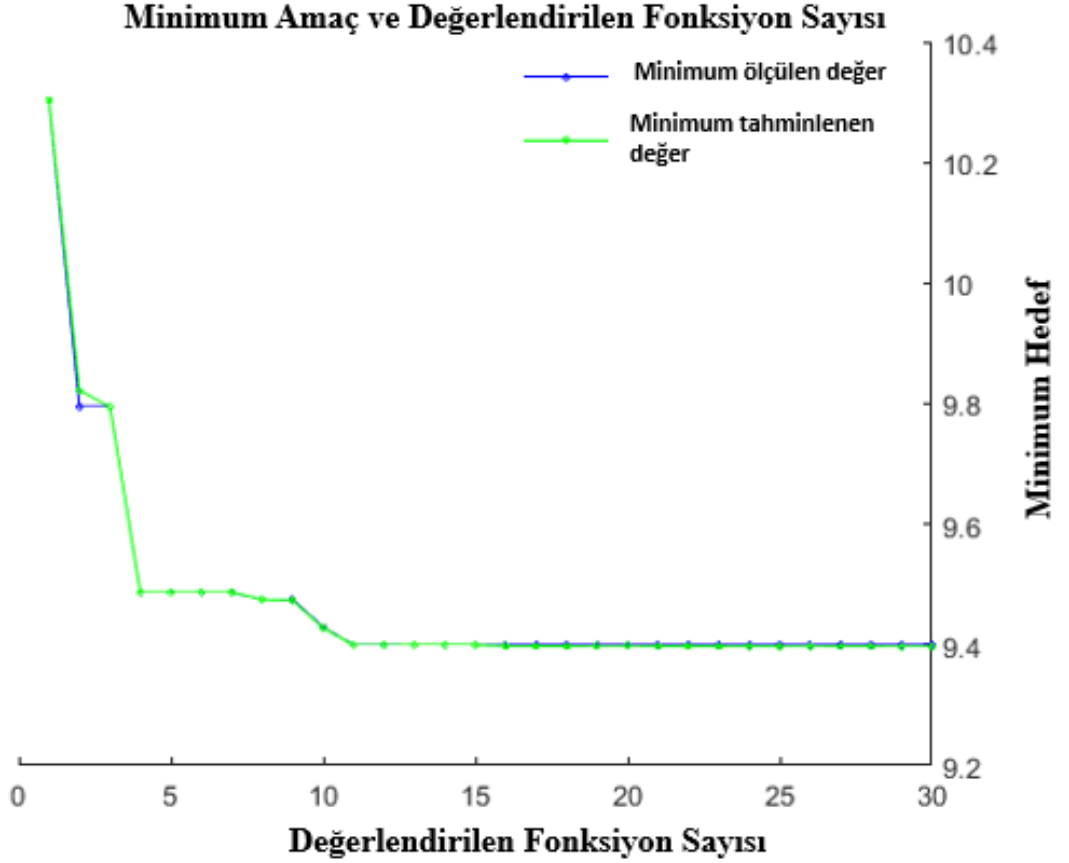
Çalışma kapsamında BO işlemi MATLAB paket programı üzerinde kurulan ve yazılan bir kod dizisi aracılığıyla gerçekleştirilmiştir. MATLAB paket programı üzerinde BO algoritması parametre tahmin aşamasında oluşturulan ANN-IV tahmin modeli ile bağlanmış ve BO döngüsü kurulmuştur. Model 2 farklı amaç fonksiyonu için ayrı ayrı değerlendirilmiş ve 1. mod frekans değerini maksimize ederken, jantın ağırlık değerini minimize eden değere ulaşmak hedeflenmiştir. Kurulan model üzerinde 30 iterasyon sonucunda optimum sonuca ulaşılmıştır.

Oluşturulan kod dizisi öncelikle tasarım değişkenlerinin belirlenmesi, tasarım değişkenlerinin alt ve üst limitlerinin tanımlanmasını gerçekleştirir. Akabinde amaç ve kısıt fonksiyonlarının tanımlanması yapılarak bayes optimizasyon döngüsü başlatılır. Döngü amaç ve kısıt fonksiyonlarını göz önüne alarak optimum sonuca ulaşana kadar devam eder. Algoritma detayları Şekil 4.11’te verilmiştir.



Şekil 4.12 BO iterasyon ve 1. mod frekans optimizasyonu

Kurulan BO optimizasyon modeli çalıştırıldığında 30 iterasyon sonucunda elde edilen maksimum 1. mod frekans ve minimum jant ağırlık değerleri MATLAB paket programı üzerinde elde edilmiş ve program üzerinden elde edilen optimizasyon sonuç değerleri ve çevrim sonuçları Şekil 4.12 ve Şekil 4.13’de gösterilmiştir. Optimizasyon işlemi sonucunda model yakınsamış ve her iki amaç fonksiyonu için de optimum değerler elde edilmiştir.



Şekil 4.13 BO iterasyon ve ağırlık optimizasyonu

BO işlemi sonucunda global optimum nokta olarak jantın 1. mod frekans değeri olarak 355.719 Hz, ağırlık olarak 9.423 kg ve maksimum yer değiştirme değeri olarak ise 0.269 mm bulunmuştur. Optimizasyon işlemi sonucunda elde edilen değerler başlangıç modelin analiz sonuçları ve bir ANN-IV+MOGA modelinin kullanıldığı optimizasyon sonuçlarıyla karşılaştırmalı olarak Çizelge 4.9’da verilmiştir.

Çizelge 4.9 Farklı optimizasyon metotlarının sonuçlarının ve başlangıç modelinin karşılaştırmalı olarak analizi

Metot	1. Mod Frekans (Hz)	Ağırlık (kg)	Maksimum Yer Değiştirme (mm)
ANN-IV+BO	355.719	9.423	0.269
ANN-IV+MOGA	356.373	9.419	0.268
Başlangıç Model	340.542	10.014	0.264

Her iki optimizasyon metoduyla gerçekleştirilen optimizasyon sonuçları kıyaslandığında her ne kadar BO ve MOGA metotları sonucunda elde edilen değerler birbirine çok yakın olsa da ANN-IV+BO metodunda 1. mod değeri 355.719 Hz, ağırlık 9.423 kg ve maksimum yer değiştirme 0.269 mm elde edilirken, ANN-IV+MOGA metoduyla gerçekleştirilen optimizasyon işlemi sonucunda 1. mod frekans değeri 356.373 Hz, ağırlık 9.419 kg ve maksimum yer değiştirme 0.268 mm olarak elde edilmiştir. Her iki çözüm de sınır değer olan 0.27 mm yer değiştirme değerinin altındadır. 1. mod frekans değeri maksimize edilmesi hedeflenirken ANN-IV+MOGA metodunda daha yüksek bir değer elde edilmiştir. ANN-IV+MOGA modeli optimizasyon amaç fonksiyonunda minimize edilmek istenen ağırlık değerinde ise daha düşük ağırlıkta bir tasarım çözümü ortaya koymuştur. Buradan hareketle MOGA metodunun BO metoduna göre daha iyi sonuç verdiği ortaya konulmuştur.

Çizelge 4.10 Optimum değerleri veren tasarım değişken değerleri

	TD-1	TD-2	TD-3	TD-4	TD-5	TD-6
ANN-IV+MOGA	3.443	2.521	3.163	11.022	16.687	403.550
ANN-IV+BO	4.062	2.577	3.048	11.147	16.656	403.312

Her iki metot için de optimum yanıt değerlerinin elde edildiği tasarım değişken değerleri karşılaştırmalı olarak Çizelge 4.10 üzerinde verilmiştir. Genel itibariyle her iki optimizasyon sonucunda da benzer tasarım değişken değerleri elde edilmiş olsa da MOGA metodu ilgili optimizasyon problemi için global değerlere en yakın sonuçları ortaya koymuştur.

5. TARTIŞMA VE SONUÇ

5.1 Önerilen Yapay Sinir Ağı Tabanlı Çok Amaçlı Genetik Algoritma Optimizasyon Metodunun Güçlü Yönleri ve Katkıları

Hsu vd. (2001), jantın yorulma gereksinimlerini sağlarken, aynı zamanda ağırlık azaltmayı hedefleyen bir jant tasarım optimizasyon uygulaması ortaya koymuşlardır. Jantın spoke arkası kısmından belirlenen 2 tasarım parametresinin farklı değerleri için deneysel sonuçlar elde etmişler ve elde edilen deneysel sonuçları ANN model eğitiminde kullanmışlardır. Ye vd. (2014), ise jant için belirlenen şekil parametrelerini parametrik olarak jantın optimizasyonu için belirlemiş ve jant mekanik özelliklerini belirlemek için kullanmışlardır. Literatürdeki çalışmalarda genel olarak jant tasarım sürecini iyileştirmek için farklı metotların kullanıldığı görülmektedir. Bazı çalışmalarda tecrübeye dayalı metotların kullanımı mevcutken, günümüzde daha çok jant tasarım parametrelerinin meta veya vekil model kullanılarak tahmin gerçekleştirildiği ve optimizasyon işleminin uygulandığı görülmektedir. Ancak literatürde uygulanan çalışmalarda regresyon tabanlı hesaplamalı metotların parametrelerin tahmin sürecinde uygulamaları mevcuttur. Parametre tahmin sürecinde ANN gibi hem tasarım uzayı içerisinde hem de tasarım uzayı dışında tahmin doğruluğu daha yüksek metotların kullanımıyla hem parametre tahmin doğruluğunu hem de optimizasyon sonuçlarını iyileştirmek mümkündür.

Bu çalışma kapsamında jant tasarım sürecinde jantın modal frekans değerini arttırmak ve ağırlık azaltımı sağlamak amacıyla ANN ve GA tabanlı parametre tahmin ve optimizasyon metodu sunulmuştur. Ayrıca ANN parametre tahmin metoduna alternatif olarak regresyon tabanlı MLR metoduyla hem parametre tahmin doğruluğu hem de optimizasyon sonuçları açısından kıyaslanmıştır. Ye vd. (2014), tarafından önerilen regresyon tabanlı metoda alternatif ve doğruluğu daha yüksek bir jant optimizasyon metodu olarak katkı sağlamıştır. Bununla birlikte jant tasarım optimizasyon sürecinde tasarım uzayı dışında parametre değerlerinin belirlenmesi durumlarında ANN tahmin metodunun kullanımının optimizasyon sürecine katkı sağladığı gösterilmiştir.

Çalışma kapsamında önerilen ANN ve GA tabanlı metot yaklaşımıyla jant tasarım süreci iyileştirilmiş ve daha yüksek jant performans sonuçları elde edilmiştir. Bu durum aynı

zamanda mühendislere jant tasarım sürecinde yeni tasarım önerileri ve yeni alternatiflerin uygulanmasında uzun süren hesaplamalı analizlerin veya deneylerin tekrarlanmasına gerek kalmadan optimizasyon işleminin gerçekleştirilmesine olanak sağlamaktadır.

Uygulanan diğer parametre tahmin metotlarına kıyasla ANN-LM parametre tahmin ve GA optimizasyon metoduyla jantın modal frekans performansını iyileştirmek ve ağırlığını azaltmak aşamasında daha yüksek tahmin ve optimizasyon performansı gösterdiği görülmektedir. Ayrıca önerilen metot jant tasarım sürecinde hesaplama süresi ve tasarım süresini de kısaltmaktadır. Şekil 4.4 ve Şekil 4.6'da sunulan optimizasyon sonuçları göre ANN ve GA uygulamasıyla MLR ve GA metoduna kıyasla jantın 1. mod frekans değerinde 14% (+2 Hz), ağırlığında 8% (-0.16 kg/araç) daha iyi sonuçlar elde edildiği görülmektedir. Sonuç olarak başlangıç jant tasarımına kıyasla +16 Hz 1. mod frekans değeri elde edilmiş ve jant başına-0.59 kg ağırlık azaltılmıştır. Bu nedenle önerilen ANN tabanlı parametre tahmin metodunun diğer MLR ve DOE tabanlı metotlara kıyasla daha iyi performans gösterdiğini söylemek mümkündür.

Çalışma dahilinde MOGA optimizasyon metoduna alternatif olarak BO metodu da yine parametre tahmin aşamasında en yüksek doğruluğa sahip olan ANN-IV tahmin modeliyle birlikte uygulanmıştır. Her iki optimizasyon metodu da aynı parametre tahmin metoduyla birlikte uygulanmış ve sonuçları karşılaştırmalı olarak değerlendirilmiştir. Ancak elde edilen optimizasyon sonuçları kıyaslandığında MOGA optimizasyon metodunun jant tasarım sürecinde BO metoduna göre global optimum değere daha yakın sonuçlar ortaya koyduğu görülmüştür.

Çalışma kapsamında önerilen metotla ANN tasarım parametrelerini tahmin etmek için vekil model olarak kullanılmış ve GA modeli kurularak jantın tasarım optimizasyonu gerçekleştirilmiştir. Bu çalışma ürün geliştirme sürecinde, akıllı jant tasarım metotları alanında ANN tabanlı tahmin algoritmalarının kullanılmasında öncü bir yaklaşımdır. Geliştirilen metot jantın tasarım ve hesaplama zamanlarını kısaltırken, aynı zamanda jant modal performansını iyileştirmekte ve araç ağırlığını azaltmaktadır.

Zorlu jant tasarım hedefleri ve farklı tasarım hedefleri söz konusu olduğunda, jant tasarım parametrelerinin tahmin edilmesi ve hesaplamalı olarak optimum sonucun bulunmasında ANN tabanlı tahmin metodu kolaylıkla jant tasarım ve ürün geliştirme süreçlerine uygulanabilir bir metottur. Bu çalışma ve çalışma sonucunda elde edilen sonuçlar, tecrübeye dayalı yeni tasarım önerilerinin kullanılması veya jant tasarım parametrelerinin tahmininde kullanılan diğer metotlar ile yeni tasarım çözümlerinin tahmin edilmesinde ANN metodunun etkinliğini ortaya koymakta ve jant tasarım süreçleri için yeni bir metodun kullanımını literatüre kazandırmaktadır.

5.1 Gelecek Çalışmalar

Çalışma kapsamında uygulanan ve önerilen tüm ANN tabanlı tahmin metotlarında modelin parametreleri rastgele seçilmiş veya GA kullanılarak optimize edilmiştir. Kurulan MLP modelleri Çizelge 3.12’de belirtildiği gibi modelin tipine bağlı olarak rastgele veya GA metoduyla ağırlık ve bias gibi parametreleri Şekil 3.18’de belirtilen akış diyagramına göre optimizasyonu ile belirlenmiştir. Ancak jant tasarım sürecinde ANN modelinin performansını daha ileriye taşıyabilecek farklı optimizasyon algoritmaları kullanılarak karşılaştırma yapılması kapsam dışında kalmıştır. Farklı optimizasyon metotlarının ANN parametrelerinin optimizasyonundaki etkinliğinin kıyaslanması gelecekte araştırmacılar için iyi bir araştırma konusu olabilir.

Ayrıca çalışma kapsamında elde edilen sonuçlarla ANN tabanlı tasarım parametresi tahmin metodunun jant tasarım optimizasyonu süreçlerindeki başarısı ile önerilen metodun oldukça etkili ve rekabetçi bir metot olduğu görülmüştür. Bu nedenle çalışma kapsamında uygulandığı gibi farklı alanlardaki literatür çalışmaları incelenerek parametre tahmin metotları irdelenerek jant tasarım sürecinde performansı iyileştirmek adına değerlendirilebilir ve jant tasarım süreçleri için yeni metotlar geliştirilebilir. ANN metodunun jant tasarım sürecindeki etkinliğinin farklı yapısal tasarım parçaları üzerinde de parametre tahmin sürecinde değerlendirilme yapılması ve farklı disiplinlerde de uygulama örnekleri ortaya konulması mümkündür.

KAYNAKLAR

- Abd Ellah, A. R., Essai, M. H., Yahya, A. (2015). Comparison of different backpropagation training algorithms using robust M-estimators performance functions. *Conference: 2015 Tenth International Conference on Computer Engineering & Systems (ICCES)*, <https://doi.org/10.1109/ICCES.2015.7393080>
- Abrouguia, K., Gabsib, K., Mercatorisc, B., Khemisa, C., Amamia, R., Chehaibia, S. (2019). Prediction of organic potato yield using tillage systems and soil properties by artificial neural network (ANN) and multiple linear regressions (MLR). *Soil & Tillage Research*, 190: 202-208. <https://doi.org/10.1016/j.still.2019.01.011>
- Anvari, S. Mahian, O. Solomin, E. Wongwises, S. Desideri, U. (2021). Multi-objective optimization of a proposed multi-generation cycle based on pareto diagrams: Performance improvement, cost reduction, and CO2 emissions. *Sustainable Energy Technologies and Assessments*, 45. <https://doi.org/10.1016/j.seta.2021.101197>
- Bae, J., Jung, K., Yoo, S., Chang, S., Kim, M., Lim, T. (2015). Design and fabrication of a metal-composite hybrid wheel with a friction damping layer for enhancement of ride comfort. *Composite structures*, 133: 576-584. <http://dx.doi.org/10.1016/j.compstruct.2015.07.113>
- Balla, V.K., Coox, L., Deckers, E., Plyumers, B., Desmet, W., Marudachalam, K. (2018). Obtaining manufactured geometries of deep-drawn components through a model updating procedure using geometric shape parameters. *Mechanical Systems and Signal Processing*, 98:382-401. <http://dx.doi.org/10.1016/j.ymsp.2017.05.009>
- Bawne, S. K. Yenarkar, Y.L. (2015). Optimization Of Car Rim. *Int. Journal of Engineering Research and Applications*, 5 (10) : 1-8.
- Baykasoğlu, A., Baykasoğlu, C., Cetin, E. (2020). Multi-objective crashworthiness optimization of lattice structure filled thin-walled tubes. *Thin-Walled Structures*, 149:106630. <https://doi.org/10.1016/j.tws.2020.106630>
- Beale, M. H., Hagan, M. T., Demuth, H. B. (2017). *Neural Network Toolbox™ User's Guide*. The MathWorks, Inc.
- Bogoclu, C., Roos, D., Nestorović, T. (2021). Local Latin hypercube refinement for multi-objective design uncertainty optimization. *Applied Soft Computing*, 112. <https://doi.org/10.1016/j.asoc.2021.107807>
- Borecki, M., Rychlik, A., Vrublevskiy, O., Olejnik, A., Pawlowski, M.L.K. (2021). Method of non-Invasive determination of wheel rim technical condition using vibration measurement and artificial neural network. *Measurement*, 185. <https://doi.org/10.1016/j.measurement.2021.110050>
- Chaiyaratana, N., Piroonratana, T., Sangkawelert, N. (2007). Effects of diversity control in single-objective and multi-objective genetic algorithms. *J Heuristics*, 13:1–34. <https://doi.org/10.1007/s10732-006-9003-1>
- Cremers, Dr. L., Masri, N. E. Tamarozzi, T, Coox L., Landrain, M., Vanderheggen, B. (2012). Full vehicle early-phase concept optimization for premium NVH comfort at BMW. *MSc Software 2012 Regional User Conference*,
- Das, B., Paula, S. K., Singha, A., Arorab, K. S., Shome M. (2020). The effect of thickness variation and pre-strain on the cornering fatigue life prediction of a

DP600 steel wheel disc. *International Journal of Fatigue*, 139. <https://doi.org/10.1016/j.ijfatigue.2020.105799>

Das, S. (2014). Design and weight optimization of aluminum alloy wheel. *International Journal of Scientific and Research Publications*, 4 (6).

Deng, Y., Zhao, Y., Lin F., Zang, L. (In Press). Influence of structure and material on the vibration modal characteristics of novel combined flexible road wheel. *Defence Technology*, <https://doi.org/10.1016/j.dt.2021.05.016>

Ding, Y., Deng, Y. & Li, A. (2010). Study on correlations of modal frequencies and environmental factors for a suspension bridge based on improved neural networks. *Technological Sciences*, 53 (9):2501-2509. <https://doi.org/10.1007/s11431-010-4056-7>

Dong, B., Goetchius, G. M., Balasubramanian, M., Duncan, A. E., Gogate, S. D. (1999). "Process to achieve NVH goals: Subsystem targets via digital prototype simulations. *Society of Automotive Engineers*, 1999-01-1692.

E.T.R.T.O. (2021). Standards manual. *European Tyre and Rim Technical Organisation*.

Farahani, A. & M., Heshmatnejad. H. (2017). Towards automotive NVH enhancement: structural dynamics analysis of a vehicle wheel. *American Scientific Research Journal for Engineering, Technology, and Sciences (ASRJETS)*, 2313-4410:51-58.

Fletcher, R. & Reeves, C. M. (1964). Function minimization by conjugate gradients. *Comput. J.*, 7:149-154.

Fürst, A. & Vietor T. (2019). A methodical approach for improved control of safety-related product properties in early phases of the automotive product development process. *Procedia CIRP*, 84: 605-610. <https://doi.org/10.1016/j.procir.2019.04.209>

Ge, Y., Lin, Y., Tao, S., He, Q., Chen, B., Huang, S. (2021). Shape optimization for a tube bank based on the numerical simulation and multi-objective genetic algorithm. *International Journal of Thermal Sciences*, 161. <https://doi.org/10.1016/j.ijthermalsci.2020.106787>

Ghosal, P. S., Gupta, A. K. (2016). Enhanced efficiency of ANN using non-linear regression for modeling adsorptive removal of fluoride by calcined Ca-Al-(NO₃)-LDH. *Journal of Molecular Liquids*, 222: 564-570. <http://dx.doi.org/10.1016/j.molliq.2016.07.070>

Ghosal, P. S., Gupta, A. K. (2016). Enhanced efficiency of ANN using non-linear regression for modeling adsorptive removal of fluoride by calcined Ca-Al-(NO₃)-LDH. *Journal of Molecular Liquids*, 222: 564-570. <http://dx.doi.org/10.1016/j.molliq.2016.07.070>

Giunta, A. A., Wojtkiewicz, S. F. Jr., Eldred, M., S.. (2003). Overview of modern design of experiments methods for computational simulations. *American Institute of Aeronautics and Astronautics*, 2003-0649. <https://doi.org/10.2514/6.2003-649>

Gobbi, M. & Mastini, G. (2001). Analytical description and optimization of the dynamic behaviour of passively suspended road vehicles. *Journal of Sound and Vibration*, 245 (3): 457-481. <https://doi.org/10.1006/JSVI.2001.3591>

Goelke, M. (2017). Introduction into design of experiments DOE with hyperStudy.

Hagan, M.T. & Menhaj, M. B. (1994). Training feedforward networks with the marquardt algorithm. *IEEE Transactions on Neural Networks*, 5:6 989-993.

- Hamidian, H., Lahijani, A. T., Shahriari, S. (2017). Fatigue life enhancement of automobile wheel disc considering multi-axial stresses based on critical plane approach. *Journal of Mechanical Science and Technology*, 31 (6): 2883-2892. <https://doi.org/10.1007/s12206-017-0531-4>
- He, K., Jia, M., Liu C., Zhao, Z. (2019). Sensor layout optimization by integrating Bayesian approach to diagnose multi-station assembly processes. *Measurement*, 146 230-240. <https://doi.org/10.1016/j.measurement.2019.06.021>
- Hsu, Y., Hsu, M. (2001). Weight reduction of aluminium disc wheels under fatigue constraints using a sequential neural network approximation method. *Computers in industry*, 46: 167-179. [https://doi.org/10.1016/S0166-3615\(01\)00125-7](https://doi.org/10.1016/S0166-3615(01)00125-7)
- Huda, A.S.N., & Taib, S. A. (2014). A Comparative study of MLP networks using backpropagation algorithms in electrical equipment thermography. *Arab J Sci Eng*, 39:3873–3885. <https://doi.org/10.1007/s13369-014-0989-7>
- Ibrahim, N., Cox, S., Mills, R., Aftelak, A., Shah, H. (2021). Multi-objective decision-making methods for optimising CO2 decisions in the automotive industry. *Journal of Cleaner Production*, 314. <https://doi.org/10.1016/j.jclepro.2021.128037>
- Işık, M., Gören, B. K., Özer, S., Kara, A. (2018). Alüminyum alaşımlı binek araç jantlarının dinamik viraj yorulması davranışının deneysel ve sayısal olarak incelenmesi. *9th International Automotive Technologies Congress, OTEKON 2018*: 859-868.
- Jape, R. K. & Jadhav, S. G. (2016). CAD modeling and FEA analysis of wheel rim for weight reduction. *International Journal of Engineering Science and Computing*, 6 (6):7404-7411. [http://dx.doi.org/10.1016/S0921-5093\(99\)00653-X](http://dx.doi.org/10.1016/S0921-5093(99)00653-X)
- Jiang, B., Berliner, M. D., Lai, K., Asinger, P. A., Zhao, H., Herring, P. K., Bazant, M. Z., Braatz, R. D. (2022). Fast charging design for lithium-ion batteries via bayesian optimization. *Applied Energy*, 307. <https://doi.org/10.1016/j.apenergy.2021.118244>
- Jiang, X., Liu, H., Lyu, R., Fukushima, Y., Kawada, N., Zhang, Z., Ju, D. (2019). Optimization of Magnesium Alloy Wheel Dynamic Impact Performance. *Advances in Materials Science and Engineering*, Volume 2019. <https://doi.org/10.1155/2019/2632031>
- Jiang, X., Lyu, R., Fukushima, Y., Otake, M., Ju, D.Y. (2018). Lightweight design and analysis of automobile wheel based on bending and radial loads. *International Conference on Material Strength and Applied Mechanics*, 372. <http://dx.doi.org/10.1088/1757-899X/372/1/012048>
- Kalogirou, S.A. (2003). Artificial intelligence for the modeling and control of combustion processes: a review. *Progress in Energy and Combustion Science*, 29: 515-566. [https://doi.org/10.1016/S0360-1285\(03\)00058-3](https://doi.org/10.1016/S0360-1285(03)00058-3)
- Kaya, N., Karen, I., Öztürk, F. (2010). Re-design of a failed clutch fork using topology and shape optimisation by the response surface method. *Materials and Design*, 31: 3008–3014. <https://doi.org/10.1016/j.matdes.2010.01.002>
- Kim, J., Kim, J.J., Jang, I.G. (2022). Integrated topology and shape optimization of the five-spoke steel wheel to improve the natural frequency. *Structural and Multidisciplinary Optimization*, 65:78 <https://doi.org/10.1007/s00158-022-03183-3>

- Kong, Y.S., Schramm, S., Abdullah, D., Omar, M.Z., Haris, S.M. (2019). Optimization of spring fatigue life prediction model for vehicle ride using hybrid multi-layer perceptron artificial neural networks. *Mechanical Systems and Signal Processing*, 122:597-621. <https://doi.org/10.1016/j.ymssp.2018.12.046>
- Lin, H. (2012). Optimizing the auto-brazing process quality of aluminum pipe and flange via a Taguchi-Neural-Genetic approach. *J IntellManuf*, 23:679–686 <https://doi.org/10.1007/s10845-010-0418-z>
- Lipiński, T., (2020). Mechanical properties the AL-7%SiMg Alloy With CuAl10Fe3Mn2 Used in Machine Building and Civil Engineering. *QPI*, 2:247-258. <https://doi.org/10.2478/cqpi-2020-0028>
- Liu, L., Ao, T., Zhou, L., Takeuchi, K., Gusyev, M., Zhang, X., Wang, W., Ren, Y. (2022). Comprehensive evaluation of parameter importance and optimization based on the integrated sensitivity analysis system: A case study of the BTOP model in the upper Min River Basin, China. *Journal of Hydrology*, 610. <https://doi.org/10.1016/j.jhydrol.2022.127819>
- Marzbanrad, J. & Ebrahimi, M. R. (2011). Multi-Objective Optimization of aluminum hollow tubes for vehicle crash energy absorption using a genetic algorithm and neural networks. *Thin-Walled Structures*, 49:1605-1615. <https://doi.org/10.1016/j.tws.2011.08.009>
- Mayén, J., Abúndez, A., Pereyra, I., Colín, J., Blanco, A., Serna, S. (2017). Comparative analysis of the fatigue short crack growth on Al6061-T6 alloy by the exponential crack growth equation and a proposed empirical model. *Engineering Fracture Mechanics*, 177: 203-217. <http://dx.doi.org/10.1016/j.engfracmech.2017.03.036>
- Miller W.S., Zhuang, L., Bottema, J., Wittebrood, A.J., Smet, P. D., Haszler, A., Vieregge, A., (2000). Recent development in aluminium alloys for the automotive industry. *Materials Science and Engineering*, A280: 37-49. [https://doi.org/10.1016/S0921-5093\(99\)00653-X](https://doi.org/10.1016/S0921-5093(99)00653-X)
- Mohammadi, S., Sadeghi, A., Sadeghi, M.H. (2018). Fatigue behavior of MG alloys automotive components. *9th International Automotive Technologies Congress, OTEKON*, 2018: 83-91.
- Motoyama, Y., Tamura, R., Yoshimura, K., Terayama, K., Ueno T., Tsuda K., (2022). Bayesian optimization package: PHYSBO. *Computer Physics Communications*, 278. <https://doi.org/10.1016/j.cpc.2022.108405>
- Oh, S., Jiang, C., Jiang, C., Marcus, P. S., (2018). Finding the optimal shape of the leading-and-trailing car of a high-speed train using design-by-morphing. *Comput Mech.*, 62:23-45. <https://doi.org/10.1007/s00466-017-1482-4>
- Özaydın, O., Arman, E., Özdemir K. (2018). Jant Kolu Arkası Boşluğunun Parametrik Tasarımı ve Optimizasyonu. *10. Uluslararası döküm kongresi*.
- Park H., Dang, X. (2010). Structural optimization based on CADCAE integration and metamodeling techniques. *Computer-Aided Design*, 42:889-902. <https://doi.org/10.1016/j.cad.2010.06.003>
- Park, S. Y., Park, Y.G., Park, S.H., Ha, M.Y. (2021). Numerical study and multilayer perceptron-based prediction of melting process in the latent heat thermal energy storage system with a finned elliptical inner cylinder. *Journal of Energy Storage*, 42. <https://doi.org/10.1016/j.est.2021.103008>
- Prasad, BGN. S., Kumar, M. A. (2013). “Topology optimization of alloy wheel”. *Altair technology conference 2013*.

Quinonero-Candela, J., Rasmussen, C.E., (2005). A unifying view of sparse approximate gaussian process regression. *Journal of Machine Learning Research*, 6 1939-1959.

Ryberg, AB., Bäckryd, R.D. & Nilsson, L. A. (2015). A metamodel-based multidisciplinary design optimization process for automotive structures. *Engineering with computers*, 31:711-728. <https://doi.org/10.1007/s00366-014-0381-y>

SAE handbook. (2009). “J328 J1095_200910”. Society of Automotive Engineers.

Sathe, S. L., Kulkarni, R.D., Ghalke, A. B. (2015). Analytical and experimental investigation of natural frequency by vibration of optimized alloy wheel. *Journal of Emerging Technologies and Innovative Research (JETIR)*, 2 (11): 8-13.

Savaia, G., Formentin, S., Savaresi, S. M. (2020). Semi-Active Suspension Control Design via Bayesian Optimization. *IFAC PapersOnLine*, 53-2 14312-14317. <https://doi.org/10.1016/j.ifacol.2020.12.1374>

Shin, S., Lee, Y., Kim, M., Park, J., Lee, S., Min, K. (2020). Deep neural network model with Bayesian hyperparameter optimization for prediction of NOx at transient conditions in a diesel engine. *Engineering Applications of Artificial Intelligence*, 94. <https://doi.org/10.1016/j.engappai.2020.103761>

Siavash, N. K., Ghobadian, B., Najafi, G., Rohani, A., Tavakoli, T., Mahmoodi, E., Mamat, R., Mazlan, M. (2021). Prediction of power generation and rotor angular speed of a small wind turbine equipped to a controllable duct using artificial neural network and multiple linear regression. *Environmental Research*, 196. <https://doi.org/10.1016/j.envres.2020.110434>

Somayaji, A., Marakala, N., Somayaji, S., Hebbale, A. M.. In press. Studies on modal analysis of aluminium based carbon fibre reinforced optimized alloy wheel used in automotive sectors. *Materials Today: Proceedings*, <https://doi.org/10.1016/j.matpr.2021.08.099>

Stearns, J., Srivatsan, T.S., Prakash, A., Lam, P.C. (2004). Modeling the mechanical response of an aluminum alloy automotive rim. *Materials Science and Engineering*, A366:262-268. <https://doi.org/10.1016/j.msea.2003.08.017>

Tang, B. (2014). Orthogonal array-based latin hypercubes. *Journal of the American Statistical Association*, 88:424 1392-1397. <http://dx.doi.org/10.1080/01621459.1993.10476423>

Tran, A., Sun, J., Furlan, J. M., Pagalthivarathi, K. V., Visintainer, R. J., Wanga, Y. (2019), pBO-2GP-3B: A batch parallel known/unknown constrained Bayesian optimization with feasibility classification and its applications in computational fluid Dynamics. *Comput. Methods Appl. Mech. Engrg*, 347 : 827-852. <https://doi.org/10.1016/j.cma.2018.12.033>

Tusar, T., Gantar, K., Koblar, V., Zenko, B., Filipic, B. (2017). A study of overfitting in optimization of a manufacturing qualitycontrol procedure. *Applied Soft Computing*, 59: 77-87. <http://dx.doi.org/10.1016/j.asoc.2017.05.027>

Wanga, X., Zhang, X. (2010). Simulation of dynamic cornering fatigue test of a steel passenger car wheel. *International Journal of Fatigue*, 32: 434–442. <https://doi.org/10.1016/j.ijfatigue.2009.09.006>

Wolff, S., Brönnner, M., Held, M., Lienkamp, M. (2020). Transforming automotive companies into sustainability leaders: A concept for managing current challenges. *Journal of Cleaner Production*, 276. <https://doi.org/10.1016/j.jclepro.2020.124179>

- Yadav, O. P., Goel, P. S. (2008). Customer satisfaction driven quality improvement target planning for product development in automotive industry. *Int. J. Production Economics*, 113: 997-1011. <https://doi.org/10.1016/j.ijpe.2007.12.008>
- Yaman, M., Yegin, B. (2014). A light commercial vehicle wheel design optimization for weight, NVH and durability considerations. *5th ANSA & μ ETA International Conference*.
- Ye, Z., Li, J., Zhang, M. (2014). Application of ridge regression and factor analysis in design and production of alloy wheels. *Journal of Applied Statistics*, 41 (7):1436-1452. <https://doi.org/10.1080/02664763.2013.872233>
- Yi, J., Liu, X., Shan, Y., Dong, H. (2019). Characteristics of sound pressure in the tire cavity arising from acoustic cavity resonance excited by road roughness. *Applied Acoustics*, 146: 218-226. <https://doi.org/10.1016/j.apacoust.2018.11.025>
- Zhang, Y., Shan, Y., Liu, X., He, T. (2021). An integrated multi-objective topology optimization method for automobile wheels made of lightweight materials. *Structural and Multidisciplinary Optimization*, 641:1585-1605. <https://doi.org/10.1007/s00158-021-02913-3>
- Zhang, Z., Jia, H., Sun, J., Wang, M. (2012). Application of topological optimization on aluminum alloy automobile wheel designing. *Advanced Materials Research*, Vols. 562-564: 705-708. <https://doi.org/10.4028/www.scientific.net/AMR.562-564.705>

ÖZGEÇMİŞ

Adı Soyadı : Anıl TOPALOĞLU
Doğum Yeri ve Tarihi : ALTINDAĞ / 23.01.1992
Yabancı Dil : İngilizce ve İtalyanca

Eğitim Durumu
Lise : Beşiktaş Anadolu Lisesi, 2009
Lisans : Uludağ Üniversitesi, 2013
Yüksek Lisans : Galatasaray Üniversitesi, 2020

Çalıştığı Kurum/Kurumlar : TOFAŞ Türk Otomobil Fabrikası A.Ş (2013-...)

İletişim (e-posta) : aniltopaloglu@hotmail.com
anil.topaloglu@tofas.com.tr

Yayınları :

Topaloğlu, A., Öztürk, F., Kaya, N., (2022). Predictions of the design decisions for vehicle alloy wheel rims using deep neural network. *Proceedings of the IMechE, Part D: Journal of Automotive Engineering*, (Yayın Aşamasında) DOI: 10.1177/09544070221115484.

Topaloğlu, A., Öztürk, F., Kaya, N., (2021). Design and optimization of aluminium alloy Wheel for passenger vehicle. *OTEKON Uluslararası 10. Otomotiv Teknolojileri Kongresi*, 11-20.