

**T.C.**  
**BALIKESİR ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**  
**MİMARLIK ANABİLİM DALI**



**UYARLANABİLİR CEPHELER BAĞLAMINDA YAPAY ZEKA**  
**ALGORİTMALARININ GÖRELİ ETKİNLİĞİNİN ANALİZİ**

**RESUL ÖZLÜK**

**DOKTORA TEZİ**

**Jüri Üyeleri :** **Prof. Dr. Yusuf YILDIZ (Tez Danışmanı)**  
**Prof. Dr. Türkan GÖKSAL ÖZBALTA**  
**Doç. Dr. Fatih AYDIN**  
**Prof. Dr. Bedriye ASIMGİL**  
**Doç. Dr. Filiz UMAROĞULLARI**

**BALIKESİR, EYLÜL – 2025**

## **ETİK BEYAN**

Balıkesir Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak tarafımda hazırlanan **“Uyarlanabilir Cepheler Bağlamında Yapay Zeka Algoritmalarının Görelî Etkinliğinin Analizi”** başlıklı tezde;

- Tüm bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- Kullanılan veriler ve sonuçlarda herhangi bir deęişiklik yapmadığımı,
- Tüm bilgi ve sonuçları bilimsel araştırma ve etik ilkelere uygun şekilde sunduğumu,
- Yararlandığım eserlere atıfta bulunarak kaynak gösterdiğimi,

beyan eder, aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ederim.

**Resul ÖZLÜK**

**Bu tez çalışması Balıkesir Üniversitesi Bilimsel Araştırma Projeleri Birimi tarafından (2024/156) nolu proje ile desteklenmiştir.**

## ÖZET

**UYARLANABİLİR CEPHELER BAĞLAMINDA YAPAY ZEKA  
ALGORİTMALARININ GÖRELİ ETKİNLİĞİNİN ANALİZİ  
DOKTORA TEZİ  
RESUL ÖZLÜK  
BALIKESİR ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ  
MİMARLIK ANABİLİM DALI  
(TEZ DANIŞMANI: PROF. DR. YUSUF YILDIZ)**

**BALIKESİR, EYLÜL - 2025**

Uyarlanabilir cepheler, binalarda enerji verimliliğini arttırmanın yanı sıra bina içinde aşırı ısınmayı önleme ve kullanıcı konforunu sağlamada etkili bir araçtır. Uyarlanabilir cephe sistemlerinin performansa dayalı optimizasyonu için AI algoritmaları sıklıkla kullanılmakla birlikte çeşitli meta-model ve optimizasyon algoritmalarını bütünleştiren çok amaçlı optimizasyon yöntemlerine de ihtiyaç duyulur. Çalışmanın amacı, uyarlanabilir cephe sistemlerinin enerji verimliliği ve gün ışığı performansını değerlendirme bağlamında farklı yapay zekâ optimizasyon algoritmalarının performansını karşılaştırmaktır. Bu amaçla çalışmada çok aşamalı ve sistematik bir yöntem geliştirilmiştir. Optimizasyon sürecinde verileri sağlamak için BESTEST bina geometrisinin parametrik modellenmesi ve simülasyonu Rhino/Grasshopper ortamında yapılmıştır. Simülasyonlar aracılığıyla veriler oluşturulmuş ve farklı özellik seçimi algoritmaları kullanılarak optimizasyon süreci için etkili parametreler belirlenmiştir. Verilerin sağlanmasıyla makine öğrenmesi yöntemlerine ait olan tekli ve hibrit meta-modellerin performansları karşılaştırılmıştır. En düşük hata oranı ve en yüksek güvenilirliğe sahip ANN-CatBoost meta-modeli, optimizasyon algoritmaları için amaç fonksiyonu olarak kullanılmıştır. Algoritmaların performansı, hesaplama süresi açısından incelendiğinde SA 3.68 dk ile en hızlı, EP algoritması ise 277 dk ile en yavaş algoritma olarak belirlenmiştir. Dolayısıyla SA algoritmasının uyarlanabilir cephelerin erken tasarım süreçlerinde kullanılabileceği öngörülmekle birlikte, çözüm kalitesi açısından en olumsuz performansı gösterdiği saptanmıştır. SMA algoritması enerji performansı değerlendirilmesinde 6397,24 kWh değeri ile DE algoritması ise yararlı gün ışığı aydınlatması performansında %93,82 oranı ile en etkili algoritmalar olarak belirlenmiştir. Enerji tüketimi ve aydınlatmayı kapsayan genel performans karşılaştırılmasında ise DE, SMA, MFO ve EP algoritmaları en yüksek performans değerlerini sergilemişlerdir. Anılan algoritmalar tüm iterasyonlarda çok düşük uygunluk değerlerine ulaşarak, çok amaçlı probleme en etkili çözümleri üretmişlerdir. Ayrıca optimizasyona yönelik amaçlara dinamik ağırlık ataması yapıldığında, algoritma performanslarının önemli ölçüde değiştiği görülmektedir. Uyarlanabilir cephelerin optimizasyonuna yönelik gelecek çalışmalarda, bu çalışmada kullanılan optimizasyon algoritmaları performanslarının farklı tasarım senaryoları ile karşılaştırmalı olarak incelenmesi konuya ilişkin çalışmalara katkı sağlayacaktır.

**ANAHTAR KELİMELELER:** Binalarda enerji verimliliği, görsel konfor, makine öğrenmesi algoritmaları, uyarlanabilir cepheler, yapay zekâ optimizasyon algoritmaları

Bilim Kod / Kodları: 80135, 80126, 80130, 92444, 92432

Sayfa Sayısı: 116

## ABSTRACT

### ANALYSIS OF THE RELATIVE EFFECTIVENESS OF ARTIFICIAL INTELLIGENCE ALGORITHMS IN THE CONTEXT OF ADAPTIVE FACADES

PH.D THESIS

RESUL ÖZLÜK

BALIKESİR UNIVERSITY INSTITUTE OF SCIENCE

ARCHITECTURE

(SUPERVISOR: PROF. DR. YUSUF YILDIZ )

BALIKESİR, SEPTEMBER - 2025

Adaptive facades are an effective tool for increasing energy efficiency in buildings, as well as preventing overheating inside the building and ensuring user comfort. AI algorithms are often used for performance-based optimization of adaptive facades, but there is a need for a multi-objective optimization method that integrates various meta-models and optimization algorithms. The aim of this study is to compare the performance of different AI optimization algorithms for evaluating the energy efficiency and daylight performance of adaptive facade systems. For this purpose, a multi-stage and systematic method has been developed. The parametric modeling and simulation of the BESTEST building geometry were performed in the Rhino/Grasshopper environment to provide data for the optimization process. Data was generated through simulations, and effective parameters for the optimization process were determined using different feature selection algorithms. With the data provided, the performance of single and hybrid meta-models belonging to machine learning methods was compared. The ANN-CatBoost meta-model, which had the lowest error rate and highest reliability, was used as the objective function for the optimization algorithms. When the performance of the algorithms was examined in terms of computation time, SA was the fastest algorithm at 3.68 minutes, while EP was the slowest at 277 minutes. The SA algorithm can be used in the early design stages of adaptive facades, but it showed the worst performance in terms of solution quality. The SMA algorithm was the most effective in terms of energy performance (6397.24 kWh), while the DE algorithm was the most effective in terms of useful daylighting performance (93.82%). In the overall performance comparison, DE, SMA, MFO, and EP were the algorithms with the highest performance. These algorithms achieved very low fitness values in all iterations, producing the most effective solutions to the multi-objective problem. Furthermore, it is observed that the performance of the algorithms changes significantly when dynamic weighting is applied to the optimization objectives. In future studies on the optimization of adaptive facades, comparing the performance of the optimization algorithms used in this study with different design scenarios will contribute to research on this topic.

**KEYWORDS:** Energy efficiency in buildings, visual comfort, machine learning algorithms, adaptive facades, AI optimization algorithms

Science Code / Codes : 80135, 80126, 80130, 92444, 92432

Page Number : 116

# İÇİNDEKİLER

Sayfa

<b>ÖZET</b> .....	<b>i</b>
<b>İÇİNDEKİLER</b> .....	<b>iii</b>
<b>ŞEKİL LİSTESİ</b> .....	<b>iv</b>
<b>TABLO LİSTESİ</b> .....	<b>v</b>
<b>SEMBOL VE KISALTMA LİSTESİ</b> .....	<b>vi</b>
<b>ÖNSÖZ</b> .....	<b>vii</b>
<b>1. GİRİŞ</b> .....	<b>1</b>
1.1 Literatür Taraması.....	3
1.2 Literatürdeki Boşluklar .....	9
1.3 Çalışmanın Amacı ve Araştırma Soruları .....	12
<b>2. AI ALGORİTMALARI VE BİNA ENERJİ MODELLEME/SİMÜLASYON ARAÇLARINA GENEL BAKIŞ</b> .....	<b>14</b>
<b>3. YÖNTEM</b> .....	<b>19</b>
3.1 AF'ler bağlamında optimize edilmiş hedefler ve tasarım değişkenleri.....	20
3.2 Binanın Modellenmesi ve Simülasyonu .....	29
3.3 Özellik Seçimi Algoritmaları .....	30
3.4 Makine Öğrenmesi Algoritmaları .....	33
3.5 Meta-sezgisel Optimizasyon Algoritmaları .....	35
<b>4. BULGULAR VE TARTIŞMA</b> .....	<b>41</b>
4.1 Özellik Seçimi Algoritmaları ve Etkili Parametrelerin Karşılaştırılması .....	41
4.2 Makine Öğrenmesi Algoritmaları Model Seçimi ve Performans Karşılaştırması .....	46
4.3 AI Optimizasyon Algoritmaları İçin Performans Karşılaştırması .....	56
<b>5. SONUÇ</b> .....	<b>74</b>
<b>6. KAYNAKLAR</b> .....	<b>78</b>
<b>ÖZGEÇMİŞ</b> .....	<b>115</b>

## ŞEKİL LİSTESİ

### Sayfa

Şekil 3.1: Çalışmanın yöntem akış şeması.....	20
Şekil 3.2: BESTEST geometrisinin modellenmesi ve simülasyonu .....	30
Şekil 3.4: Özellik seçimi için genel bir akış şeması.....	31
Şekil 3.5: Optimizasyon süreci akış şeması .....	39
Şekil 4.1: 11 parametrenin enerji tüketimi üzerindeki önem sırası.....	43
Şekil 4.2: Enerji tüketimini etkileyen parametrelerin etkisi.....	44
Şekil 4.3: 11 parametrenin UDI üzerindeki önem sırası .....	44
Şekil 4.4: UDI'yi etkileyen parametrelerin etkisi .....	45
Şekil 4.5: Çalışma kapsamında incelenen ML algoritma sonuçları.....	53
Şekil 4.6: Tüm algoritmalara ait optimizasyon sonuçları .....	60
Şekil 4.7: Optimum çözümler için algoritmaların çalışma süreleri. ....	61
Şekil 4.8: Meta-sezgisel algoritmalara ait optimum tasarım değişkenleri .....	62
Şekil 4.9: Meta-sezgisel optimizasyon algoritmaların hiperhacmi .....	64
Şekil 4.10: Meta-sezgisel optimizasyon algoritmalarının iterasyon sayısına göre uygunluk değerleri. ....	65
Şekil 4.11: Farklı optimizasyon yöntemlerinin GD performansına ait eğrileri .....	67
Şekil 4.12: Farklı optimizasyon yöntemlerinin GD performansına ait eğrileri .....	67
Şekil 4.13: Farklı optimizasyon yöntemlerinin SP performansına ait eğrileri.....	68
Şekil 4.14: 100 iterasyon sonunda farklı algoritmalara ait optimum sonuçlar .....	70
Şekil 4.15: Optimizasyon algoritmaları sonucuna ait dağılımlar.....	72
Şekil 4.16: 100 iterasyon boyunca optimizasyon algoritmaların hiperhacmi .....	73

## TABLO LİSTESİ

### Sayfa

<b>Tablo 1.1:</b> AF bağlamında incelenen çalışmalara ait farklı yöntemlerin özeti.....	6
<b>Tablo 2.1:</b> Yaygın olarak bilinen BEMS araçları .....	16
<b>Tablo 2.2:</b> Bina enerji optimizasyonunda AI algoritmaları ve BEMS araçlarının güçlü yönleri ve sınırlamaları .....	18
<b>Tablo 3.1:</b> Çalışmalarda kullanılan amaç fonksiyonları ve tasarım parametreleri .....	21
<b>Tablo 3.2:</b> Değişken olarak seçilen tasarım parametreleri.....	28
<b>Tablo 4.1:</b> Özellik seçimi algoritma sonuçlarının karşılaştırılması .....	42
<b>Tablo 4.2:</b> Model tahmini için kullanılan farklı ML algoritmalarının karşılaştırılması .....	47
<b>Tablo 4.3:</b> Model tahmini için kullanılan farklı ML algoritmalarının karşılaştırılması .....	50
<b>Tablo 4.4:</b> Bina performansı optimizasyonunda meta-modele dayanan çalışmalar .....	56
<b>Tablo 4.5:</b> Optimizasyon algoritmalarına ait temel parametre ayarları .....	59
<b>Tablo 4.6:</b> Tüm algoritmalara ait optimizasyon sonuçları .....	60
<b>Tablo 4.7:</b> Amaç fonksiyonlarına farklı ağırlıklandırma atanarak elde edilen sonuçlar .....	70

## SEMBOL VE KISALTMA LİSTESİ

<b>CO<sub>2</sub></b>	: Karbondioksit
<b>SHGC</b>	: Güneş Enerjisi Toplam Geçirgenlik
<b>U-değeri</b>	: Isıl geçirgenlik katsayısı (W/m <sup>2</sup> k)
<b>T<sub>vis</sub></b>	: Gün ışığı geçirgenliği
<b>n/a</b>	: yok
<b>BEMS</b>	: Bina Enerji Modellemesi Simülasyonu
<b>BESTEST</b>	: Bina enerji simülasyon testi
<b>UDI</b>	: Yararlı gün ışığı aydınlatması
<b>PV</b>	: Fotovoltaik
<b>ACH</b>	: Hava sızdırmazlık değeri
<b>AF</b>	: Uyarlanabilir cepheler
<b>TS 825</b>	: Binalarda Isı Yalıtım Standartı
<b>SR</b>	: Güneş yansıtma oranı
<b>RMSE</b>	: Ortalama Karesel Hata
<b>MAE</b>	: Ortalama Mutlak Hata
<b>MAPE</b>	: Ortalama Mutlak Yüzde Hata
<b>R<sup>2</sup></b>	: Belirleme katsayısı

## ÖNSÖZ

Doktora tezimi hazırlama sürecinde maddi ve manevi desteklerini hiçbir zaman esirgemeyen, değerli aileme ve özellikle sevgili babama en içten teşekkürlerimi sunarım.

Tez sürecinin her aşamasında akademik rehberliğini, bilgi ve deneyimlerini benimle paylaşan, sabır ve anlayışıyla yolumu aydınlatan değerli danışmanım Prof. Dr. Yusuf Yıldız'a şükranlarımı sunarım.

Ayrıca çalışmam boyunca akademik fikirleriyle desteğini ve yönlendirmelerini her zaman hissettiren Prof. Dr. Türkan GÖKSAL ÖZBALTA ve Doç. Dr. Fatih AYDIN'a teşekkür ederim.

Tez süreci boyunca her konuda anlayış gösteren, karşılaştığım sorunların çözümünde her zaman yapıcı yaklaşım sergileyen Balıkesir Üniversitesi Fen Bilimleri Enstitüsü'ne en içten teşekkürlerimi sunarım.

**Balıkesir, 2025**

**Resul Özlük**

# 1. GİRİŞ

İklim deęişiklięi, tüm dünyada canlı yaşamları öncelikli olmak üzere çevreye olan olumsuz etkileri nedeniyle endişeleri arttırmaktadır. Yapılı çevrenin enerji ihtiyacı, fosil kökenli enerji kaynaklarının kullanımından dolayı sera gazlarını arttırmakta ve bu artış küresel ısınmaya neden olmaktadır. 2018 IPCC raporuna göre küresel ısınma, iklim deęişikliğine ve olumsuz ani hava deęişikliklerine yol açmaktadır [1]. İklim deęişikliği; sıcak hava dalgaları, sel, orman yangınları ve yerel iklim koşullarındaki yapısal deęişikliklere neden olabilecek olumsuz etkilere sahiptir [2]. Uluslararası Enerji Ajansı (IEA) tarafından hazırlanan rapora göre yapılı çevre, enerji tüketiminin %34'ü ve toplam emisyonların neredeyse üçte ikisinden sorumludur [3]. Enerji kullanımında ticari binalar, ofis binaları ve üniversite binaları öncü rol oynamaktadır [4]. Ayrıca binalar CO<sub>2</sub> emisyonlarının da %40'ından sorumludur [5].

Dünya genelinde, yapı sektöründeki enerji kullanımının 2050'ye kadar yaklaşık %30 oranında azaltılması hedeflenmektedir [6]. Yapılarda enerji verimlilięi; kapsamlı yenilemeler, düşük emisyonlu enerji tedariki ve düşük emisyonlu malzemelere geçiş ile sağlanabilir [7]. Son zamanlarda enerji verimlilięine ve fosil yakıt kullanımının azaltılmasına verilen öneme baęlı olarak bina kabuęu performansının ve işlevsellięinin artırılmasına yönelik talepler de artmaktadır [8]. Böylelikle bina kabuęunun pasif teknolojik çözümlerden, yenilenebilir kaynaklardan enerji üretebilen aktif sistemlere dönüşümü hedeflenmektedir. Uyarlanabilir cephe sistemleri deęişen ortam koşulları altında, bina enerji performansını ve iç mekânlarda kullanıcı konforunu iyileştirebilir [9,10].

Binaların enerji tüketiminin yaklaşık %20-60'ından bina kabuęunun önemli bir parçası olan bina cepheleri sorumludur. Bu nedenle bina cepheleri, enerji tasarrufunda önemli bir role sahiptir [11]. Binaların enerji tüketimini önemli ölçüde etkileyen parametrelerden birinin bina kabuęu olduęu dikkate alındığında, cephe elemanlarının bina enerji verimlilięi ve kullanıcı konforu açısından "esnek tasarımı" önemlidir. Böylelikle bina cepheleri, kullanıcılara konforlu yaşam koşulları sağlamada önemli bir rol oynayacaktır [12]. Bina cephesi, iç ortam ile dış ortam arasında fiziksel bir sınır sağlar. Ayrıca bina cepheleri gölgeleme, yapay aydınlatma, mahremiyet, aşırı ısınma, gün ışığı kontrolü vb. işlevlerden sorumludur [13]. Statik bir cephe, deęişkenlik gösteren hava koşullarında iç mekân çevre kalitesinin sağlanmasında sınırlı bir etkiye sahiptir [14]. Ancak teknolojik gelişmeler ve iklimin deęişkenlik gösterdięi günümüz koşullarında, binaların gereksinimleri de sıklıkla

değişmektedir [15]. Bu nedenle statik bir cephe tasarımı yerine aktif ve pasif sistemlerin bir arada kullanıldığı [16,17] ve cephe özelliklerinin optimum şekilde değişebildiği uyarlanabilir cephe kullanımının yaygınlaşması kaçınılmazdır [18,19].

Son birkaç on yılda, uyarlanabilir cepheler, araştırmacıların büyük ilgisini çekmiştir [20]. Uyarlanabilir cepheler (AF), anlık hava dalgalanmaları, günlük veya mevsimsel döngüler şeklinde değişen sınır koşullara uyum sağlayabilen bina kabuklarıdır [21]. AF'ler aşırı ısınmayı ve parlamayı önlerken aynı zamanda güneş ısısı kazancı sağlaması ve gün ışığını kontrol etmesi gibi önemli avantajlara sahiptir [22]. AF sistemlerinde uyarlanabilir davranışı etkileyen iklim, insan ve uyarlanabilir mekanizmalar gibi faktörler bulunmaktadır [23]. Ayrıca AF'lerin tasarımında iç mekân ısı konfor ve görsel konfor koşullarının sağlanması, hava sirkülasyonu ve enerji verimliliği dikkat çeken parametrelerdir [13,24].

Literatürde, cephe bağlamında birbirinin yerine kullanılan ve karışıklığa neden olan benzer “uyarlanabilir” terimleri vardır. Romano [10] ve Tabadkani [25]’nin çalışmalarına dayanan, AF'ler aşağıdaki terimleri içerir: Aktif cepheler [26,27], Pasif cepheler [28,29], Biyo-mimetik cepheler [30,31], Kinetik cepheler [32,33], Zeki cepheler [34–36], İnteraktif veya Medya cepheler [37], Taşınabilir cepheler [38], Duyarlı cepheler [39,40], Akıllı cepheler [41,42], Dinamik cepheler [43,44] Değiştirilebilir cepheler [45], Gelişmiş cepheler [46] şeklinde sıralanır. AF tipolojileri incelendiğinde her bir tipolojinin belirli bir sınırı ve potansiyeli olduğu görülür. Örneğin; Taşınabilir cephe tipolojisinde kullanıcı konforunun sağlanmasının temel amaç olmaması bir sınırlama iken enerji üretebilmesi bu cephe tipinin önemli bir avantajıdır. AF tipolojileri, teknoloji desteği ve kullanılan malzemelerin özelliklerine bağlı olarak gelişme potansiyeline sahiptir ve performansı yüksek tipolojiye yükseltilebilir. Pasif bir cephenin zeki bir cepheye, taşınabilir bir cephenin kinetik bir cepheye, kinetik bir cephenin de daha gelişmiş duyarlı bir cepheye yükseltilmesi mümkün olabilir [25]. Bu tipolojilerden aktif, pasif, biyo-mimetik, kinetik, taşınabilir ve akıllı gibi cephelerde kullanıcı etkileşimi söz konusu olmaz iken zeki, interaktif, duyarlı ve değiştirilebilir gibi cephelerde kullanıcı etkileşimi olabilir [13,25,47].

Özetle, uyarlanabilirlik; bir sistemin, uzun veya kısa süreli değişen koşullar altında farklı değişkenleri dikkate alarak zaman içinde hedeflenen işlevselliği sağlaması olarak kabul edilebilir [47,48]. AF sistemlerine baktığımızda dış hava koşullarından korunma, gün ışığı ve içerinden/dışardan görünümü (manzara) sağlar. Özellikle kullanıcı tercihlerine göre

konforu, enerji verimliliği, gün ışığı ve taze hava akışı kontrollü olarak sağlayabilen işlevlere sahip olabilir [49]. Uyarlanabilir cephe sistemleri, değişen dış çevre koşulları ve kullanıcı tercihleri doğrultusunda çoklu performans hedeflerine ulaşmak zorundadır. Bu hedefler arasında denge kurmak ve en uygun çözümleri üretmek için optimizasyon yöntemleri kritik bir araçtır. Uyarlanabilir cephe sistemleri, gelecekte yeni binalarda önemli bir paya sahip olacak etkili teknolojilerdir [9]. Gelecekte karbon emisyonları ve enerji tüketiminin arttığı; hava sıcaklıkları ve konfor koşullarının dünya çapında değişeceği dikkate alınırsa AF sistemlerinin kullanımı giderek yaygınlaşacaktır.

### **1.1 Literatür Taraması**

AF'ler ile ilgili literatürdeki çalışmaların çoğu ilk tasarım aşaması ve tasarım süreçleri [50–53], performanslarının değerlendirilmesi [54–58], kontrol sistemleri [59–61] ve bu özelliklerin birlikte değerlendirilmesi [47,62,63] gibi farklı yönlerde dayanmaktadır. AF'ler ısı konforu, görsel konforu (gün ışığı, parlama, görünüm), hava sirkülasyonu ve enerji tüketiminin azaltılması gibi amaçlarla tasarlanır [13,24]. Bu nedenle ısı konfor, görsel konfor [25] ve enerji gibi performansların değerlendirilmesi önemlidir. Belirtilen performans kriterlerini değerlendirmek için literatürde; bina performans simülasyonu (BPS) [64–68], kullanıcı anketi [69,70], sayısal hesaplamalar veya tahminler [71,72] ve deneye dayalı [73–77] gibi farklı yöntemler kullanılmıştır. Bu yöntemlerin kendi içerisinde avantaj ve sınırlılıkları mevcuttur. Bu yöntemler arasında deneyler en doğru ve güvenilir olmakla birlikte deneylerin maliyeti yüksektir ve genellikle zaman alıcıdır. Mevcut ekipmanlarla yapıldığı düşünülürse tasarım parametreleri çoğunlukla sınırlıdır [25]. Simülasyonlar deneysel yöntemlere göre daha yaygın kullanılır ve maliyet düşüktür. Değişkenlerin çeşitliliği nedeniyle tahmin değerleri gerçek değerlerden önemli ölçüde farklılık gösterebilir [21]. BPS, cephe tasarımını ve performans analizini birlikte değerlendirir ancak cephe tasarımının ilk aşaması için karmaşıktır [14]. Sayısal hesaplamalar; tahmin kriterleri kullanan belirli durumlarda uygulanırsa da süre ve maliyet açısından uygun bir yöntemdir. Bir diğer yöntem olan anketler, sonuca ulaşmak için uzun bir ölçüm ve veri toplama süresi gerektirir [25].

AF ile ilgili yapılan çalışmalar incelendiğinde, performanslarının değerlendirilmesinde farklı yöntemlerin kullanıldığı görülmektedir. Uyarlanabilir cepheler bağlamında tasarım parametrelerinin seçimi ve amaçların optimize edilmesinde bina performans simülasyonlarının diğer yöntemlere göre daha sık kullanıldığı görülmektedir. Özellikle son

yıllarda, AF'lerin tasarımı, enerji performansı, ısı ve görsel konforun sağlanması ile sürdürülebilirliğin gelişmesine katkıda bulunan bina performans optimizasyonu alanında önemli çalışmalar yapılmıştır. Aşağıda AF'lerin genel performanslarının değerlendirilmesine yönelik olarak yapılan bazı çalışmalara yer verilmiştir.

Curpek et al. [78], faz değiştiren malzeme ile entegre edilmiş iklime duyarlı çift cidarlı bir cephenin performansını değerlendirmek için bina enerji simülasyonu ve deneysel ölçümler kullanmıştır. Barone et al. [42], çok katlı bir binanın mevcut durumundan daha gelişmiş olan bir cephe sistemi kullanıldığında enerji tüketiminin önemli ölçüde azaldığı sonucuna ulaşmıştır. Marfil et al. [79], uyarlanabilir cam cephenin U-değeri ve SHGC gibi tasarım değişkenlerin farklı değerlerini kullanarak deneysel bir simülasyon yöntemi kullanmıştır. Sonuçlar, iç ortam sıcaklığı üzerinde SHGC'nin U-değerinden daha önemli bir etkiye sahip olduğunu göstermektedir. Shen and Han [80], farklı uyarlanabilir cephe modülleriyle tamsayı programlama (IP) yöntemini kullanarak binanın gün ışığı performansını optimize etmiştir. Bu yöntemin geleneksel simülasyon tabanlı yöntemlere göre süre ve performans açısından daha etkili olduğu görülmüştür. Ochoa and Capeluto [81], akıllı bir cephenin farklı tasarım girdilerini kullanarak EnergyPlus simülasyon aracı ile uyumlu çalışabilen görsel konfor ve enerji tüketimine dayalı yeni bir program (NewFacades) geliştirmiştir. Bir diğer çalışmada, Le-Thanh et al. [82], simülasyon programı ile Dengeleyici Bileşik Hareket Optimizasyonu (BCMO) yöntemini birleştirmiştir. Üretilen yöntem ile kinetik gölgeleme elemanının, binanın gün ışığı performansı ve enerji tüketimini iyileştirdiği görülmüştür. Liu et al. [36], geliştirdikleri yöntemde dinamik cepheye sahip bir odanın hem enerji hem de konfor performansını simüle etmişlerdir. Yapılan çalışmada basitleştirilmiş yöntem ile geliştirilen (BSim) yöntemin benzer sonuçlar verdiği görülmüştür. Valitabar et al. [83], hareketli gölgeleme elemanlarıyla, görsel konfor ve enerji tasarrufu sağlamak için çok amaçlı optimizasyon yöntemini kullanmıştır. Bui et al. [84], uyarlanabilir bir cephenin performansını analiz etmek için hesaplamalı bir optimizasyon yöntemi önermiştir ve bu yöntem ile enerji tüketiminde önemli bir azalma sağlandığı doğrulanmıştır. Tabadkani et al. [85], gün ışığı performansına ve parlama rahatsızlığına yönelik bir kinetik altıgen gölgeleme sistemi geliştirmiştir. Evrimsel temelli bir optimizasyon yöntemi kullanılarak kinetik cephenin gün ışığı iyileştirmesi ve gölgeleme sağlayabileceği belirlenmiştir. Hosseini et al. [31], bitkilerin stoma hareketi ve davranışlarından esinlenerek kinetik bir cephe önermiştir. Kullanıcıların görsel konforunu iyileştirmeyi amaçlayan bu cephe, parametrik simülasyonlar yapılarak geliştirilmiştir. Webb et al. [86], ofis binasına ait biyo-mimetik bir cephenin yaz

koşullarında, farklı sıcaklık parametrelerini karşılaştırmıştır. TRNSYS yazılım aracı kullanarak yüzey sıcaklıklarının azaldığı görülmüştür. Hosseini et al. [87], parametrik simülasyonlar uygulayarak gün ışığı performansını iyileştirmek için çok katmanlı bir biyomimetik kinetik cephe geliştirdi. Basit bir pencereye kıyasla, kullanıcıların gün ışığı performansını iyileştirmek ve görsel rahatsızlığı önlemek için biyo-ilhamlı kinetik bir cephenin yüksek performans gösterdiği belirtilmiştir. Hosseini et al. [88], gün ışığı performansını iyileştirmek için kinetik bir cepheyi renkli camlarla bütünleşmesini araştırmıştır. Parametrik simülasyonlar kullanarak kinetik cephe durumu simüle edilmiş olup sonuçların gün ışığı performansını iyileştirmek için etkileşimli kinetik cephelerin yüksek performans gösterdiğini doğrulamaktadır. Panya et al. [37], etkileşimli cephe tasarımının hareket yönünü analiz etmek ve gün ışığı performansını değerlendirmek için çok sayıda parametrik simülasyonlar yapmıştır. Hosseini et al. [89], farklı boyutlardaki cephe tasarımının gün ışığı üzerinde farklı sonuçları olduğu ve üç boyutlu şekil değiştiren kinetik cephenin daha faydalı gün ışığı sağladığı sonucuna ulaşmıştır. Shi et al. [90], çalışmalarında, farklı simülasyon sonuçlarını karşılaştırarak, mevcut duruma göre dinamik cephelerin uygulanmasıyla enerji ve gün ışığı performansının iyileştiğini saptamışlardır. Bir diğer çalışmada, Tabadkani et al. [91], simülasyonlar aracılığı ile farklı iklim koşullarının otomatik gölgeleme kontrol senaryolarını önemli ölçüde etkilediğini göstermiştir. Mahmoud and Elghazi [92], farklı dinamik cephe gölgeleme tipolojilerinin kullanıcı konforu ve enerji performansı üzerindeki etkilerinin de farklı olduğu sonucuna ulaşmıştır. Liu et al. [93], akıllı camlı cepheye sahip bir ofis binasının statik bir cepheye oranla enerji tüketimini azalttığı ve bina konfor performansının iyileştirebildiğini doğrulamıştır.

Binalarda AF sistemleri kullanıldığında enerji verimliliği, kullanıcı konforu ve diğer amaçlar arasında bir denge sağlanabilir. Bu dengeyi sağlamak için tasarım parametrelerinin optimum değerlerini bulmak gerekmektedir. Çalışmanın amacına göre en uygun parametreleri belirlemek ve bu değişkenlerin en uygun değerlerini saptamak için optimizasyon teknikleri, simülasyon araçları, modelleme programları ve diğer yöntemler sıklıkla kullanılır. Bu yöntemler bina performansı açısından AF'ler ile en iyi performansı elde etmek için gerekli parametrelerin değerlerini optimize etmeye yardımcı olur. AF'lerden en iyi performansı elde etmek için kullanılan yapay zekâ optimizasyon teknikleri, modellemenin yapıldığı program, simülasyon araçları ve optimizasyon için kullanılan araçlar Tablo 1.1'de detaylı şekilde özetlenmiştir.

**Tablo 1.1:** AF bağlamında incelenen çalışmalara ait farklı yöntemlerin özeti

Referans	Optimizasyon Yöntemi	Modelleme/Görselleştirme araçları	Simülasyon Araçları	Optimizasyon Araçları
[94]	GA	Rhino- Grasshopper	Ladybug-tools, (Radiance)	Grasshopper (Galapagos)
[95]	Macine learning (BPNN, BPNN-Adaboost ve GWO-BPNN-Adaboost)- NSGA-II	Rhino- Grasshopper	Ladybug-tools, (Radiance, EnergyPlus)	MATLAB
[96]	MOGA	Rhino- Grasshopper	Ladybug-tools, (Radiance, EnergyPlus)	Grasshopper (Octopus)
[97]	MOGA	Rhino- Grasshopper	Ladybug-tools, (Radiance, EnergyPlus)	Grasshopper (Octopus)
[98]	MOO	Rhino- Grasshopper	Ladybug-tools, (Radiance, EnergyPlus)	Grasshopper (Colibri)
[99]	NSGA-II	DesignBuilder	EnergyPlus	DesignBuilder
[100]	Çok Amaçlı Evrimsel Algoritma (MOEA)	Rhino- Grasshopper	Ladybug-tools, (Radiance)	Grasshopper (Wallacei)
[101]	MOGA	Rhino- Grasshopper	Ladybug-tools, (Radiance, EnergyPlus)	Grasshopper (Octopus)
[102]	Makine Öğrenmesi (Decision Tree Classifier (DTC)), Hassasiyet Analizi	n/a	EnergyPlus	Python
[103]	Bulanık Mantık ve GA	Rhino- Grasshopper	Ladybug-tools (LBT), Radiance and DAYSIM	Python
[104]	Çoklu Etki Alanı Optimizasyonu	n/a	IDA ICE	Python
[105]	Çok Amaçlı Evrimsel Algoritma (MOEA)	Rhino- Grasshopper	Ladybug, Honeybee (EnergyPlus)	Grasshopper (Wallacei)
[106]	Multi-Objective Genetic Algorithm (MOGA) and Artificial Neural Network (ANN)	Rhino- Grasshopper	Radiance	Grasshopper
[107]	Multi-Objective Evolutionary Algorithm	Rhino- Grasshopper	EnergyPlus, Dayism, and Radiance	Grasshopper (Octopus)
[108]	Time-Saving Algorithm	IES.VE	IES.VE	Excel software
[109]	Arithmetical Optimization Algorithm	DesignBuilder	EnergyPlus	MATLAB (MLE+ toolbox)
[110]	Multi-Objective Genetic Algorithm (MOGA)	Rhino- Grasshopper	EnergyPlus, Radiance	Grasshopper (Octopus)
[111]	Sequential Search	Rhino- Grasshopper	EnergyPlus	n/a
[112]	Multi-Objective Evolutionary Algorithm, Non-Dominated Sorting Genetic Algorithm (NSGA-2)	Rhino- Grasshopper	EnergyPlus	Grasshopper
[113]	Brute Force Search Algorithm	Rhino- Grasshopper	Radiance	R software
[67]	Parametric Simulation	Rhino- Grasshopper	EnergyPlus	Python

**Tablo 1.1** (devam)

[71]	Machine learning (Convolutional Neural Network (CNN))	Rhino- Grasshopper	EnergyPlus	Python
[114]	Genetic Algorithm, Model predictive control (MPC)	n/a	EnergyPlus	MATLAB
[115]	Brute Force Search Algorithm	Rhino- Grasshopper	EnergyPlus	Grasshopper (Colibri)
[116]	Parametric simulation	Rhino- Grasshopper	Ladybug, Honeybee, DAYSIM, Radiance	n/a
[80]	Integer Programming Algorithm and Simulated Annealing Algorithm	Rhino- Grasshopper	Radiance	Grasshopper
[117]	Brute-force search algorithm	Rhino- Grasshopper	EnergyPlus (DIVA)	Grasshopper
[16]	Multi-Objective Evolutionary Algorithm (MOEA)	Rhino- Grasshopper (Climate Studio)	Radiance and EnergyPlus (Climate Studio)	Grasshopper (Wallacei)
[63]	Parametric Simulations, Robust Multi-criteria decision- making, Sensitivity analysis	Rhino- Grasshopper	Radiance and EnergyPlus (Climate Studio)	Grasshopper
[118]	Multi-Objective Genetic Algorithm (MOGA)	Rhino- Grasshopper	Radiance and EnergyPlus	Grasshopper (Octopus)
[119]	Genetic Algorithm	Rhino- Grasshopper	ClimateStud io tools, Ladybug	Grasshopper(Galapagos)
[120]	Genetic Algorithm (NSGA-2)	Rhino- Grasshopper	DAYSIM, Radiance, and EnergyPlus	Grasshopper (octopus)
[121]	GA, ANN	Rhino- Grasshopper	EnergyPlus	Grasshopper(Galapagos)
[122]	Machine learning (K-Nearest Neighbor (KNN)) Algorithm	DesignBuilder	EnergyPlus	n/a
[91]	Brute-force search algorithm	Rhino- Grasshopper	EnergyPlus and OpenStudio, Radiance and Daysim	n/a
[82]	Balancing Composite Motion Optimization (BCMO)	Rhino- Grasshopper	DIVA	MATLAB
[123]	Parametric simulation and Genetic algorithm, Statistical validation in sensitivity analysis	n/a	Radiance	n/a
[124]	Parametric simulation and Genetic algorithm	Rhino- Grasshopper	Ladybug- Honeybee	Grasshopper(Octopus)
[125]	Genetic Algorithm	n/a	EnergyPlus	Python
[126]	Machine learning	Rhino- Grasshopper	DIVA	n/a
[127]	Simulated Annealing Algorithm	n/a	n/a	ASA software
[31]	Parametric simulation	Rhino- Grasshopper	DIVA	Grasshopper
[128]	Genetic Algorithm (NSGA-2)	Rhino- Grasshopper	Radiance and EnergyPlus	Grasshopper (Wallacei X)

**Tablo 1.1 (devam)**

[129]	Multi-Objective Optimisation, Sensitivity analysis	Rhino- Grasshopper	Radiance and EnergyPlus	Grasshopper (octopus)
[130]	Multi-objective Optimization (MOO)	Rhino- Grasshopper	EnergyPlus	Grasshopper (Colibri plugin)
[131]	Genetic Algorithm	Rhino- Grasshopper	Radiance and EnergyPlus	Grasshopper (octopus)
[132]	Parametric behavior map (PBM), Evolutionary Multi-objective Optimization (EMO)	Rhino- Grasshopper	EnergyPlus	Grasshopper(octopus)
[133]	Radial Basis Function Neural Network (RBF)	Rhino- Grasshopper	DIVA	n/a
[90]	Parametric simulation	Rhino- Grasshopper	Radiance and EnergyPlus	Grasshopper
[84]	Modified Firefly Algorithm (MFA)	Revit	EnergyPlus	Python
[88]	Parametric simulation	Rhino- Grasshopper	Radiance and EnergyPlus	Grasshopper
[134]	Parametric behavior map (PBM) algorithm	Rhino- Grasshopper	Ladybug and Honeybee	Grasshopper
[135]	Genetic Algorithm	Rhino- Grasshopper	Radiance	Grasshopper(Galapagos)
[85]	Genetic Algorithm	Rhino- Grasshopper and SketchUp	EnergyPlus	Grasshopper(Galapagos)
[136]	Machine learning (SVM) and Simulated Annealing Algorithm	Rhino- Grasshopper	Radiance	Python
[137]	Genetic Algorithm	Rhino- Grasshopper(DIVA)	DIVA	Grasshopper (Galapagos) and Python
[138]	Multi-Objective Evolutionary Optimization	Rhino- Grasshopper	Radiance and EnergyPlus	Grasshopper (Octopus)
[139]	ANN	Revit/Dynamo	DOE-2	NeuralBuilder
[140]	Genetic Algorithm	Rhino- Grasshopper	Radiance and DAYSIM	Grasshopper(Galapagos)
[141]	Raytracing algorithm	Rhino- Grasshopper	DAYSIM and EnergyPlus	Grasshopper
[142]	Computational simulation (variations-oriented algorithm)	Diva-for-Rhino-Grasshopper and Archsim	Radiance and EnergyPlus	Grasshopper
[143]	Genetic Algorithm and AR optimization	Rhino- Grasshopper	Radiance and EnergyPlus	Grasshopper
[144]	Genetic Algorithm (NSGA-2)	SurfaceControl:Movable Insulation	EnergyPlus	MATLAB
[145]	Facade Optimization System (FOS)	Rhino- Grasshopper	DIVA	MATLAB
[146]	Model-based control Algorithm (MBC)	WINDOW 7 Software	n/a	Matlab v8.5 (R2014b) and LabVIEW Software
[92]	Parametric simulation	Rhino- Grasshopper	DIVA	Grasshopper
[147]	Genetic Algorithm	Rhino- Grasshopper	Radiance (DIVA)	Grasshopper(Galapagos)
[148]	Fuzzy Logic, Computational simulations	Rhino- Grasshopper	Radiance	MATLAB
[149]	Generalized Pattern Search (GPS) algorithm and PSO	WinOpt	EnergyPlus	GenOpt

**Tablo 1.1 (devam)**

[150]	Hybrid optimisation algorithm, (Particle Swarm Optimization with Generalized Pattern Search)	n/a	EnergyPlus	GenOpt/MATLAB
[23]	Genetic Algorithm (NSGA-2)	n/a	DIVA, TRNSYS	n/a
[151]	Parametric simulation	Rhino- Grasshopper (DIVA)	Radiance	Grasshopper
[152]	Genetic Algorithm	Rhino- Grasshopper	Ecotect	Grasshopper (Galapagos)

Yapay zekâ optimizasyon algoritmaları, çeşitli faktörlere ve kısıtlamalara bağlı olarak uyarlanabilir cephelerin performanslarının değerlendirilmesinde önemli bir rol oynamaktadır. Uyarlanabilir cephelerin performansını değerlendirmek için yaygın olarak kullanılan AI optimizasyon algoritmaları şunlardır: Genetik algoritma (NSGA-2, MOGA, MOEA), Brute Force Arama algoritması, Parametric Behavior Map (PBM) algoritması, Bulanık mantık, Generalized Pattern Search (GPS) algoritması, Particle Swarm Optimization (PSO), Makine öğrenmesi algoritmaları, Model-based Control algoritması (MBC), Raytracing algoritması, Variations-Oriented algoritması, Simulated Annealing algoritması, Simülasyon ve Rule based optimization, Balancing Composite Motion Optimization (BCMO), Derin öğrenme algoritmaları, Radial Basis Function Neural Network (RBF), Modified Firefly Algorithm (MFA), Integer Programming algoritması, Time-Saving algoritması, Arithmetical optimizasyon algoritması, Multi-domain optimizasyon ve bunların birlikte kullanıldığı (GA- ANN, Generalized Pattern Search algoritması – PSO) algoritması. Ayrıca anılan yapay zekâ optimizasyon algoritmalarına ek olarak parametrik simülasyonlar, istatistiksel analizler ve hassasiyet analizi gibi yöntemler de AF'lerin performansının değerlendirilmesinde kullanılmıştır. Bu yöntemler tek amaçlı veya çok amaçlı optimizasyon yaklaşımı olarak değerlendirilir.

## 1.2 Literatürdeki Boşluklar

Önceki bölümde analizi yapılan tek veya çok amaçlı optimizasyon çalışmalarının çoğu, optimizasyon sürecini otomatik hale getirmek için simülasyon araçları ve optimizasyon algoritmalarını birlikte uygulamışlardır. Ancak, bina performansının optimizasyonu ile ilgili mevcut araştırmalar temel olarak iki yaklaşımı benimsemişlerdir: (1) optimizasyon algoritmalarıyla simülasyon aracını birleştiren yöntemler [94,96,98,153] ve (2) simülasyon aracı yerine meta-model veya vekil model kullanan yöntemler [95,154,155]. İlk yaklaşımda kullanılan simülasyon araçlarının optimizasyon sürecinde sürekli olarak çalıştırılması genellikle uzun zaman almaktadır. Çok amaçlı problemlerde, optimizasyon algoritmaları

genellikle birden fazla kriteri birlikte analiz ederek en uygun sonucu bulmaya çalışır. [156,157]. Birçok simülasyon aracı birden fazla kritere ait hesaplamaları gerçekleştirmesi önemli miktarda zaman gerektirir. Bu durum, özellikle çok amaçlı optimizasyonun büyük çaplı binalarda uygulanmasını önemli ölçüde güçleştirir. Mimarlar, mühendisler, tasarımcılar ve diğer uygulayıcılar genellikle sınırlı bir sürede projelerini gerçekleştirirler. Yüksek hesaplama süreleri, modellerin karmaşıklığı ve maliyetler bina tasarımında optimizasyon yapılmasının önündeki engellerden bazılarıdır [154]. Son zamanlarda, araştırmacılar daha hızlı ve pratik optimizasyon çözümleri üretmek için, ikinci yaklaşım olan meta modelleri ve optimizasyon algoritmalarını birleştiren modeller kullanmışlardır [158–160]. Bu modeller, yalnızca girdi-çıkı verilerinin dağılımını dikkate aldıkları için fizik tabanlı simülasyon araçlarından hesaplama açısından daha verimlidir [158]. Meta-model ve makine öğrenme tekniklerinin kullanılması bina performansı için optimizasyon sürecine önemli katkılar sağlar çünkü bu yöntemler orijinal modelin davranışını taklit edebilir ve hesaplama süresini azaltılabilir [157,160,161]. Meta modellerin optimizasyon problemlerinde uygulanması için süreye ek olarak kabul edilebilir bir tahmin performansına ve hata oranına sahip olması kritik bir öneme sahiptir. Sonraki süreçlerde optimizasyon için uygun bir algoritmanın kullanılması da bu kriterler kadar önemlidir. Birçok çalışmada bu modeller kullanılmıştır. Magnier et al. [162], GA-ANN meta-modelini kullanarak ısı konfor ve enerji tüketimine yönelik çok amaçlı optimizasyon yapmıştır. Chegari et al. [160], ANN meta-modelini farklı optimizasyon algoritmalarının performans değerlendirmesi için uygulamıştır. Sonuçlar, Çok Amaçlı Parçacık Sürü Optimizasyonunun (MOPSO) evrimsel temelli algoritmalarından daha iyi performansa sahip olduğunu göstermiştir. Diğer bir çalışmada, Si et al. [163], ANN meta-modelinin amaç fonksiyonu olarak kullanıldığı optimizasyon probleminde, NSGA-II optimizasyon algoritmasının diğer algoritmalara göre daha yüksek performans gösterdiğini bulmuştur. Ayrıca bina performansı optimizasyonu alanında birden fazla meta-model karşılaştırarak çok amaçlı optimizasyon yapan çalışmalar da mevcuttur [155,157,164,165]. Çalışmaların sonuçları, ANN meta-modelle karşılaştırıldığında GLSSVM, ELM ve XGBoost algoritmaları daha yüksek performans göstermiştir.

Özetle, uyarlanabilir cephelerin optimizasyonuna yönelik araştırmalarda önemli ilerlemeler kaydedilmiş olsa da aşağıdaki üç temel kategoride bilgi eksiklikleri ve araştırma boşlukları devam etmektedir:

- **1:** Uyarlanabilir cepheler bağlamında yapılan çok amaçlı optimizasyon çalışmalarının çoğu, optimum çözümlere ulaşmak için simülasyon araçları (ör. Radiance, EnergyPlus) ile optimizasyon algoritmalarının entegrasyonunu esas alır. Bu araçlara dayalı tasarım optimizasyonuna yönelik ilgi artmasına rağmen, birçok çalışma yüksek hesaplama maliyetinin süreci yavaşlattığını belirtmektedir [155,157,165]. Uyarlanabilir cephe optimizasyonunda çok sayıda değişkenin dikkate alınması gerektiğinden hem hızlı hem de pratik çok amaçlı tasarım çözümleri geliştirmek için meta-modeller ile optimizasyon algoritmalarını birleştiren çalışmalar oldukça sınırlıdır. Mevcut çalışmalar genellikle yapay sinir ağları (ANN) [106] veya destek vektör makineleri (SVM) [136] gibi tekli meta-modelleri kullanmıştır. Ancak farklı meta-model türlerinin çeşitli kriterler doğrultusunda karşılaştırmalı analizleri literatürde eksiktir. Bu nedenle, yüksek güvenilirliğe sahip farklı meta-modellerin eğitimi, uygulama kapsamı ve karşılaştırılması, incelenmeye değer açık bir araştırma konusudur.
- **2:** Uyarlanabilir cephelerin optimizasyonu için incelenen çalışmaların büyük çoğunluğu evrimsel temelli algoritmalara (GA, NSGA-II, MOGA, MOEA) odaklanmıştır ve buna karşılık diğer meta-sezgisel optimizasyon algoritmalarını değerlendiren çalışmalar oldukça sınırlıdır. Her tasarım probleminin çözümü için farklı optimizasyon algoritmalarının performansının değişebileceği açıktır. Bu nedenle, birden fazla meta-sezgisel algoritmanın belirli bir problem çerçevesinde bir meta-modelle entegre edilmesini sağlayan, iyi yapılandırılmış çok amaçlı optimizasyon çerçevesine ihtiyaç duyulmaktadır [153,156,161].
- **3:** Uyarlanabilir cephelerin optimizasyonunda kullanılan modelleme ve simülasyon programlarına (Rhino-grashopper, DesignBuilder- EnergyPlus, Radiance) hazır kullanılan optimizasyon eklentileri (Wallacei, Octopus, Galapagos, Colibri ve evrimsel algoritma eklentileri) yaygın olarak kullanılmaktadır. Ayrıca, Matlab, Python ve R gibi programlama dilleriyle özelleştirilmiş optimizasyon yaklaşımları da literatürde mevcuttur (bkz. Tablo 1.1). Ancak mevcut çalışmaların büyük bölümünde, kullanılan hazır eklentilerin esnek olmayan yapısı nedeniyle optimizasyon öncesinde, amaç fonksiyonlarına atanan ağırlık katsayıları genellikle sabit ve eşit oranlı olarak belirlenmektedir (örneğin; enerji tüketimi: 0.5, yararlı gün ışığı aydınlatması:0.5). Bu durum, tasarımcının tercihlerini, farklı optimizasyon

algoritmalarının performanslarını hem de elde edilen optimum çözümlerin geçerliliğini sınırlayabilir. Literatürde, amaç fonksiyonlarının ağırlıklarının dinamik olarak değiştirilmesinin optimizasyon sonuçlarına etkisine dair çalışmalar son derece sınırlıdır.

## 1.2 Çalışmanın Amacı ve Araştırma Soruları

Uyarlanabilir cephelerin tasarımı ve performansının optimizasyonu ile ilgili mevcut çalışmalar, yüksek doğruluklu meta-modellerin geliştirilmesi ve farklı optimizasyon algoritmalarının etkin biçimde karşılaştırılması için gelişmiş çok amaçlı optimizasyon yöntemlerine ihtiyaç duymaktadır. Bu çalışma, uyarlanabilir cephe sistemlerinin enerji verimliliği ve gün ışığı performansını artırmaya yönelik çok amaçlı optimizasyon süreçlerinde, farklı yapay zekâ optimizasyon algoritmalarının performansını karşılaştırmaktır. Bu doğrultuda, mimari tasarım parametreleri ile çevresel koşulların etkisini göz önünde bulunduran; farklı özellik seçimi algoritmaları, meta-model yapıları ve çeşitli meta-sezgisel optimizasyon algoritmalarını entegre eden bütüncül bir yaklaşım önerilmiştir.

Bu kapsamda aşağıdaki araştırma soruları ele alınmıştır:

1. Farklı meta-model türlerinin (örneğin LR, CNN, ANN, XGB, CatBoost ve bunların hibrit yapılarının) uyarlanabilir cephe optimizasyonundaki tahmin doğrulukları ve genel performansları nasıldır?
2. Enerji verimliliği ve gün ışığı sağlama açısından uyarlanabilir cephelerin çok amaçlı optimizasyonunda, farklı meta-sezgisel algoritmaların (AOA, EP, GA, PSO, SMA, MFO vb.) performansları ve elde edilen optimum tasarım çözümleri ne ölçüde değişiklik göstermektedir?
3. Mimari tasarımda amaç fonksiyonlarına sabit ağırlıklar atamak yerine, bu ağırlıkların dinamik olarak değiştirilmesi, optimum çözümler ve farklı meta-sezgisel algoritmaların performansı üzerinde nasıl bir etki yaratmaktadır?

Tezin yapısı şu şekilde organize edilmiştir; İkinci bölüm, yapay zekâ algoritmaları ve simülasyon araçları hakkında genel bir bakış sunmaktadır. Üçüncü bölümde, bu tezde

önerilen yöntemlerin genel çerçevesi ve uygulama adımları ayrıntılı şekilde tanımlanmaktadır. Dördüncü bölümde, elde edilen sonuçlar detaylı olarak analiz edilmekte ve bulgular bağlamında kapsamlı bir tartışma yapılmaktadır. Son bölüm ise tezin genel sonuçlarını özetlemekte ve konuya ilişkin ilerleyen çalışmalar için öneriler sunmaktadır.

## 2. AI ALGORİTMALARI VE BİNA ENERJİ MODELLEME/SİMÜLASYON ARAÇLARINA GENEL BAKIŞ

**Yapay zekâ (AI)**, bilgisayar sistemlerinin bilişsel işlevleri gerçekleştirebilme kapasitesini ifade eder [166,167]. AI algoritmaları, değişen koşullar altında çeşitli algoritmalarla binaların ve alt bileşenlerinin performansını analiz etmek için kullanılır. Bu nedenle, AI algoritmaları, enerji verimliliği, ısıl/görsel konfor ve diğer bina performans ölçütlerine göre uyarlanabilir cephenin optimizasyonunda önemli bir rol oynar. Optimizasyon algoritmaları, bir probleme çözüm garantisi bulması açısından genel olarak iki grupta kategorize edilebilir:

**Stokastik (rastgele)** yaklaşımlar; özellikle karmaşık ve çok amaçlı arama alanlarında etkili çözümler sunar [168]. Genetik algoritma (GA), karınca kolonisi optimizasyonu (ACO) ve parçacık sürü optimizasyonu (PSO) gibi algoritmalar uyarlanabilir cephe optimizasyonunda yaygın olarak kullanılmaktadır [168–170]. Özellikle çok amaçlı genetik algoritmalar (MOGA, NSGA-II ve SPEA2 gibi) bina performansının çeşitli hedefleri arasında denge sağlayan optimal tasarım çözümleri üretmekte yaygın şekilde tercih edilmektedir [171,172]. Son zamanlarda, çok amaçlı genetik algoritmalar (MOGA), problemleri çözmek için klasik genetik algoritmalarından daha popüler hale gelmiştir. NSGA-II (Doğal Olmayan Sıralama Genetik Algoritması II) ve SPEA2 (Güç Pareto Evrimsel Algoritma 2) gibi popüler çok amaçlı optimizasyon algoritmaları bulunmaktadır [173]. Özellikle, bina performansı optimizasyonunda yaygın olarak kullanılmaktadır [174,175]. MOGA sayesinde, ısıl konfor ve enerji tüketimi arasında çeşitli dengeler sağlayan birçok potansiyel tasarım çözümü ortaya çıkmıştır [162]. ACO, karıncaların yiyecek arama davranışını taklit eder ve hedefler arasındaki en kısa yolu bularak optimizasyon problemlerini çözmede etkilidir [176]. ACO, elektrik tüketimini azaltma ve bina konforunu artırma potansiyeli taşır [177]. Kuşların veya balıkların sosyal davranışlarından esinlenen PSO, parçacık konumlarını iteratif olarak ayarlayarak optimal çözümler arar [178]. Genel olarak, Stokastik yöntemler, gerçek dünyadaki çevresel belirsizliklerin ve değişkenliklerin olduğu senaryolarda üstünlük sağlar [179].

İkincisi, gradyan inişi (Gradient descent), Newton yöntemi, iç nokta yöntemi, simpleks yöntemi vb. dahil olmak üzere deterministik (rastgelelik olmayan) yaklaşımlardır. Kesin tamsayı programlama (IP) algoritmaları, enerji tasarrufu yatırımlarının değerlendirilmesi [180] ve gün ışığı optimizasyonu [80] gibi optimizasyon problemlerinde kullanılmaktadır. QP yöntemi, enerji yönetim sistemi tasarımı [181] ve akıllı ev enerji sistemleri [182] ile

ilgili problemleri çözmek için kullanılır. Doğrusal olmayan programlama yöntemleri, sürdürülebilir bina tasarımı için uygun yapı malzemeleri ve sistemleri seçmek [183] ve farklı hava koşullarında güneş enerjisi kazancını optimize etmek [184] için yapılan çalışmalarda kullanılmıştır. Ancak, deterministik yöntemler genellikle karmaşık, yüksek boyutlu ve çok amaçlı problemlerde uygulama zorlukları yaşamaktadır. Ayrıca, değişken ve belirsiz koşullara uyum sağlama esnekliği sınırlıdır.

Makine öğrenmesi, bilgisayar biliminin en hızlı büyüyen alanlarından biridir ve çok çeşitli uygulamaları vardır [185]. Makine öğrenimi algoritmaları, denetimli, denetimsiz ve pekiştirmeli öğrenme olarak sınıflandırılabilir [186]. Bina performansında, Yapay Sinir Ağları (ANN), Karar Ağaçları (DT), Rastgele Orman (RF), Gradyan Güçlendirme (GB), Doğrusal Regresyon (LR) ve K-En Yakın Komşular (KNN) gibi algoritmalar sıklıkla sınıflandırma, regresyon, optimizasyon ve boyut indirgeme amaçlarıyla kullanılmaktadır. ML algoritmaları, meta-sezgisel yöntemlerle entegre edildiğinde, gerçek zamanlı verilerin işlenmesinde ve dinamik koşullara adaptasyonda önemli avantajlar sunar ve böylece uyarlanabilir cephe optimizasyonunda kritik bir rol oynar [187,188].

**Bina Enerji Modellemesi Simülasyonu (BEMS)**, binalarda enerji talebini azaltmak ve ısı konforu artırmak için kullanılan temel araçlardandır [189]. Son altmış yılda, farklı özelliklere sahip çok sayıda BEMS aracı geliştirilmiştir. Yaygın olarak bilinen bazı simülasyon araçları ve özellikleri Tablo 2.1'de özetlenmiştir. Bina enerji performansının optimizasyonuna olan artan ilgi, yapay zekâ algoritmalarının simülasyon araçlarıyla entegrasyonunu beraberinde getirmiştir. Birçok simülasyon aracı, yapay zekâ algoritmalarını kendi başına çalıştıramaz. Bu nedenle, simülasyon araçlarının farklı programlama araçlarıyla birlikte veya bu araçlar içinde kullanılması gerekir. Örneğin, jEPlus parametrik analiz ve optimizasyon için Energyplus'ı kullanır. DesignBuilder'da bina tasarım optimizasyon sorunlarını çözmek için sınırlı sayıda algoritma bulunur. Ayrıca, optimizasyon olarak sunulan araştırmaların çoğunun aslında parametrik çalışmalar olduğu ve sonuçlarının optimize edilmiş çıktılar olarak yorumlanmaktadır [190].

**Tablo 2.1:** Yaygın olarak bilinen BEMS araçları

Araçlar	Araç türü	Temel özellikler
EnergyPlus	Simülasyon motoru	Yüksek esnekliğe sahip [191], IDF dosyası desteği [192], detaylı enerji analizleri [192–194], ileri düzey/gelişmiş modeller [193,195–197]
TRNSYS	Simülasyon motoru	Eklenti desteği [198], dinamik simülasyon [86,199], sınırlı CAD uyumluluğu [198], harici araçlarla birleştirilmiş [199,200], detaylı kontrol stratejileri ve yenilenebilir enerji entegrasyonu [198,200]
jEPlus	Grafiksel Kullanıcı Arayüzleri (GUI)	Parametrik analizler ve optimizasyon [201].
DesignBuilder	Grafiksel Kullanıcı Arayüzleri (GUI)	3D modelleme arayüzü [202,203], basit geometrileri destekler [204], parametrik ve optimizasyon çalışmaları için yararlıdır (gün ışığı-CFD-ısı konfor-ayrıntılı HVAC) [205]
OpenStudio	Grafiksel Kullanıcı Arayüzleri (GUI)	Şablonlar için geniş kütüphane, açık kaynak, radiance entegrasyonu, özelleştirilebilir, Ladybug Tools ile entegre ve optimizasyon için bulut tabanlı hesaplama [206,207]
Ladybug Tools	Çevresel Araçlar	EnergyPlus, Radiance ve OpenStudio ile entegrasyon, iklim verileri desteği [208,209]

Yukarıdaki tartışmalar ışığında, kavramsal güçlü yönler ve sınırlılıklar Tablo 2.2’de özetlenmiştir:

- AI algoritmaları, optimizasyon problemlerini çözmek için kullanılan yöntemlerdir. AI optimizasyon algoritmaları ve BEMS araçları, bina performansının optimizasyonunda birbirini tamamlayıcı roller oynar [169]. Bu iki konu arasında yanlış anlaşılmalara yol açacak kavramsal bir örtüşme yoktur. BEMS araçları, tanımlanmış hedef fonksiyonlar ve kısıtlamalar dahilinde veri üretir. AI optimizasyon algoritmaları ise bu veriler ışığında en uygun çözümleri bulur.
- Bina simülasyon araçlarını kullanırken, modelleme sürecinde ayrıntılı bilgiye ihtiyaç duyulması, çok sayıda girdi parametresi nedeniyle uzun hesaplama süreleri ve tahmin edilen performans ile ölçülen performans arasındaki farkı azaltmanın zorluğu gibi önemli sınırlamalar vardır [210]. Bina simülasyon araçlarıyla optimizasyon algoritmaları kullanıldığında, tahmin edilen ve ölçülen sonuçlar arasındaki farktan

kaynaklanan hata payı deęişmeyecektir. Ancak, verileri hızlı bir şekilde üretmek ve veri sayısını artırmak için yapay zekâ algoritmalarının kullanılmasına olan ilgi giderek artmaktadır [211].

- Stokastik algoritmalar, önceki yinelemelerde seçilen en iyi çözümleri koruyarak daha iyi çözümler bulmaya çalışır [212,213]. ML modelleri, optimizasyon süreçlerini iyileştirmek ve hesaplama süresini azaltmak için stokastik algoritmalarla entegre edilebilir [214–216]. Ayrıca, ML modelleri optimizasyon algoritmalarıyla birlikte çok kriterli karar destek sistemlerinde kullanılabilir. Stokastik algoritmalar, büyük ölçekli ve karmaşık optimizasyon problemlerini ele almak için kullanışlıdır, ancak hiper-parametrelerin seçimine baęlı olarak hesaplama süreleri uzun olabilir. Bu algoritmalar, uygulama kolaylığı ve doğru sonuçları verimli bir şekilde üretme yetenekleriyle bilinir [170].
- AI algoritmaları arasındaki temel farklar, problemleri çözme yöntemleriyle ilgilidir [168]. Stokastik algoritmalar, rastgele bir başlangıç popülasyonu seçilerek başlatılır ve çözüm her çalıştırmada farklı bir sonuç üretir. Ancak, deterministik algoritmaların ürettięi sonuç deęişmez [136]. Ayrıca, deterministik yöntemler genellikle konveks problemler için global bir çözüme ulaşır.
- Deterministik optimizasyon yöntemlerinin yerel minimumlarda takılıp kalabilmesine karşın, stokastik algoritmalar küresel arama yeteneklerine sahiptir, bu da daha iyi çözümler bulmalarını sağlar. Makine öğrenimi yöntemleri veri odaklıdır. ML yöntemleri karmaşık ilişkileri modelleme yeteneğine sahiptir. ML modellerinin dezavantajlarına örnek olarak, bazı durumlarda model eğitim süresinin uzun olması, açıklanabilirlik sorunu (kara kutu sorunu) ve yeterli veri olmadan düşük performans göstermesi verilebilir. Deterministik yöntemler kesin çözümler sağlar, ancak dinamik problemleri çözmede yetersiz kalabilir. Ayrıca, bu yöntemler zaman alıcı olabilir ve farklı optimal çözümleri bulmak için birden fazla yineleme gerektirebilir, bu da hesaplama süresini artırır [217]. Tanımlanmış kısıtlamalarla çalışabilme özellikleri nedeniyle çok amaçlı optimizasyon problemlerinde kullanıma uygun değildirler [218]. Her yaklaşımın güçlü ve zayıf yönleri incelendiğinde, ML modelleri ile optimizasyon algoritmalarını birleştiren hibrit modellerin kullanımını giderek yaygınlaşmaktadır.

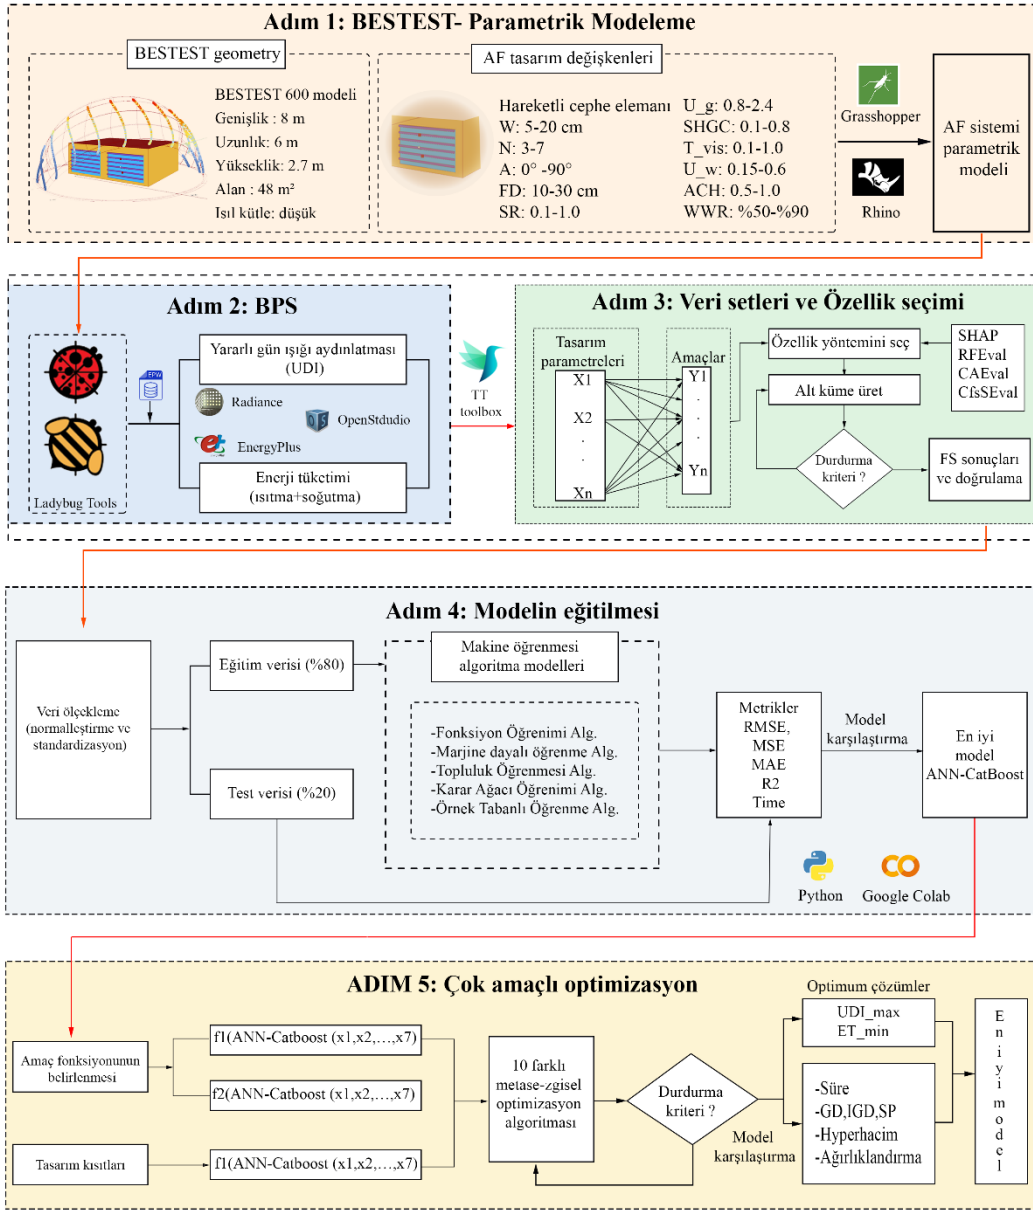
**Tablo 2.2:** Bina enerji optimizasyonunda AI algoritmaları ve BEMS araçlarının güçlü yönleri ve sınırlamaları

	<b>Güçlü yönler</b>	<b>Sınırlılıklar</b>	<b>Uygulama örnekleri</b>
BEMS	Yüksek doğruluk ve kesin sonuçlar, tasarım alternatiflerinin karşılaştırılması, geçmiş verilerin bulunmadığı durumlarda performans tahmini [169,194,219,220].	Hesaplama yoğunluğu, hesaplama maliyeti, karmaşıklık, gerekli uzmanlık, statik varsayımlar, mevcut binalar için daha az uygun, gerçek zamanlı uygulama sınırlamaları [169,218,221–223].	Enerji verimliliği iyileştirme analizi, iklim uyum stratejileri, yenilenebilir enerji entegrasyonu, yaşam döngüsü değerlendirmesi
Stokastik yaklaşımlar	Esnek ve ölçeklenebilir, tek amaçlı ve çok amaçlı optimizasyon, uygulama kolaylığı ve doğru sonuçların verimli bir şekilde üretilmesi, çözümün hızı ve kalitesi, potansiyel çözümlerin kapsamlı bir şekilde araştırılması [168,170,218,224]	Hesaplama açısından yoğun, zorlu parametre ayarlaması, sınırlı gerçek zamanlı uyarlanabilirlik [168,170,224].	Alternatif tasarım senaryoları oluşturmak ve aramak, alan kullanımı, enerji ve konforu optimize etmek, iç mekân hava kalitesi yönetimi
Makine öğrenmesi	Gerçek zamanlı verilere uyum sağlar, hızlı hesaplama süreleri sunar, doğrusal olmayan durumları işleyebilir, optimizasyon süreçleri için uygundur, tasarım alternatiflerinin karşılaştırılmasına olanak tanır, diğer yapay zekâ algoritmalarıyla entegre edilebilir [210,221,225–227].	Eğitim verilerinin kapsamıyla sınırlıdır, ölçülen verilerdeki belirsizlikleri göz ardı eder, açıklanabilirlik sorunu (Kara kutu sorunu), büyük eğitim veri kümeleri gerektirir, hesaplama maliyeti, aşırı uyum riski [210,212,226,228,229].	İklimeye duyarlı tasarım, enerji tüketimi ve konfor tahmini, doluluk tahmini ve alan kullanımı, yenilenebilir enerji kullanımını optimize etme
Deterministik yaklaşımlar	Yerel optimizasyon için mükemmel, belirli sorunlara kesin çözümler sunar, yüksek boyutlu arama uzayı için idealdir. [168,218,224].	Zaman alıcı, farklı optimal çözümler için birden fazla yineleme gerektirir, pratik değildir, yüksek boyutlu ve dinamik problemlerde zorluklar yaratır, türevlenebilir amaç fonksiyonları gerektirir, yerel minimumlarda takılı kalır. [168,218,224].	Enerji yönetimi, malzeme seçimi, gün ışığı optimizasyonu

### 3. YÖNTEM

Uyarlanabilir bir cephenin tasarımı, gün ışığı ve enerji tüketimi üzerinde önemli bir etkiye sahiptir. Bu nedenle, bu çalışmada, uyarlanabilir cephelerin enerji verimliliği ve yararlı gün ışığı aydınlatmasını optimize etmeyi amaçlayan çok aşamalı ve sistematik bir yöntem izlenmiştir.

Şekil 3.1, önerilen beş aşamalı çok amaçlı optimizasyon yönteminin çerçevesini göstermektedir. Birinci aşama, parametrik modellemenin gerçekleştirilmesidir. Bu aşamada, BESTEST bina geometrisi referans alınarak, bina tasarım değişkenleri belirlenmiş ve parametrik modelleme Rhino ve Grasshopper yazılımları kullanılarak oluşturulmuştur. İkinci aşamada, bina enerji ve gün ışığı performansını değerlendirmek için farklı simülasyon araçları kullanılmıştır. Bu aşamada, yararlı gün ışığı aydınlatması (UDI) hesaplanmış ve enerji tüketimi (ısıtma-soğutma yükleri) analiz edilmiştir. Üçüncü aşama, veri setlerinin oluşturulması ve özellik seçimi algoritmalarına dayanır. Simülasyon aşamasından elde edilen sonuçlar, veri setlerinin oluşturulmasını sağlamıştır. Özelliklerin önem derecesi ve sırasını belirlemek için çok sayıda özellik seçimi algoritma yöntemi kullanılmıştır. Bu süreç, sonraki aşamalar için en uygun parametrelerin belirlenmesini sağlamıştır. Bu işlem, sonraki makine öğrenmesi ve optimizasyon aşamaları için en uygun girdilerin seçilmesini sağlamıştır. Aynı aşamada, oluşturulan veri setleri 18 farklı makine öğrenmesi algoritması ile eğitilmiş ve her modelin performansı literatürde yaygın kullanılan değerlendirme metrikleriyle analiz edilmiştir. Son aşama, çok amaçlı optimizasyon algoritmalarının uygulanması ve karşılaştırılmasına yöneliktir. Bu bölümde, seçilen algoritmalar ve optimizasyon süreci ayrıntılı şekilde açıklanmaktadır.



Şekil 3.1: Çalışmanın yöntem akış şeması

### 3.1 AF'ler bağlamında optimize edilmiş hedefler ve tasarım değişkenleri

Çalışmanın bu bölümü; AF'lerin performansının değerlendirilmesi ve optimizasyonu bağlamında yapılan araştırmalar ile ilgili; referans, araştırmadaki amaçlar ve bu amaçlar için kullanılan tasarım parametrelerini ele almaktadır (Tablo 3.1).

**Tablo 3.1:** Çalışmalarda kullanılan amaç fonksiyonları ve tasarım parametreleri

Referans	Amaçlar	Tasarım parametreleri
[102]	Enerji, Gün Işığı	Bina yönelimi [0°-360°], PV paneller ile yatay düzlem arasındaki açı [0-90°], PV panellerin genişliğinin PV panel dizisinin aralığına oranı [0.2-2].
[103]	Görsel konfor	Cephe modülü konumları, kullanıcı noktası, çıta açısı
[104]	Enerji, Isıl konfor, Hava kalitesi	Pencere açıklıkları, fan (açık/kapalı), gölgeleme açısı konumu [0°-90°]
[105]	Enerji, Görsel konfor	Zaman, PV açısı (°), gölgeleme tipi
[106]	Gün Işığı, Parlama	Delikli alüminyum levhadaki deliklerin sayısı ve boyutu, dikey çıtalar (dönüş açısı ve genişliği)
[107]	Görsel konfor (gün ışığı, parlama) ve Enerji	Işıklık-çatı oranı [0.10-0.90], ışıklık cam tipleri (1, 2, 3, 4, 5), görünür geçirgenlik [0.10-0.90], panjur boyutu (1, 2, 3, 4, 5) ve panjur eğimi [0°-90°],
[108]	Enerji	Cephenin yönü (doğu, batı, güney), kanatların açılma açısı (0°, 45°, 90°)
[109]	Enerji, Görsel konfor	Cephe tipi, cam VT [0.05,0.9] ve U değeri (W/m <sup>2</sup> K)
[110]	Gün Işığı, Enerji	Cam oranı, cam tipi malzemeler, modül parlaklık malzemesi, modüllerin dönme açısı [0°-90°], modülün cama uzaklığı (cm) [1-50], güneşin konum açısı [0°-180°]
[111]	Enerji	Eğri kontrol noktası, pencere duvar oranı [0.01-0.98], pencere yüksekliği (m) [2-4.37], pencere eşik yüksekliği (m) [0.20-1], L şekli [0°-25°], konum, kule en-boy oranı [0.5-2], cam VT [0.05,0.91] ve U değeri (W/m <sup>2</sup> K) [0.1,5.82]
[112]	Gün ışığı	Açık, yarı açık ve kapalı konfigürasyonlar, U ve V yönündeki düğüm sayısı [1-10], Dönme eksenini için modül kenarı [0 - 2], Modüllerin duvara uzaklığı (m) [0 - 1,5]
[113]	Görsel konfor	Cephe açıları (°), cephe konfigürasyonları, cephe yönelimleri ve cephe konumları
[67]	Enerji, Görsel konfor	Cephe ızgarası üzerindeki gölgeleme konumları (tamamen kapalı, tamamen açık, ara açık ve kapalı), çıta açısı (°) (tamamen kapalı ve açık)
[71]	Parlama, Isıl konfor	Cephe döndürme [- 180°, 180°], güneş açısı (°)

**Tablo 3.1** (devam)

[114]	Enerji maliyeti	Yarı saydam yalıtım katmanının SHGC değeri [0: 0.2: 0.8], Beton katmanın kalınlığı (cm) [10:5:30], Yarı saydam yalıtım katmanının U değeri (W/m <sup>2</sup> K) [0.7:0.3:1.3]
[115]	Görsel konfor	Gölgeleme tipi, çita malzemesi, ışık rafı [50°:10:70°], çita açısı
[116]	Gün ışığı	Cephe yönleri, gölgeleme cihazı tipi (sabit ve uyarlanabilir gölgeleme cihazı yok), çita açıları [-45°:5:45°]
[80]	Gün ışığı	Gölgeleme elemanının dönme açısı [-75°:15 :75°], cephe tipi (cephe yok, statik cephe, tek tip AF, modüler AF)
[117]	Gün ışığı	Cephe yönleri, cephe konumları/iklim bölgeleri, duyarlı panjurların yatay veya dikey dönüşü [-90°, 90°], cephe tipi (duyarlı panjurlar, panjursuz ve sabit panjurlar)
[63]	Gün Işığı, Enerji ve Manzara	Pencere-duvar oranları (WWR), cam malzemeleri (U-değeri (W/m <sup>2</sup> K), Güneş Isı Kazanç Katsayısı SHGC, Görünür geçirgenlik Tvis (%)), perde malzemeleri (Görünür geçirgenlik VT (%), Açıklık Faktörü OF (%), Görüş netliği indeksi VCI) ve kontrol eşikleri, bina konumları,
[118]	Gün ışığı, Enerji (soğutma enerjisi tüketimi)	Bina yönelimi [- 30: 1:30], kanat dönüşü [0°:1:9°], kanat boyutu (cm) [2:1:9], aralık (cm) [2:1:10], çıkıntı (cm) [1:1:3],
[119]	Gün Işığı, Parlama	Cephe tipleri (düz ve dinamik), güneş konumu
[120]	Isıl konfor ve Enerji	Klima (açık, kapalı), gölgeleme sistemi (uyarlanabilir, gölgeleme yok)
[121]	Enerji (soğutma talebi)	Yönelim (güney, batı, kuzey, doğu), cephe seviyesi yüksekliği (ortalamadan düşük, ortalama ve ortalamadan yüksek), dış duvar U-değeri (W/m <sup>2</sup> K) (0,1,3), cam tipi U-değeri (W/m <sup>2</sup> K) [0:1:3]
[122]	Parlama, Enerji (ısıtma yükü, soğutma yükü)	Pencere yönü (Güney, Doğu), elektrokromik camın çalışması (açık, kapalı)
[91]	Enerji performansı ve kullanıcıların görsel/Isıl konforu	Bina yönelimi (°) (0,90,180,270), WWR (35,45,55), bina konumu

**Tablo 3.1** (devam)

[82]	Gün Işıđı, Enerji	Bina ve cephe yönleri: güney, kuzey, doğu, batı, güney-dođu, kuzey-dođu, güney-batı ve kuzey-batı, açıklık boyutunun varyasyonları, kinetik gölgeleme cihazının şekli
[123]	Gün ışığı	İç raf derinliđi (cm) [20:10:80], dış raf derinliđi (cm) [20:10:120], dış raf eğim açısı [50°:5:125°], dikey kanat (kanat derinliđi (cm) [20:10:40], kanat eğim açısı [0°:5:30°])
[124]	Görsel ve Isıl konfor	Gölgeleme tipi (Gölgeleme yok, Geleneksel ve Otomatik kullanıcı algılayıcı gölgeleme)
[125]	Enerji	Elektrokromik pencerelerin davranışı (ađartılmış durumda güneş ısı kazanç katsayısı (SHGC), renkli durumda SHGC, ađartılmış durumda görünür ışık geçirgenliđi)
[128]	Gün Işıđı, Parlama	Pencere boyutları (pencere uzunluđu ve yüksekliđi, yatay ve dikey görel koordinat), pencere-duvar konumu, güneş konumu (saat, gün ve ay), yatay gölge elemanı (yatay eleman derinliđi ve eğimi, dikey batı tarafı gölge elemanı derinliđi, dikey doğu tarafı gölge elemanı derinliđi), dikey gölge elemanı
[130]	Görsel konfor, Enerji	Gölgeleme cihazı tipi (dinamik gölgeleme (%20-%70 açıklık), sabit gölgeleme (%20 ve %70 açıklık))
[131]	Görsel konfor ve Isıl Enerji	Işık rafları: konum yüksekliđi (m) [1.80:0.1:2.20], dış ve iç dönme açısı [-30°:10:30°], dış ve iç derinlik oranı (m) [0.5:0.25:1.50]
[132]	Gün ışığı, Enerji (sođutma yükünü en aza indirme)	Çeşitli dinamik ve statik uyarlanabilir bina kabuđu tasarımı
[230]	Gün ışığı, Enerji (ısıtma ve sođutma yükleri)	Gölgelik eleman açısı 0° (tamamen kapalı) ile 90° (tamamen açık) arasında deđişir, gölgeleme tipi (stor perde, jaluzi)
[133]	Görsel konfor ve Aydınlatma	Gölgelik eleman eğim açısı [0°: 10: 90°]
[90]	Görsel konfor, Enerji	Dinamik cephe parametreleri: bileşen boyutu (m) [0,2: 0,2:0,6], eksen (yatay, diyagonal, dikey) [0: 1:2], geçirgenlik (dađımık geçirgenlik, dađımık yansımaya, speküler yansımaya) [%0, %25, %50, %75]

**Tablo 3.1** (devam)

[84]	Enerji, Görsel konfor	Cephe tipi (uyarlanabilir ve sabit cephe), uyarlanabilir cephe: Tvis ve U- değeri (W/m <sup>2</sup> K)
[231]	Enerji, Solar İrradasyon ve Ekonomik Maliyet	PV kurulum stratejileri: eğimli açı [0°:15: 90°], mesafe/uzunluk oranları
[88]	Görsel konfor	Cam rengi, kinetik cephe açısı (0°-45° ve 0°-90°)
[232]	Görsel konfor, Isıl konfor ve Enerji	Cephe sistemi: (jaluziler ve değiştirilebilir pencere), kontrol stratejileri (dinamik ve statik)
[134]	Gün Işığı, Enerji	İklima uyarlanabilir bina kabuklarının geometrik konfigürasyonları tip (tip1 ve tip 2), açıklıklar (b1, b2, b3, b4, b5)
[85]	Görsel konfor	Zaman parametreleri, zamanlama düğümleri, altıgen modül malzemeleri, iç mekân görüş açısı
[137]	Gün Işığı ve Parlama	Gölgeleme geometrisinin derecesi, gölgeleme geometrisi desenleri
[233]	Enerji, Görsel konfor	Pencere-duvar oranı, cephe elemanları U-değerleri (W/m <sup>2</sup> K) ve SGHC değerleri
[234]	Isıl Konfor	Uyarlanabilir cephenin özellikleri: Tsol, Tvis, SHGC, U-değeri (W/m <sup>2</sup> K)
[138]	Gün Işığı, Enerji	Hareketli gölgeleme cihazı tipi (p1, p2, p3, p4)
[235]	Güneş Radyasyonu, Enerji	Malzeme katmanı (aktif (Ahşap levha) ve pasif (GFRP polimer, PET polimer, PC polimer ve Ahşap levha))
[142]	Gün Işığı, Enerji	Cephe konfigürasyonları
[143]	Enerji	Cam tipleri (cam U-değerleri (W/m <sup>2</sup> K) [0.7:0.4:6], cam SHGC (0.7, 0.62, 0.60, 0.34, 0.31, 0.24), cam Tvis (0.88, 0.80, 0.65, 0.65, 0.47, 0.30)), duvar yalıtımı (U-değeri (W/m <sup>2</sup> K) (0.70, 0.46, 0.37, 0.32, 0.26, 0.19, 0.12)), sızdırmazlık (0.25, 0.18, 0.15, 0.12), dikey gölgeleme elemanlarının derinliği (mm) [100:100:1000], dikey gölgeleme elemanlarının dönüş açısı [30°:15:150°]
[144]	Enerji, Isıl konfor	Uyarlanabilir kabuk tasarımı ve kontrol parametreleri
[145]	Kullanıcı Konforu, Enerji	Cephenin eğim açısı (°)
[236]	Enerji	Cephe sistemleri (dış jaluzi, gün ışığı yönlendirme sistemi), cephe alanı (FA1, FA2, FA3), bina konumu
[146]	Görsel konfor, Enerji	Model tabanlı kontrol stratejileri, model tabanlı kontrol stratejileri (1 dakikalık kontrol aralığı, değişken kontrol aralığı)

**Tablo 3.1** (devam)

[92]	Gün ışığı	Kinetik hareket türü: dönme hareketi [30°: 15:165°] ve hücre boyutunun %10-%100'ü kadar öteleme hareketi [10:10:100]
[147]	Gün ışığı	Panjurun yatay/dikey açısı [-60°:30: 60°], panjur sayısı [5:1:13], panjur derinliği (cm) [2:1:6], pencere paneli U ve V yönündeki bölme sayısı [5:2:13], tüm pencere panelinden çıkarma oranı [0.2:0.15:0.8], desen sayısı [10:10:50]
[148]	Gün ışığı	Gölgeleme cephe durumu, gölgeleme dönme açısı
[149]	Isıl konfor ve Enerji	Azimut Açısı [0°:10: 90°], pencere duvar oranı (%) [20:10:80], çıkıntı derinliği (m) [0.2:0.1:1], en-boy oranı [1:0.1:2], cam tipi: U değeri (W/m <sup>2</sup> K) (1.5, 3.72, 1.5, 5.7), Güneş Isı Kazanç Katsayısı (SHGC) (0.25, 0.28, 0.20,0.67), Görünür Işık Geçirgenliği (VLT) (%) (50,27,35,67)
[150]	Enerji	Bina konumu ve yönelimi, U-duvar (W/m <sup>2</sup> K), U-cam (W/m <sup>2</sup> K), Tvis
[23]	Enerji, IEQ	Özgül ısı (kJ/kgK) [0,8-2,0], ısı iletkenlik (W/mK) [0,1-2,5], yoğunluk (kg/m <sup>3</sup> ) [50-3000], dış yüzey emiciliği [0,1-0,9], pencere/duvar oranı (WWR) [0,1-0,8], cam ID [1-7]: (cam U-değeri (W/m <sup>2</sup> K))
[152]	Gün ışığı	Hareket türleri: dönme ve kayma

Yukarıda irdelenen çalışmalardaki amaç fonksiyonlarının genellikle; enerji [108,143,237], görsel konfor [31,88,103], ısı konfor [234], iç hava kalitesi [104], maliyet [231] ile ilgili olduğu görülmektedir.

AF'lerin performansının optimizasyonunda kullanılan amaç fonksiyonlarının daha kapsamlı değerlendirilmesi aşağıda verilmiştir:

- Enerjiyle ilgili (%14,7): enerji tüketimini [125,143,150,236], enerji talebini [102,121], enerji yükünü en aza indirmek [122], enerji verimliliğini ve tasarrufunu sağlamak [111,133] ve enerji yoğunluğu [131] ile ilgili farklı amaç fonksiyonları oluşturulmuştur.

- Görsel konfor ve ısı konfor [124,234] ile ilgili amaç fonksiyonları bulunur ancak AF bağlamında yapılan çalışmalarda amaç fonksiyonları çoğunlukla görsel konforun (%30,7) [31,85,88,106,113,115,119] sağlanmasıyla ilgilidir. Wang et al. [71], görsel konfor kapsamında, gün ışığı performansını ve görünüşü en üst düzeye çıkarmak, parlamayı ve konforsuzluğu en aza indirmek gibi farklı amaç fonksiyonları kullanmıştır. Ek olarak gün ışığı ile ilgili; UDI [117], DA [112], ASE [116] ve DF [16] gibi metrikler amaç fonksiyonu olarak çalışmalarda yer almaktadır.
- Görsel konfor ve enerji performansının sağlanmasına yönelik amaç fonksiyonları bulunmaktadır (%37,3) [63,67,84,90,105,107,109,122,130,131,133,141,146,233,238]. Genellikle AF'lerin performansının değerlendirilmesine yönelik çok amaçlı bir optimizasyon kapsamında en çok araştırılan hedefler enerji tüketimini minimize ve gün ışığı performansını maximize etmek olarak öne çıkıyor (%40) [82,102,110,118,134,136,138,142].
- Isıl konfor ve enerji tüketimi ile ilgili amaç fonksiyonları çalışmaların %5,3'nü oluşturmaktadır [104,120,127]. Bunların dışında iç hava kalitesi [104] ve görsel konforun da amaç fonksiyonu olduğu çalışmalarda vardır [91,232].

Uyarlanabilir bir cephe/gölgeleme sisteminin kullanılması, iç mekâna ulaşan güneş radyasyonu miktarını azaltabilir. Bu durum, yazın soğutma enerjisi tüketimini azaltmak için faydalı olsa da ancak kışın ısıtma enerjisi tüketiminin artmasına neden olabilir. Bu sebeple, tüm yıl boyunca genel enerji tüketimini dikkate almak önemlidir. Bu sistemler odaya giren gün ışığı miktarını azaltabilir ve böylece aşırı iç mekân aydınlatmasının neden olduğu rahatsız edici parlamayı önleyebilir. Ancak, bu aynı zamanda bazı alanlarda yetersiz gün ışığına neden olarak yapay aydınlatma gereksiniminin artmasına yol açabilir. Bu nedenle hem görsel konfor hem de enerji tüketiminin dengelenmesi önemlidir. Çalışma kapsamında, amaç fonksiyonları bina enerji tüketimini azaltmak ve yararlı gün ışığı miktarını arttırmaktır. Enerji tüketimi; ısıtma ve soğutma enerji tüketimlerinin toplamı dikkate alınarak hesaplanmıştır. Bu çalışmada, dikkate alınan toplam enerji tüketimi, aşağıdaki formül kullanılarak hesaplanan soğutma ve ısıtma enerjisi tüketiminin toplamıdır:

$$E_{\text{Toplam tüketim}} = E_{\text{Toplam soğutma tüketim}} + E_{\text{Toplam ısıtma tüketim}} \quad (3.1)$$

Faydalı Gün Işığın Aydınlatması (UDI), iç mekanlarda gün ışığının varlığını değerlendirmek için kullanılan dinamik bir yıllık gün ışığından yararlanma metriğidir ve birçok çalışmada yaygın olarak kullanılmıştır [94,95]. CBDM (Climate Based Daylight Modelling) simülasyonuna dayalı olarak gün ışığı aydınlatmasını değerlendirmek için kullanılan UDI indeksi, kullanıcılar tarafından yararlı olarak kabul edilen aralık için işyerinde yıllık aydınlatma oluşumu olarak tanımlanmaktadır [239]. Nabil ve Mardaljevic [239] tarafından açıklanan UDI, faydalı aydınlatmayı 100 ile 2000 lux (UDI) arasında bir aralık olarak tanımlar. İç mekân gün ışığı koşulları üç ayrı aralığa ayrılır: 100 lx'in altında (çok karanlık), 100 ile 2000 lx arasında (faydalı gün ışığı aralığı) ve 2000 lx'in üzerinde (aşırı parlak) [94,240,241].

$$UDI = \frac{\sum_i w_{f_i} \cdot t_i}{\sum_i t_i} \in [0,1] \quad (3.2)$$

$$UDI_{Useful} \text{ with } w_{f_i} = \left\{ \begin{array}{l} 1 \text{ if } E_{Lower \text{ limit}} \leq E_{Daylight} \leq E_{Upper \text{ limit}} \\ 0 \text{ if } E_{Daylight} < E_{Lower \text{ limit}} \vee E_{Daylight} > E_{Upper \text{ limit}} \end{array} \right\}$$

Bu çalışmada, gün ışığının kullanılabilirliğini analiz etmek ve farklı aydınlatma aralıklarını göz önünde bulundurarak bir alanın doğal olarak ne ölçüde aydınlatıldığını değerlendirmek için UDI kullanılmıştır.

Uyarlanabilir cephelerin tasarımında, farklı parametrelere ait değerler cephe sisteminin performansı üzerinde önemli rol oynar. İncelenen çalışmalarda uyarlanabilir cephelerin performansını optimize etmek için yaygın olarak kullanılan parametreler Tablo 3.1'de detaylı olarak verilmiştir. Bunlar opak malzeme özellikleri, cam özellikleri, kontrol stratejileri, hava akışı, yönlenme, bina konumu ve cephe konfigürasyonu (açık, yarı-açık kapalı konfigürasyonlar) olarak kategorize edilebilir. Genel olarak bu parametrelerin her biri, uyarlanabilir bir cephenin genel performansı üzerinde farklı etkilere sahip olabilir. Bu parametrelerin değerleri tasarımcının amacına, amaç fonksiyonunun optimum değerine ve kullanılan kısıtlamalara bağlı olarak değişkenlik gösterebilir.

Gün ışığı ve enerji tüketimi için simülasyon gerekliliklerini göz önünde bulundurarak, bu çalışmada ilk aşama için parametrik modelle ilgili Tablo 3.2'deki tasarım parametreleri ve değerleri belirlenmiştir.

**Tablo 3.2:** Değişken olarak seçilen tasarım parametreleri

<b>Parametreler</b>	<b>Min.</b>	<b>Max.</b>	<b>Birim</b>
Gölgelik elemanı derinliği	0.1	0.3	m
Pencere duvar oranı (WWR)	50	90	%
Gölgelik elemanı sayısı	3.0	7.0	-
Gölgelik elemanı cephe mesafesi	0.1	0.3	m
Gölgelik elemanı dönme açısı	0	90	°
Gölgelik elemanı Güneş yansıtma oranı (SR)	0.1	1.0	-
Cam SHGC	0.1	0.8	-
Cam T_vis	0.1	1.0	%
Cam Kuruluşuna ait U-değeri	0.8	2.4	W/m <sup>2</sup> K
Duvar U-değeri	0.15	0.6	W/m <sup>2</sup> K
Sızdırmazlık değeri	0.5	1.0	ACH

İlk aşamada tasarım parametreleri olarak cam kuruluşuna ait özellikler (toplam ısı geçirgenlik katsayısı (U-değeri), güneş enerjisi toplam geçirgenliği (SHGC), gün ışığı geçirgenliği (Tvis)) ve pencere duvar oranı, bina sızdırmazlık değeri (ACH), dış duvar toplam ısı geçirgenlik katsayısı (U-değeri) ve hareketli gölgeleme elemanına ait özellikler seçilmiştir (kırıcı sayısı, derinlik, cephe mesafesi, dönme açısı, güneş yansıtma oranı (SR)). Bu değişkenler için belirlenen min. ve max. değerleri, literatürde (Tablo 3.1 bkz.) ve TS 825'de yaygın olarak kullanılan aralıklar arasından seçilmiştir. Sonraki aşamada özellik seçimi algoritmalarının kullanılmasıyla en etkili parametreler belirlenecektir. Seçilen parametrelerin amaç fonksiyonları üzerindeki etkilerinin belirlenmesiyle model tahmini ve optimizasyon yapılacaktır.

Çok amaçlı optimizasyon sürecinde, her bir amaç için bir amaç fonksiyonu tanımlanması gerekir. Bölüm 4.2'deki ANN-Catboost algoritması kullanılarak her bir optimizasyon amacı tahmin edilir. Bina cephesine ait tasarım değişkenleri ile her bir optimizasyon amacı arasında kurulan doğrusal olmayan model amaç fonksiyonu olarak kullanılır. Amaç fonksiyonu, ANN-Catboost algoritmasının çıktı fonksiyonu ile temsil edilebilir:

$$\min f_y(\text{ANN} - \text{Catboost}(x_1, x_2, x_3 \dots, x_n)) \quad (3.3)$$

Burada;  $f_y$  her optimizasyon hedefinin çıktı fonksiyonudur,  $x_n$  optimize edilecek değişkenlerin kümesidir. Uygun optimizasyon sonuçları elde etmek için, bina tasarım değişkenlerine belirli kısıtlamalar konulur. Genel kısıtlamalar aşağıdaki biçimde verilmiştir:

$$p_{ia} \leq x_i \leq p_{iu} \quad (3.4)$$

Burada;  $x_i$  tasarım değişkeni,  $p_{ia}$  tasarım değişkenine ait alt sınırlar ve  $p_{iu}$  tasarım değişkenine ait üst sınırları ifade etmektedir.

### 3.2 Binanın Modellenmesi ve Simülasyonu

Bu çalışmada farklı algoritmaların performanslarını karşılaştırmak için farklı enerji simülasyon yazılımlarının çıktılarının test edilmesi amacıyla geliştirilmiş ve ideal bir örnek olan ANSI/ASHRAE 140–2001 [242] standardındaki BESTEST 600 modeli kullanılmıştır. BESTEST 600 modelinin tüm girdi ve çıktı değerlerinin bilinmesi, simülasyon programında kullanıldığında gerçek çıktının elde edilmesini sağlar.

BESTEST referans binasının özellikleri, ABD ve Avrupa inşaatları arasındaki yönetmeliklere yanıt verir. BESTEST bina modelinde, hafif kütleli (600'den 650'ye kadar olan durumlar) ve ağır kütleli binalar (900'den 950'ye kadar olan durumlar) olmak üzere iki dizi yeterlilik durumu dikkate alınmaktadır [243]. Bu çalışma için BESTEST 600 (8 m × 6 m × 2,7 m, güney cephesinde 2 pencere, ısıl kütle: düşük, sızdırmazlık: 0.5 ACH, iç kazançlar: 200 W, Ayarlama noktası: ısıtma için 20°C, soğutma için 27°C) bina geometrisi kullanılmıştır. BESTEST 600, güneye bakan iki pencereye sahip basit dikdörtgen yalıtımlı bir odadır. Referans bina 48 m<sup>2</sup> taban alanına sahip dikdörtgen formu iç bölmeleri olmayan tek bir ısıl bölge olarak tanımlanmıştır. BESTEST 600 modeline ait yapı malzemelerinin termo-fiziksel özellikleri ve diğer özellikleri bina simülasyonu modellemesinde kullanılmıştır.

BESTEST 600 Referans bina Rhino/Grasshopper'da modellenmiştir (Şekil 3.2). Rhino eklentisi olan Grasshopper, tasarımcıların kod yazmadan form oluşturma algoritmaları geliştirmelerini sağlayan görsel programlama dilidir [244]. Grasshopper eklentisi olarak

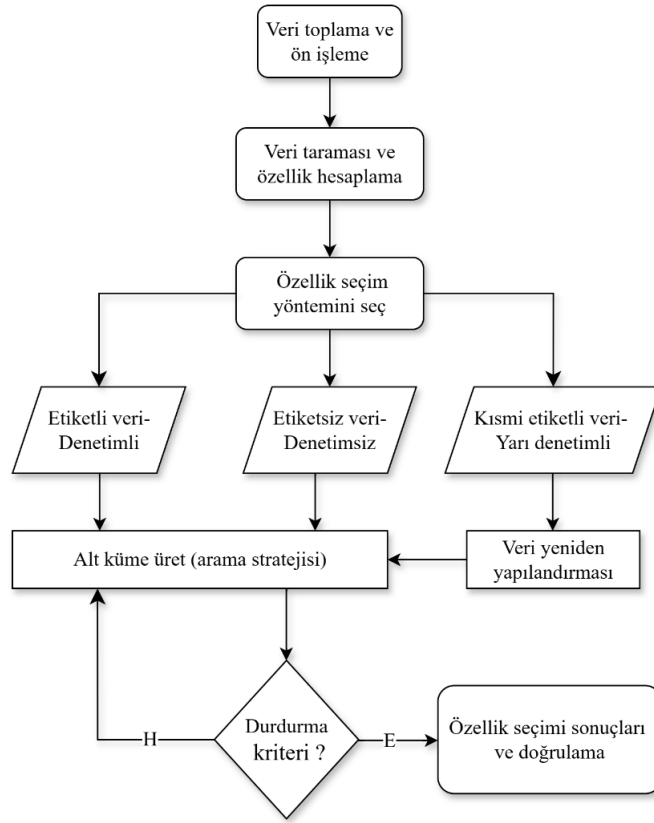
kullanılan LadybugTools enerji tüketimi ve UDI hesaplaması yapmak için kullanılmıştır. Ladybug Tools, mimarlık alanında iklim, enerji ve çevresel performans analizleri yapmayı kolaylaştıran, açık kaynaklı ve ücretsiz bir eklentidir. Ladybug Tools hesaplamalar için Radiance, EnergyPlus/ OpenStudio gibi simülasyon araçlarını kullanır [209]. Bu nedenle çalışma kapsamında, enerji tüketimi ve görsel konfor analizleri için Radiance, EnergyPlus/OpenStudio yazılımları kullanılmıştır.



**Şekil 3.2:** BESTEST geometrisinin modellenmesi ve simülasyonu

### 3.3 Özellik Seçimi Algoritmaları

Özellik Seçimi (FS), genellikle makine öğreniminde bir ön işleme adımı olarak kullanılır. FS, mühendislik, bilgisayar bilimi ve diğer birçok alan için karmaşık bir problemdir. Kullanılan eğitim verilerine (etiketli, etiketsiz veya kısmen etiketli) göre, özellik seçimi yöntemleri denetlenen, denetlenmeyen ve yarı denetlenen modellere ayrılabilir (Şekil 3.4). Özellik seçimi yaklaşımları genel olarak 5 kategoride gruplandırılır: (i) filtre; (ii) online; (iii) hibrit; (iv) sarmalayıcı; (v) ve gömülü [245]. Filtre yöntemleri, hedef özelliği tahmin etmek için özellikler arasındaki ilişkiyi dikkate alır ve en etkili özelliği belirlemek için özellikler üzerinde çeşitli istatistiksel testler uygular [246].



**Şekil 3.3:** Özellik seçimi için genel bir akış şeması

Sarmalayıcı yöntemleri, çapraz doğrulama yoluyla özelliklerin bir alt kümesini tahmin doğruluklarına göre değerlendirir. Gömülü yöntem, filtre yöntemi ve sarmalayıcı yöntemini birleştiren hibrit bir yöntem olarak kullanılır [246]. Çevrimiçi yöntemler, çevrimiçi araçlara dayalı yöntemlerdir. Hybrid yöntemler ise daha iyi sonuçlar elde etmek için yukarıdaki birden fazla farklı yöntemi birleştirir [245]. FS, ilgili öğrenme algoritması için iyi bir tahmin modeli oluşturmak için en etkili özellik kümesini seçmeyi amaçlar. FS, ML model geliştirme aşamasında önemli bir süreçtir çünkü tüm özellikler model üzerinde etkili olmayabilir [247]. FS, boyutluluğu azaltmak, alakasız verileri kaldırmak ve öğrenme doğruluğunu artırmak için etkili bir stratejidir [246,248].

Bu çalışma kapsamında, FS algoritmalarını uygulamak için WEKA ve Python yazılımları kullanılmıştır. WEKA'da özellik (attribute) seçimi, ML modellerinin performansını artırmak için veri ön işleme aşamasında kullanılan önemli bir adımdır. WEKA, özelliklerin sıralanması veya seçilmesi için çeşitli değerlendiriciler (özellik değerlendirici: Cfs Subset Eval, Relief Attribute Eval, Correlation Attribute Eval, Wrapper Subset Eval ve Classifier Attribute Eval) ve arama yöntemlerini (arama yöntemleri: BestFirst, Ranker, Greedy

Stepwise) sunar [249]. Çalışma kapsamında özellik değerlendirici olarak CfsSubsetEval, RelifAttributeEval ve CorrelationAttributeEval yöntemleri kullanılmıştır. CfsSubsetEval (Correlation-based Feature Subset Evaluator), her bir özelliğin bireysel tahmin yeteneğini ve aralarındaki fazlalık derecesini dikkate alarak bir özellik alt kümesinin değerini belirler [246]. CfsSubsetEval kriteri, Denklem 3.5'te gösterildiği gibi tanımlanmıştır:

$$CFS = \max_{S_K} \left[ \frac{r_{cf1} + \dots + r_{cfk}}{\sqrt{k + 2(r_{f1f2} + r_{f1fj} + \dots + r_{fkfk-1})}} \right] \quad (3.5)$$

$S_K$ ,  $k$  özellikten oluşan bir özellik alt kümesi  $S$ 'yi temsil eder,  $r_{cfi}$  giriş özellikleri ile çıkış hedefi arasındaki korelasyondur,  $r_{fifj}$  giriş özellikleri arasındaki karşılıklı korelasyondur [249].

RelifAttributeEval, her bir özelliğin sınıflar arasındaki ayırım gücünü ölçer. Özellik etkileşimlerine karşı özellikle hassas olan bir özellik ağırlıklandırma algoritmasıdır [250]. Özellik  $X$ 'in ağırlığı için olasılık farkı Denklem 3.6'da gösterilmiştir [249]:

$$W_X = P(X' \text{ in farklı değeri} | \text{farklı sınıf}) - P(X' \text{ in farklı değeri} | \text{aynı sınıf}) \quad (3.6)$$

Bu, aşağıdaki şekilde yeniden ifade edilebilir:

$$\begin{aligned} \text{Relief } f_x &= \frac{\text{Gini}'_x \sum_{x \in X} p(x)^2}{(1 - \sum_{o \in O} p(o)^2) \sum_{o \in O} p(o)^2} \quad (3.7) \\ \text{Gini}' &= \left[ \sum_{o \in O} p(o)(1 - p(o)) \right] \\ &- \sum_{x \in X} \left( \frac{p(x)^2}{\sum_{x \in X} p(x)^2} \sum_{o \in O} p(o|x)(1 - p(o|x)) \right) \end{aligned}$$

burada  $O$  çıktıdır ve  $\text{Gini}'$  değiştirilmiş Gini endeksidir.

CorrelationAttributeEval, bir niteliğin değerini, o nitelik ile sınıf arasındaki korelasyonu (Pearson's) ölçerek puanlar ve eşitlik 3.8'deki gibi formülize edilir [246]:

$$r = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{(\sum (x_i - \bar{x})^2)(\sum (y_i - \bar{y})^2)}} \quad (3.8)$$

Özelliklerin seçiminde kullanılan bir diğer algoritma olarak SHAP (Shapley Additive ExPlanations) algoritması kullanılmıştır. SHAP, makine öğrenmesi modellerinin yorumlanmasında oyun teorisi yaklaşımını kullanır. Klasik oyun teorisi Shapley değeri, her bir girdi özelliğinin model çıktısına katkısını açıklamak için açıklanabilir bir yaklaşım sunar. Shapley değeri eşitlik 3.9'daki gibi hesaplanır:

$$\phi_i = \sum_{S \subseteq F \setminus \{i\}} \frac{|S|! (|F| - |S| - 1)!}{|F|!} [f_{S \cup \{i\}}(x_{S \cup \{i\}}) - f_S(x_S)] \quad (3.9)$$

Burada F tüm özelliklerin kümesini, S i'inci özelliği hariç tutan özelliklerin alt kümesini ve  $f_{S \cup \{i\}} - f_S$  i'inci özelliği dahil eden ve hariç tutan tahminler arasındaki farkı temsil eder. Mevcut makine öğrenimi modelleri genellikle araştırmacıların model tahminlerini yorumlamasında zorluklar yaratır ve kara kutu modelleri olarak işlev görür. Kara kutu algoritmaları yoruma kapalıdır. Algoritmaya verilen bir girdiden, bir çıktı alınmakta fakat nedeni anlaşılammaktadır [251]. SHAP yöntemi, makine öğrenmesi modellerinin kara kutu yapısını, açıklanabilir olmasını sağlar.

### 3.4 Makine Öğrenmesi Algoritmaları

Makine öğrenmesi (ML), geniş kapsamlı uygulamalarıyla bilgisayar biliminin en hızlı büyüyen alanlarından biridir [185]. ML, bilgisayarların verilerden öğrenmesini ve amaçlar için modellerin geliştirilmesini sağlar. Ayrıca ML, makinelerle verileri nasıl daha verimli şekilde kullanacaklarını öğretir [212,252]. Çalışma kapsamında tekli (ANN, SVM, KNN vb. gibi) ve hibrit (ANN-SVM, ANN-CatBoost vb. gibi) modeller olmak üzere 18 farklı makine öğrenmesi algoritması kullanılmıştır. Bu algoritmalar öğrenme açısından; Fonksiyon Öğrenimi (Function Learning: LR, ANN, DNN, RBFNN, MLP), Marjine dayalı öğrenme (Margin-based Learning: SVM), Topluluk Öğrenmesi (Ensemble Learning: Catboost, Adaboosting regressor, ETR, GBR, LGBM, EGB), Karar Ağacı Öğrenimi (Decision Tree Learning CART) ve Örnek Tabanlı Öğrenme (Lazy learning / Instance-based learning: KNN) olarak kategorize edilebilir (her algoritma için detaylı bilgiye Tablo 4.2'de yer alan araştırmacıların çalışmalarından ulaşılabilir). Her bir öğrenme yönteminde konuya ilişkin literatürde sıklıkla kullanılan algoritmalara değinilecektir. **Fonksiyon Öğrenimi** kategorisindeki algoritmalar, veriye bir fonksiyon yaklaştırmayı amaçlamaktadır (girdi ile

çıkı arasında matematiksel ilişki fonksiyonla modellenir). Bu kategoride yer alan ANN, bir sistem için girdi ve çıkı deęişkenleri arasındaki ilişkileri bulmak için doğrusal olmayan regresyon modelleri kullanır. ANN modelleri, beyin ve sinir sisteminin elektriksel aktivitesini simüle eder [253]. ANN, çok sayıda nöronun birbirine baęlı birimlerinden oluşur. Aędaki her nöron, giriş sinyallerini alabilir ve bir çıkış sinyali gönderebilir. Bir dizi aęırlıklı sinaps, girdi verilerini toplamak için bir toplayıcı ve bir aktivasyon fonksiyonundan oluşmaktadır [254]. ANN, bina optimizasyonunda karar deęişkenleri ile amaç fonksiyonu arasında bir ilişki kurulmasında Gray Wolf Optimizer [255], MOGA [187,188], MOEA [256], NSGA-III [257], PSO ve dięer algoritmalar [258] ile birlikte uygulanmıştır. ANN modeli, bina optimizasyonu alanında en yaygın kullanılan makine öğrenmesi algoritmasıdır [259,260]. **Marjine dayalı öğrenme algoritmaları**, farklı sınıflar arasında marjinal mesafeyi saęlayan bir karar sınırını oluşturur ve SVM makine öğreniminde en güçlü sınıflandırma algoritmaları arasındadır. SVM eğitiminin temel fikri, iki eğitim desen sınıfını ayıran optimum hiper düzlemi bulmaktır [261]. SVM algoritması bina performansı optimizasyonunda ANN algoritması ile birlikte sıklıkla kullanılan bir yöntemdir. Ming [262], bina enerji performansının iyileştirilmesinde, SVM algoritmasını FHO ve LHHO optimizasyon algoritmaları ile birlikte kullanmıştır. **Topluluk Öğrenmesi**, zayıf öğrencileri kullanarak, bir modelin performansını artırmayı amaçlar. Topluluk öğrenmesinin temeli, öğrenme için birçok temel makine öğrenme modeli oluşturmaktır. Bu öğrenme modellerine belirli stratejiler uygulanarak birden fazla makine öğrenme modelini birleştirir. Yeni oluşan model temel makine öğrenme yöntemlerinden daha iyi sonuçlar verir [263]. Zhang et al. [263], konut binalarının ısıtma enerjisi tahmini için topluluk öğrenme tabanlı yaklaşım önermiş ve mevcut makine öğrenmesi algoritmalarına (MLR, ELM, EGB ve SVR) göre daha iyi sonuçlar elde etmiştir. Bu kategoride yer alan CatBoost, sınıflandırma ve regresyon için karar aęaçları kullanan bir öğrenme yöntemidir. CatBoost, kategorik verilerle çalışması (Cat) ve gradyan güçlendirme (Boost) kullanması iki temel özelliğidir. Bu yöntem, dięer makine öğrenimi modelleri gibi kapsamlı eğitim verisine ihtiyaç duymaz ve çeşitli veri formatları üzerinde çalışabilir [264]. Dasi et al. [215] CatBoost algoritmasını ve farklı meta sezgisel algoritmaların entegrasyonuna dayalı bir yöntem kullanarak binaların ısıtma enerjisini yüksek doğrulukla tahmin etmiştir. **Karar Aęacı Öğrenimi**, verileri ardışık karar kurallarına göre böler ve CART modeli hem sınıflandırma hem de regresyon problemlerinde kullanılan bir algoritmadır. Algoritma, girdinin aralık deęerinin testini temsil eden düğümler ve bir regresyon fonksiyonuna karşılık gelen yapraklardan oluşur [265]. Zekić-Sušac et al. [265], çalışmalarında kamu binalarının enerji maliyetinin tahmini için CART algoritmasıyla

birlikte ANN ve RF öğrenme algoritmalarını kullanmıştır. Sonuçlar, bir diğer karar ağacı yöntemlerinden olan RF algoritmasının en iyi performansı gösterdiğini doğrular. **Örnek Tabanlı Öğrenme** yöntemlerinden olan KNN, bir örneğin değerini, ona en yakın 'k' komşusunun ortalamasına göre belirlemektedir. KNN algoritması test ve eğitim örnekleri arasındaki mesafeyi hesaplar. Hesaplamadan sonra doğrusal arama yöntemini kullanır ve k'ye en yakın komşuyu bulur [266]. Genel olarak makine öğrenimi, verilerden öğrenmeyi ve karar almayı sağlayan algoritmalar ve modeller geliştirir. Uyarlanabilir cephelerin performansının değerlendirilmesinde; DTC [102], ANN [121,139], SVM [136] ve K- K-NN [122] gibi makine öğrenmesi algoritmaları kullanılmaktadır. Ayrıca birden fazla makine öğrenmesi algoritmasının (K-NN, SVM, Random Forest (RF)) tek bir çalışmada karşılaştırıldığı da görülmüştür [126]. Alammar ve Jabi [121] AF sistemlerinin saatlik soğutma yüklerini mevcut simülasyon araçlarına kıyasla daha kısa sürede tahmin edebilen ANN modelini tabanlı bir yaklaşım sunmuştur. Tahmin sonuçları, önerilen modelin soğutma yüklerini çok kısa süre içerisinde tahmin edebilen güvenilir bir model olduğunu göstermiştir. K. Hiyama ve Y. Omodaka [122], bir diğer yöntem olan KNN algoritmasını, soğutma işlemi problemini çözmek için kullanmış ve bu problemi başarıyla çözmüştür. Yapılan bu çalışmalara ek olarak, J. Zhu [126] çalışmasında, gün ışığı simülasyonundan elde edilen verilerle, gölgeleme aracı kontrolüne yönelik tahmin modellerini eğitmek için KNN, SVM, Random Forest (RF) gibi makine öğrenmesi algoritmalarını kullanmıştır. Makine öğrenmesi algoritmalarının tahmin modellerinin, yüksek doğruluğa sahip oldukları kanıtlanmıştır. Ayrıca tasarlanan bu gölgeleme sistemi aydınlatma enerjisinden önemli bir tasarruf sağlamıştır.

### 3.5 Meta-sezgisel Optimizasyon Algoritmaları

Mevcut Sezgisel yöntemin aksine, Meta-sezgisel yöntem etki alanından bağımsız olup genellikle yerel araması gerçekleştirir. Genellikle belirli bir çözümü kullanarak çözüme yakın olan daha iyi çözümler aranır. Bu algoritmalar, küresel olarak en uygun çözümü bulmayı garanti etmeyebilir [179]. Bu algoritmalar; Matematiksel optimizasyon yaklaşımları, Evrimsel yaklaşımlar, Fizik tabanlı algoritmalar ve Biyolojik ilhamlı yaklaşım olarak kategorize edilebilir. Çalışmanın meta-modeli, 10 farklı meta-sezgisel algoritmanın entegrasyonu ile destekleniyor: Aritmetik Optimizasyon Algoritması (AOA), Biyocoğrafya Tabanlı Optimizasyon (BBO), Simüle Edilmiş Tavlama (SA), Diferansiyel Evrim (DE), Genetik Algoritmalar (GA), Gri Kurt Optimizasyonu (GWO), Parçacık Sürüsü

Optimizasyonu (PSO), Güve Alev Optimizasyonu (MFO), Evrimsel Programlama (EP), Sümük Küfü Algoritması (SMA).

Evrimsel yaklaşımlar, türlerin kademeli olarak adapte olduğu, doğal evrim ilkesine dayalı arama ve optimizasyon teknikleridir. Evrimsel algoritmalara; Genetik Algoritmalar (GA), Genetik Programlama (GP) ve Evrimsel Programlama (EP) örnek verilebilir [267]. Bu yaklaşımlar genellikle biyoloji [268], bilgisayar bilimi [269], optimizasyon [270,271] ve mühendislik [272] dahil olmak üzere çeşitli alanlarda karmaşık sorunlarına yönelik çözümleri geliştirmek için kullanılır. **Genetik Algoritma (Genetic Algorithm) (GA)**, tarihteki en bilinen evrimsel algoritmalarından biridir. Bu algoritma, Darwin'in doğadaki en güçlü olanın hayatta kalması teorisinden yararlanır. Bununla birlikte doğadaki kromozomlardan ve genlerden ilham alır. Bir optimizasyon probleminde kromozomlar potansiyel bir çözüme ve her gen bir değişkene karşılık gelmektedir [273,274]. GA'lar, arama işlemi sırasında seçim, mutasyon ve çaprazlama gibi çeşitli operatörler kullanır [275]. GA, optimizasyon problemi geniş aralıklı parametrelere sahip olduğunda ve çok amaçlı fonksiyonlara sahip olduğunda etkilidir [171,172]. Çok amaçlı optimizasyon, bir problemin birden fazla amaç fonksiyonu ile optimizasyonunu ifade etmektedir [276]. Son zamanlarda, problemlerin çözümlerine yönelik Çok Amaçlı Genetik Algoritmalar (MOGA) klasik genetik algoritmaya göre daha popüler olmuştur. MOGA, genetik algoritmanın değiştirilmiş versiyonudur. Ayrıca bu algoritmalar uygunluk fonksiyonu açısından genetik algoritmadan farklıdır. Kalan adımları genetik algoritmaya benzemektedir [277]. NSGA-II (Non-dominated Sorting Genetic Algorithm) ve SPEA2 (Strength Pareto Evolutionary Algorithm 2) başta olmak üzere SMS-EMOA (S-metric Selection Evolutionary Multiobjective Optimization Algorithm), MOPSO (Multi-Objective Particle Swarm Optimization), ve MOEA/D (Multiobjective Evolutionary Algorithm based on Decomposition) gibi popüler çok amaçlı optimizasyon algoritmaları mevcuttur [173]. MOGA'lar birçok farklı alandaki problemlerin çözümünde ve geliştirilmesinde [278–282] kullanılmasının yanı sıra son zamanlarda bina optimizasyonunda da popüler olmuştur [174,175,283–285]. Birden çok hedefi içeren optimizasyon oluşturmak genellikle son derece zaman alan bir süreçtir. MOGA'nın uygun olan en iyi çözümleri üreterek ısı konfor ve enerji tüketimi açısından sonuçlarda azalma sağladığı görülmektedir [187,286]. Ek olarak MOGA kullanıldığında binanın enerji tüketiminde ve yapı maliyetinde de önemli azalmaların olduğu doğrulanmıştır [287]. **Evrimsel Programlama (Evolutionary Programming) (EP)**, biyolojik evrim sürecinden ilham alan bir optimizasyon ve problem

çözme tekniğidir. Evrimsel programlama (EP), karşılaştırma işlevleri için küresel bir optimum bulmaya çalışan önemli bir evrimsel algoritmadır [288]. EP geliştirildiğinde karmaşık problemleri çözmek için güçlü bir çerçeve sağlar [289] ve genellikle minimizasyon problemlerini çözmek için yaygın olarak kullanılır [290]. Yinelemeli olarak mutasyon operatörleri tarafından iki evrimsel operatöre (varyasyon ve seçime) uygulanır. Evrimsel programlamada; başlatma, mutasyon, değerlendirme ve seçim gibi ana bileşenler bulunmaktadır [291]. **Diferansiyel Evrim (Differential Evolution Algorithm) (DEA)**, doğrusal olmayan, çok modlu ve türevlenemeyen bir optimizasyon problemini çözmek için kullanılan önemli bir tekniktir [292]. Uygunluktan bağımsız olarak tüm çözümlerin ebeveyn olarak seçilme olasılığı aynıdır [293]. Diğer evrimsel algoritmalarda olduğu gibi mutasyon, seçim ve diğer operatörler mevcuttur [294,295]. **Simüle Edilmiş Tavlama (Simulated annealing) (SA)**, metallerin ısıtıldığı ve ardından yavaşça soğutulduğu işlemlerden sonra ilham alan fizik tabanlı bir optimizasyon algoritmasıdır. Optimizasyon bağlamında, tavlama sürecini simüle ederek karmaşık bir probleme en uygun çözümü bulmaya çalışır [292]. SA, optimizasyon probleminin global optimumunu bulmak için benzetilmiş bir tavlama yoluna ihtiyaç duyar. SA'nın tavlama yolu T sıcaklığının başlangıç değeri, bir soğutma fonksiyonu ve her sıcaklıkta gerçekleştirilecek iterasyon sayısı tarafından belirlenir. Bina optimizasyonu için genetik algoritma (GA) ile kullanılabilir. GA ve SA ile oluşturulan hibrit algoritma güvenilir ve sağlam sonuçlar vermiştir [296]. **Aritmetik Optimizasyon Algoritması (Arithmetic Optimization Algorithm) (AOA)**, matematiksel kurguya dayalı bir meta-sezgisel (metaheuristic) algoritmadır. Matematikte kullanılan dört temel aritmetik operatör bu optimizasyon yaklaşımının temelini oluşturur (toplama, çıkarma, çarpma ve bölme). Keşif aşaması (Exploration), çözüm uzayının daha geniş bir alanında arama yapar. Bu evrede çarpma ve bölme işlemleri kullanılır. Sömürü aşaması (Exploitation), iyi çözümler etrafında yoğunlaşarak daha detaylı ayarlamalar ve aramalar yapılır. Bu aşamada toplama ve çıkarma işlemleri etkindir. MOA (Math Optimizer Accelerated), keşif/sömürü dengesini kontrol eden parametredir ve aday çözümler, rastgele başlatılır ve iteratif olarak güncellenir [297].

Son zamanlarda, biyolojik ve doğal sistemlerin davranışlarını taklit ederek doğadan ilham alan birçok optimizasyon algoritması oluşturulmuştur. Biyo-ilhamlı optimizasyon algoritmaları, karmaşık optimizasyon problemlerini çözmek için biyolojik ve doğal süreçleri taklit eden optimizasyon teknikleridir [213]. Bu algoritmalar, çeşitli alanlarda en uygun çözümleri bulmak için doğada bulunan evrim [298] ve sürü zekâsı [299,300] gibi davranışları ve mekanizmaları taklit eder. **Particle Swarm Optimization (PSO)**, kuşların

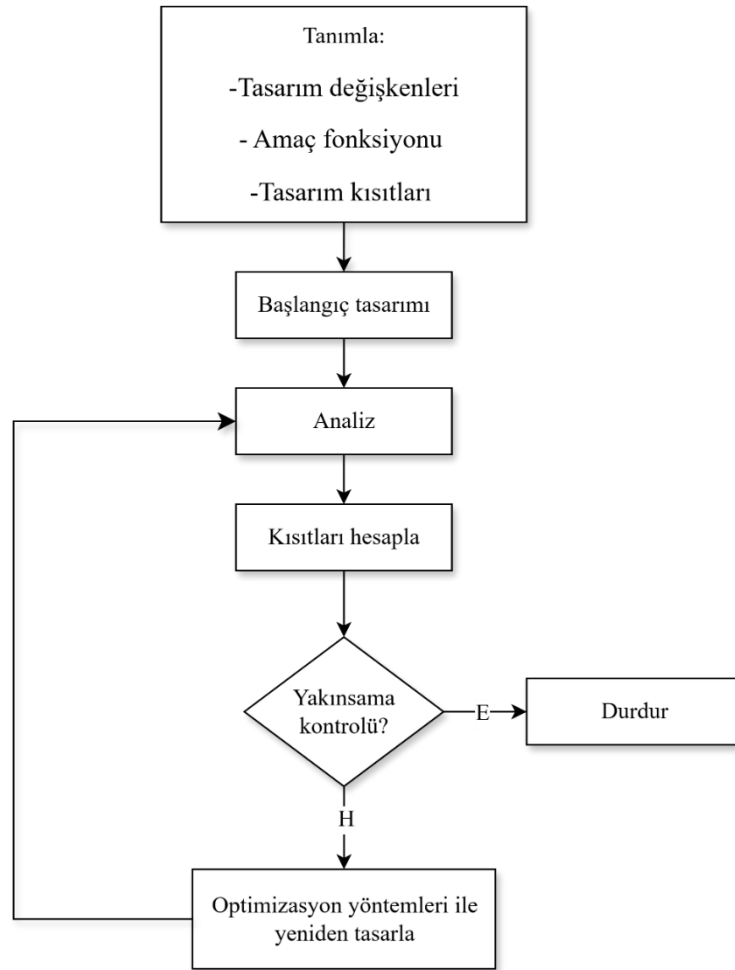
veya balık sürülerinin sosyal davranışlarından ilham alan hesaplamalı bir optimizasyon tekniğidir. PSO' da temel amaç popülasyon içindeki her parçacık için en iyi konumu bulmaktır [301]. Her parçacık, arama uzayındaki bir sonraki hareketini belirlemek için mevcut veya en iyi konumu ve rastgele bozulmalar gibi çeşitli yönlerini sürüdeki diğer bireylerle birleştirir. Bu süreç yinelemeli olarak gerçekleşir [177]. PSO kullanılarak optimize edilmiş bir konutun enerji tüketiminin, mevcut konuta oranla azaldığı sonucuna ulaşmıştır [178]. Benzer şekilde bu yöntemin kullanılmasıyla iç mekân konforunu korunduğu ve iklimlendirme için enerji tüketiminin azaldığını doğrulamıştır [302]. PSO, cam yoluyla güneş ısı kazanımlarıyla ilgili geometrik tasarım için de kullanılmıştır. Bina cephesinde dış gölgeleme için farklı geometrilerin modellenmesinde bu algoritma kullanılmıştır [303].

**Güve Alev Optimizasyonu (MFO)**, S. Mirjalili [304], 2015 yılında geliştirdi. Güveler süslü böceklerdir ve kelebek ailesine çok benzerler. Doğada güvelerin ışık kaynağına logaritmik spiral hareketle yönelme davranışını taklit eder. Güveler, "alev" adı verilen referans noktaları etrafında spiral şekilde hareket eder. Bu hareketle global optimum çözümü bulmaya çalışırlar. Her güve bir çözüm adayı ve alevlerde iyi bir çözüme ait konumu belirtir. Güveler, spiraller çizerek alevlere yaklaşır [304].

**Sümük Küfü Algoritması (SMA)**, doğadan ilham alan en yeni algoritmalarından biri SMA'dır. SMA, doğada sümük küflerinin besin arama davranışını taklit eden doğa esinli bir optimizasyon algoritmasıdır. Balçık küflerinin dalga yayılımını simüle etmek ve yiyecek bağlantıları için en iyi rotayı bulmak için matematiksel bir model kullanılır. Model, dalga yayılımı boyunca hem pozitif hem de negatif geri bildirim uyarlanabilir bir şekilde taklit eder [305].

**Grey Wolf Optimization (GWO)**, gri kurtların sosyal hiyerarşisine ve avlanma davranışına dayalı doğadan ilham alan bir optimizasyon algoritmasıdır. GWO, bir sorunun potansiyel çözümleri bir kurt sürüsü olarak temsil edilir ve davranışları sürü içindeki dört ana kurt türünden etkilenir: alfa, beta, delta ve omega kurtlar. GWO algoritmasında avlanma (optimizasyon)  $\alpha$ ,  $\beta$  ve  $\delta$  tarafından yönlendirilir.  $\omega$  kurtları, küresel optimum arayışında bu üç kurdu takip eder [306]. Diğer metasezgisel algoritmalar gibi, GWO algoritması da global optimal çözümü bulmayı garanti etmez ancak uygun bir sürede daha iyi çözümler bulmayı amaçlar [276]. Gri Kurt Optimizasyonu, mühendislik [307,308], bilgisayar bilimi [309], ve diğer farklı alanlarda da çeşitli optimizasyon problemlerine uygulanmıştır. Son and Khon, enerji tüketimini azaltmak ve ısı konforu optimum düzeye çıkarmak için GWO ve yapay sinir ağının algoritma modellerini kullanmıştır. Çok amaçlı optimizasyon, mevcut tasarımlara kıyasla ısı konfor ve enerji tüketimi açısından en iyi sonuçları gösterdiği saptanmıştır [255]. Ek olarak, Ghalambaz et al. [310], çalışmalarında, bina enerji optimizasyonu için kullanmış olup GWO'nun optimize

edilmiş çözümlerinin, literatürdeki diğer optimizasyon algoritmalarından daha iyi olduğu doğrulanmıştır. **Biyocoğrafya Tabanlı Optimizasyon (Biogeography-Based Optimization) (BBO)**, türlerin coğrafi dağılımı ve göçü prensiplerine dayanan (biyocoğrafya sürecinden ilham alan), bir optimizasyon algoritmasıdır. BBO hem tek amaçlı hem de çok amaçlı optimizasyon problemlerini çözmek için kullanılır. Dan Simon tarafından optimizasyon problemlerini çözmek için tür göçü ve habitat seçimi sürecini taklit etmenin bir yolu olarak tanıtılmıştır. Habitat (birey), HSI (uygunluk değeri), göç (iyi çözümlerden kötü çözümlere bilgi aktarımı), mutasyon ve göç oranları bu algorithmada temel kavramlar olarak ele alınabilir [311]. Optimizasyon algoritmalarına ait genel akış şeması Şekil 3.5'te gösterilmektedir.



Şekil 3.4: Optimizasyon süreci akış şeması

Yukarıda açıklanan yöntemlerden de anlaşılacağı üzere farklı alanlardaki problemlerin çözümlerine yönelik farklı yapay zekâ optimizasyon yöntemlerinin kullanıldığı görülebilir.

Optimizasyon problem türleri; amaç fonksiyonu sayısı, kısıtlama türleri, değişken türleri, tasarım değişkenlerinin izin verilen değeri ve problem yapısı açısından kategorize edilebilir [312]. Sonuç olarak, kullanılan bu yöntemleri incelediğimizde; probleme bağlı olarak maximum veya minimum olarak tanımlanacak amaç fonksiyonu, tüm olası çözümler için bir arama uzayı, arama uzayı içindeki başlangıç çözümleriyle başlama, daha iyi çözümler için bir dizi yinmeli süreç, yeni çözümler için çeşitli operatörler ve yöntemlerin kullanılması ve optimizasyonu durdurmak için durdurma koşulları veya yakınsama kriterleri içermesi gibi özellikler çeşitli AI optimizasyon tekniklerinde bulunan genel özelliklerdir.

## 4. BULGULAR VE TARTIŞMA

Binalarda AF sistemleri kullanıldığında enerji verimliliği ve kullanıcı konforu arasında bir denge sağlanabilir. Bu dengeyi sağlamak için önceki bölümde anlatılan tasarım parametrelerin optimum değerlerinin bilinmesi gerekmektedir. Doğru değişken parametrelerini belirlemek ve bu değişkenlerin en uygun değerlerini saptamak için optimizasyon teknikleri, simülasyon/modelleme araçları, kodlama programları ve diğer yöntemler sıklıkla kullanılır. Bu yöntemler, bina performansı açısından AF'ler ile en iyi performansı elde etmek için gerekli parametrelerin optimum değerlerini bulmaya yardımcı olur. Optimum değerlerin bilinmemesi durumunda, cephe sistemi iklim koşullarına ve kullanıcı ihtiyaçlarına uygun tepki veremez; bu da ısıtma, soğutma ve aydınlatma için gereğinden fazla enerji tüketilmesine yol açabilir. Gün ışığı miktarının yetersiz veya fazla olması, kamaşma gibi görsel konfor sorunları oluştururken, ısı dalgalanmalar kullanıcıların konforunu ve verimliliğini olumsuz etkiler. Bu durumda, uyarlanabilir cephenin yatırım maliyetine karşın beklenen enerji tasarrufu ve konfor artışı sağlanamaz, sistemin etkinliği düşer ve kullanıcı memnuniyeti azalır. AF performans değerlendirmesi için kullanılan yapay zekâ optimizasyon teknikleri, modellemenin yapıldığı simülasyon araçları ve optimizasyon için kullanılan araçlar ilk bölümde, Tablo 1.1'de detaylı şekilde özetlenmiş ve irdelenmiştir.

### 4.1 Özellik Seçimi Algoritmaları ve Etkili Parametrelerin Karşılaştırılması

Özellik Seçimi Algoritmaları (Feature Selection Algorithms), genellikle makine öğrenmesinde eldeki veri kümesindeki en anlamlı ve en etkili özellikleri (değişkenleri) seçmek için kullanılır. Çalışma kapsamında, bina enerji tüketimi ve görsel konforu etkileyen parametrelerin etkilerini karşılaştırmak için ReliefAttributeEval, CorrelationAttributeEval, CfsSubsetEval ve SHAP (Model eğiticisi: XGBoost) [313] gibi farklı algoritmalar kullanılmış ve sonuçları analiz edilmiştir. Tablo 4.1, her algoritmanın etkisini ve her parametrenin önem katsayısını göstermektedir. Enerji tüketimi ve görsel konfor üzerinde etkili ilk beş parametrenin tüm algoritmalarda ortak olduğu görülmüştür, ancak diğer parametrelerin önem sırası değişmektedir. En etkili değişkenleri bularak değişken sayısını azaltmak hem modelin performansı hem de hesaplama verimliliği açısından önemli faydalar sağlar.


**Tablo 4.1:** Özellik seçimi algoritma sonuçlarının karşılaştırılması

<b>SHAP</b>		<b>RelifAttributeEval</b>	
Enerji Tüketimi	UDI	Enerji Tüketimi	UDI
Infiltration (1134.95)	WWR (3.83)	Infiltration (0.468034)	WWR (0.2533)
U_glazing (339.97)	Depth (2.27)	U_glazing (0.109194)	Depth (0.1323)
WWR (173.14)	Count (1.9)	WWR (0.00257)	Count (0.1091)
U_wall (171.6)	Angle (1.06)	U_wall (0.000781)	Angle (0.0532)
SHGC (103.64)	Facade_offset (0.52)	SHGC (-0.024116)	Facade_offset (-0.0318)
Angle (39.45)	Infiltration (0.03)	Angle (-0.083405)	U_wall (-0.0518)
Depth (15.54)	SHGC (0.03)	Depth (-0.086767)	Infiltration (-0.0769)
Count (14.54)	U_glazing (0.03)	Count (-0.088497)	Sol_ref (-0.0902)
Facade_offset (11.18)	T_vis (0.03)	Sol_ref (-0.095333)	T_vis (-0.0964)
Sol_ref (0.00)	Sol_ref (0.03)	Facade_offset (-0.100318)	SHGC (-0.0998)
T_vis (0.00)	U_wall (0.02)	T_vis (-0.102143)	U_glazing (-0.1009)

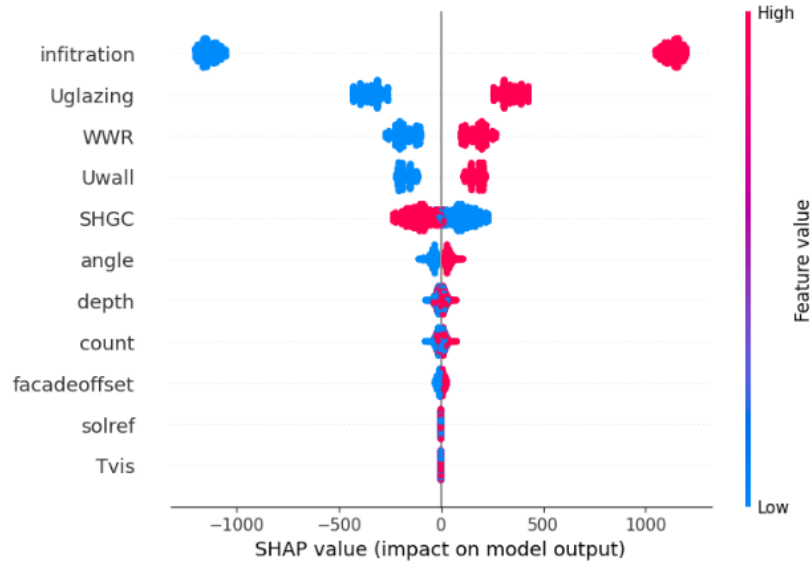
<b>CorrelationAttributeEval</b>		<b>CfsSubsetEval</b>	
Energy	UDI	Energy	UDI
Infiltration (0,9269)	WWR (-0,4640)	Infiltration (% 100)	WWR (% 100)
U_glazing (0,2777)	Count (0,1736)	U_glazing (% 100)	Count (% 100)
WWR (0,1414)	Depth (0,2415)	WWR (% 100)	Depth (% 100)
U_wall (0,1402)	Angle (-0,0316)	U_wall (% 100)	Angle (% 100)
SHGC (-0,0850)	Facade_offset (-0,0140)	SHGC (% 100)	Facade_offset (% 70)
Angle (0,0322)	U_glazing (0,0016)	Angle (% 90)	SHGC (% 30)
Facade_offset (0,0091)	Sol_ref (-0,0010)	Facade_offset (% 40)	Sol_ref (% 20)
Count (0,0042)	Infiltration (0,0001)	Count (% 30)	Infiltration (% 20)
Depth (0,0025)	U-Wall (-0,0008)	Depth (% 10)	U-Wall (% 20)
Sol_ref (0,0010)	Tvis (0,0001)	Sol_ref (% 10)	U_glazing (% 10)
T_vis (0,0000)	SHGC (0,0000)	T_vis (% 10)	Tvis (% 0)

Bina Enerji tüketimi ve yararlı gün ışığı (UDI) performansını etkileyebilecek 11 tasarım parametresinin etki dereceleri SHAP (SHapley Additive exPlanations) algoritması kullanılarak hesaplanmıştır. SHAP değerleri, her bir parametrenin model çıktıları üzerindeki ortalama katkısını niceliksel olarak analiz etmektedir. SHAP algoritması açıklanabilir bir model yapısına sahip olduğu için parametrelerin etkilerinin yorumlanmasında ve görselleştirilmesinde kullanılmıştır. Sonuçlara göre, enerji tüketimini etkileyen parametrelerin önem sırası Şekil 4.1'de gösterilmektedir. Hava Sızdırmazlığı oranı (infiltration: +1134.95) en yüksek SHAP değeri ile enerji tüketimi üzerinde en büyük etkiye sahip parametre olarak belirlenmiştir. Bu sonuç, hava sızdırmazlık oranının bina enerji tüketiminini önemli ölçüde etkilediğini göstermektedir ve seçilen aralık diğer parametrelere oranla yüksek bir etkiye sahip olduğu için çok amaçlı optimizasyon aşamasında da 0.6-1.0 aralığı kullanılmıştır.



**Şekil 4.1:** 11 parametrenin enerji tüketimi üzerindeki önem sırası

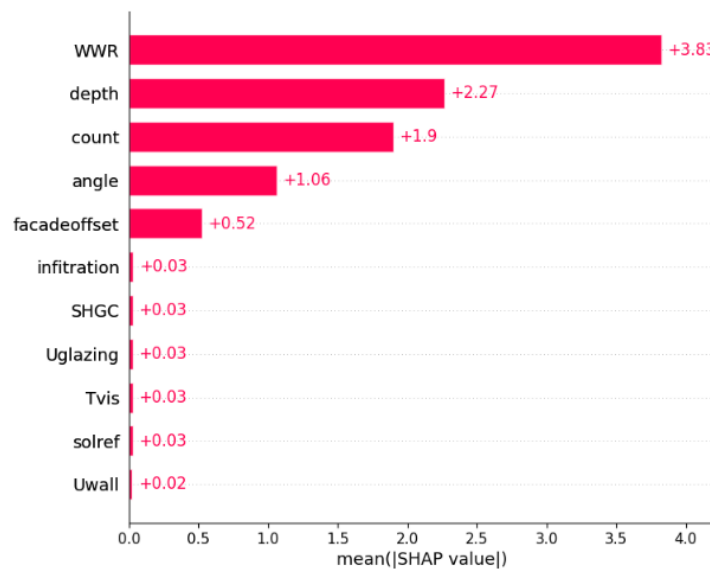
Cam kuruluşunun Toplam Isı Geçirgenliği (U\_glazing: +339.97), Pencere-Duvar Oranı (WWR: +173.14) Duvar Toplam Isı Geçirgenliği (Uwall: +171.6) ve Cam Güneşten Isı Kazanç Katsayısı (SHGC: +103.64) etkili diğer parametreler iken, geri kalan parametrelerin etkisi daha düşük seviyelerde kalmıştır. Bu sonuçları Şekil 4.2 doğrulamaktadır.



**Şekil 4.2:** Enerji tüketimini etkileyen parametrelerin etkisi


Infiltration, U\_glazing, WWR ve U\_wall parametrelerinin en düşük ve en yüksek seviyeleri arasındaki farkın diğer faktörlerden daha yüksek olması bu parametrelerin etkilerinin yüksek olduğunu gösterir. Özellikle Sol\_ref ve T\_vis enerji tüketimi üzerinde neredeyse hiçbir etkiye sahip olmadığı görülmektedir.

Yararlı gün ışığı aydınlatmasını (UDI) etkileyen parametrelerin önem sırası ise Şekil 4.3'te gösterilmektedir. Pencere-Duvar Oranı (WWR: +3.83) en yüksek değer ile en etkili parametre olarak öne çıkmıştır.



**Şekil 4.3:** 11 parametrenin UDI üzerindeki önem sırası

Bu, WWR'nin UDI üzerinde önemli bir etkiye sahip olduğunu göstermektedir. Derinlik (depth: +2.27), hareketli cephe eleman sayısı (count: +1.9) ve dönme açısı (angle: +1.06) etkili diğer parametrelerdir. Geri kalan parametreler (facadeoffset, infiltration, SHGC, Uglazing, Tvis, solref, Uwall) ise görece daha düşük etki değerlerine sahiptir (+0.52 ile +0.02 aralığında), bu sonuç UDI üzerindeki etkilerinin sınırlı olduğunu göstermektedir. Bu sonuçları Şekil 4.4 doğrulamaktadır.



**Şekil 4.4:** UDI'yi etkileyen parametrelerin etkisi

WWR, hareketli gölgelik elemana ait derinlik, sayı ve açı değerlerinin en düşük ve en yüksek seviyeleri arasındaki farkın diğer faktörlere göre daha büyük olduğu görülmektedir. Özellikle, Infiltration, SHGC, U\_glazing, T\_vis, Sol\_ref ve U\_wall, UDI üzerinde neredeyse hiçbir etkiye sahip değildir.

Bu çalışmada, özellik seçimi ve açıklanabilirlik açısından SHAP, CfsSubsetEval, ReliefAttributeEval ve CorrelationAttributeEval yöntemleri tercih edilmiştir. SHAP, özniteliklerin model üzerindeki katkılarını açıklamada güçlü bir araçtır. Relief, özellikle sınıflandırma problemlerinde özniteliklerin ayırım gücünü başarılı bir şekilde değerlendirmiştir. CfsSubsetEval, öznitelik alt kümelerinin tahmin performansını optimize etmede başarılı iken, CorrelationAttributeEval doğrusal ilişkileri hızlı ve etkili bir şekilde analiz etmiştir. Elde edilen sonuçlar, bu yöntemlerin birlikte kullanılmasıyla daha doğru ve

güvenilir öznitelik seçim sonuçları analiz edilebileceği görülmüştür. Çalışma, farklı yöntemlerin avantaj ve sınırlamalarını ortaya koyarak, uyarlanabilir cephelerin enerji tüketimi ve UDI performansına olan optimum katkısını belirlemeye yönelik modellerin geliştirilmesine ve bu modellere ilişkin sonuçların analizine katkı sağlamaktadır. Analiz sonuçları, enerji tüketimi ve UDI performansını optimize etmek için farklı tasarım parametrelerinin önemini ortaya koymaktadır. Örneğin, UDI'ye yönelik performans artışı için WWR ve derinlik gibi parametreler öncelikli olarak ele alınmalı, enerji tüketimi performansını artırmak için ise infiltration ve U\_glazing gibi faktörlerin doğru değerlerine odaklanılmalıdır. Ayrıca, WWR her iki amaç fonksiyonu üzerinde de önemli bir etkiye sahiptir. Makine öğrenimi aşaması için özellik seçimi algoritmalarının sonuçlarına bakıldığında, sonuçlar üzerinde etkili olan parametreler; Pencere duvar oranı (WWR), Sızdırmazlık değeri (infiltration), Hareketli cephe elemanı derinliği (depth), Hareketli cephe elemanı sayısı (count), Hareketli cephe elemanı dönme açısı (dönme açısı), Cam kuruluşunun Toplam Isı Geçirgenliği (U\_glazing) ve Duvar Toplam Isı Geçirgenliği (U\_wall) parametreleri olduğu analiz edilmiştir.

#### **4.2 Makine Öğrenmesi Algoritmaları Model Seçimi ve Performans Karşılaştırması**

Son zamanlarda, araştırmacılar bina performansını tahmin etmek için ML tekniklerinin kullanımı üzerinde çalışmaktadır. Bina enerji tüketimi ve görsel konfor modellemesi için birçok istatistiksel ve yapay zekâ tekniği kullanılmaktadır [95,314,315]. Özellikle literatürde yapılan çalışmalar bina enerji tüketiminin (ısıtma ve soğutma tüketimi) tahminin iyileştirilmesine odaklanmaktadır [316–318]. Tablo 4.2, bina performans tahmininde kullanılan makine öğrenmesi (ML) algoritmalarını sistematik bir şekilde özetlemektedir. Tablo, bu alandaki yöntemlerin tekli modellerden hibrit ve optimizasyon tabanlı yaklaşımlara kadar çeşitlendiğini göstermektedir. Literatürde, ANN, RF, DT, XGB, SVM, KNN, GLM, RF, GBM, DNN, QR, DT, Stacking ve GPR gibi makine öğrenmesi algoritmalarının bina performans tahmininde tek başına kullanıldığı görülmektedir. Ancak, tekli modellerin karmaşık ve doğrusal olmayan problemlerde sınırlı tahmin performansı gösterebilir. Bu nedenle çalışmalarda, BPNN-Adaboost [95], LASSO-ANN [158], ANN-SVM [155] gibi makine öğrenmesine dayalı hibrit modellerin kullanıldığı görülmektedir.

Hibrit yaklaşımlar, farklı algoritmaların avantajlarını birleştirerek daha güçlü tahmin modelleri oluşturmayı hedefler. Dahası, makine öğrenmesi algoritmalarının parametre optimizasyonu için SVR (Parametre optimizasyonu: AEO, SSA, GWO, ABC, AOA, SMA)

[319], MLP (Parametre optimizasyonu: GA, ABC, MFO, PSO, BBO, GWO, AGWO, PSO, GWO) [320], CatBoost (Parametre optimizasyonu: AOA, SBO, PSO, SMA, GWO, ABC) [215], SVM (Parametre optimizasyonu: BRO, PSO, GWO, ARCHOA, MFO, ABC) [214], CatBoost (Parametre optimizasyonu: PSO, FOA, SBO, BRO, MFO, ALO) [264], FFNN (Parametre optimizasyonu: EDA, ASO, FSA, SBO) [321], RBFNN, GRNN, ELM, Gradient based RBFNN, RBF (Parametre optimizasyonu: MGO, PSO, GA) [322], ANN (Parametre optimizasyonu: PSO, ICA, TLBO, ACO) [323] gibi optimizasyon teknikleriyle entegre edildiği görülmüştür. Bu yaklaşım, modellerin hiper-parametrelerinin optimize edilmesi yoluyla tahmin performansını arttırmayı amaçlamaktadır ancak modelin tahmin süresini uzatmaktadır. Bu çalışmada bina performans tahmin modeli için LR, ANN, DNN, SVM, CatBoost, Ada Boosting Regressor, DT, Extra Treesregressor, GBR, LGBM, XGB, KNN, RBF, MLP, ANN-MLP, ANN- CatBoost, DNN-ANN ve SVM-ANN gibi tekli ve hibrit yapay zekâ modelleri kullanılmıştır. Algoritmalara ait tahmin modellerinin performansını karşılaştırmak için literatürde sıklıkla kullanılan çoklu değerlendirme kriterleri ( $R^2$ , MSE, RMSE, MAE ve Eğitim Süresi (saniye)) metrik olarak seçilmiştir (Tablo 4.2).

**Tablo 4.2:** Model tahmini için kullanılan farklı ML algoritmalarının karşılaştırılması

Referans	Algoritma	Metrikler
Wang et al. 2020 [324]	Stacking, RF, DT, XGB, SVM, KNN	RMSE, CVRMSE, MAE, MAPE
Ngarambe et al. 2020 [314]	GLM, RF, GBM, DNN, LSTM	RMSE, MAE, $R^2$
Wang et al. 2020 [325]	ANN, SVM, Gradient Boosted Decision Trees (GBDT)	NMBE, CVRMSE
Gong et al. 2020 [326]	RF, LGBM, MLP, SVM	RMSE, MAE, MAPE, $R^2$
Gao et al. 2021 [327]	RF, SVR, KNN, XGB, GPR, ANN, CNN, LSTM	MAE, CVRMSE
Nsangou et al. 2022 [316]	QR, DT, ANN	RMSE, MAPE, MAE, $R^2$ , Eğitim süresi
Olu-Ajayi et al. 2022 [317]	DNN, ANN, SVM, RF, Gradient boosting, KNN, DT, LR, Stacking	Training Time, $R^2$ , MAE, RMSE, MSE,
Guo et al. 2022 [328]	ANN, SVM (Parametre optimizasyonu: GA)	RMSE, $R^2$
Cai et al. 2023 [319]	SVR (Parametre optimizasyonu: AEO, SSA, GWO, ABC, AOA, SMA)	MSE, RMSE, MAE, MAPE, SE, RAE, NMSE, R

**Tablo 4.2** (devam)

Zhussupbekov et al. 2023 [329]	MLR, MNLR, ANN, SVM	CVRMSE, $R^2$ , MAE, RMSE
Afzal et al. 2023 [320]	MLP (Parametre optimizasyonu: GA, ABC, MFO, PSO, BBO, GWO, AGWO, PSOGWO)	MSE, RMSE, MAPE, MAE, RAE, NMES, $R^2$
Khajavi et al. 2023 [214]	SVM (Parametre optimizasyonu: BRO, PSO, GWO, ARCHOA, MFO, ABC)	RMSE, MAPE, RAE, MAE, $R^2$
Dasi et al. 2023 [215]	CatBoost (Parametre optimizasyonu: AOA, SBO, PSO, SMA, Grey Wolf Optimizer GWO, ABC)	MAE, RMSE, MAPE, $R^2$ , RAE, NMSE
Ngnamsie Njimbouom et al. 2023 [330]	RF, GBDT, SVR, DT	RMSE, MAE
Zhang et al. 2023 [264]	CatBoost (Parametre optimizasyonu: PSO, FOA, SBO, BRO, MFO, ALO)	RMSE, MAPE, MAE, RAE, $R^2$ , WI
Fallah et al. 2023 [321]	FFNN (Parametre optimizasyonu: EDA, ASO, FSA, SBO)	$R^2$ , MAE, RMSE
Ming 2024 [262]	SVR (Parametre optimizasyonu: FHO, LHHO)	RMSE, $R^2$ , MSE, MAE, MAPE
Bian et al. 2025 [315]	XGBoost, Regression models, DT, RF, Gradient Boosting, SVR, MLP, LightGBM	RMSE, $R^2$ , MSE, MAE
Khastar et al. 2025 [322]	RBFNN, GRNN, ELM, gradient based RBFNN, RBF (Parametre optimizasyonu: MGO, PSO, GA)	RMSE, $R^2$ , MSE, MAE, MAPE
Ortega-Díaz et al. 2025 [318]	MLR, ARIMA, DNN, LSTM	RMSE, MAE, $R^2$
Zhang et al. 2025 [95]	BPNN, BPNN-Adaboost, and GWO-BPNN-Adaboost	RMSE, MAE, $R^2$
Worthy et al. 2025 [331]	CATBoost, XGBoost, RF, DT, LR	RMSE, $R^2$
Bazazzadeh et al. 2025 [332]	LGBMR, RF, ANN, SVR	RMSE, $R^2$
Mehraban et al. 2025 [333]	LR, DT, RF, GBM, SVR, KNN XGB, FNN	MAPE, $R^2$
Kangalli Uyar et al. 2025 [334]	MLR, DT, KNN, SVR, ANN, RF, XGBoost	RMSE, $R^2$
Fellah et al. 2025 [335]	SVM, ANN, RF, XGBoost	RMSE, MSE, MAE, $R^2$
Zhang et al. 2025 [336]	KELM (Parametre optimizasyonu: RTH, SCHO, TTAO)	VAF, RMSE, MAPE, $R^2$
Kalooop et al. 2025 [323]	ANN (Parametre optimizasyonu: PSO, ICA, TLBO, ACO)	$R^2$ , VAF, VIF, PI, RMSE, MAE, MBE, PE
Bu çalışma	LR, ANN, DNN, SVM, CatBoost, AdaBoostingRegressor, DT, Extra TreesRegressor, GBR, LGBM, XGB, KNN, RBF, MLP, ANN-MLP, ANN- CatBoost, DNN-ANN, SVM-ANN	MAE, RMSE, MSE, Eğitim süresi (saniye), $R^2$

Tahmin modellerinin performansını karşılaştırmak için birden fazla değerlendirme ölçütü kullanılır. Modelin doğruluğu, çıktılarının sağlanan verilerle ne kadar iyi uyumlu olduğunu belirlemek için değerlendirilir. Belirleme katsayısı ( $R^2$ ), regresyon modelinin oluşturduğu çıktılarının gerçek verilerle ne kadar uyduğunu gösterir. Bu değer 0 ile 1 arasında değişir. 1 değeri, gerçek ve tahmin edilen değerler arasında mükemmel bir uyumu gösterir. Bu da değerlerin aynı eğilime sahip olduğu anlamına gelir. MSE, gerçek değerler ile tahmin edilen değerler arasındaki farkların karesinin ortalamasıdır. Bu hata metriği modelin doğru tahminlerde ne kadar başarılı olduğunu ölçmektedir. Kök ortalama kare hatası (RMSE), bir veri noktasının dikey bir çizgi boyunca ölçülen, uydurulmuş çizgiden ortalama uzaklığıdır. Bu metrik, istenmeyen büyük farkları etkili bir şekilde belirler. MAE, tahmin edilen ve gerçek değerler arasındaki ortalama mutlak farkı hesaplayarak, tahmin edilen ve gerçek sonuçlar arasındaki ortalama sapmanın sezgisel bir ölçüsünü sağlar. Daha küçük bir MAE değeri, daha yüksek tahmin doğruluğu ve tahmin edilen ve gerçek değerler arasında daha yakın bir eşleşme olduğunu gösterir. Performans metriklerine ait hesaplama formülü aşağıda verilmiştir:

$$R\text{-Squared}= 1- \frac{\sum(y_i-y_p)^2}{\sum(y_i-y_m)^2} \quad (4.1)$$

$$MAE= \frac{1}{N} \sum_{i=1}^N |y_i - y_p| \quad (4.2)$$

$$MSE= \frac{1}{N} \sum_{i=1}^N (y_i - y_p)^2 \quad (4.3)$$

$$RMSE= \frac{1}{N} \sum_{i=1}^N (y_i - y_p)^2 \quad (4.4)$$

$$RMSE= \sqrt{MSE}= \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - y_p)^2}$$

Burada, N; örneklem sayısı,  $y_i$ ; gerçek değer,  $y_p$ ; y'nin tahmin edilen değeri ve  $y_m$  y'nin ortalama değeridir.

MAE, MSE ve RMSE değerleri sıfıra yakın olan modeller iyi tahmin modelleriyken,  $R^2$  değerleri bire yakın olan modeller en güvenilir modellerdir. Bu çalışma, bina performans tahmini veya benzer bir regresyon problemini çözmek için kullanılan farklı makine öğrenmesi (ML) algoritmalarının performansını RMSE, MSE, MAE, R-Squared ( $R^2$ ) ve


eđitim süresi metrikleri üzerinden karşılařtırmaktadır. Tablo 4.3, hem geleneksel hem de modern ML yöntemlerinin yanı sıra hibrit modelleri içermektedir. Bu çalıřma kapsamında, ANN-CATBOOST hibrit modeli en yüksek  $R^2$  deęeri (0.980) ile en iyi performansı göstermiřtir. Yani modelin verideki varyansın %98'ini açıklayabilmektedir; dolayısı ile dięer modellere kıyasla üstün bir performans göstermektedir. Ayrıca bu hibrit model hata oranı en düşük modeldir (RMSE: 0.026, MSE: 0.001, MAE: 0.006). CatBoost ve DNN-ANN ikinci en iyi tahmin modelleri olarak ortaya çıktı.

**Tablo 4.3:** Model tahmini için kullanılan farklı ML algoritmalarının karşılařtırılması


Model	RMSE	MSE	MAE	$R^2$	Eđitim süresi (saniye)
Linear Regression (LR)	0.115	0.013	0.092	0.59	0.348
Artificial Neural Network (ANN)	0.066	0.004	0.041	0.871	43.25
Deep Neural Network (DNN)	0.252	0.005	0.051	0.848	31.57
Support Vector Machine (SVM)	0.117	0.014	0.094	0.589	44.455
CatBoost Algorithm	0.064	0.004	0.038	0.877	5.21
AdaBoostingRegressor	0.113	0.013	0.092	0.624	12.35
Decision Tree (DT)	0.119	0.014	0.095	0.57	0.76
Extra Treesregressor	0.114	0.013	0.092	0.60	6.35
GradientBoostingRegressor (GBR)	0.083	0.007	0.064	0.793	3.24
Light Gradient boosting machine (LGBM)	0.073	0.005	0.053	0.841	0.30
Extreme Gradient Boosting (XGB)	0.070	0.005	0.041	0.855	37.1
K-Nearest Neighbors (KNN)	0.082	0.007	0.056	0.802	<b>0.24</b>
Radial Basis Function (RBF)	0.074	0.005	0.055	0.836	72.327
Multi-layer Perceptron (MLP)	0.087	0.007	0.069	0.783	13.061
MLP-ANN	0.067	0.005	0.047	0.864	48.26
ANN-CATBOOST	<b>0.026</b>	<b>0.001</b>	<b>0.006</b>	<b>0.980</b>	94.15
DNN-ANN	0.061	0.004	0.041	0.877	52.26
SVM-ANN	0.068	0.005	0.047	0.860	25.566

SVM algoritması, Chou et al. [337] çalışmasında ısıtma enerji tüketimini tahmin etmede en etkili algoritma iken bu çalışmada, düşük bir performans göstermiştir. Ancak, SVM algoritması, yüksek performansa sahip ANN tekli algoritması ile hibrit bir model oluşturarak (ANN-SVM), diğer algoritmalarından daha iyi performans göstermiştir. DT, Extra Treesregressor ve LR tabanlı modeller en düşük performansa sahip olmakla birlikte, LR modelinin eğitim süresi bu algoritmalara göre daha kısadır. En hızlı eğitim süresi (0,24 saniye) KNN algoritmasına aittir, ancak KNN'nin  $R^2$  değeri (0.80) tekli modellere (ANN, Catboost, DNN, MLP, XGB, LGBM) göre daha düşük performans göstermiştir. LR'nin düşük  $R^2$  (0.59) ve yüksek RMSE (0.115), değerlerine sahip olması doğrusal olmayan problemlerde zayıf kaldığını gösterir. Eğitim süresinin kısa olması (0.348 saniye), basit problemler için daha etkili olduğunu doğrulamaktadır. Boosting tabanlı ensemble (topluluk) yöntemlerinden XGBoost ve LightGBM, iyi bir performansa sahip ( $R^2 \sim 0.85$ , düşük RMSE) ve hızlı eğitim süreleriyle öne çıkmaktadır. CatBoost, en yüksek  $R^2$  (0.877) değerine sahip topluluk algoritması iken AdaBoost, en düşük performans ( $R^2$ : 0.624, RMSE: 0.616) gösteren algoritma olmuştur. ANN ve MLP'nin performansı incelendiğinde ANN, en düşük hata metrikleriyle (RMSE: 0.066) en iyi tekli modeldir. MLP, ANN'den daha düşük bir performans göstermiştir ( $R^2$ : 0.783), ancak eğitim süresi daha kısadır (13.061 saniye). Şekil 4.5'teki grafikler, Tablo 4.3'teki algoritmalara dayalı sonuçları göstermektedir. Burada x eksenini gerçek değerleri, y eksenini ise tahmin edilen değerleri göstermektedir. Chou et al. [337] en iyi topluluk modeli iki en iyi tekil modelden (SVR + ANN) türetmiştir. Özellikle, topluluk modelinin en iyi performansı, bireysel tahmin modellerinin en iyi performansından üstündü. Bu çalışmada en iyi iki tekli model olan ANN ve CatBoost algoritması benzer bir yöntem kullanılarak mevcut tüm modeller arasında en yüksek doğruluk ve en iyi tahmin sonuçlarına sahip olmuştur. Bu, CatBoost'un gradient boosting yeteneği ile ANN'nin doğrusal olmayan modelleme gibi güçlü yönlerinin etkisini yansıtır. Hosamo et al. [155], çalışmalarında önerdikleri GLSSVM enerji tüketimi tahmin modeli, mevcut tüm modeller arasında en yüksek doğruluk ve en iyi tahmin sonuçlarına sahiptir. Bu, çoğunlukla tek bir modele dayanan diğer yöntemlere kıyasla, hibrit model tekniği sayesinde mümkün olmaktadır. Benzer şekilde, Zhang et al. [95], BPNN'nin sınırlamalarını gidermek için Adaboost algoritması BPNN için bir optimizasyon yöntemi olarak önerilmiştir. Adaboost algoritması aracılığıyla birden fazla zayıf BPNN öngörücüsünü güçlü bir öngörücüye birleştirmiştir. Böylelikle yüksek tahmin yeteneğine sahip bir BPNN-Adaboost modeli oluşturmuştur. Hibrit yöntem, farklı yapaya zekâ ve geleneksel yöntemlerin güçlü yönlerini birleştirdiği için en iyi performansı vermelidir. Literatürden, modern yapay zekâ


yöntemlerinin geleneksel yöntemlerle karşılaştırıldığında doğruluk açısından daha iyi sonuçlar verme potansiyeline sahip olduğu görülebilir [338]. Literatürde yapılan çalışmalarda, ANN-CatBoost hibrit modelinin hem enerji tüketimi hem de görsel konforun tahmininde kullanılmadığı görülmektedir. Genellikle bu alanda ANN ve SVM yöntemleri ön plana çıkmaktadır. Ancak ANN-CatBoost hibrit modelinin ANN-SVM hibrit modelinden daha iyi performans gösterdiği gözlemlenmiştir. Ahmad et al. [339] ve Hosamo et al. [155] çalışmalarının sonuçları, bu çalışmanın sonuçlarını desteklemektedir. Literatürdeki diğer çalışmalarda makine öğrenmesi modellerinin hiperparametrelerini optimize etmek ve tahmin doğruluğunu arttırmak için çok sayıda optimizasyon algoritması kullanılmışlardır [95,214,215,319,323]. Bu yöntemler tahmin performansını önemli ölçüde arttırmakla birlikte anılan yöntemleri kullanmak zaman alıcıdır ve optimizasyon verimliliğini etkiler. Bu çalışmada önerilen ANN-CatBoost hibrit modeli bu çalışmalara göre benzer bir doğruluğa sahiptir ancak incelen bu yöntemlere göre daha hızlı bir performans göstermiştir.




ANN




SVM




CatBoost algorithm



DNN




LR




ANN-SVM


Şekil 4.5: Çalışma kapsamında incelenen ML algoritma sonuçları




ANN- CatBoost algorithm




MLP




RBF



XGB




KNN




LGBM


Şekil 4.5 (devam)




GBR




Extra Treesregressor




DT



MLP-ANN



Adaboosting-Regressor



DNN-ANN

Şekil 4.5 (devam)

### 4.3 AI Optimizasyon Algoritmaları İçin Performans Karşılaştırması

Uyarlanabilir cepheler bağlamında, UDI ve toplam enerji tüketimi ilgili tasarım parametrelerinin optimizasyonu için meta-model ve meta-sezgisel algoritmalar kullanılmıştır. Bu çalışma, çok amaçlı bir optimizasyon oluştururken Pareto çözümlerini belirlemek üzere meta-modelleri optimizasyon algoritmalarıyla birleştirmiştir. Optimizasyon algoritmasında amaç fonksiyonu için Tablo 4.4'te gösterildiği gibi bir meta-model kullanılmış ve Pareto çözüm kümesi, meta-modelin çok amaçlı optimizasyon algoritmasıyla birleştirilmesiyle elde edilmiştir. Literatür incelendiğinde genellikle benzer optimizasyon algoritmaları (GA türleri, PSO, RVEA, C-TAEA) kullanılmıştır (Tablo 4.4). Diğer meta-sezgisel algoritmalara ve karşılaştırmalarına çok az çalışmada yer verilmiştir. Benzer durum meta-modellerin uygulanması için de söylenebilir. Çalışmalarda genellikle ANN meta-modeli sıklıkla kullanılmıştır, ancak diğer algoritmalar meta-model olarak kullanıldığında ANN'ye göre daha iyi performans gösterdiği görülmektedir. Çalışma kapsamında amaç fonksiyonu ile tasarım değişkenleri arasındaki ilişki ANN-CatBoost doğrusal olmayan regresyon ilişkisine dayanır. Bu regresyon ilişkisi, çok amaçlı optimizasyon problemini çözmek için AOA, BBO, SA, DE, GA, GWO, PSO, MFO, EP ve SMA gibi farklı meta-sezgisel algoritmalarında uygunluk fonksiyonu olarak kullanılacaktır.

Çalışma kapsamında kullanılan özellik seçimi algoritmaları ile belirlenen etkili 7 adet tasarım değişkeninin değer aralığına dayalı olarak toplam enerji tüketimini en aza indirirken, UDI'yi en üst düzeye çıkarmayı amaçlamaktadır. Optimizasyon problemi minimizasyona dayandığı için UDI amaç fonksiyonu değeri,  $1/UDI$  olarak ele alınmıştır.

**Tablo 4.4:** Bina performansı optimizasyonunda meta-modele dayanan çalışmalar

Referans	Amaçlar	Optimizasyon algoritmaları	Uygunluk fonksiyonu	Değerlendirme kriteri
Magnier et al. 2010 [162]	Isıl konfor, Enerji tüketimi	GA	ANN metamodel	Optimum çözüm
Si et al. 2019 [163]	Isıl konfor, Enerji tüketimi	MOPSO, NSGA-II, MOSA, ES	ANN metamodel	Öklid mesafeleri, standartlaştırılmış aralık ölçüsü göstergesi, standartlaştırılmış nesil mesafesi göstergesi

**Tablo 4.4** (devam)

Xu et al. 2021 [161]	Isıl konfor, Gün ışığı	<b>NSGA-II</b> , MOPSO	<b>ANN metamodel</b>	Pareto çözümlerinin sayısı
Chegari et al. 2021 [160]	Enerji tüketimi, Isıl konfor	<b>NSGA-II</b> , <b>MOPSO</b> , MOGA	<b>ANN metamodel</b>	GD, IGD, hesaplama süresi, optimum çözümler ve çeşitliliği.
Chen et al. 2022 [340]	Karbon emisyonları, Isıl konfor, Maliyet	<b>NSGA-II</b> , <b>NSGA-III</b> , MOEA/D	<b>BPNN metamodel</b>	Süre, HV
Araújo et al. 2023 [154]	Enerji tüketimi, Maliyet	<b>NSGA-II</b> , SMPSO, OMOPSO, IBEA	<b>CNN metamodel</b>	Ayarlanmış hiperparametreler
Kubwimana et al. 2023 [341]	Enerji tüketimi	Bayesian optimization, <b>GA</b>	<b>ANN metamodel</b>	Optimum çözüm, zaman, yakınsama
Shi et al. 2024 [342]	Isıl konfor, Gün ışığı, Enerji tüketimi	<b>NSGA-II</b> , <b>NSGA-III</b> , and RVEA	<b>OPT-ANN metamodel</b> , ANN, RF, XGB, KNN, DT	GD, IGD, SP
Shan et al. 2025 [159]	Enerji tüketimi, Karbon emisyonları, Maliyet	<b>NSGA-II</b>	<b>LightGBM metamodel</b> (Other algorithms: FRF, MVL, ANN)	Mahalanobis mesafesi ve göreceli yakınlık
Singh Rajput et al. 2023 [256]	Isıl konfor, Enerji tüketimi	<b>NSGA-II</b> , PSO	<b>ANN metamodel</b>	Nesil sayısında yakınsama, Optimum çözüm, ortalama pareto dağılımı
Zhan et al. 2024 [158]	Konfor, Karbon emisyonları, Maliyet	<b>NSGA-II</b> , <b>NSGA-III</b> , <b>C-TAEA</b>	<b>Two-stage meta model</b> , FC-ANN, LASSO-ANN	HV
Wu et al. 2024 [157]	Enerji tüketimi, Gün ışığı, Isıl konfor	<b>NSGA-II</b>	<b>Bayesian optimization-XGBoost meta model</b> (Diğer algoritmalar: KNN, SVR, RF)	Optimum çözüm
Yan et al. 2022 [164]	Enerji tüketimi, Gün ışığı, Isıl konfor	<b>MOGA</b>	<b>XGBoost metamodel</b> , Linear model, Bayesian model, MLP, LSTM	Optimum çözüm
Ilbeigi et al. 2020 [270]	Enerji tüketimi	<b>GA (Galapagos)</b>	<b>ANN metamodel</b>	Optimum çözüm

**Tablo 4.4** (devam)

Hosamo et al. [155]	Enerji tüketimi, Isıl konfor	NSGA-II	<b>GLSSVM metamodel</b> (Diğer algoritmalar: LR, ANN, SVM, GPR, DNN, RF, XGB, ANN-SVM, LSSVM, GMDH)	Optimum çözüm
Zhang et al. 2025 [95]	Gün ışığı, Enerji tüketimi	NSGA-II	<b>GWO-BPNN-Adaboost metamodel</b> , (Diğer algoritmalar: BPNN, BPNN-Adaboost)	Optimum çözüm
Afzal et al. 2024 [156]	Enerji tüketimi	<b>MOBBO</b> , MOPSO	<b>ELM metamodel</b> (Diğer algoritmalar: MLP, RSM, RBF)	Optimum çözüm
Luo et al. 2025 [165]	Enerji tüketimi, Gün ışığı, ısı konfor, Maliyet	<b>NSGA-II</b> , NSGA-III, RVEA, C-TAEA	<b>XGBoost metamodel</b> , (Diğer algoritmalar: RF, SVM, ANN)	HV
Bu çalışma	Enerji tüketimi, UDI	AOA, BBO, SA, DE, GA, GWO, PSO, MFO, EP, SMA	<b>ANN-CatBoost meta-model</b> , (Diğer algoritmalar: LR, ANN, DNN, SVM, CatBoost, AdaBoostingRegressor, DT, ExtraTreesRegressor, GBR, LGBM, XGB, KNN, RBF, MLP, ANN-MLP, DNN-ANN, SVM-ANN)	HV, Optimum çözüm, Süre, GD, IGD, SP

Çok amaçlı optimizasyon problemi aşağıda gösterildiği gibi tanımlanmıştır:

$$\begin{cases} \text{Enerji tüketimi}_{min}(\text{ANN} - \text{Catboost}(x_1, x_2, x_3, \dots, x_7)) \\ 1/\text{UDI}_{min}(\text{ANN} - \text{Catboost}(x_1, x_2, x_3, \dots, x_7)) \\ X1 \in [5, 20], X2 \in [3, 7], X3 \in [50, 90], \\ X4 \in [0.8, 2.4], X5 \in [0.6, 1.0], X6 \in [0, 90], X7 \in [0.15, 0.6] \end{cases} \quad (18)$$

Çok amaçlı optimizasyon yapmadan önce, Pareto önü doğruluğu ile hesaplama karmaşıklığı arasında en iyi dengeyi elde etmek için optimizasyon algoritma parametrelerini ayarlamak

gerekir [154,155,160,341]. Bu çalışmada, optimizasyon algoritmaları için parametre ayarları Tablo 4.5'te verilmiştir.

**Tablo 4.5:** Optimizasyon algoritmalarına ait temel parametre ayarları

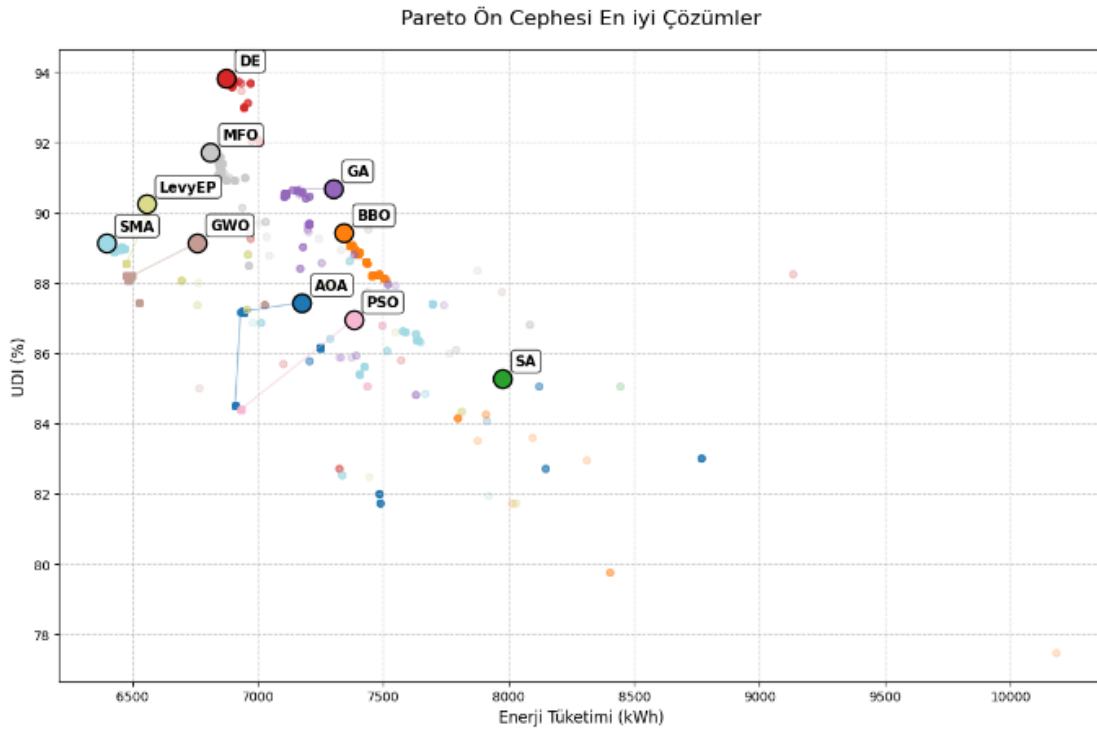
Optimizasyon Algoritması	Parametreler
AOA	(epoch=1000, pop_size=50, alpha = 5, miu = 0.5, moa_min = 0.2, moa_max = 0.9)
BBO	epoch=1000, pop_size=50, p_m=0.01, n_elites=2
SA	epoch=1000, pop_size=50, temp_init = 100, step_size = 0.1
DE	(epoch=1000, pop_size=50, miu_f = 0.5, miu_cr = 0.5, pt = 0.1, ap = 0.1)
GA	(epoch=1000, pop_size=50, pc=0.9, pm=0.05)
GWO	(epoch=1000, pop_size=50)
PSO	(epoch=1000, pop_size=50, alpha=0.4)
MFO	(epoch=1000, pop_size=50)
EP	(epoch=1000, pop_size=50, bout_size = 0.05)
SMA	(epoch=1000, pop_size=50, pr=0.03)

Popülasyon büyüklüğünün 50 ve iterasyon sayısının 1000 olduğu tüm algoritmalara ait pareto cephesi optimum çözümler ve algoritmaların çalışma süresi Tablo 4.6 ve Şekil 4.6'da verilmiştir.

**Tablo 4.6:** Tüm algoritmalara ait optimizasyon sonuçları

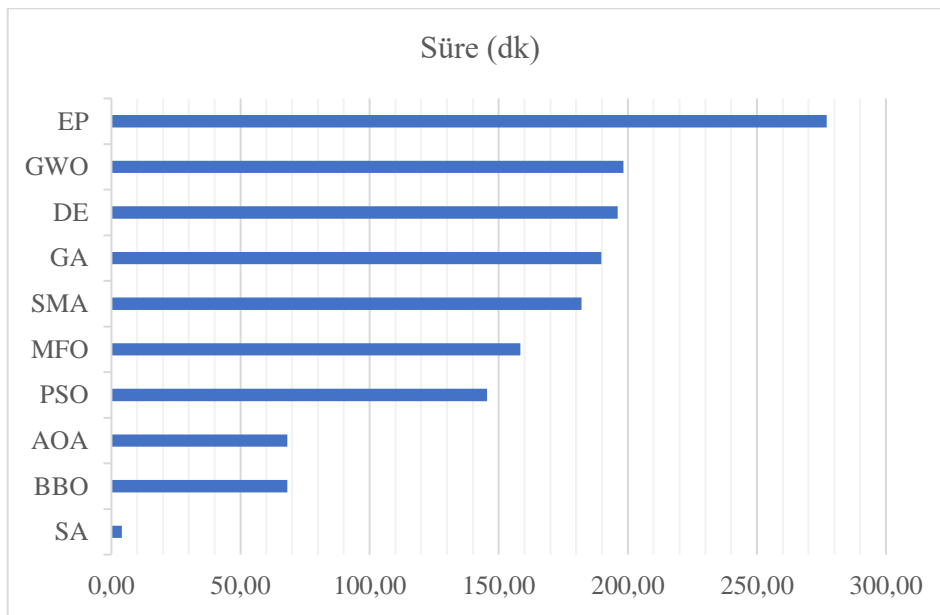
Algoritmalar	Optimum tasarım değişkenleri							Amaçlar		Süre dk
	X1	X2	X3	X4	X5	X6	X7	Energy (kWh)	UDI (%)	
AOA	20	7	89.9	1.20	0.70	22.50	0.15	6931.59	87.17	68.18
BBO	20	7	79.8	0.80	0.70	45.02	0.25	7343.63	89.42	68.15
SA	20	6	83.65	1.00	0.75	46.41	0.25	7975.50	85.27	<b>3.68</b>
DE	20	7	85.00	1.40	0.71	35.60	0.22	6875.54	<b>93.82</b>	196.1
GA	20	7	81.30	0.80	0.72	45.90	0.22	7108.24	90.54	189.8
GWO	20	7	85.20	0.90	0.62	34.98	0.22	6476.36	88.19	198.3
PSO	20	5	86.90	0.80	0.70	24.63	0.19	6933.37	84.39	145.5
MFO	20	6	85.00	0.80	0.71	37.50	0.20	6810.21	91.72	158.4
EP	20	6	85.04	0.90	0.65	31.34	0.15	6557.30	90.24	277.0
SMA	20	7	85.00	1.00	0.60	22.50	0.15	<b>6397.24</b>	89.12	182.1

X1: Hareketli gölgelik elemanın derinliği (cm), X2: Hareketli gölgelik elemanın sayısı, X3: Pencere duvar oranı, X4: Cam kuruluşunun Toplam Isı Geçirgenliği, X5: Sızdırmazlık oranı, X6: Hareketli gölgelik elemanın dönme açısı, X7: Duvar Toplam Isı Geçirgenliği

**Şekil 4.6:** Tüm algoritmalara ait optimizasyon sonuçları

SMA algoritması en düşük enerji tüketimini (6397.24 kWh) hesaplarırken GWO (6476.36 kWh) ve EP (6557.30 kWh) sırasıyla ikinci ve üçüncü sırada yer almıştır. Ancak, SA algoritması optimizasyon sonucunda en yüksek enerji tüketimine (7975.50 kWh) ulaşan çözümler üretmiştir. DE algoritması, UDI performansını en yüksek (%93,82) bulan

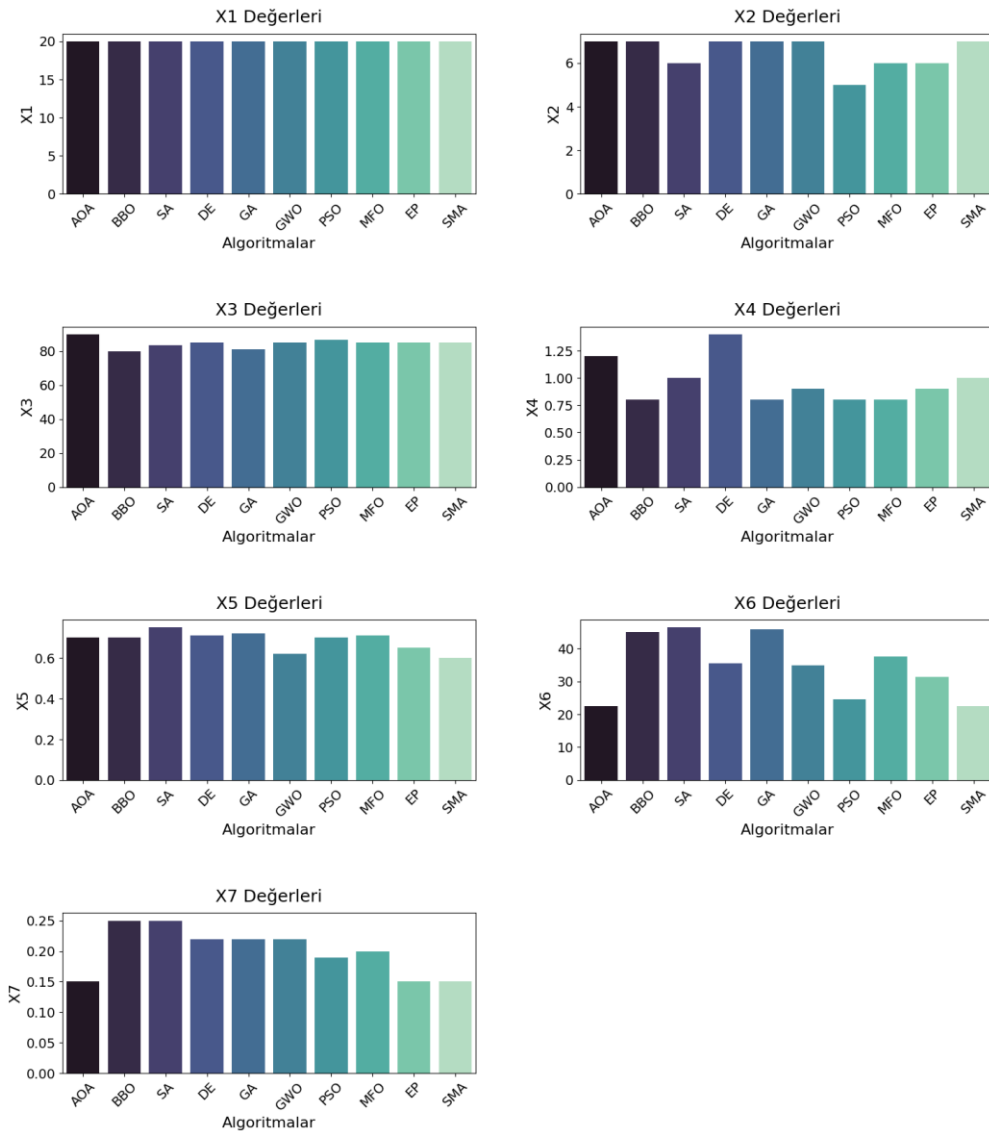
optimizasyon algoritması olmuştur. MFO (%91,72) ve GA (%90,54) algoritmaları görsel konfor açısından en iyi performans gösteren diğer algoritmalar olurken PSO algoritması, %84,39 ile en düşük UDI değerini hesaplamıştır. Algoritmaların performansı hesaplama süresi açısından incelendiğinde SA algoritması, 3.68 dk ile en hızlı sonuç üreten optimizasyon algoritmasıdır (Şekil 4.7). SA, hızlı yakınsaması nedeniyle erken tasarım aşamalarında ve sürenin daha ön planda olduğu tasarım problemlerinde kullanımı tercih edilebilir. Böylelikle parametrik tasarım süreçlerinde SA algoritması ile konsept çeşitliliği hızlı bir şekilde test edilebilir. Dahası, EP optimum sonuçları bulmada başarılı iken hesaplama süresi açısından (277.0 dk) en düşük performansı gösteren algoritma olmuştur.



**Şekil 4.7:** Optimum çözümler için algoritmaların çalışma süreleri

Şekil 4.8, meta-sezgisel algoritmaların optimizasyon sürecinde amaç fonksiyonlarına bağlı olarak optimum tasarım değişkenlerinin değişimini göstermektedir. Tüm optimizasyon algoritmaları, hareketli gölgelik elemanı derinliğini (X1) 20 cm olarak bulmuştur. Bu sonuçla hareketli gölgelik elemanın derinliğinin 20 cm olduğunda hem enerji tüketimi azalmış hem de iç mekâna istenmeyen gün ışığının nüfuz etmesini engellenmiştir. Hareketli gölgelik elemanın sayısı (X2) 5 ile 7 arasında değişkenlik göstermektedir. Hareketli gölgelik elemanın sayısını PSO algoritması en düşük sayıda bulmuştur ve UDI açısından diğer algoritmalara göre en düşük değeri hesaplamıştır. Ancak 84.39% UDI ile kabul edilebilir görsel konfor aralığı sağlanmıştır. Diğer algoritmaların sonuçlarına göre hareketli gölgelik elemanın sayısının artması güneş kontrolünü olumlu yönde etkilemektedir. Bu sayı, seçilen

binaya ait diğer uygun parametrelerle kullanıldığında enerji verimliliği yüksek tasarım seçeneği olarak değerlendirilebilir. Optimum pencere duvar oranı (X3) %79,8 (BBO) ile %89,9 (AOA) arasında değişmektedir. Pencere duvar oranı %85 değerinde olduğunda hem yararlı gün ışığı aydınlatması hem de enerji tüketimi performansı dengelemektedir. Hareketli gölgelik elemanının dönme açısının (X6) tam kapalı veya tam açık olmadığı (22.50 - 46.41) açılar optimum çözümler olarak tespit edilmiştir. Tam kapalı çözüm mimari açıdan kabul edilir olmadığından diğer alternatifler uygulamada tercih edilebilir. Genellikle tüm algoritmalar optimum çözümler için düşük hava sızdırmazlık oranını bulmuştur. Ayrıca, duvara ait düşük toplam ısı geçirgenlik (X7) (0.15 W/m<sup>2</sup>K) enerji tüketimini önemli ölçüde azaltmıştır.



**Şekil 4.8:** Meta-sezgisel algoritmalara ait optimum tasarım değişkenleri

Bu çalışmada, 10 optimizasyon algoritmasının performansı yakınsama ve çeşitliliğe dayanarak değerlendirilmiştir. Çok amaçlı optimizasyon algoritmalarını karşılaştırmak için literatürde sıklıkla kullanılan; algoritmaların yürütme süresi, HV (Hypervolume) [158,165], GD (Generational Distance), IGD (Inverted Generational Distance) ve SP (Spacing metric) [153,163,342] metrikleri optimizasyon algoritmalarının performans göstergesi olarak kullanılmıştır. Bu göstergeler bir optimizasyon yönteminin yakınsamasını ve optimizasyon sonuçlarının güvenilir olup olmadığını değerlendirmek için kullanılır [342]. Hiperhacim çözüm uzayındaki veri noktaları tarafından oluşturulan hiperküpün hacmini temsil etmektedir. Bu gösterge, gerçek Pareto cepheleri veya bir dizi referans senaryosu olmadan çok boyutlu bölgelerde yakınsama performansı değerlendirmesine yardımcı olur [158,340].

GD, bir optimizasyon algoritmasının bulduğu çözümler kümesinin her birinden ( $A \{a_1, a_2 \dots a_n\}$ ) Pareto cephesine ( $Z \{z_1, z_2 \dots z_n\}$ ) olan mesafeyi ölçer [343]. Optimizasyon sürecinin yakınsama özelliklerini değerlendirmek için kullanılır. GD değeri ne kadar küçükse, optimizasyon sürecinin yakınsaması o kadar iyidir [342]. GD değeri aşağıdaki gibi formülize edilir:

$$GD (A) = \frac{1}{|A|} \left( \sum_{i=1}^{|A|} d_i^p \right)^{\frac{1}{p}} \quad 4.5$$

Her bir  $a_i \in A$  çözümü için,  $Z$ 'deki en yakın noktaya olan Öklid mesafesi ( $p=2$ ) olan  $d_i$  hesaplanır. Burada,  $d_i$ ;  $a_i$  çözümünün Pareto ön cephesine ( $Z$ ) olan en kısa mesafesini temsil eder.

IGD, GD'yi tersine çevirerek  $Z$  kümesindeki her bir noktanın  $A$  kümesindeki en yakın noktaya olan uzaklığını ölçer. Böylelikle her algoritmanın bulduğu çözüm kümesinin ( $A$ ), Pareto cephesine ( $Z$ ) ne kadar iyi dağıldığını gösterir [344]. IGD, her bir algoritmanın yakınsama kalitesini ve çözüm çeşitliliğini değerlendirir. Bu değer ne kadar küçükse, iyi yakınsama ve çözümler düzgünlük gösterir [153,163,342]. IGD değeri aşağıdaki gibi formülize edilir:

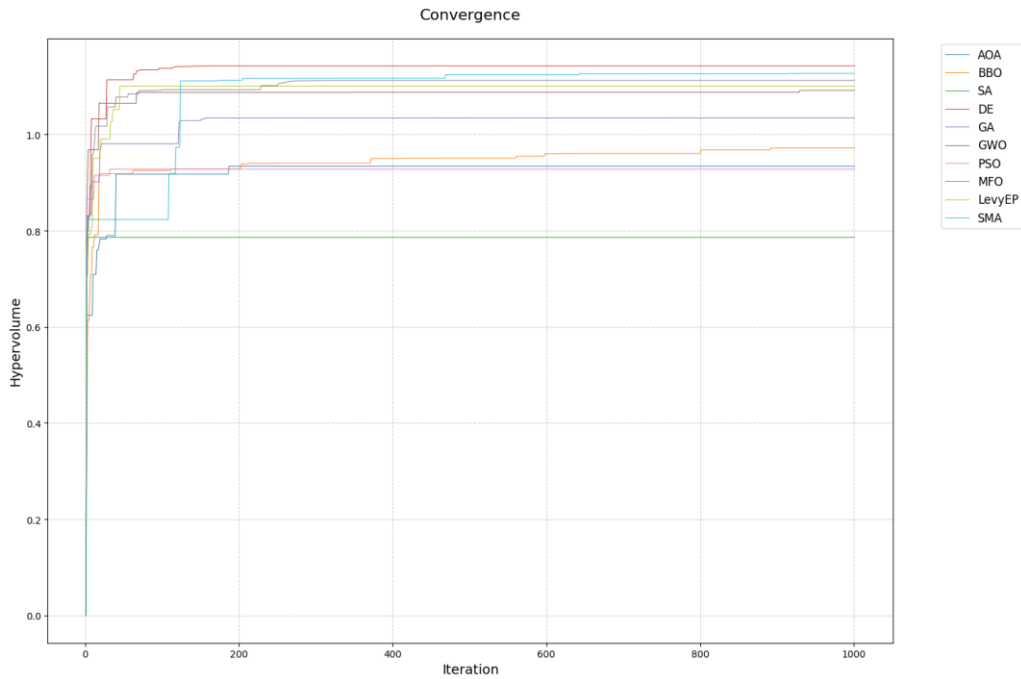
$$IGD (A) = \frac{1}{|Z|} \left( \sum_{i=1}^{|Z|} \hat{d}_i^p \right)^{\frac{1}{p}} \quad 4.6$$

Burada  $\hat{d}_i$ ,  $z_i$  noktasının A kümesindeki en yakın referans noktasına olan Öklid mesafesi ( $p=2$ ) olarak tanımlanır.

SP, optimize edilmiş çözüm kümesinin dağılım özelliklerini (çeşitlilik) değerlendirmek için kullanılır. SP değeri ne kadar küçükse, elde edilen Pareto sınır dağılımının daha düzgün olduğunu gösterir [345].

$$SP(A) = \frac{1}{|A|-1} \left( \sum_{i=1}^{|A|} (d_i - \bar{d}_i)^2 \right) \quad 4.7$$

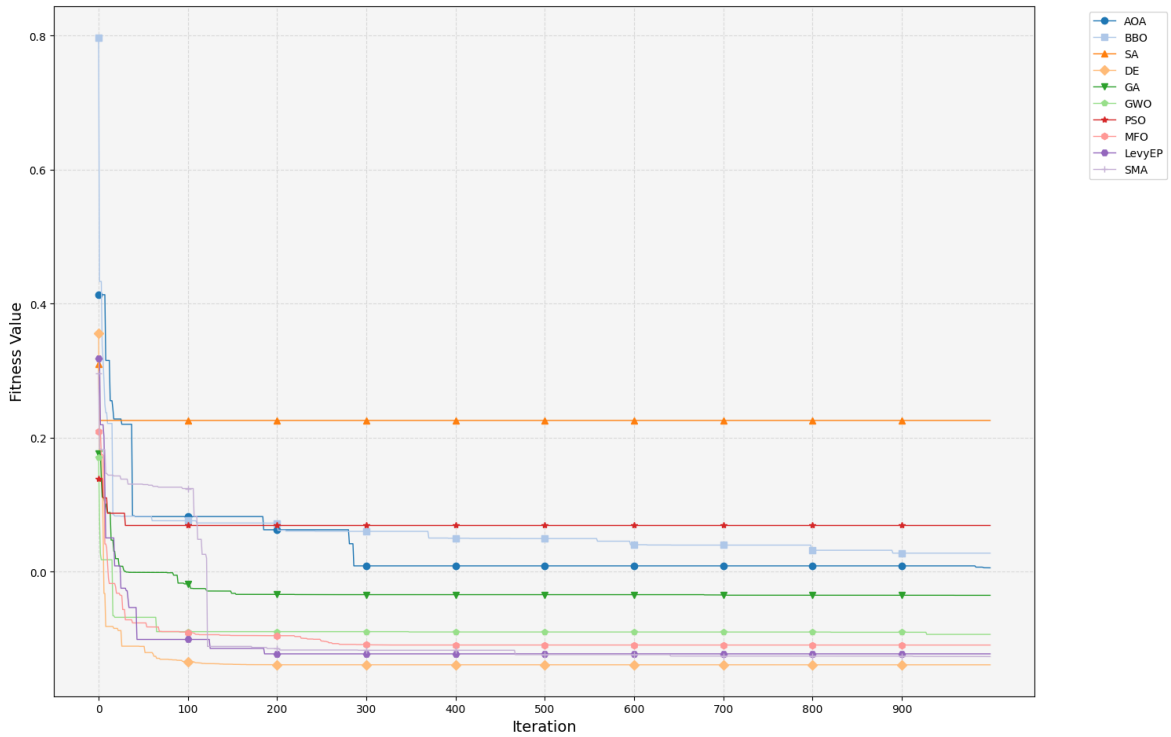
Şekil 4.9'da her optimizasyon algoritmasının HV performansı, her algoritmaya farklı bir renk verilerek karşılaştırılması yapılmıştır.



**Şekil 4.9:** Meta-sezgisel optimizasyon algoritmalarının hiperhacmi

Şekil 4.9'a göre DE, SMA, MFO, EP ve GWO algoritmalarının en başarılı algoritmalar olup DE algoritması en yüksek hiperhacim değerine sahiptir. DE algoritması, yaklaşık 100–200 iterasyon içerisinde hypervolume değerini en yükseğe çıkarmıştır. Sonraki iterasyonlarda SMA, MFO ve BBO algoritmaları HV artışıyla birlikte yukarı doğru bir büyüme göstermektedir. Özellikle DE, SMA, MFO ve EP algoritmaları, optimizasyon süreci boyunca bu algoritmaların performansının iyi olduğu ve hedef fonksiyonlarını her


hesaplama neslinde daha fazla optimize etmişlerdir [165,257]. İterasyon sayıları ilk iterasyondan son iterasyona kadar büyüyen bir eğimle devam etmektedir. Tüm algoritmalar 1000 iterasyondan itibaren göreceli bir kararlılığa ulaşmaktadır ve sonraki iterasyonlarda çok daha iyi çözümlere ulaşamayacağını göstermektedir [257]. Bu algoritmalar hem yakınsama hem de çeşitlilik açısından güçlü bir denge sağlamıştır. SA ve PSO hızlı yakınsama eğilimi göstermiş olmasına rağmen, HV değerleri diğer algoritmalara göre düşük seviyede kalmıştır ve ilk iterasyonlardan sonra çok az değişim göstermiştir. Özellikle SA algoritmasının çözüm çeşitliliği açısından yeterli performansı gösteremediğini ve çözüm uzayını yeterince keşfedemediğini göstermektedir (Şekil 4.10). SA ve PSO algoritmalarının HV performansının diğer algoritmalara göre düşük olması uyarlanabilir bir cephenin çok amaçlı optimizasyon probleminde çeşitli çözümler üretmede yetersiz kaldığını gösterir ve ilk iterasyonlarda yerel minimuma takılmalarından kaynaklanabilir. Bu nedenle Pareto ön cephesi için çeşitli çözümler üretememişlerdir. Yukarıdaki sonuçları Şekil 4.10 doğrulamaktadır. Şekil 4.10, optimizasyon algoritmalarının iterasyon sayısına bağlı değişen fitness (uygunluk) değerlerini göstermektedir. Bu şekil, algoritmaların optimum çözümleri bulma yetenekleri, çözüm kalitesi ve yakınsama hızı ile ilgili bilgiler vermektedir.



**Şekil 4.10:** Meta-sezgisel optimizasyon algoritmalarının iterasyon sayısına göre uygunluk değerleri

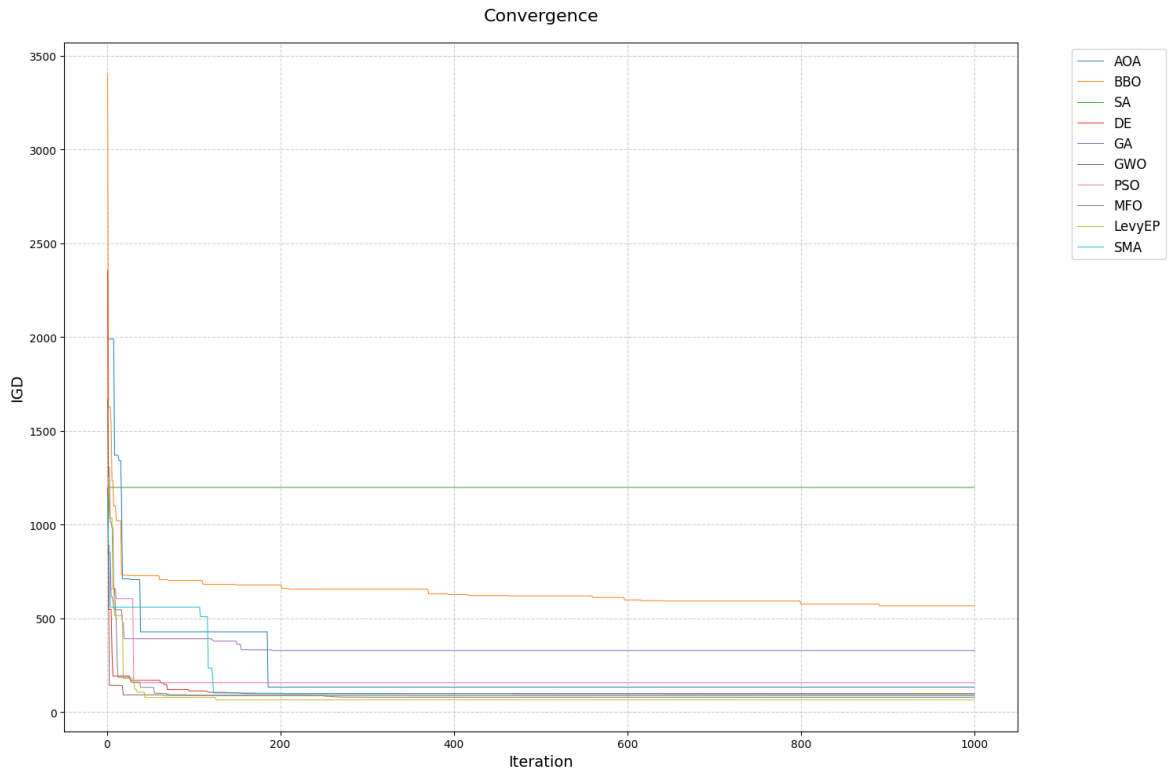
DE, LevyEP, MFO ve SMA algoritmaları, ilk 200 iterasyonda en iyi çözümleri bulmada keskin düşüşler göstermişlerdir. Bu algoritmalar, 1000 iterasyon sonucunda, çok düşük fitness değerlerine ulaşarak çok amaçlı problemi çözmede diğer algoritmalara göre daha kaliteli çözümler (enerji tüketimi düşük, UDI değeri yüksek) üretmişlerdir. Bu sonuçlar Tablo 4.6 ile paralellik göstermektedir. Temeli arama olan her algoritma exploration (keşif) ve exploitation (sömürü) yeteneği arasında bir denge sağlamalıdır. Keşif, arama uzayında yeni bir bölgeye erişme sürecidir ve arama uzayında geniş bir bölgeyi tarayarak potansiyel çözümleri keşfeder. Algoritmaların keşif amacı, küresel kapsamda baskın olan çözümleri içeren bölgeyi kaçırmamaktır. Sömürü ise daha önce bulunan iyi çözümler etrafında yoğun aramalar yaparak optimal çözümü bulmaya çalışır. Sömürü, algoritma arama sonuçlarının iyileştirilmesinde etkilidir [346,347]. Çalışmada, DE, SMA, MFO ve LevyEP yüksek sömürü (exploitation) kapasitesine sahip olan algoritmalarlardır. SA, AOA, PSO ve BBO algoritmaları, grafikte diğerlerine kıyasla yüksek fitness değerlerinde sabit kalmıştır. Sonuç olarak bu optimizasyon algoritmaları küresel minimuma etkili bir şekilde ulaşamamış (global optimuma yakın olmayan çözümler) ve uyarlanabilir cephelerin çok amaçlı optimizasyon problemini çözmede etkili keşif veya sömürü dengesi kuramamıştır [346,347].

Şekil 4.11' optimizasyon algoritmalarının GD performansını göstermektedir. DE, EP ve MFO önemli optimizasyon yakınsama hızları ve yüksek kararlılık göstermiştir. Bu algoritmalar 1000 iterasyon sonunda en düşük GD değerlerini elde ettiği için yüksek kaliteli Pareto-optimal kümeler elde etmede en iyi performansı göstermiştir. Bu algoritmaları sırasıyla GWO, PSO, SMA, AOA, GA, BBO ve SA algoritmaları takip etmektedir. Özellikle SA'nın Pareto-optimal kümelerini referansa yakın bir yere yerleştirme becerisi en düşük olan algoritmadır. Bu nedenle tüm algoritmalar arasında tüm performans metriklerinde en düşük değerlere sahiptir. Si et al. [163] çalışmasında, NSGA-II, MOPSO, MOSA ve ES algoritmalarını önerilen çok amaçlı optimizasyon problemine uygulamış ve MOSA algoritmasının diğer algoritmalara göre düşük performans gösterdiği sonucuna ulaşmıştır. Tez çalışmasından elde edilen sonuçlarda da SA algoritması en düşük performansı göstermiş ve bu durum yapılan çalışma ile paralellik göstermektedir.



**Şekil 4.11:** Farklı optimizasyon yöntemlerinin GD performansına ait eğrileri


Şekil 4.12, 10 farklı optimizasyon yöntemlerine ait IGD eğrilerini göstermektedir.



**Şekil 4.12:** Farklı optimizasyon yöntemlerinin IGD performansına ait eğrileri

EP, MFO, DE, SMA ve GWO optimizasyon algoritmalarının IGD performansı oldukça iyidir. Ayrıca, Pareto ön cephesindeki çözümlerin dengeli dağılımı, bu algoritmaların çeşitliliği etkin şekilde koruduğunu gösterir [153,163,342]. AOA ve PSO algoritmaları bu algoritmalarından sonra görece yüksek performans göstermişlerdir. Ancak GA, BBO ve SA algoritması IGD performansı düşük olan algoritmalar ve çözümler açısından önemli bir çeşitlilik göstermemişlerdir. Özellikle BBO algoritması 200 iterasyondan sonra bile IGD sonuçları önemli ölçüde dalgalanmaktadır. Bu dalgalanma optimizasyon süresince daha yüksek bir belirsizlik düzeyine işaret etmektedir [342].

Pareto sınır dağılımının düzgün dağılımı ile ilgili olan SP metriği ile ilgili sonuçlar Şekil 4.13'te gösterilmiştir.



**Şekil 4.13:** Farklı optimizasyon yöntemlerinin SP performansına ait eğrileri

Bu grafiğe göre SMA VE AOA algoritmaları hariç diğer algoritmalar son iterasyonlara doğru dalgalanmaları yok denecek kadar az olup görece iyi performans sergilemişlerdir. İlk 100 iterasyonda SMA iyi bir performans gösterirken sonraki iterasyonlarda yüksek SP değerine ulaşarak kötü bir performans göstermiştir. Genel olarak bu sonuçlar, uyarlanabilir

cephelerin çok amaçlı optimizasyonu probleminde metasezgisel algoritmaların değişken performansa sahip olduğu görülmektedir. Literatürde yapılan çalışmalarda da her performans ölçütüne yönelik algoritmaların performansının değişkenlik gösterdiği [153,163,342] görülmüştür. Singh Rajput et al. [256] ANN meta-modeli kullanarak yaptıkları çok amaçlı optimizasyon çalışmasında NSGA-II algoritmasının PSO algoritmasına göre etkili çözümleri bulmada daha başarılı olduğu görülürken, PSO'nun daha hızlı bir şekilde yakınsadığı görülmektedir. Luo et al. [165], NSGA-II'nin, yinelemeler boyunca sürekli olarak yüksek çözüm çeşitliliği elde ettiği için, MOO problemini çözmede NSGA-III, C-TAEA ve RVEA algoritmalarına göre daha yüksek bir performans göstermiştir. Bu nedenle çalışmalarında NSGA-II MOO problemini ele almak için en uygun algoritma olarak kabul edilmiş ve sonraki analiz ve tartışmalarda kullanılmıştır. Zhan et al. [158] ise çalışmalarında benzer algoritmaları HV performans göstergesi kullanarak karşılaştırmıştır. Sonuçlar, C-TAEA algoritmasının NSGA-II ve NSGA-III algoritmasına göre daha iyi performans gösterdiğini doğrulamıştır. Benzer şekilde Chen et al. [340], aynı performans göstergesini kullanarak NSGA-III algoritmasının NSGA-II ve MOEA/D algoritmalarına göre daha iyi performans gösterdiği sonucuna ulaşmıştır. Xu et al. [161], ısı ve görsel konfora dayanan çok amaçlı optimizasyon çalışmasında, ANN meta-modelini kullanarak NSGA-II algoritmasının MOPSO algoritmasına göre çözümleri bulmada daha etkili olduğunu bulmuştur (bina optimizasyonunda meta-model ile optimizasyon algoritmalarına yönelik diğer çalışmalar Tablo 4.5'te özetlenmiştir) Özetle problemin amacına göre doğru optimizasyon algoritmasının seçimi optimizasyon başarısı açısından önemlidir. Her optimizasyon algoritmasının çok amaçlı problemler için eşit derecede optimal çözümler ve eşit performans gösteremeyeceği görülür. DE, LevyEP, MFO ve SMA, hem yakınsama hızı hem de çözüm çeşitliliği bakımından en iyi performansı sergileyen optimizasyon algoritmalarıdır.

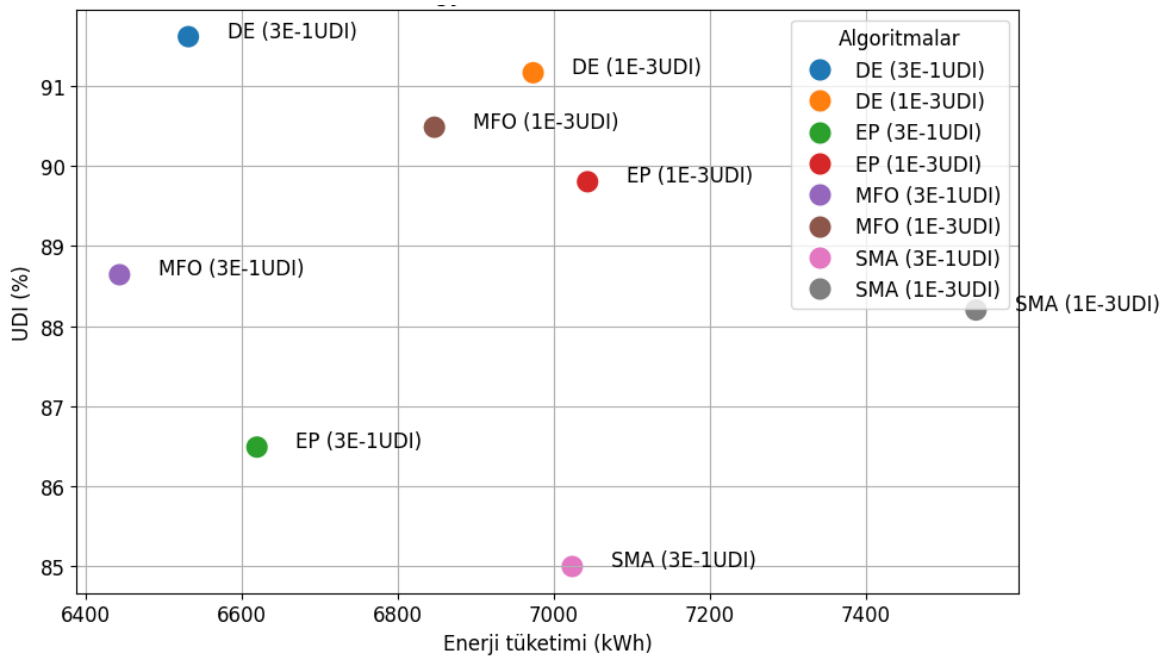
En iyi performansı gösteren optimizasyon algoritmaları kullanılarak amaç fonksiyonlarına dinamik ağırlıklar atanmıştır. Dinamik ağırlık atama, çok amaçlı optimizasyon problemlerinde farklı amaç fonksiyonlarının önem derecesini (ağırlıklarını) değiştirerek tasarımcının amacına uygun daha esnek ve etkili çözümler üretmeyi sağlar. Dinamik ağırlıklar atanarak elde edilen optimum çözümler ve algoritmaların çalışma süresi Tablo 4.7'de verilmiştir.

**Tablo 4.7:** Amaç fonksiyonlarına farklı ağırlıklandırma atanarak elde edilen sonuçlar

Algoritmalar	Optimum tasarım değişkenleri							Amaç fonksiyonları		Hesap-lama süresi dk
	X1	X2	X3	X4	X5	X6	X7	Energy (kWh)	UDI (%)	
DE (3E-1UDI)	20	6	85	0.80	0.65	36.90	0.20	6531.29	<b>91.61</b>	17.5
DE (1E-3UDI)	20	7	85.10	1.80	0.70	37.50	0.19	6973.31	91.16	18.2
EP (3E-1UDI)	20	7	86.10	0.80	0.65	27.3	0.18	6619.21	86.49	30.3
EP (1E-3UDI)	20	7	86.75	1.90	0.71	33.80	0.22	7043.06	89.80	22.9
MFO (3E-1UDI)	20	6	85	0.80	0.60	26.85	0.15	<b>6443.03</b>	88.64	20.8
MFO (1E-3UDI)	20	7	85	1	0.63	37.50	0.23	6846.68	90.48	<b>15.8</b>
SMA (3E-1UDI)	20	7	60	0.8	0.68	22.64	0.16	7023.41	85	22.6
SMA (1E-3UDI)	20	7	60	0.8	0.70	37.18	0.22	7541.01	88.20	16

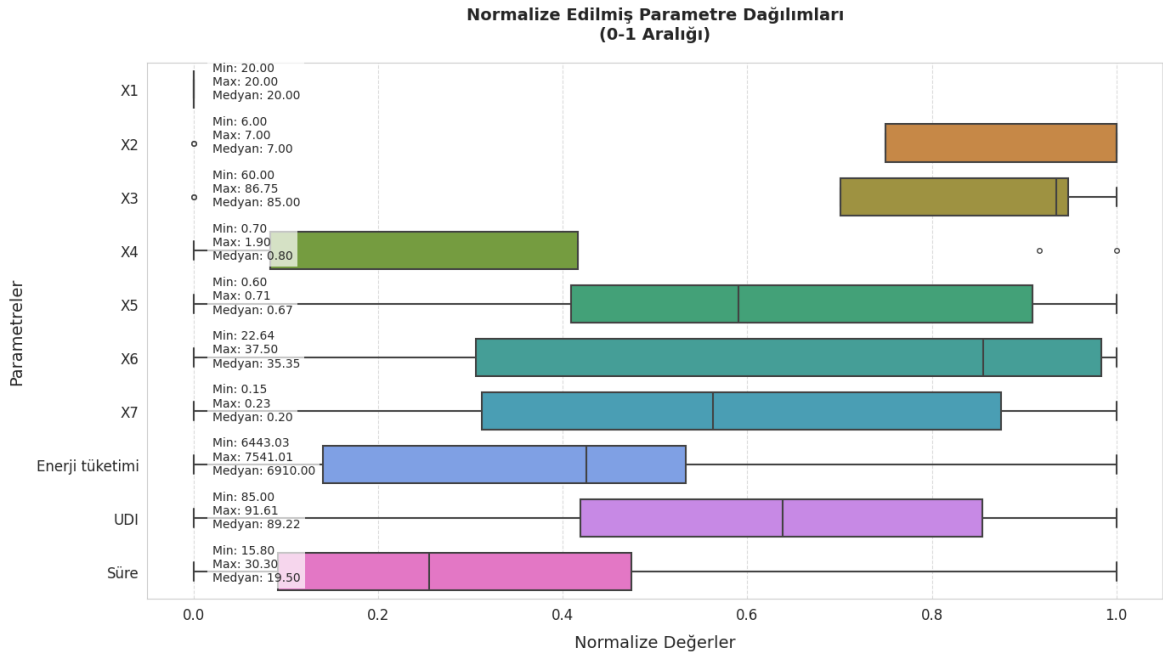
X1: Hareketli gölgelik elemanın derinliği (cm), X2: Hareketli gölgelik elemanın sayısı, X3: Pencere duvar oranı, X4: Cam kuruluşunun Toplam Isı Geçirgenliği, X5: Sızdırmazlık oranı, X6: Hareketli gölgelik elemanın dönme açısı, X7: Duvar Toplam Isı Geçirgenliği

Bu aşamada optimizasyon algoritmalarının performanslarını değerlendirmek için popülasyon büyüklüğü 50 ve iterasyon sayısı 100 olarak alınmıştır. MFO (3E-1UDI) algoritması en düşük enerji tüketimini (6443.03kWh) verirken DE (3E-1UDI) (6531.29 kWh) ve EP (3E-1UDI) (6619.21 kWh) algoritmaları sırasıyla ikinci ve üçüncü sırada yer almıştır. Enerji tüketimini minimize amacına yüksek ağırlık ataması yapıldığında, SMA algoritması, diğer algoritmalara göre daha yüksek enerji tüketimine (7023.41 kWh) neden olmuştur (Şekil 4.14).




**Şekil 4.14:** 100 iterasyon sonunda farklı algoritmalara ait optimum sonuçlar

Yararlı gün ışığı aydınlatması (UDI) performansı incelendiğinde DE algoritması her iki ağırlık atamasında dahi görsel konfor açısından en iyi optimizasyon algoritması olmuştur. MFO algoritması görsel konfor açısından en iyi performans gösteren ikinci algoritma olurken, SMA algoritması %85 ile en düşük UDI değerini bulmuştur. Algoritmaların performansı hesaplama süresi açısından incelendiğinde EP (3E-1UDI) algoritması 30.3 dk ile en yavaş sonuçlar üreten optimizasyon algoritmasıdır. MFO (1E-3UDI) optimum sonuçları bulmada hesaplama süresi açısından (15.8 dk) en iyi performansı gösteren algoritma olmuştur. 100 iterasyon sonunda tüm optimizasyon algoritmalarına ait optimum çözümlerin dağılımı Şekil 4.15'te gösterilmiştir. Tüm algoritmalar, hareketli gölgelik elemanı derinliğini (X1) 20 cm olarak bulmuştur. Hareketli gölgelik elemanın sayısı (X2) 6 ile 7 arasında değişkenlik göstermektedir. Hareketli gölgelik elemanı sayısının en düşük olduğu algoritmalar DE ile MFO algoritmalarının enerji ağırlık atamasının yüksek olduğu senaryolara ait olmuştur. Bu değer (X2: 6) ile MFO algoritmasında enerji performansı açısından, DE algoritmasında ise UDI performansı açısından en yüksek değeri sağlamıştır. Bu sayı, seçilen binaya ait, diğer parametrelerle uygun tasarım seçeneği olarak değerlendirilebilir. Optimum pencere duvar oranı (X3) %60 (SMA) ile %86,75 (AOA) arasında değişmektedir. Pencere duvar oranı %60 olduğu değerler hem yararlı gün ışığı aydınlatması hem de enerji tüketimi performansının en düşük olduğu orandır. Yüksek pencere duvar oranına sahip tasarımlar hem enerji hem de görsel konfor açısından tercih edilebilir. Ancak, binalarda enerji verimliliği açısından düşük pencere duvar oranları tercih edilse de uyarlanabilir bir cephenin güneş kontrol stratejileri sayesinde yüksek oranlar optimum çözümler olarak bulunmuştur. Uyarlanabilir bir cephenin mevsimsel ve günlük güneş ışınımı değişimlerine yanıt vererek soğutma yüklerini azalttığı ve UDI performansını arttırdığı görülmüştür. Böylelikle, uyarlanabilir cephe sistemleriyle entegre tasarlanan yüksek pencere-duvar oranlı binalar hem enerji tüketimini azaltabilir hem de yararlı gün ışığı seviyelerini (UDI) koruyabilir. Bu da uyarlanabilir cephelerle entegre tasarımları sürdürülebilir bir çözüm haline getirmektedir. Tüm algoritmalar enerji tüketimi ağırlık atamasının yüksek olduğu durumlarda cam kuruluşunun toplam ısı geçirgenliğini en düşük (X4: 0.80) seviyede tutmuştur. 100 iterasyon boyunca bu tasarım değişkeninin enerji performansı üzerinde önemli derecede etkili olduğu görülmüştür.



**Şekil 4.15:** Optimizasyon algoritmaları sonucuna ait dağılımlar

Hareketli gölgelik elemanının dönme açısının (X6) tam kapalı ve tam açık olmadığı (22.64 – 37.50) açılar optimum çözümler olarak bulunmuştur. Bu durum hem enerji hem de yararlı gün ışığı performansını olumlu etkilemektedir. SMA (3e-1u) algoritması en düşük dönme açısı değerini bulmuştur ve UDI performansı açısından diğer algoritmalara göre en düşük performansı göstermiştir. Özellikle duvar kuruluşuna ait toplam ısı geçirgenlik değerinin (X7) küçük olduğu değerler tüm algoritmalarda enerji performansını arttırmıştır. Genel olarak algoritmaların hem enerji hem de UDI performansı üzerinde tasarım değişkenlerine ait farklı senaryolar ürettikleri için optimum sonuçları bulmada performansları farklılaşmaktadır. 100 iterasyon boyunca dört algoritmaya ait HV performansı şekil 4.16'da verilmiştir.



**Şekil 4.16:** 100 iterasyon boyunca optimizasyon algoritmalarının hiperhacmi

DE (3e-1u) algoritması en yüksek hyperhacim değerini gösterirken SMA (1e-3u) algoritması en düşük HV değerini göstermiştir. Enerji tüketimine ait amaç fonksiyonuna yüksek ağırlık değeri atandığı zaman DE algoritması 100 iterasyon sonunda hypervolume değerini en yükseğe çıkarmıştır. Bu nedenle Pareto ön cephesi için çeşitli çözümler üretmede en etkili algoritma olmuştur. Ancak aynı algoritmanın amaç fonksiyonuna farklı bir ağırlık atandığında (DE (1e-3u)) HV performansı düşmektedir. Diğer tüm algoritma sonuçlarına bakıldığında farklı ağırlık atanmasıyla algoritma performansının değiştiği görülmektedir. Sonuç olarak, uyarlanabilir cephelerin çok amaçlı optimizasyonunda her bir algoritma için 100 iterasyon boyunca farklı ağırlık senaryosu altında optimizasyon yapılmıştır. Pareto-optimal çözümlerin kalitesini ölçmek için kullanılan HV performans göstergesi sonuçları, ağırlık atamalarındaki değişikliklerin algoritmaların göreceli performansını önemli ölçüde etkilemiştir. Bu sonuç, uyarlanabilir cephelerin çok amaçlı optimizasyon problemlerinin çözümünde amaç fonksiyonlarının dinamik ağırlıklandırılmasının önemli bir rol oynayacağını göstermektedir.

## 5. SONUÇ

Binalarda uyarlanabilir cephe sistemlerinin kullanımı, enerji verimliliği, kullanıcı konforu ve diğer performans hedefleri arasında bir denge kurulmasını gerektirmektedir. Belirtilen dengeyi sağlamak amacıyla, son yıllarda çeşitli yapay zekâ algoritmaları ile simülasyon araçlarının kullanımı yaygınlaşmıştır.

Bu çalışma, enerji verimliliği ve görsel konforun ele alınmasında 18 farklı meta-modelin (tekli modeller: LR, ANN, DNN, SVM, CatBoost, AdaBoostingRegressor, DT, Extra Treesregressor, GBR, LGBM, XGB, KNN, RBF, MLP, hibrit modeller: MLP-ANN, ANN-CatBoost, DNN-ANN, SVM-ANN) ve 10 farklı metasezgisel algoritmaların (AOA, BBO, SA, DE, GA, GWO, PSO, MFO, EP, SMA) karşılaştırmalı performansı yoluyla çeşitli bina tasarım değişkenlerinin optimum çözümlerine ait kombinasyonu göstermektedir. Algoritmaların performanslarını karşılaştırmak için hata payının en düşük olacağı net ve yalın bir geometriye sahip BESTEST 600 tercih edilmiştir. Modelden sonra, bina tasarım değişkenleri belirlenmiş ve Rhino/Grasshopper ortamında parametrik modelleme süreci gerçekleştirilmiştir. Parametrik olarak modellenen BESTEST 600 bina geometrisinin simülasyonu için görsel programlama dil aracında (Grasshopper) eklenti olarak yer alan EnergyPlus (enerji simülasyonu) ve Radiance (görsel konfor simülasyonu) hesaplama yazılımları kullanılmıştır. Simülasyon aşamasından elde edilen sonuçlar, veri setlerinin oluşturulmasında kullanılmıştır. Amaç fonksiyonları üzerinde etkili parametrelerin belirlenmesi için farklı özellik seçimi algoritmaları kullanılmış ve tasarım değişkenlerinin önem sırası tespit edilmiştir. Görece en etkili parametrelerin belirlenmesiyle bir sonraki aşama için meta-modeller kullanılmış ve en etkili meta-modelin seçiminde literatürde sıklıkla kullanılan performans metrikleri (MAE, RMSE, MSE, Eğitim süresi,  $R^2$ ) tercih edilmiştir. En etkili meta-modelin seçiminde kullanılan bu metrikler, optimizasyon algoritmaları için güvenilir bir amaç fonksiyonu sonucu sağlar. Meta-modeli amaç fonksiyonu olarak kullanan optimizasyon algoritmaları; süre, yakınsama ve optimum çözümlerin çeşitliliği ve kalitesi (hiperhacim, GD, IGD, SP) açısından karşılaştırılmıştır. Meta-model kullanılarak elde edilen uygunluk fonksiyonu ve on farklı meta-sezgisel optimizasyon algoritmasının karşılaştırılmasında, performans göstergelerine göre farklı algoritmalar daha üstün olarak öne çıkmaktadır. Uyarlanabilir cephelerin optimizasyonu ile ilgili elde edilen sonuçlar aşağıda özetlenmiştir:

- Literatürde, uyarlanabilir cephe sistemlerinin optimizasyonuna ilişkin çalışmalarda, tasarım parametrelerinin belirlenmesi ve ön seçim süreci çoğunlukla ayrıntılı olarak ele alınmamıştır. Seçilen parametreler genellikle literatürde sıklıkla kullanılan parametreler olup bu aşama ile ilgili bilgi eksikliği mevcuttur. Bu çalışmada, tasarım değişkenlerinin belirlenmesinde farklı özellik seçimi algoritmaları kullanılmıştır. Enerji tüketimi ve görsel konfor üzerinde daha etkili ilk beş parametre seçilen tüm algoritmalarda ortaktır. Enerji tüketimi üzerinde hava sızdırmazlık oranı, cam kuruluşu ve duvara ait toplam ısı geçirgenlik ve pencere-duvar oranı en etkili parametreler olmuştur. UDI üzerinde en etkili parametreler ise pencere-duvar oranı, hareketli gölgelik elemanının derinliği, sayısı ve dönme açısı olarak bulunmuştur.
- Daha doğru ve etkili optimizasyon süreci için literatürde sıklıkla kullanılan tekli modellerin yanı sıra hibrit modeller de çalışma kapsamında değerlendirilmiştir. Etkili ve güvenilir tahmin performansı kanıtlanan ANN-CatBoost, en etkili meta-model olmuştur. Bu nedenle ANN-CatBoost meta-modeli, optimizasyon sürecinde uygunluk fonksiyonu olarak seçilmiştir. Amaçlara yönelik tahminlerde hata oranı en düşük (RMSE: 0.026, MSE: 0.001, MAE: 0.006) ve güvenilirliği ( $R^2$ : 0.980) en yüksek meta-model olmuştur. Literatürde, bina optimizasyonu alanında daha önce bu meta-modelin kullanılmamış olması sonraki yapılan çalışmalar için yöntem çeşitliliği sağlayabilir. Ayrıca DT, Extra Treesregressor ve LR tabanlı modeller en düşük performansa sahip modeller olmuştur. En hızlı eğitim süresi KNN (0,24 sn) algoritmasına ait olduğu tespit edilmiştir.
- Uyarlanabilir cephelerin optimizasyonu ile ilgili süreç ANN-CatBoost doğrusal olmayan regresyon modeline dayanmaktadır ve bu model kullanılarak optimum çözümler üretilmektedir. SMA algoritması tüm algoritmalar arasında en düşük enerji tüketimini (6397.24 kWh) sağlayan çözümler üretirken SA algoritması en yüksek enerji tüketimine (7975.50 kWh) neden olan çözümler üretmiştir. DE (%93,82) algoritması UDI performansı açısından en iyi performans gösterirken PSO algoritması, %84,39 ile en düşük UDI değerine sahiptir.
- Algoritmaların performansı hesaplama süresi açısından incelendiğinde SA algoritması, 3.68 dk ile en hızlı sonuçları üreten optimizasyon algoritmasıdır. Buna

karşın optimum çözümleri bulmada en yavaş algoritma 277 dk ile EP algoritması olmuştur.

- DE, SMA, MFO ve EP algoritmalarının HV performansı açısından en başarılı beş algoritma olduğu görülmektedir. Ancak, SA algoritması HV performansı en düşük algoritma olmuştur. Bu algoritmanın çözüm çeşitliliği açısından yeterli performansı gösteremediği ve çözüm uzayını yeterince keşfedemediği görülmüştür.
- DE, EP ve MFO algoritmaları, GD metriği açısından yüksek performans gösteren algoritmalar. Bu optimizasyon algoritmaları, düşük GD değerlerine sahip oldukları için yüksek kaliteli Pareto-optimal kümeler sağlamıştır. EP, MFO, DE, SMA ve GWO optimizasyon algoritmalarının IGD performansı diğer optimizasyon algoritmalarına göre oldukça iyidir. Ancak GA, BBO ve SA algoritması IGD performansı düşük olan algoritmalar olup çözümler açısından çeşitlilik göstermede yetersiz kalmışlardır. Son metrik olan SP ile ilgili çoğu algoritma son iterasyonlara doğru dalgalanmaları yok denecek kadar az olduğu için iyi performans göstermişlerdir. Genel olarak, DE, MFO, SMA ve LevyEP optimizasyon algoritmaları 1000 iterasyon sonucunda, çok düşük fitness değerlerine ulaşarak hem hızlı hem de çok amaçlı problemi çözmeye diğer algoritmalara göre daha kaliteli çözümler üretmişlerdir.
- Uyarlanabilir cephelerin enerji tüketimi ve UDI amaçlarına farklı ağırlık değeri atandığı zaman algoritmaların optimum çözümleri, yürütme süreleri ve HV performansı karşılaştırılmıştır. Enerji tüketimine ait amaca yüksek ağırlık değeri atandığı zaman DE (3e-1u) algoritması HV performansı en yüksek algoritma olup Pareto ön cephesi için çeşitli çözümler üretmede en etkili algoritma olmuştur. Amaçlara farklı ağırlıklar atandığında tüm algoritmaların optimum sonuçları ve performansları değişmektedir.

Literatürde yapılan çalışmalarda genellikle ANN meta-modeli, diğer modellerle karşılaştırılması yapılmadan optimizasyon süreçlerinde yaygın olarak seçilmektedir. Bu çalışmada Hibrit model olan ANN-CatBoost meta-modeli literatürde kullanılmayan bir model olup bu çalışma kapsamında çok yüksek bir performans göstermiştir. Ancak, ANN-CatBoost ve farklı optimizasyon algoritmalarının enerji ve UDI performanslarını optimize

etmede güvenilirliđi bu alıřmada dođrulanmıř olsa da bu iki ama dıřında diđer amaları ele alan bir tasarım optimizasyonuna hala ihtiya vardır. alıřma BESTEST bina modeli ve Balıkesir iklim verileri kullanılarak yapılmıřtır. Farklı iklim blgeleri ve farklı bina trleri iin algoritmaların nasıl performans gstereceđi ve sonular reteceđi diđer alıřmalar ile test edilmelidir. Bu nedenle, alıřma kapsamında nerilen ANN-CatBoost hibrit modelinin gelecekteki bina performansına iliřkin alıřmalarda nasıl bir performans gstereceđi merak konusudur. Literatrde, optimizasyon ncesi iin ama fonksiyonlarına eřit ve sabit ađırlık katsayıları atanmıřtır. ok amalı optimizasyon problemlerinde ama fonksiyonlarına atanan ađırlıkların dinamik olarak deđiřebilmesi, kullanıcıların tercihlerine gre zmler retebilir. Bu nedenle, gelecekte yapılacak alıřmalarda, optimizasyon ncesi ađırlık katsayılarının dinamik veya kademeli olarak deđiřebildiđi yntemlerin mevcut optimizasyon aralarıyla kullanımı nerilmektedir.

Ayrıca modelleme veya simlasyon programlarına daha kolay entegre olan Genetik algoritma eřitleri ve PSO algoritması literatrde sıklıkla kullanılan algoritmalarıdır. Ancak bu alıřma kapsamında eřitli meta-sezgisel algoritmalar ile karřılařtırıldıđında kaliteli ve eřitli zmler retmede ođu algoritmaya gre yetersiz kalmıřlardır. zellikle bu alıřmada zm kalitesi aısından yksek performans gsteren DE, SMA, MFO ve EP algoritmalarının literatrde meta-modele dayanan optimizasyon alıřmalarında kullanılmamıř olması literatrdeki eřitli algoritmaların performans karřılařtırmasına ynelik bořluđun hala devam ettiđini gstermektedir. Uyarlanabilir cephelerin optimizasyonu ile ilgili bu alıřmanın sonuları, bina tasarımında uyarlanabilir cephelerin kullanılmasının optimum enerji performansına ve grsel konfora ulařmada ne kadar etkili olduđunu gstermektedir. Ancak, uyarlanabilir cephelerin performansının deđerlendirilmesinde meta-model tabanlı optimizasyon ile ilgili alıřmaların henz az sayıda olduđu dikkat ekmektedir.

## 6. KAYNAKLAR

- [1] **IPCC**, “Summary for Policymakers. In: Global Warming of 1.5°C. An IPCC Special Report on the impacts of global warming of 1.5°C above pre-industrial levels and related global greenhouse gas emission pathways, in the context of strengthening the global response to the threat of climate change, sustainable development, and efforts to eradicate poverty,” Cambridge University Press, Jun. 2022. doi: 10.1017/9781009157940.001.
- [2] **J. C. Ciscar and P. Dowling**, “Integrated assessment of climate impacts and adaptation in the energy sector,” *Energy Econ*, vol. 46, pp. 531–538, Nov. 2014, doi: 10.1016/j.eneco.2014.07.003.
- [3] **United Nations Environment Programme**, *2022 Global Status Report for Buildings and Construction: Towards a Zero-emission, Efficient and Resilient Buildings and Construction Sector*. 2022. [Online]. Available: [www.globalabc.org](http://www.globalabc.org).
- [4] **M. S. Gul and S. Patidar**, “Understanding the energy consumption and occupancy of a multi-purpose academic building,” *Energy Build*, vol. 87, pp. 155–165, Jan. 2015, doi: 10.1016/j.enbuild.2014.11.027.
- [5] **International Energy Agency**, “Energy Efficiency 2021,” 2021. [Online]. Available: [www.iea.org/t&c/](http://www.iea.org/t&c/)
- [6] **United Nations Environment Programme**, “2020 Global Status Report for Buildings and Construction: Towards a Zero-emission, Efficient and Resilient Buildings and Construction Sector.,” 2020. [Online]. Available: <http://www.un.org/Depts/>
- [7] **IEA**, “GlobalABC/IEA/UNEP (Global Alliance for Buildings and Construction, International Energy Agency, and the United Nations Environment Programme) (2020): GlobalABC Roadmap for Buildings and Construction: Towards a zero-emission, efficient and resilient buildings and construction sector,” Paris, 2020. [Online]. Available: [www.iea.org](http://www.iea.org)
- [8] **D. Lee, Y. H. Cho, and J. H. Jo**, “Assessment of control strategy of adaptive façades for heating, cooling, lighting energy conservation and glare prevention,” *Energy Build*, vol. 235, Mar. 2021, doi: 10.1016/j.enbuild.2021.110739.
- [9] **S. Attia, R. Lioure, and Q. Declaude**, “Future trends and main concepts of adaptive facade systems,” *Energy Sci Eng*, vol. 8, no. 9, pp. 3255–3272, Sep. 2020, doi: 10.1002/ese3.725.

- [10] **R. Romano, L. Aelenei, D. Aelenei, and E. S. Mazzucchelli**, “What is an adaptive façade? Analysis of recent terms and definitions from an international perspective,” *Journal of Facade Design and Engineering*, vol. 6, no. 3, pp. 065–076, 2018, doi: 10.7480/jfde.2018.3.2478.
- [11] **R. Cheng, X. Wang, and Y. Zhang**, “Energy-efficient building envelopes with phase-change materials: New understanding and related research,” in *Heat Transfer Engineering*, Jul. 2014, pp. 970–984. doi: 10.1080/01457632.2013.863674.
- [12] **S. M. Hosseini and S. Heidari**, “General morphological analysis of Orosi windows and morpho butterfly wing’s principles for improving occupant’s daylight performance through interactive kinetic façade,” *Journal of Building Engineering*, vol. 59, Nov. 2022, doi: 10.1016/j.job.2022.105027.
- [13] **A. Tabadkani, A. Roetzel, H. X. Li, and A. Tsangrassoulis**, “A review of automatic control strategies based on simulations for adaptive facades,” May 15, 2020, *Elsevier Ltd.* doi: 10.1016/j.buildenv.2020.106801.
- [14] **S. Soudian and U. Berardi**, “Development of a performance-based design framework for multifunctional climate-responsive façades,” *Energy Build*, vol. 231, Jan. 2021, doi: 10.1016/j.enbuild.2020.110589.
- [15] **M. Asefi, M. Mitton, and S. Currie**, “A New Foldable Kinetic Architectural System: Through an Evaluative Approach of Built Examples, Case Studies: Resonant Chamber, Cheiljedang Research Center, Madina Shadi Project \*,” *Armanshahr Architecture & Urban Development*, vol. 10, no. 18, pp. 1–12, 2017.
- [16] **S. Sankaewthong, T. Horanont, K. Miyata, J. Karnjana, C. Busayarat, and H. Xie**, “Using a Biomimicry Approach in the Design of a Kinetic Façade to Regulate the Amount of Daylight Entering a Working Space,” *Buildings*, vol. 12, no. 12, Dec. 2022, doi: 10.3390/buildings12122089.
- [17] **B. Kahramanoğlu and N. Çakıcı Alp**, “Enhancing visual comfort with Miura-ori-based responsive facade model,” *Journal of Building Engineering*, vol. 69, Jun. 2023, doi: 10.1016/j.job.2023.106241.
- [18] **F. Isaia, M. Fiorentini, V. Serra, and A. Capozzoli**, “Enhancing energy efficiency and comfort in buildings through model predictive control for dynamic façades with electrochromic glazing,” *Journal of Building Engineering*, vol. 43, Nov. 2021, doi: 10.1016/j.job.2021.102535.

- [19] **F. Favoino, M. Overend, and Q. Jin**, “The optimal thermo-optical properties and energy saving potential of adaptive glazing technologies,” *Appl Energy*, vol. 156, pp. 1–15, Oct. 2015, doi: 10.1016/j.apenergy.2015.05.065.
- [20] **M. Michael and M. Overend**, “Closed cavity façade, an innovative energy saving façade,” *Building Services Engineering Research and Technology*, vol. 43, no. 3, pp. 279–296, May 2022, doi: 10.1177/01436244221080030.
- [21] **S. Attia, S. Bilir, T. Safy, C. Struck, R. Loonen, and F. Goia**, “Current trends and future challenges in the performance assessment of adaptive façade systems,” *Energy Build*, vol. 179, pp. 165–182, Nov. 2018, doi: 10.1016/j.enbuild.2018.09.017.
- [22] **S. Attia, S. Bertrand, M. Cuchet, S. Yang, and A. Tabadkani**, “Comparison of Thermal Energy Saving Potential and Overheating Risk of Four Adaptive Façade Technologies in Office Buildings,” *Sustainability (Switzerland)*, vol. 14, no. 10, May 2022, doi: 10.3390/su14106106.
- [23] **C. Kasinalis, R. C. G. M. Loonen, D. Cóstola, and J. L. M. Hensen**, “Framework for assessing the performance potential of seasonally adaptable facades using multi-objective optimization,” *Energy Build*, vol. 79, pp. 106–113, 2014, doi: 10.1016/j.enbuild.2014.04.045.
- [24] **D. Borschewski, M. P. Voigt, S. Albrecht, D. Roth, M. Kreimeyer, and P. Leistner**, “Why are adaptive facades not widely used in practice? Identifying ecological and economical benefits with life cycle assessment,” *Build Environ*, vol. 232, Mar. 2023, doi: 10.1016/j.buildenv.2023.110069.
- [25] **A. Tabadkani, A. Roetzel, H. X. Li, and A. Tsangrassoulis**, “Design approaches and typologies of adaptive facades: A review,” *Autom Constr*, vol. 121, Jan. 2021, doi: 10.1016/j.autcon.2020.103450.
- [26] **H. Altan, I. Ward, J. Mohelnikova, and F. Vajkay**, “An internal assessment of the thermal comfort and daylighting conditions of a naturally ventilated building with an active glazed facade in a temperate climate,” *Energy Build*, vol. 41, no. 1, pp. 36–50, Jan. 2009, doi: 10.1016/j.enbuild.2008.07.009.
- [27] **H. Elarga, M. De Carli, and A. Zarrella**, “A simplified mathematical model for transient simulation of thermal performance and energy assessment for active facades,” *Energy Build*, vol. 104, pp. 97–107, Jul. 2015, doi: 10.1016/j.enbuild.2015.07.007.

- [28] **K. Fabbri and J. Gaspari**, “A replicable methodology to evaluate passive façade performance with sma during the architectural design process: A case study application,” *Energies (Basel)*, vol. 14, no. 19, Oct. 2021, doi: 10.3390/en14196231.
- [29] **T. Srisamranrungruang and K. Hiyama**, “Balancing of natural ventilation, daylight, thermal effect for a building with double-skin perforated facade (DSPF),” *Energy Build*, vol. 210, Mar. 2020, doi: 10.1016/j.enbuild.2020.109765.
- [30] **W. T. Sheikh and Q. Asghar**, “Adaptive biomimetic facades: Enhancing energy efficiency of highly glazed buildings,” *Frontiers of Architectural Research*, vol. 8, no. 3, pp. 319–331, Sep. 2019, doi: 10.1016/j.foar.2019.06.001.
- [31] **S. M. Hosseini, M. Mohammadi, T. Schröder, and O. Guerra-Santin**, “Bio-inspired interactive kinetic façade: Using dynamic transitory-sensitive area to improve multiple occupants’ visual comfort,” *Frontiers of Architectural Research*, vol. 10, no. 4, pp. 821–837, Dec. 2021, doi: 10.1016/j.foar.2021.07.004.
- [32] **C. I. Seyrek, B. Widera, and A. Woźniczka**, “Sustainability-related parameters and decision support tools for kinetic green façades,” *Sustainability (Switzerland)*, vol. 13, no. 18, Sep. 2021, doi: 10.3390/su131810313.
- [33] **S. Haghghat and H. Sadeh**, “Parametric design of an automated kinetic building façade using BIM: A case study perspective,” *Journal of Building Engineering*, vol. 73, Aug. 2023, doi: 10.1016/j.jobbe.2023.106800.
- [34] **E. Karakoc and G. Cagdas**, “Adaptive architecture based on environmental performance: an advanced intelligent façade (Aif) module,” *Gazi University Journal of Science*, vol. 34, no. 3, pp. 630–650, 2021, doi: 10.35378/gujs.725902.
- [35] **M. Liu, K. B. Wittchen, and P. K. Heiselberg**, “Verification of a simplified method for intelligent glazed façade design under different control strategies in a full-scale façade test facility - Preliminary results of a south facing single zone experiment for a limited summer period,” *Build Environ*, vol. 82, pp. 400–407, Sep. 2014, doi: 10.1016/j.buildenv.2014.09.009.
- [36] **M. Liu, K. B. Wittchen, and P. K. Heiselberg**, “Development of a simplified method for intelligent glazed façade design under different control strategies and verified by building simulation tool BSim,” *Build Environ*, vol. 74, pp. 31–38, Apr. 2014, doi: 10.1016/j.buildenv.2014.01.003.
- [37] **D. S. Panya, T. Kim, and S. Choo**, “A methodology of interactive motion facades design through parametric strategies,” *Applied Sciences (Switzerland)*, vol. 10, no. 4, Feb. 2020, doi: 10.3390/app10041218.

- [38] **A. Kontadakis, A. Tsangrassoulis, L. Doulos, and F. Topalis**, “An active sunlight redirection system for daylight enhancement beyond the perimeter zone,” *Build Environ*, vol. 113, pp. 267–279, Feb. 2017, doi: 10.1016/j.buildenv.2016.09.029.
- [39] **N. Heidari Matin and A. Eydgahi**, “Technologies used in responsive facade systems: a comparative study,” 2022, *Taylor and Francis Ltd.* doi: 10.1080/17508975.2019.1577213.
- [40] **F. Ascione, N. Bianco, T. Iovane, M. Mastellone, and G. M. Mauro**, “The evolution of building energy retrofit via double-skin and responsive façades: A review,” *Solar Energy*, vol. 224, pp. 703–717, Aug. 2021, doi: 10.1016/j.solener.2021.06.035.
- [41] **M. Jafari and A. Alipour**, “Review of approaches, opportunities, and future directions for improving aerodynamics of tall buildings with smart facades,” *Sustain Cities Soc*, vol. 72, Sep. 2021, doi: 10.1016/j.scs.2021.102979.
- [42] **G. Barone et al.**, “Concentrating PhotoVoltaic glazing (CoPVG) system: Modelling and simulation of smart building façade,” *Energy*, vol. 238, Jan. 2022, doi: 10.1016/j.energy.2021.121597.
- [43] **A. Luna-Navarro, G. Lori, D. Callewaert, and M. Overend**, “Semi-automated vs manually controlled dynamic facades: assessment through a field study on multi-domain occupant satisfaction,” *Energy Build*, vol. 286, May 2023, doi: 10.1016/j.enbuild.2023.112912.
- [44] **A. Luna-Navarro, G. R. Hunt, and M. Overend**, “Dynamic façades – An exploratory campaign to assess occupant multi-domain environmental satisfaction and façade interaction,” *Build Environ*, vol. 211, Mar. 2022, doi: 10.1016/j.buildenv.2021.108703.
- [45] **S. W. Tong, W. P. Goh, X. Huang, and C. Jiang**, “A review of transparent-reflective switchable glass technologies for building facades,” Dec. 01, 2021, *Elsevier Ltd.* doi: 10.1016/j.rser.2021.111615.
- [46] **Y. Zhou and C. M. Herr**, “A Review of Advanced Façade System Technologies to Support Net-Zero Carbon High-Rise Building Design in Subtropical China,” Feb. 01, 2023, *MDPI*. doi: 10.3390/su15042913.
- [47] **X. Zhang, H. Zhang, Y. Wang, and X. Shi**, “Adaptive Façades: Review of Designs, Performance Evaluation, and Control Systems,” Dec. 01, 2022, *MDPI*. doi: 10.3390/buildings12122112.

- [48] **R. C. G. M. Loonen, M. Trčka, D. Cóstola, and J. L. M. Hensen**, “Climate adaptive building shells: State-of-the-art and future challenges,” 2013. doi: 10.1016/j.rser.2013.04.016.
- [49] **C. Struck, M. G. Almeida, S. M. Silva, and R. Mateus**, “Adaptive facade systems-review of performance requirements, design approaches, use cases and market needs Local Dutch Energy Transition View project Integrated Building Controls and Dynamic Glazing View project”, doi: 10.13140/RG.2.1.2023.8165.
- [50] **Z. Nie, S. Chen, S. Zhang, H. Wu, T. Weiss, and L. Zhao**, “Adaptive Façades Strategy: An architect-friendly computational approach based on co-simulation and white-box models for the early design stage,” *Energy Build*, vol. 296, Oct. 2023, doi: 10.1016/j.enbuild.2023.113320.
- [51] **M. P. Voigt, K. Chwalek, D. Roth, M. Kreimeyer, and L. Blandini**, “The integrated design process of adaptive façades – A comprehensive perspective,” *Journal of Building Engineering*, vol. 67, May 2023, doi: 10.1016/j.job.2023.106043.
- [52] **M. P. Voigt, D. Roth, and M. Kreimeyer**, “Decision Support for Defining Adaptive Façade Design Goals in the Early Design Phase,” *Energies (Basel)*, vol. 16, no. 8, Apr. 2023, doi: 10.3390/en16083411.
- [53] **N. Heidari Matin and A. Eydgahi**, “Factors affecting the design and development of responsive facades: a historical evolution,” Oct. 01, 2020, *Taylor and Francis Ltd.* doi: 10.1080/17508975.2018.1562414.
- [54] **M. Baracani et al.**, “Experimental assessment of the energy performance of microfluidic glazing components: The first results of a monitoring campaign carried out in an outdoor test facility,” *Energy*, vol. 280, Oct. 2023, doi: 10.1016/j.energy.2023.128052.
- [55] **H. M. Taleb and R. Moarbes**, “Improving illuminance performance by implementing a kinetic façade system: case study of office building in Dubai,” *Journal of Asian Architecture and Building Engineering*, vol. 22, no. 5, pp. 2809–2826, 2023, doi: 10.1080/13467581.2022.2160636.
- [56] **M. Talaei, M. Mahdavinejad, R. Azari, H. M. Haghghi, and A. Atashdast**, “Thermal and energy performance of a user-responsive microalgae bioreactive façade for climate adaptability,” *Sustainable Energy Technologies and Assessments*, vol. 52, Aug. 2022, doi: 10.1016/j.seta.2021.101894.

- [57] **N. H. Matin, A. Eydgahi, and P. Matin**, “The Effect of Smart Colored Windows on Visual Performance of Buildings,” *Buildings*, vol. 12, no. 6, Jun. 2022, doi: 10.3390/buildings12060861.
- [58] **Q. Jin, X. Long, and R. Liang**, “Numerical analysis on the thermal performance of PCM-integrated thermochromic glazing systems,” *Energy Build*, vol. 257, Feb. 2022, doi: 10.1016/j.enbuild.2021.111734.
- [59] **L. Martirano, G. Parise, L. Parise, and M. Manganelli**, “A Fuzzy-Based Building Automation Control System: Optimizing the Level of Energy Performance and Comfort in an Office Space by Taking Advantage of Building Automation Systems and Solar Energy,” *IEEE Industry Applications Magazine*, vol. 22, no. 2, pp. 10–17, Mar. 2016, doi: 10.1109/MIAS.2015.2459097.
- [60] **S. Ham, H. Cho, H. Lee, and G. Lee**, “Prototype development of responsive kinetic façade control system for the elderly based on Ambient Assisted Living,” *Archit Sci Rev*, vol. 62, no. 4, pp. 273–285, Jul. 2019, doi: 10.1080/00038628.2019.1614902.
- [61] **A. Ozadowicz and G. Walczyk**, “Energy Performance and Control Strategy for Dynamic Façade with Perovskite PV Panels—Technical Analysis and Case Study,” *Energies (Basel)*, vol. 16, no. 9, May 2023, doi: 10.3390/en16093793.
- [62] **A. Shafaghat and A. Keyvanfar**, “Dynamic façades design typologies, technologies, measurement techniques, and physical performances across thermal, optical, ventilation, and electricity generation outlooks,” Oct. 01, 2022, *Elsevier Ltd.* doi: 10.1016/j.rser.2022.112647.
- [63] **D. M. Le, D. Y. Park, J. Baek, P. Karunyasopon, and S. Chang**, “Multi-criteria decision making for adaptive façade optimal design in varied climates: Energy, daylight, occupants’ comfort, and outdoor view analysis,” *Build Environ*, vol. 223, Sep. 2022, doi: 10.1016/j.buildenv.2022.109479.
- [64] **E. Anzaniyan, M. Alaghmandan, and A. Montaser Koohsari**, “Design, fabrication and computational simulation of a bio-kinetic façade inspired by the mechanism of the *Lupinus Succulentus* plant for daylight and energy efficiency,” *Sci Technol Built Environ*, vol. 28, no. 10, pp. 1456–1471, 2022, doi: 10.1080/23744731.2022.2122675.
- [65] **M. Juaristi, F. Favoino, T. Gómez-Acebo, and A. Monge-Barrio**, “Adaptive opaque façades and their potential to reduce thermal energy use in residential buildings: A simulation-based evaluation,” *J Build Phys*, vol. 45, no. 5, pp. 675–720, Mar. 2022, doi: 10.1177/17442591211045418.

- [66] **S. S. Golzan, M. Pouyanmehr, and H. Sadeghi Naeini**, “Recommended angle of a modular dynamic façade in hot-arid climate: daylighting and energy simulation,” *Smart and Sustainable Built Environment*, vol. 12, no. 1, pp. 27–37, Jan. 2023, doi: 10.1108/SASBE-04-2021-0075.
- [67] **A. Tabadkani, A. Roetzel, H. X. Li, and A. Tsangrassoulis**, “Simulation-based personalized real-time control of adaptive facades in shared office spaces,” *Autom Constr*, vol. 138, Jun. 2022, doi: 10.1016/j.autcon.2022.104246.
- [68] **E. Catto Lucchino, G. Gennaro, F. Favoino, and F. Goia**, “Modelling and validation of a single-storey flexible double-skin façade system with a building energy simulation tool,” *Build Environ*, vol. 226, Dec. 2022, doi: 10.1016/j.buildenv.2022.109704.
- [69] **M. Koyaz and A. Ünlü**, “Human-centred performance criteria for adaptive façade design: Based on the results of a user experience survey,” *Build Environ*, vol. 222, Aug. 2022, doi: 10.1016/j.buildenv.2022.109386.
- [70] **S. Attia, S. Garat, and M. Cools**, “Development and validation of a survey for well-being and interaction assessment by occupants in office buildings with adaptive facades,” *Build Environ*, vol. 157, pp. 268–276, Jun. 2019, doi: 10.1016/j.buildenv.2019.04.054.
- [71] **Y. Wang, Y. Han, Y. Wu, E. Korkina, Z. Zhou, and V. Gagarin**, “An occupant-centric adaptive façade based on real-time and contactless glare and thermal discomfort estimation using deep learning algorithm,” *Build Environ*, vol. 214, Apr. 2022, doi: 10.1016/j.buildenv.2022.108907.
- [72] **T. Iwata, T. Taniguchi, and R. Sakuma**, “Automated blind control based on glare prevention with dimmable light in open-plan offices,” *Build Environ*, vol. 113, pp. 232–246, Feb. 2017, doi: 10.1016/j.buildenv.2016.08.034.
- [73] **M. Iommi**, “The mediterranean smart adaptive wall. An experimental design of a smart and adaptive facade module for the mediterranean climate,” *Energy Build*, vol. 158, pp. 1450–1460, Jan. 2018, doi: 10.1016/j.enbuild.2017.11.025.
- [74] **A. Aksamija, Z. Aksamija, C. Counihan, D. Brown, and M. Upadhyaya**, “Experimental study of operating conditions and integration of thermoelectric materials in facade systems,” *Front Energy Res*, vol. 7, no. FEB, 2019, doi: 10.3389/fenrg.2019.00006.

- [75] **C. Bedon et al.**, “Structural characterisation of adaptive facades in Europe - Part II: Validity of conventional experimental testing methods and key issues,” Sep. 01, 2019, *Elsevier Ltd.* doi: 10.1016/j.jobe.2019.100797.
- [76] **T. Araújo et al.**, “The Adaptive Power of *Ammophila arenaria*: Biomimetic Study, Systematic Observation, Parametric Design and Experimental Tests with Bimetal,” 2021, doi: 10.3390/polym.
- [77] **S. Soudian and U. Berardi**, “Experimental performance evaluation of a climate-responsive ventilated building façade,” *Journal of Building Engineering*, vol. 61, Dec. 2022, doi: 10.1016/j.jobe.2022.105233.
- [78] **J. Čurpek and M. Čekon**, “Building performance simulation of a photovoltaic façade enhanced with latent heat storage: Model validation and power generation prediction,” *J Energy Storage*, vol. 56, Dec. 2022, doi: 10.1016/j.est.2022.106143.
- [79] **L. J. Claros-Marfil, V. Zetola, J. F. Padial, and B. Lauret**, “Experimental-simulation methodology for estimation of thermal parameters of adaptive facades in mild climate conditions: A water-flow glazing case study,” *Journal of Building Engineering*, vol. 45, Jan. 2022, doi: 10.1016/j.jobe.2021.103384.
- [80] **L. Shen and Y. Han**, “Optimizing the modular adaptive façade control strategy in open office space using integer programming and surrogate modelling,” *Energy Build*, vol. 254, Jan. 2022, doi: 10.1016/j.enbuild.2021.111546.
- [81] **C. E. Ochoa and I. G. Capeluto**, “Advice tool for early design stages of intelligent facades based on energy and visual comfort approach,” *Energy Build*, vol. 41, no. 5, pp. 480–488, May 2009, doi: 10.1016/j.enbuild.2008.11.015.
- [82] **L. Le-Thanh, T. Le-Duc, H. Ngo-Minh, Q. H. Nguyen, and H. Nguyen-Xuan**, “Optimal design of an Origami-inspired kinetic façade by balancing composite motion optimization for improving daylight performance and energy efficiency,” *Energy*, vol. 219, Mar. 2021, doi: 10.1016/j.energy.2020.119557.
- [83] **M. Valitabar, M. Mahdavejad, H. Skates, and P. Pilechiha**, “A dynamic vertical shading optimisation to improve view, visual comfort and operational energy,” *Open House International*, vol. 46, no. 3, pp. 401–415, Oct. 2021, doi: 10.1108/OHI-02-2021-0031.
- [84] **D. K. Bui, T. N. Nguyen, A. Ghazlan, N. T. Ngo, and T. D. Ngo**, “Enhancing building energy efficiency by adaptive façade: A computational optimization approach,” *Appl Energy*, vol. 265, May 2020, doi: 10.1016/j.apenergy.2020.114797.

- [85] **A. Tabadkani, M. Valinejad Shoubi, F. Soflaei, and S. Banihashemi**, “Integrated parametric design of adaptive facades for user’s visual comfort,” *Autom Constr*, vol. 106, Oct. 2019, doi: 10.1016/j.autcon.2019.102857.
- [86] **M. Webb, L. Aye, and R. Green**, “Simulation of a biomimetic façade using TRNSYS,” *Appl Energy*, vol. 213, pp. 670–694, Mar. 2018, doi: 10.1016/j.apenergy.2017.08.115.
- [87] **S. M. Hosseini, F. Fadli, and M. Mohammadi**, “Biomimetic kinetic shading facade inspired by tree morphology for improving occupant’s daylight performance,” *Journal of Daylighting*, vol. 8, no. 1, pp. 65–82, 2021, doi: 10.15627/jd.2021.5.
- [88] **S. M. Hosseini, M. Mohammadi, T. Schröder, and O. Guerra-Santin**, “Integrating interactive kinetic façade design with colored glass to improve daylight performance based on occupants’ position,” *Journal of Building Engineering*, vol. 31, Sep. 2020, doi: 10.1016/j.jobbe.2020.101404.
- [89] **S. M. Hosseini, M. Mohammadi, and O. Guerra-Santin**, “Interactive kinetic façade: Improving visual comfort based on dynamic daylight and occupant’s positions by 2D and 3D shape changes,” *Build Environ*, vol. 165, Nov. 2019, doi: 10.1016/j.buildenv.2019.106396.
- [90] **X. Shi, T. Abel, and L. Wang**, “Influence of two motion types on solar transmittance and daylight performance of dynamic façades,” *Solar Energy*, vol. 201, pp. 561–580, May 2020, doi: 10.1016/j.solener.2020.03.017.
- [91] **A. Tabadkani, A. Roetzel, H. Xian Li, A. Tsangrassoulis, and S. Attia**, “Analysis of the impact of automatic shading control scenarios on occupant’s comfort and energy load,” *Appl Energy*, vol. 294, Jul. 2021, doi: 10.1016/j.apenergy.2021.116904.
- [92] **A. H. A. Mahmoud and Y. Elghazi**, “Parametric-based designs for kinetic facades to optimize daylight performance: Comparing rotation and translation kinetic motion for hexagonal facade patterns,” *Solar Energy*, vol. 126, pp. 111–127, Mar. 2016, doi: 10.1016/j.solener.2015.12.039.
- [93] **M. Liu, K. B. Wittchen, and P. K. Heiselberg**, “Control strategies for intelligent glazed façade and their influence on energy and comfort performance of office buildings in Denmark,” *Appl Energy*, vol. 145, pp. 43–51, May 2015, doi: 10.1016/j.apenergy.2015.02.003.
- [94] **M. Shahmoradi and M. Yeganeh**, “A novel method for simulating dynamic facades to analysing, and optimizing daylight and visual comfort in office buildings,” *Results in Engineering*, vol. 27, Sep. 2025, doi: 10.1016/j.rineng.2025.105608.

- [95] **W. Zhang, Z. Ma, H. Qiu, Y. Pan, Y. Shi, and L. Zhang**, “Machine learning-boosted multi-objective optimization of integrated shading systems: Enhancing daylight availability, glare protection, and energy savings,” *Build Environ*, vol. 280, Jul. 2025, doi: 10.1016/j.buildenv.2025.113124.
- [96] **Y. Yaman, E. Kizilorenli, and A. Tokuc**, “Multi-Objective Optimization of a Folding Kinetic Facade System Proposal for Thermal, Daylight, and Energy Performances,” *Gazi University Journal of Science*, vol. 38, no. 1, pp. 1–16, Mar. 2025, doi: 10.35378/gujs.1433809.
- [97] **Z. Yuan, J. Pan, X. Chen, and Y. Peng**, “Research on the Optimization Design of High-Rise Office Building Performance Based on a Multi-Objective Genetic Algorithm,” *Buildings*, vol. 15, no. 10, May 2025, doi: 10.3390/buildings15101636.
- [98] **M. H. Abedini, H. Gholami, and H. Sangin**, “Multi-objective Optimization of Window and Shading Systems for Enhanced Office Building Performance: A Case Study in Qom, Iran,” *Journal of Daylighting*, vol. 12, no. 1, pp. 91–110, Jun. 2025, doi: 10.15627/jd.2025.6.
- [99] **L. Li et al.**, “Multi-objective optimization of building performance: Integrating sensitivity analysis for energy efficiency and comfort,” *International Communications in Heat and Mass Transfer*, vol. 165, Jun. 2025, doi: 10.1016/j.icheatmasstransfer.2025.109009.
- [100] **F. Wagiri, S. G. Shih, K. Harsono, and D. C. Wijaya**, “Multi-objective optimization of kinetic facade aperture ratios for daylight and solar radiation control,” *J Build Phys*, vol. 47, no. 4, pp. 355–385, Jan. 2024, doi: 10.1177/17442591231219793.
- [101] **M. Talaei and H. Sangin**, “Multi-objective optimization of energy and daylight performance for school envelopes in desert, semi-arid, and mediterranean climates of Iran,” *Build Environ*, vol. 255, May 2024, doi: 10.1016/j.buildenv.2024.111424.
- [102] **J. Liu, G. Bi, G. Gao, and L. Zhao**, “Optimal design method for photovoltaic shading devices (PVSDs) by combining geometric optimization and adaptive control model,” *Journal of Building Engineering*, vol. 69, Jun. 2023, doi: 10.1016/j.job.2023.106101.
- [103] **A. Tabadkani, A. Nikkhah Dehnavi, F. Mostafavi, and H. G. Naeini**, “Targeting modular adaptive façade personalization in a shared office space using fuzzy logic and genetic optimization,” *Journal of Building Engineering*, vol. 69, Jun. 2023, doi: 10.1016/j.job.2023.106118.

- [104] **E. Catto Lucchino and F. Goia**, “Multi-domain model-based control of an adaptive façade based on a flexible double skin system,” *Energy Build*, vol. 285, Apr. 2023, doi: 10.1016/j.enbuild.2023.112881.
- [105] **N. Bioria, M. Makki, and N. Abdollahzadeh**, “Multi-performative façade systems: The case of real-time adaptive BIPV shading systems to enhance energy generation potential and visual comfort,” *Front Built Environ*, vol. 9, 2023, doi: 10.3389/fbuil.2023.1119696.
- [106] **S. Wen, X. Hu, G. Hua, P. Xue, and D. Lai**, “Comparing the performance of four shading strategies based on a multi-objective genetic algorithm: A case study in a university library,” *Journal of Building Engineering*, vol. 63, Jan. 2023, doi: 10.1016/j.jobee.2022.105532.
- [107] **Y. Xue and W. Liu**, “A Study on the Optimization of Atrium Daylight and Energy Performance through Skylight and Shading Design in Commercial Buildings in Cold Zones,” *Buildings*, vol. 13, no. 1, Jan. 2023, doi: 10.3390/buildings13010228.
- [108] **J. Gaspari and K. Fabbri**, “Exploring the Effects of Climate-Adaptive Building Shells: An Applicative Time-Saving Algorithm on a Case Study in Bologna, Italy,” *Energies (Basel)*, vol. 15, no. 21, Nov. 2022, doi: 10.3390/en15218168.
- [109] **L. Shi and S. Pouramini**, “Adaptive façade for building energy efficiency improvement by arithmetical optimization algorithm,” *Concurr Comput*, 2022, doi: 10.1002/cpe.7152.
- [110] **S. Besbas, F. Nocera, N. Zemmouri, M. A. Khadraoui, and A. Besbas**, “Parametric-Based Multi-Objective Optimization Workflow: Daylight and Energy Performance Study of Hospital Building in Algeria,” *Sustainability (Switzerland)*, vol. 14, no. 19, Oct. 2022, doi: 10.3390/su141912652.
- [111] **L. E. Hinkle, J. Wang, and N. C. Brown**, “Quantifying potential dynamic façade energy savings in early design using constrained optimization,” *Build Environ*, vol. 221, Aug. 2022, doi: 10.1016/j.buildenv.2022.109265.
- [112] **S. O. Sadegh, E. Gasparri, A. Brambilla, and A. Globa**, “Kinetic facades: An evolutionary-based performance evaluation framework,” *Journal of Building Engineering*, vol. 53, Aug. 2022, doi: 10.1016/j.jobee.2022.104408.
- [113] **N. H. Matin, A. Eydgahi, A. Gharipour, and P. Matin**, “A Novel Framework for Optimizing Indoor Illuminance and Discovering Association of Involved Variables,” *Buildings*, vol. 12, no. 7, Jul. 2022, doi: 10.3390/buildings12070878.

- [114] **Z. Zeng, G. Augenbroe, and J. Chen**, “Realization of bi-level optimization of adaptive building envelope with a finite-difference model featuring short execution time and versatility,” *Energy*, vol. 243, Mar. 2022, doi: 10.1016/j.energy.2021.122778.
- [115] **M. Valitabar, A. GhaffarianHoseini, A. GhaffarianHoseini, and S. Attia**, “Advanced control strategy to maximize view and control discomforting glare: a complex adaptive façade,” *Architectural Engineering and Design Management*, vol. 18, no. 6, pp. 829–849, 2022, doi: 10.1080/17452007.2022.2032576.
- [116] **R. A. Mangkuto et al.**, “Design Optimisation of Fixed and Adaptive Shading Devices on Four Façade Orientations of a High-Rise Office Building in the Tropics,” *Buildings*, vol. 12, no. 1, Jan. 2022, doi: 10.3390/buildings12010025.
- [117] **N. Heidari Matin and A. Eydgahi**, “A data-driven optimized daylight pattern for responsive facades design,” *Intelligent Buildings International*, vol. 14, no. 3, pp. 363–374, 2022, doi: 10.1080/17508975.2021.1872478.
- [118] **R. P. Khidmat, H. Fukuda, B. Paramita, M. D. Koerniawan, and Kustiani**, “The optimization of louvers shading devices and room orientation under three different sky conditions,” *Journal of Daylighting*, vol. 9, no. 2, pp. 137–149, 2022, doi: 10.15627/jd.2022.11.
- [119] **H. Özdemir and B. Y. Çakmak**, “Evaluation of Daylight and Glare Quality of Office Spaces with Flat and Dynamic Shading System Facades in Hot Arid Climate,” *Journal of Daylighting*, vol. 9, no. 2, pp. 197–208, Dec. 2022, doi: 10.15627/JD.2022.15.
- [120] **S. Wang, Q. Zhang, P. Liu, R. Liang, and Z. Fu**, “A Parameterized Design Method for Building a Shading System Based on Climate Adaptability,” *Atmosphere (Basel)*, vol. 13, no. 8, Aug. 2022, doi: 10.3390/atmos13081244.
- [121] **A. Alammar and W. Jabi**, “PREDICTING COOLING ENERGY DEMANDS OF ADAPTIVE FACADES USING ARTIFICIAL NEURAL NETWORK,” in *Annual Modeling and Simulation Conference (ANNSIM)*, San Diego, 2022, pp. 656–669. doi: 10.23919/ANNSIM55834.2022.9859413.
- [122] **K. Hiyama and Y. Omodaka**, “Operation of climate-adaptive building shells utilizing machine learning under sparse data conditions,” *Journal of Building Engineering*, vol. 43, Nov. 2021, doi: 10.1016/j.job.2021.103027.
- [123] **M. Ishac and W. Nadim**, “Standardization of optimization methodology of daylighting and shading strategy: a case study of an architectural design studio—the

- German University in Cairo, Egypt,” *J Build Perform Simul*, vol. 14, no. 1, pp. 52–77, 2021, doi: 10.1080/19401493.2020.1846618.
- [124] **R. A. Rizi and A. Eltaweel**, “A user detective adaptive facade towards improving visual and thermal comfort,” *Journal of Building Engineering*, vol. 33, Jan. 2021, doi: 10.1016/j.jobbe.2020.101554.
- [125] **F. Carlucci, A. Cannavale, and F. Fiorito**, “Electrochromic window integration in adaptive building envelopes in different climates: A genetic optimization of switchable glazing parameters to reduce energy consumptions in office buildings,” in *Journal of Physics: Conference Series*, IOP Publishing Ltd, Dec. 2021. doi: 10.1088/1742-6596/2069/1/012131.
- [126] **J. Zhu**, “A data-driven method to minimize sensor use for dynamic shading control,” in *Journal of Physics: Conference Series*, IOP Publishing Ltd, May 2021. doi: 10.1088/1742-6596/1904/1/012014.
- [127] **R. Hammoud, K. El Khoury, and R. Z. Daou**, “On the possibility of using simple weather forecast in the adaptation of building envelopes for energy efficiency,” in *2021 IEEE 3rd International Multidisciplinary Conference on Engineering Technology, IMCET 2021*, Institute of Electrical and Electronics Engineers Inc., 2021, pp. 179–183. doi: 10.1109/IMCET53404.2021.9665544.
- [128] **E. Sorooshnia, M. Rashidi, P. Rahnamayiezekavat, F. Rezaei, and B. Samali**, “Optimum external shading system for counterbalancing glare probability and daylight illuminance in Sydney’s residential buildings,” *Engineering, Construction and Architectural Management*, vol. 30, no. 1, pp. 296–320, Feb. 2023, doi: 10.1108/ECAM-03-2021-0191.
- [129] **R. P. Khidmat, H. Fukuda, and Kustiani**, “Parametric study of expanded metal shading toward Daylight Glare Possibility (DGP) optimization,” in *IOP Conference Series: Earth and Environmental Science*, IOP Publishing Ltd, Nov. 2021. doi: 10.1088/1755-1315/881/1/012019.
- [130] **H. Bazazzadeh et al.**, “Efficient shading device as an important part of daylightophil architecture; a designerly framework of high-performance architecture for an office building in Tehran,” *Energies (Basel)*, vol. 14, no. 24, Dec. 2021, doi: 10.3390/en14248272.
- [131] **A. A. S. Bahdad, S. F. S. Fadzil, H. O. Onubi, and S. A. BenLasod**, “Sensitivity analysis linked to multi-objective optimization for adjustments of light-shelves design

- parameters in response to visual comfort and thermal energy performance,” *Journal of Building Engineering*, vol. 44, Dec. 2021, doi: 10.1016/j.job.2021.102996.
- [132] **H. Kim and M. J. Clayton**, “A multi-objective optimization approach for climate-adaptive building envelope design using parametric behavior maps,” *Build Environ*, vol. 185, Nov. 2020, doi: 10.1016/j.buildenv.2020.107292.
- [133] **Z. Luo, C. Sun, and Q. Dong**, “A daylight-linked shading strategy for automated blinds based on model-based control and Radial Basis Function (RBF) optimization,” *Build Environ*, vol. 177, Jun. 2020, doi: 10.1016/j.buildenv.2020.106854.
- [134] **H. Kim and M. J. Clayton**, “Parametric behavior maps: A method for evaluating the energy performance of climate-adaptive building envelopes,” *Energy Build*, vol. 219, Jul. 2020, doi: 10.1016/j.enbuild.2020.110020.
- [135] **A. A. S. Bahdad, S. F. S. Fadzil, and N. Taib**, “Optimization of daylight performance based on controllable light-shelf parameters using genetic algorithms in the tropical climate of malaysia,” *Journal of Daylighting*, vol. 7, no. 1, pp. 122–136, 2020, doi: 10.15627/jd.2020.10.
- [136] **H. Yi, M. J. Kim, Y. Kim, S. S. Kim, and K. I. Lee**, “Rapid simulation of optimally responsive façade during schematic design phases: Use of a new hybrid metaheuristic algorithm,” *Sustainability (Switzerland)*, vol. 11, no. 9, May 2019, doi: 10.3390/su11092681.
- [137] **R. Sharston**, “Advanced daylight admission systems using auxetic structures in Florida, USA,” in *UrbSys 2019 - Proceedings of the 1st ACM International Workshop on Urban Building Energy Sensing, Controls, Big Data Analysis, and Visualization, Part of BuildSys 2019*, Association for Computing Machinery, Inc, Nov. 2019, pp. 6–13. doi: 10.1145/3363459.3363538.
- [138] **H. J. Kim, C. S. Yang, and H. J. Moon**, “A Study on Multi-Objective Parametric Design Tool for Surround-Type Movable Shading Device,” *Sustainability (Switzerland)*, vol. 11, no. 24, Dec. 2019, doi: 10.3390/su11247096.
- [139] **S. Y. Chen**, “Enhancing validity of green building information modeling with artificial-neural-network-supervised learning —taking construction of adaptive building envelope based on daylight simulation as an example,” *Sensors and Materials*, vol. 31, no. 6, pp. 1831–1845, 2019, doi: 10.18494/SAM.2019.2147.
- [140] **A. Tabadkani, S. Banihashemi, and M. R. Hosseini**, “Daylighting and visual comfort of oriental sun responsive skins: A parametric analysis,” *Build Simul*, vol. 11, no. 4, pp. 663–676, Aug. 2018, doi: 10.1007/s12273-018-0433-0.

- [141] **L. Giovannini et al.**, “A novel methodology to optimize visual comfort and energy performance for transparent adaptive façades,” 2018.
- [142] **M. Ayoub**, “Integrating illuminance and energy evaluations of cellular automata controlled dynamic shading system using new hourly-based metrics,” *Solar Energy*, vol. 170, pp. 336–351, Aug. 2018, doi: 10.1016/j.solener.2018.05.041.
- [143] **R. Shan and L. Junghans**, “Adaptive radiation’ optimization for climate adaptive building facade design strategy,” *Build Simul*, vol. 11, no. 2, pp. 269–279, Apr. 2018, doi: 10.1007/s12273-017-0406-8.
- [144] **F. Favoino, Q. Jin, and M. Overend**, “Design and control optimisation of adaptive insulation systems for office buildings. Part 1: Adaptive technologies and simulation framework,” *Energy*, vol. 127, pp. 301–309, 2017, doi: 10.1016/j.energy.2017.03.083.
- [145] **A. P. Biju, C. Sarkar, and R. Venkatesha Prasad**, “Poster: An energy-harvesting facade optimization system for built environments,” in *BuildSys 2017 - Proceedings of the 4th ACM International Conference on Systems for Energy-Efficient Built Environments*, Association for Computing Machinery, Inc, Nov. 2017. doi: 10.1145/3137133.3141442.
- [146] **J. Xiong and A. Tzempelikos**, “Model-based shading and lighting controls considering visual comfort and energy use,” *Solar Energy*, vol. 134, pp. 416–428, Sep. 2016, doi: 10.1016/j.solener.2016.04.026.
- [147] **K. S. Lee, K. J. Han, and J. W. Lee**, “Feasibility study on parametric optimization of daylighting in building shading design,” *Sustainability (Switzerland)*, vol. 8, no. 12, 2016, doi: 10.3390/su8121220.
- [148] **R. Velasco, R. Hernández, N. Marrugo, and C. Díaz**, “Notes on the design process of a responsive sun-shading system: A case study of designer and user explorations supported by computational tools,” in *Artificial Intelligence for Engineering Design, Analysis and Manufacturing: AIEDAM*, Cambridge University Press, Oct. 2015, pp. 483–502. doi: 10.1017/S0890060415000463.
- [149] **V. Garg, A. Mittal, R. Patni, A. Rathish, A. Bhatia, and P. Haves**, “WinOpt-An Early Stage Design Tool for Optimizing Window Parameters Cool Roof Implications on Thermal Adaptation in Built Environment View project PhD: Modeling of Displacement Ventilation and Chilled Ceiling Systems using Nodal Models View project.” [Online]. Available: <https://www.researchgate.net/publication/301671998>

- [150] **F. Favoino, Q. Jin, and M. Overend**, “Towards an ideal adaptive glazed façade for office buildings,” in *Energy Procedia*, Elsevier Ltd, 2014, pp. 289–298. doi: 10.1016/j.egypro.2014.12.390.
- [151] **J. Kim**, “Adaptive façade design for the daylighting performance in an office building: The investigation of an opening design strategy with cellular automata,” *International Journal of Low-Carbon Technologies*, vol. 10, no. 3, pp. 313–320, Jul. 2013, doi: 10.1093/ijlct/ctt015.
- [152] **K. Sharaidin, J. Burry, and F. Salim**, “Integration of Digital Simulation Tools With Parametric Designs to Evaluate Kinetic Façades for Daylight Performance.”
- [153] **M. Hamdy, A. T. Nguyen, and J. L. M. Hensen**, “A performance comparison of multi-objective optimization algorithms for solving nearly-zero-energy-building design problems,” *Energy Build*, vol. 121, pp. 57–71, Jun. 2016, doi: 10.1016/j.enbuild.2016.03.035.
- [154] **G. R. Araújo, R. Gomes, M. G. Gomes, M. C. Guedes, and P. Ferrão**, “Surrogate Models for Efficient Multi-Objective Optimization of Building Performance,” *Energies (Basel)*, vol. 16, no. 10, May 2023, doi: 10.3390/en16104030.
- [155] **H. H. Hosamo, M. S. Tingstveit, H. K. Nielsen, P. R. Svennevig, and K. Svidt**, “Multiobjective optimization of building energy consumption and thermal comfort based on integrated BIM framework with machine learning-NSGA II,” *Energy Build*, vol. 277, Dec. 2022, doi: 10.1016/j.enbuild.2022.112479.
- [156] **S. Afzal, A. Shokri, B. M. Ziapour, H. Shakibi, and B. Sobhani**, “Building energy consumption prediction and optimization using different neural network-assisted models; comparison of different networks and optimization algorithms,” *Eng Appl Artif Intell*, vol. 127, Jan. 2024, doi: 10.1016/j.engappai.2023.107356.
- [157] **C. Wu, H. Pan, Z. Luo, C. Liu, and H. Huang**, “Multi-objective optimization of residential building energy consumption, daylighting, and thermal comfort based on BO-XGBoost-NSGA-II,” *Build Environ*, vol. 254, Apr. 2024, doi: 10.1016/j.buildenv.2024.111386.
- [158] **J. Zhan, W. He, and J. Huang**, “Comfort, carbon emissions, and cost of building envelope and photovoltaic arrangement optimization through a two-stage model,” *Appl Energy*, vol. 356, Feb. 2024, doi: 10.1016/j.apenergy.2023.122423.
- [159] **R. Shan, W. Lai, H. Tang, X. Leng, and W. Gu**, “Residential Building Renovation Considering Energy, Carbon Emissions, and Cost: An Approach Integrating Machine

- Learning and Evolutionary Generation,” *Applied Sciences (Switzerland)*, vol. 15, no. 4, Feb. 2025, doi: 10.3390/app15041830.
- [160] **B. Chegari, M. Tabaa, E. Simeu, F. Moutaouakkil, and H. Medromi**, “Multi-objective optimization of building energy performance and indoor thermal comfort by combining artificial neural networks and metaheuristic algorithms,” *Energy Build*, vol. 239, May 2021, doi: 10.1016/j.enbuild.2021.110839.
- [161] **Y. Xu, G. Zhang, C. Yan, G. Wang, Y. Jiang, and K. Zhao**, “A two-stage multi-objective optimization method for envelope and energy generation systems of primary and secondary school teaching buildings in China,” *Build Environ*, vol. 204, Oct. 2021, doi: 10.1016/j.buildenv.2021.108142.
- [162] **L. Magnier and F. Haghghat**, “Multiobjective optimization of building design using TRNSYS simulations, genetic algorithm, and Artificial Neural Network,” *Build Environ*, vol. 45, no. 3, pp. 739–746, Mar. 2010, doi: 10.1016/j.buildenv.2009.08.016.
- [163] **B. Si, J. Wang, X. Yao, X. Shi, X. Jin, and X. Zhou**, “Multi-objective optimization design of a complex building based on an artificial neural network and performance evaluation of algorithms,” *Advanced Engineering Informatics*, vol. 40, pp. 93–109, Apr. 2019, doi: 10.1016/j.aei.2019.03.006.
- [164] **H. Yan, G. Ji, and K. Yan**, “Data-driven prediction and optimization of residential building performance in Singapore considering the impact of climate change,” *Build Environ*, vol. 226, Dec. 2022, doi: 10.1016/j.buildenv.2022.109735.
- [165] **C. Luo, C. Feng, H. Zhong, Y. Liu, and M. Dou**, “Design optimization of climate-responsive rural residences in solar rich areas considering sustainability and occupant comfort,” *Energy Build*, vol. 336, Jun. 2025, doi: 10.1016/j.enbuild.2025.115546.
- [166] **P. van Esch and J. Stewart Black**, “Artificial Intelligence (AI): Revolutionizing Digital Marketing,” *Australasian Marketing Journal*, vol. 29, no. 3, pp. 199–203, Aug. 2021, doi: 10.1177/18393349211037684.
- [167] **Y. Xu, C. H. Shieh, P. van Esch, and I. L. Ling**, “AI customer service: Task complexity, problem-solving ability, and usage intention,” *Australasian Marketing Journal*, vol. 28, no. 4, pp. 189–199, Nov. 2020, doi: 10.1016/j.ausmj.2020.03.005.
- [168] **M. A. Karbasforousha, M. Khajehzadeh, T. Jearsiripongkul, S. Keawsawasvong, and M. Eslami**, “A comprehensive review of building energy optimization using metaheuristic algorithms,” Dec. 01, 2024, *Elsevier Ltd.* doi: 10.1016/j.jobee.2024.111377.

- [169] **Y. Pan et al.**, “Building energy simulation and its application for building performance optimization: A review of methods, tools, and case studies,” Jun. 01, 2023, *Elsevier Ltd.* doi: 10.1016/j.adapen.2023.100135.
- [170] **A. Ravikumar and Deepthi**, “A Study from the Perspective of Nature-Inspired Metaheuristic Optimization Algorithms,” in *Proceedings of the The 2012 IEEEWICACM International Joint Conferences on Web Intelligence and Intelligent Agent Technology*, 2015.
- [171] **M. J. Ko**, “Analysis and optimization design of a solar water heating system based on life cycle cost using a genetic algorithm,” *Energies (Basel)*, vol. 8, no. 10, pp. 11380–11403, 2015, doi: 10.3390/en81011380.
- [172] **C. Yu, X. Xue, K. Shi, R. Wang, L. Zhang, and M. Shao**, “Optimization of wavy fin-and-elliptical tube heat exchanger using CFD, multi-objective genetic algorithm and radical basis function,” *Energy Sci Eng*, vol. 9, no. 9, pp. 1359–1372, Sep. 2021, doi: 10.1002/ese3.897.
- [173] **M. T. M. Emmerich and A. H. Deutz**, “A tutorial on multiobjective optimization: fundamentals and evolutionary methods,” *Nat Comput*, vol. 17, no. 3, pp. 585–609, Sep. 2018, doi: 10.1007/s11047-018-9685-y.
- [174] **E. Bonamente et al.**, “A life-cycle approach for multi-objective optimisation in building design: methodology and application to a case study,” *Civil Engineering and Environmental Systems*, vol. 35, no. 1–4, pp. 158–179, Oct. 2018, doi: 10.1080/10286608.2019.1576646.
- [175] **A. Vukadinović, J. Radosavljević, A. Đorđević, M. Protić, and N. Petrović**, “Multi-objective optimization of energy performance for a detached residential building with a sunspace using the NSGA-II genetic algorithm,” *Solar Energy*, vol. 224, pp. 1426–1444, Aug. 2021, doi: 10.1016/j.solener.2021.06.082.
- [176] **F. A. Khan, K. Ullah, A. ur Rahman, and S. Anwar**, “Energy optimization in smart urban buildings using bio-inspired ant colony optimization,” *Soft comput*, vol. 27, no. 2, pp. 973–989, Jan. 2023, doi: 10.1007/s00500-022-07537-3.
- [177] **A. G. Gad**, “Particle Swarm Optimization Algorithm and Its Applications: A Systematic Review,” *Archives of Computational Methods in Engineering*, vol. 29, no. 5, pp. 2531–2561, Aug. 2022, doi: 10.1007/s11831-021-09694-4.
- [178] **S. Lu, R. Wang, and S. Zheng**, “Passive optimization design based on particle swarm optimization in rural buildings of the hot summer and warm winter zone of China,” *Sustainability (Switzerland)*, vol. 9, no. 12, Dec. 2017, doi: 10.3390/su9122288.

- [179] **E. Henrichs, V. Lesch, M. Straesser, S. Kounev, and C. Krupitzer**, “A literature review on optimization techniques for adaptation planning in adaptive systems: State of the art and research directions,” *Inf Softw Technol*, vol. 149, Sep. 2022, doi: 10.1016/j.infsof.2022.106940.
- [180] **Y. Zhu, G. H. Huang, Y. P. Li, L. He, and X. X. Zhang**, “An interval full-infinite mixed-integer programming method for planning municipal energy systems - A case study of Beijing,” *Appl Energy*, vol. 88, no. 8, pp. 2846–2862, 2011, doi: 10.1016/j.apenergy.2011.01.058.
- [181] **V. Kumtepli et al.**, “Design and analysis of an aging-aware energy management system for islanded grids using mixed-integer quadratic programming,” *Int J Energy Res*, vol. 43, no. 9, pp. 4127–4147, Jul. 2019, doi: 10.1002/er.4512.
- [182] **M. Killian, M. Zauner, and M. Kozek**, “Comprehensive smart home energy management system using mixed-integer quadratic-programming,” *Appl Energy*, vol. 222, pp. 662–672, Jul. 2018, doi: 10.1016/j.apenergy.2018.03.179.
- [183] **A. W. A. Hammad, K. Figueiredo, A. C. Rosa, E. Vazquez, and A. Haddad**, “Enhancing the passive design of buildings: A mixed integer non-linear programming approach for the selection of building materials and construction building systems,” *Energy Reports*, vol. 7, pp. 8162–8175, Nov. 2021, doi: 10.1016/j.egyr.2021.04.063.
- [184] **P. A. Fokaides, A. Panayidou, C. Hadjichristos, and M. C. Phocas**, “Application of non-linear programming to optimize buildings’ solar exposure,” *Journal of Building Engineering*, vol. 11, pp. 127–133, May 2017, doi: 10.1016/j.jobbe.2017.04.007.
- [185] **O. F.Y, A. J.E.T, A. O, H. J. O, O. O, and A. J**, “Supervised Machine Learning Algorithms: Classification and Comparison,” *International Journal of Computer Trends and Technology*, vol. 48, no. 3, pp. 128–138, Jun. 2017, doi: 10.14445/22312803/IJCTT-V48P126.
- [186] **H. W. Ian, F. Eibe, and M. A. Hall**, *Data Mining Practical Machine Learning Tools and Techniques*.
- [187] **H. Hosamo, M. H. Hosamo, H. K. Nielsen, P. R. Svennevig, and K. Svidt**, “Digital Twin of HVAC system (HVACDT) for multiobjective optimization of energy consumption and thermal comfort based on BIM framework with ANN-MOGA,” *Advances in Building Energy Research*, vol. 17, no. 2, pp. 125–171, 2023, doi: 10.1080/17512549.2022.2136240.

- [188] **M. Baghoolizadeh, M. Rostamzadeh-Renani, S. A. H. H. Dehkordi, R. Rostamzadeh-Renani, and D. Toghraie**, “A prediction model for CO<sub>2</sub> concentration and multi-objective optimization of CO<sub>2</sub> concentration and annual electricity consumption cost in residential buildings using ANN and GA,” *J Clean Prod*, vol. 379, Dec. 2022, doi: 10.1016/j.jclepro.2022.134753.
- [189] **G. Salvalai, Y. Zhu, and M. M. Sesana**, “From building energy modeling to urban building energy modeling: A review of recent research trend and simulation tools,” *Energy Build*, vol. 319, Sep. 2024, doi: 10.1016/j.enbuild.2024.114500.
- [190] **H. Liu, Z. Du, T. Xue, and T. Jiang**, “An integrated artificial intelligence-driven approach to multi-criteria optimization of building energy efficiency and occupants’ comfort: A case study,” *Journal of Building Engineering*, p. 111944, Feb. 2025, doi: 10.1016/j.jobbe.2025.111944.
- [191] **T. Xuan Nghiem and T. X. Nghiem**, “MLE+: a Matlab-EnergyPlus Co-simulation Interface”, doi: 10.13140/RG.2.1.1127.0880.
- [192] **EnergyPlus**. Accessed: Jan. 07, 2024. [Online]. Available: <https://energyplus.net/>
- [193] **N. Fumo, P. Mago, and R. Luck**, “Methodology to estimate building energy consumption using EnergyPlus Benchmark Models,” *Energy Build*, vol. 42, no. 12, pp. 2331–2337, Dec. 2010, doi: 10.1016/j.enbuild.2010.07.027.
- [194] **D. Mazzeo, N. Matera, C. Cornaro, G. Oliveti, P. Romagnoni, and L. De Santoli**, “EnergyPlus, IDA ICE and TRNSYS predictive simulation accuracy for building thermal behaviour evaluation by using an experimental campaign in solar test boxes with and without a PCM module,” *Energy Build*, vol. 212, Apr. 2020, doi: 10.1016/j.enbuild.2020.109812.
- [195] **M. Wetter, K. Benne, H. Tummescheit, and C. Winther**, “Spawn: coupling Modelica Buildings Library and EnergyPlus to enable new energy system and control applications,” *J Build Perform Simul*, vol. 17, no. 2, pp. 274–292, 2024, doi: 10.1080/19401493.2023.2266414.
- [196] **R. Zhang, K. P. Lam, S. chune Yao, and Y. Zhang**, “Coupled EnergyPlus and computational fluid dynamics simulation for natural ventilation,” *Build Environ*, vol. 68, pp. 100–113, Oct. 2013, doi: 10.1016/j.buildenv.2013.04.002.
- [197] **Y. Chen, L. Gu, and J. Zhang**, “EnergyPlus and CHAMPS-Multizone co-simulation for energy and indoor air quality analysis,” *Build Simul*, vol. 8, no. 4, pp. 371–380, Aug. 2015, doi: 10.1007/s12273-015-0211-1.

- [198] **TRNSYS**. Accessed: Jan. 07, 2024. [Online]. Available: <https://www.trnsys.com/index.html>
- [199] **E. Asadi, M. G. da Silva, C. H. Antunes, and L. Dias**, “A multi-objective optimization model for building retrofit strategies using TRNSYS simulations, GenOpt and MATLAB,” *Build Environ*, vol. 56, pp. 370–378, Oct. 2012, doi: 10.1016/j.buildenv.2012.04.005.
- [200] **S. Lu, X. Tang, L. Ji, and D. Tu**, “Research on energy-saving optimization for the performance parameters of rural-building shape and envelope by trnsys-genopt in hot summer and cold winter zone of China,” *Sustainability (Switzerland)*, vol. 9, no. 2, 2017, doi: 10.3390/su9020294.
- [201] **Y. Zhang and I. Korolija**, “Performing complex parametric simulations with jEPlus,” 2010.
- [202] **A. J. Mettrick and Z. Ma**, “Integrating phase change materials in buildings for heating and cooling demand reduction – A global study,” *Case Studies in Thermal Engineering*, vol. 63, Nov. 2024, doi: 10.1016/j.csite.2024.105337.
- [203] **N. Amani**, “Sustainable construction of green school building using energy simulation analysis and modeling,” *Hybrid Advances*, vol. 6, p. 100236, Aug. 2024, doi: 10.1016/j.hybadv.2024.100236.
- [204] **F. Del Ama Gonzalo, B. Moreno Santamaría, and M. J. Montero Burgos**, “Assessment of Building Energy Simulation Tools to Predict Heating and Cooling Energy Consumption at Early Design Stages,” *Sustainability (Switzerland)*, vol. 15, no. 3, Feb. 2023, doi: 10.3390/su15031920.
- [205] **L. Zhang**, “Simulation analysis of built environment based on design builder software,” in *Applied Mechanics and Materials*, Trans Tech Publications Ltd, 2014, pp. 3134–3137. doi: 10.4028/www.scientific.net/AMM.580-583.3134.
- [206] **E. Weaver, N. Long, K. Fleming, M. Schott, K. Benne, and E. Hale**, “Rapid Application Development with OpenStudio: Preprint,” 2012. [Online]. Available: <http://www.osti.gov/bridge>
- [207] **N. Yu et al.**, “Integrating BIMserver and OpenStudio for Energy Efficient Building,” 2013. doi: <https://doi.org/10.1061/9780784413029.065>.
- [208] **J. Hu, Z. Wang, and W. Chen**, “A Study on Automatic Form Optimization Procedures of Building Performance Design Based on ‘ladybug+Honeybee,’” in *IOP Conference Series: Earth and Environmental Science*, Institute of Physics Publishing, Jul. 2020. doi: 10.1088/1755-1315/531/1/012020.

- [209] **Ladybug Tools**. Accessed: Jan. 10, 2024. [Online]. Available: <https://www.ladybug.tools/honeybee.html>
- [210] **P. de Wilde**, “Building performance simulation in the brave new world of artificial intelligence and digital twins: A systematic review,” Aug. 01, 2023, *Elsevier Ltd*. doi: 10.1016/j.enbuild.2023.113171.
- [211] **C. Lu, S. Li, and Z. Lu**, “Building energy prediction using artificial neural networks: A literature survey,” *Energy Build*, vol. 262, May 2022, doi: 10.1016/j.enbuild.2021.111718.
- [212] **B. Mahesh**, “Machine Learning Algorithms-A Review,” *International Journal of Science and Research*, 2018, doi: 10.21275/ART20203995.
- [213] **H. Liu, X. Liao, and B. Du**, “The applications of nature-inspired meta-heuristic algorithms for decreasing the energy consumption of software-defined networks: A comprehensive and systematic literature review,” *Sustainable Computing: Informatics and Systems*, vol. 39, Sep. 2023, doi: 10.1016/j.suscom.2023.100895.
- [214] **H. Khajavi and A. Rastgoo**, “Improving the prediction of heating energy consumed at residential buildings using a combination of support vector regression and meta-heuristic algorithms,” *Energy*, vol. 272, Jun. 2023, doi: 10.1016/j.energy.2023.127069.
- [215] **H. Dasi, Z. Ying, and B. Yang**, “Predicting the consumed heating energy at residential buildings using a combination of categorical boosting (CatBoost) and Meta heuristics algorithms,” *Journal of Building Engineering*, vol. 71, Jul. 2023, doi: 10.1016/j.jobbe.2023.106584.
- [216] **B. Chegari, M. Tabaa, E. Simeu, F. Moutaouakkil, and H. Medromi**, “Multi-objective optimization of building energy performance and indoor thermal comfort by combining artificial neural networks and metaheuristic algorithms,” *Energy Build*, vol. 239, May 2021, doi: 10.1016/j.enbuild.2021.110839.
- [217] **B. Zeng, L. Gao, and X. Li**, “Whale swarm algorithm for function optimization,” in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, Springer Verlag, 2017, pp. 624–639. doi: 10.1007/978-3-319-63309-1\_55.
- [218] **M. Jahannoush and S. Arabi Nowdeh**, “Optimal designing and management of a stand-alone hybrid energy system using meta-heuristic improved sine–cosine algorithm for Recreational Center, case study for Iran country,” *Applied Soft Computing Journal*, vol. 96, Nov. 2020, doi: 10.1016/j.asoc.2020.106611.

- [219] **C. Deb and A. Schlueter**, “Review of data-driven energy modelling techniques for building retrofit,” Jul. 01, 2021, *Elsevier Ltd.* doi: 10.1016/j.rser.2021.110990.
- [220] **A. Chakrabarty, E. Maddalena, H. Qiao, and C. Laughman**, “Scalable Bayesian optimization for model calibration: Case study on coupled building and HVAC dynamics,” *Energy Build*, vol. 253, Dec. 2021, doi: 10.1016/j.enbuild.2021.111460.
- [221] **B. Ekici, O. F. S. F. Turkcan, M. Turrin, I. S. Sariyildiz, and M. F. Tasgetiren**, “Optimising High-Rise Buildings for Self-Sufficiency in Energy Consumption and Food Production Using Artificial Intelligence: Case of Europoint Complex in Rotterdam,” *Energies (Basel)*, vol. 15, no. 2, Jan. 2022, doi: 10.3390/en15020660.
- [222] **A. E. I. Brownlee and J. A. Wright**, “Constrained, mixed-integer and multi-objective optimisation of building designs by NSGA-II with fitness approximation,” *Applied Soft Computing Journal*, vol. 33, pp. 114–126, Apr. 2015, doi: 10.1016/j.asoc.2015.04.010.
- [223] **Q. Tang, J. Dang, Y. Cui, X. Wang, and J. Jia**, “Machine Learning-Based Fast Seismic Risk Assessment of Building Structures,” *Journal of Earthquake Engineering*, vol. 26, no. 15, pp. 8041–8062, 2022, doi: 10.1080/13632469.2021.1987354.
- [224] **S. Gupta, H. Abderazek, B. S. Yıldız, A. R. Yildiz, S. Mirjalili, and S. M. Sait**, “Comparison of metaheuristic optimization algorithms for solving constrained mechanical design optimization problems,” *Expert Syst Appl*, vol. 183, Nov. 2021, doi: 10.1016/j.eswa.2021.115351.
- [225] **D. Chakraborty and H. Elzarka**, “Advanced machine learning techniques for building performance simulation: a comparative analysis,” *J Build Perform Simul*, vol. 12, no. 2, pp. 193–207, Mar. 2019, doi: 10.1080/19401493.2018.1498538.
- [226] **V. Nasteski**, “An overview of the supervised machine learning methods,” *HORIZONS.B*, vol. 4, pp. 51–62, Dec. 2017, doi: 10.20544/horizons.b.04.1.17.p05.
- [227] **Y. Boutahri and A. Tilioua**, “Machine learning-based predictive model for thermal comfort and energy optimization in smart buildings,” *Results in Engineering*, vol. 22, Jun. 2024, doi: 10.1016/j.rineng.2024.102148.
- [228] **M. Zorn, N. Catunda, L. Claus, N. Kobylinska, M. Frey, and T. Wortmann**, “Replacing energy simulations with surrogate models for design space exploration,” *Bauphysik*, vol. 44, no. 6, pp. 311–316, Dec. 2022, doi: 10.1002/bapi.202200034.
- [229] **P. De Wilde, C. Martinez-Ortiz, D. Pearson, I. Beynon, M. Beck, and N. Barlow**, “Building simulation approaches for the training of automated data analysis tools in

- building energy management,” *Advanced Engineering Informatics*, vol. 27, no. 4, pp. 457–465, Oct. 2013, doi: 10.1016/j.aei.2013.05.001.
- [230] **A. Tabadkani, A. Tsangrassoulis, A. Roetzel, and H. X. Li**, “Innovative control approaches to assess energy implications of adaptive facades based on simulation using EnergyPlus,” *Solar Energy*, vol. 206, pp. 256–268, Aug. 2020, doi: 10.1016/j.solener.2020.05.087.
- [231] **T. Mendis, Z. Huang, S. Xu, and W. Zhang**, “Economic potential analysis of photovoltaic integrated shading strategies on commercial building facades in urban blocks: A case study of Colombo, Sri Lanka,” *Energy*, vol. 194, Mar. 2020, doi: 10.1016/j.energy.2020.116908.
- [232] **A. G. Kheybari and S. Hoffmann**, “Exploring the potential of dynamic façade systems: an exterior shading system versus a switchable window,” *Bauphysik*, vol. 42, no. 6, pp. 277–288, Dec. 2020, doi: 10.1002/bapi.202000034.
- [233] **J. M. Han and D. Park**, “Seasonal optimization of a dynamic thermo-optical ETFE façade system,” in *Building Simulation Conference Proceedings*, International Building Performance Simulation Association, 2019, pp. 4887–4893. doi: 10.26868/25222708.2019.210642.
- [234] **A. L. Navarro et al.**, “Occupant-centred control strategies for adaptive facades: A preliminary study of the impact of shortwave solar radiation on thermal comfort,” in *Building Simulation Conference Proceedings*, International Building Performance Simulation Association, 2019, pp. 4910–4917. doi: 10.26868/25222708.2019.211013.
- [235] **E. S. Mazzucchelli, M. Alston, M. Brzezicki, and L. Doniacovo**, “Study of a BIPV adaptive system: Combining timber and photovoltaic technologies,” *Journal of Facade Design and Engineering*, vol. 6, no. 3, pp. 149–162, 2018, doi: 10.7480/jfde.2018.3.2602.
- [236] **M. Werner, R. Pfluger, D. Geisler-Moroder, and W. Feist**, “Analysis of worldwide performance of façade systems,” in *Building Simulation Conference Proceedings*, International Building Performance Simulation Association, 2017, pp. 864–873. doi: 10.26868/25222708.2017.267.
- [237] **R. Kay, C. Katrycz, K. Nitièma, J. A. Jakubiec, and B. D. Hatton**, “Decapod-inspired pigment modulation for active building facades,” *Nat Commun*, vol. 13, no. 1, Dec. 2022, doi: 10.1038/s41467-022-31527-6.

- [238] **L. Bande *et al.***, “Design of Innovative Parametric/Dynamic Façade Integrated in the Library Extension Building on UAEU Campus †,” *Buildings*, vol. 12, no. 8, Aug. 2022, doi: 10.3390/buildings12081101.
- [239] **A. Nabil and J. Mardaljevic**, “Useful daylight illuminance: A new paradigm for assessing daylight in buildings,” *Lighting Research and Technology*, vol. 37, no. 1, pp. 41–59, 2005, doi: 10.1191/1365782805li128oa.
- [240] **S. Motamedi and P. Liedl**, “Integrative algorithm to optimize skylights considering fully impacts of daylight on energy,” *Energy Build*, vol. 138, pp. 655–665, Mar. 2017, doi: 10.1016/j.enbuild.2016.12.045.
- [241] **I. Acosta, M. Á. Campano, and J. F. Molina**, “Window design in architecture: Analysis of energy savings for lighting and visual comfort in residential spaces,” *Appl Energy*, vol. 168, pp. 493–506, Apr. 2016, doi: 10.1016/j.apenergy.2016.02.005.
- [242] **ANSI/ASHRAE Standard 140-2001**, “Standard Method of Test for the Evaluation of Building Energy Analysis Computer Programs,” 2004. [Online]. Available: <http://www.ashrae.org>,
- [243] **J. Neymark and R. Judkoff**, “International Energy Agency Building Energy Simulation Test and Diagnostic Method for Heating, Ventilating, and Air-Conditioning Equipment Models (HVAC BESTEST) Volume 1: Cases E100-E200,” 2002. [Online]. Available: <http://www.osti.gov/bridge>
- [244] **Rhino**. Accessed: Mar. 12, 2024. [Online]. Available: <https://www.rhino3d.com/features/#grasshopper>
- [245] **Y. Masoudi-Sobhanzadeh, H. Motieghader, and A. Masoudi-Nejad**, “FeatureSelect: A software for feature selection based on machine learning approaches,” *BMC Bioinformatics*, vol. 20, no. 1, Apr. 2019, doi: 10.1186/s12859-019-2754-0.
- [246] **M. A. Hall**, “Correlation-based Feature Selection for Machine Learning,” 1999.
- [247] **H.-X. Zhao, F. Magoulès, E. C. Paris, and G. Voie Des Vignes**, “Feature Selection for Predicting Building Energy Consumption Based on Statistical Learning Method.”
- [248] **S. Egea, A. Rego Manez, B. Carro, A. Sanchez-Esguevillas, and J. Lloret**, “Intelligent IoT traffic classification using novel search strategy for fast-based-correlation feature selection in industrial environments,” *IEEE Internet Things J*, vol. 5, no. 3, pp. 1616–1624, Jun. 2018, doi: 10.1109/JIOT.2017.2787959.

- [249] **Q. Qiao, A. Yunusa-Kaltungo, and R. E. Edwards**, “Feature selection strategy for machine learning methods in building energy consumption prediction,” *Energy Reports*, vol. 8, pp. 13621–13654, Nov. 2022, doi: 10.1016/j.egyr.2022.10.125.
- [250] **M. Robnik-Sikonja, M. Robnik-Sikonja, and I. Kononenko**, “An adaptation of Relief for attribute estimation in regression,” 2000. [Online]. Available: <https://www.researchgate.net/publication/2635627>
- [251] **S. M. Lundberg, P. G. Allen, and S.-I. Lee**, “A Unified Approach to Interpreting Model Predictions.” [Online]. Available: <https://github.com/slundberg/shap>
- [252] **H. K. Gianey and R. Choudhary**, “Comprehensive Review On Supervised Machine Learning Algorithms,” in *Proceedings - 2017 International Conference on Machine Learning and Data Science, MLDS 2017*, Institute of Electrical and Electronics Engineers Inc., Jul. 2017, pp. 38–43. doi: 10.1109/MLDS.2017.11.
- [253] **S. Walczak and N. Cerpa**, “Artificial Neural Networks,” 2001. [Online]. Available: <http://www.emsl.pnl.gov:2080/proj/neuron/neural/sys->
- [254] **Z. Zhang**, “Artificial Neural Network,” in *Multivariate Time Series Analysis in Climate and Environmental Research*, Cham: Springer International Publishing, 2018, pp. 1–35. doi: 10.1007/978-3-319-67340-0\_1.
- [255] **V. H. S. Pham and V. K. Nguyen**, “A study on optimization of HVAC system in buildings using gray wolf optimizer (GWO) and artificial neural network (ANN),” *Asian Journal of Civil Engineering*, vol. 24, no. 8, pp. 3743–3757, Dec. 2023, doi: 10.1007/s42107-023-00747-6.
- [256] **T. Singh Rajput and A. Thomas**, “Optimizing passive design strategies for energy efficient buildings using hybrid artificial neural network (ANN) and multi-objective evolutionary algorithm through a case study approach,” *International Journal of Construction Management*, vol. 23, no. 13, pp. 2320–2332, 2023, doi: 10.1080/15623599.2022.2056409.
- [257] **A. Razmi, M. Rahbar, and M. Bemanian**, “PCA-ANN integrated NSGA-III framework for dormitory building design optimization: Energy efficiency, daylight, and thermal comfort,” *Appl Energy*, vol. 305, Jan. 2022, doi: 10.1016/j.apenergy.2021.117828.
- [258] **L. T. Le, H. Nguyen, J. Dou, and J. Zhou**, “A comparative study of PSO-ANN, GA-ANN, ICA-ANN, and ABC-ANN in estimating the heating load of buildings’ energy efficiency for smart city planning,” *Applied Sciences (Switzerland)*, vol. 9, no. 13, Jul. 2019, doi: 10.3390/app9132630.

- [259] **E. Elbeltagi and H. Wefki**, “Predicting energy consumption for residential buildings using ANN through parametric modeling,” *Energy Reports*, vol. 7, pp. 2534–2545, Nov. 2021, doi: 10.1016/j.egy.2021.04.053.
- [260] **Z. Li, J. Dai, H. Chen, and B. Lin**, “An ANN-based fast building energy consumption prediction method for complex architectural form at the early design stage,” *Build Simul*, vol. 12, no. 4, pp. 665–681, Aug. 2019, doi: 10.1007/s12273-019-0538-0.
- [261] **D. Kim, S. Kang, and S. Cho**, “Expected margin–based pattern selection for support vector machines,” *Expert Syst Appl*, vol. 139, Jan. 2020, doi: 10.1016/j.eswa.2019.112865.
- [262] **P. Ming**, “Hybrid machine learning application with integration of meta-heuristic algorithm for prediction of cooling load,” *Multiscale and Multidisciplinary Modeling, Experiments and Design*, vol. 7, no. 4, pp. 4133–4149, Sep. 2024, doi: 10.1007/s41939-024-00463-x.
- [263] **J. Zhang, Y. Huang, H. Cheng, H. Chen, L. Xing, and Y. He**, “Ensemble learning-based approach for residential building heating energy prediction and optimization,” *Journal of Building Engineering*, vol. 67, May 2023, doi: 10.1016/j.job.2023.106051.
- [264] **L. Zhang, Y. Chen, and Z. Yan**, “Predicting the short-term electricity demand based on the weather variables using a hybrid CatBoost-PPSO model,” *Journal of Building Engineering*, vol. 71, Jul. 2023, doi: 10.1016/j.job.2023.106432.
- [265] **M. Zekić-Sušac, A. Has, and M. Knežević**, “Predicting energy cost of public buildings by artificial neural networks, CART, and random forest,” *Neurocomputing*, vol. 439, pp. 223–233, Jun. 2021, doi: 10.1016/j.neucom.2020.01.124.
- [266] **G. Hong, G. S. Choi, J. Y. Eum, H. S. Lee, and D. D. Kim**, “The Hourly Energy Consumption Prediction by KNN for Buildings in Community Buildings,” *Buildings*, vol. 12, no. 10, Oct. 2022, doi: 10.3390/buildings12101636.
- [267] **N. Y. Dahlan, S. Z. Sakimin, M. Faizwan, N. Ajmain, and A. A. Aris**, “Automated calibration of greenhouse energy model using hybrid evolutionary programming (EP)-energy plus,” *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 12, no. 2, pp. 648–654, Nov. 2018, doi: 10.11591/ijeecs.v12.i2.pp648-654.

- [268] **M. E. Mowlaei and X. Shi**, “FSF-GA: A Feature Selection Framework for Phenotype Prediction Using Genetic Algorithms,” *Genes (Basel)*, vol. 14, no. 5, May 2023, doi: 10.3390/genes14051059.
- [269] **M. Wang and Y. Ma**, “A differential evolution algorithm based on accompanying population and piecewise evolution strategy,” *Appl Soft Comput*, vol. 143, Aug. 2023, doi: 10.1016/j.asoc.2023.110390.
- [270] **M. Ilbeigi, M. Ghomeishi, and A. Dehghanbanadaki**, “Prediction and optimization of energy consumption in an office building using artificial neural network and a genetic algorithm,” *Sustain Cities Soc*, vol. 61, Oct. 2020, doi: 10.1016/j.scs.2020.102325.
- [271] **L. Zhang, L. Zhang, and Y. Wang**, “Shape optimization of free-form buildings based on solar radiation gain and space efficiency using a multi-objective genetic algorithm in the severe cold zones of China,” *Solar Energy*, vol. 132, pp. 38–50, Jul. 2016, doi: 10.1016/j.solener.2016.02.053.
- [272] **A. Roy, S. Maity, and I. Moon**, “Multi-vehicle clustered traveling purchaser problem using a variable-length genetic algorithm,” *Eng Appl Artif Intell*, vol. 123, Aug. 2023, doi: 10.1016/j.engappai.2023.106351.
- [273] **S. Mirjalili, J. Song Dong, A. S. Sadiq, and H. Faris**, “Genetic algorithm: Theory, literature review, and application in image reconstruction,” in *Studies in Computational Intelligence*, vol. 811, Springer Verlag, 2020, pp. 69–85. doi: 10.1007/978-3-030-12127-3\_5.
- [274] **B. Alhijawi and A. Awajan**, “Genetic algorithms: theory, genetic operators, solutions, and applications,” 2023, *Springer Science and Business Media Deutschland GmbH*. doi: 10.1007/s12065-023-00822-6.
- [275] **S. Katoch, S. S. Chauhan, and V. Kumar**, “A review on genetic algorithm: past, present, and future,” *Multimed Tools Appl*, vol. 80, no. 5, pp. 8091–8126, Feb. 2021, doi: 10.1007/s11042-020-10139-6.
- [276] **S. Mirjalili, S. Saremi, S. M. Mirjalili, and L. D. S. Coelho**, “Multi-objective grey wolf optimizer: A novel algorithm for multi-criterion optimization,” *Expert Syst Appl*, vol. 47, pp. 106–119, Apr. 2016, doi: 10.1016/j.eswa.2015.10.039.
- [277] **Z. He and G. G. Yen**, “Many-Objective Evolutionary Algorithms Based on Coordinated Selection Strategy,” *IEEE Transactions on Evolutionary Computation*, vol. 21, no. 2, pp. 220–233, Apr. 2017, doi: 10.1109/TEVC.2016.2598687.

- [278] **H. H. Shin, S. Yun, M. H. Park, D. S. Jang, and Y. Kim**, “Optimization of semi-interlocking heat sinks for hotspot thermal management using multi-objective genetic algorithm,” *Int J Heat Mass Transf*, vol. 183, Feb. 2022, doi: 10.1016/j.ijheatmasstransfer.2021.122170.
- [279] **P. S. Kang and R. S. Bhatti**, “Continuous process improvement implementation framework using multi-objective genetic algorithms and discrete event simulation,” *Business Process Management Journal*, vol. 25, no. 5, pp. 1020–1039, Aug. 2019, doi: 10.1108/BPMJ-07-2017-0188.
- [280] **B. Wang, W. Pei, B. Xue, and M. Zhang**, “A Multi-objective Genetic Algorithm to Evolving Local Interpretable Model-agnostic Explanations for Deep Neural Networks in Image Classification,” *IEEE Transactions on Evolutionary Computation*, 2022, doi: 10.1109/TEVC.2022.3225591.
- [281] **J. Guo, J. Zou, B. Du, and K. Wang**, “Integrated scheduling for remanufacturing system considering component commonality using improved multi-objective genetic algorithm,” *Comput Ind Eng*, vol. 182, Aug. 2023, doi: 10.1016/j.cie.2023.109419.
- [282] **W. Song, X. Shen, Y. Huang, P. Jiang, and Y. Zhu**, “Fuel ejector design and optimization for solid oxide fuel cells using response surface methodology and multi-objective genetic algorithm,” *Appl Therm Eng*, vol. 232, Sep. 2023, doi: 10.1016/j.applthermaleng.2023.121067.
- [283] **F. Ascione, N. Bianco, C. De Stasio, G. M. Mauro, and G. P. Vanoli**, “Simulation-based model predictive control by the multi-objective optimization of building energy performance and thermal comfort,” *Energy Build*, vol. 111, pp. 131–144, Jan. 2016, doi: 10.1016/j.enbuild.2015.11.033.
- [284] **T. Méndez Echenagucia, A. Capozzoli, Y. Cascone, and M. Sassone**, “The early design stage of a building envelope: Multi-objective search through heating, cooling and lighting energy performance analysis,” *Appl Energy*, vol. 154, pp. 577–591, Sep. 2015, doi: 10.1016/j.apenergy.2015.04.090.
- [285] **X. Chen and H. Yang**, “A multi-stage optimization of passively designed high-rise residential buildings in multiple building operation scenarios,” *Appl Energy*, vol. 206, pp. 541–557, 2017, doi: 10.1016/j.apenergy.2017.08.204.
- [286] **Nasruddin, Sholahudin, P. Satrio, T. M. I. Mahlia, N. Giannetti, and K. Saito**, “Optimization of HVAC system energy consumption in a building using artificial neural network and multi-objective genetic algorithm,” *Sustainable Energy*

- Technologies and Assessments*, vol. 35, pp. 48–57, Oct. 2019, doi: 10.1016/j.seta.2019.06.002.
- [287] **G. R. Araújo, R. Gomes, M. G. Gomes, M. C. Guedes, and P. Ferrão**, “Surrogate Models for Efficient Multi-Objective Optimization of Building Performance,” *Energies (Basel)*, vol. 16, no. 10, May 2023, doi: 10.3390/en16104030.
- [288] **L. Hong, C. Liu, J. Cui, and F. Liu**, “Mutation Strategy Based on Step Size and Survival Rate for Evolutionary Programming,” *Discrete Dyn Nat Soc*, vol. 2021, 2021, doi: 10.1155/2021/1336929.
- [289] **Z. H. Sun, D. Liang, Z. Zhuang, L. Chen, and X. Ming**, “Multi-task processing oriented production layout based on evolutionary programming mechanism,” *Appl Soft Comput*, vol. 98, Jan. 2021, doi: 10.1016/j.asoc.2020.106896.
- [290] **H. Huang, S. Ye, Z. Fan, Z. Lin, L. Lv, and Z. Hao**, “Evolutionary programming with a simulated-conformist mutation strategy,” *Soft comput*, vol. 22, no. 2, pp. 659–676, Jan. 2018, doi: 10.1007/s00500-016-2365-x.
- [291] **J. Ahmad et al.**, “Evolutionary programming based technique for plug-in-hybrid electric vehicle charging system,” *International Journal of Advanced Trends in Computer Science and Engineering*, vol. 8, no. 1.3 S1, pp. 425–430, 2019, doi: 10.30534/ijatcse/2019/7381.32019.
- [292] **S. Bhol and N. C. Sahu**, “Decarbonizing the grid by optimal scheduling of solar PV-wind turbine-pumped hydro storage considering application on heuristic algorithms: A comprehensive review,” Oct. 25, 2021, *John Wiley and Sons Ltd.* doi: 10.1002/er.7036.
- [293] **M. Ghazouani, M. Bouya, and M. Benaissa**, “Thermo-economic and exergy analysis and optimization of small PTC collectors for solar heat integration in industrial processes,” *Renew Energy*, vol. 152, pp. 984–998, Jun. 2020, doi: 10.1016/j.renene.2020.01.109.
- [294] **A. Gün**, “Attitude control of a quadrotor using PID controller based on differential evolution algorithm,” *Expert Syst Appl*, vol. 229, Nov. 2023, doi: 10.1016/j.eswa.2023.120518.
- [295] **Y. Song et al.**, “Dynamic hybrid mechanism-based differential evolution algorithm and its application,” *Expert Syst Appl*, vol. 213, Mar. 2023, doi: 10.1016/j.eswa.2022.118834.

- [296] **L. Junghans and N. Darde**, “Hybrid single objective genetic algorithm coupled with the simulated annealing optimization method for building optimization,” *Energy Build*, vol. 86, pp. 651–662, 2015, doi: 10.1016/j.enbuild.2014.10.039.
- [297] **S. Khatir, S. Tiachacht, C. Le Thanh, E. Ghandourah, S. Mirjalili, and M. Abdel Wahab**, “An improved Artificial Neural Network using Arithmetic Optimization Algorithm for damage assessment in FGM composite plates,” *Compos Struct*, vol. 273, Oct. 2021, doi: 10.1016/j.compstruct.2021.114287.
- [298] **M. H. Kolaee, S. M. J. Mirzapour Al-e-Hashem, and A. Jabbarzadeh**, “A local search-based non-dominated sorting genetic algorithm for solving a multi-objective medical tourism trip design problem considering the attractiveness of trips,” *Eng Appl Artif Intell*, vol. 124, Sep. 2023, doi: 10.1016/j.engappai.2023.106630.
- [299] **F. Aljalaud, H. Kurdi, and K. Youcef-Toumi**, “Bio-Inspired Multi-UAV Path Planning Heuristics: A Review,” *Mathematics*, vol. 11, no. 10, May 2023, doi: 10.3390/math11102356.
- [300] **C. Maraveas, P. G. Asteris, K. G. Arvanitis, T. Bartzanas, and D. Loukatos**, “Application of Bio and Nature-Inspired Algorithms in Agricultural Engineering,” Apr. 01, 2023, *Springer Science and Business Media B.V.* doi: 10.1007/s11831-022-09857-x.
- [301] **A. H. Elsheikh and M. Abd Elaziz**, “Review on applications of particle swarm optimization in solar energy systems,” Feb. 04, 2019, *Center for Environmental and Energy Research and Studies*. doi: 10.1007/s13762-018-1970-x.
- [302] **M. F. Haniff, H. Selamat, N. Khamis, and A. J. Alimin**, “Optimized scheduling for an air-conditioning system based on indoor thermal comfort using the multi-objective improved global particle swarm optimization,” *Energy Effic*, vol. 12, no. 5, pp. 1183–1201, Jun. 2019, doi: 10.1007/s12053-018-9734-5.
- [303] **G. Rapone and O. Saro**, “Optimisation of curtain wall faades for office buildings by means of PSO algorithm,” *Energy Build*, vol. 45, pp. 189–196, Feb. 2012, doi: 10.1016/j.enbuild.2011.11.003.
- [304] **S. Mirjalili**, “Moth-flame optimization algorithm: A novel nature-inspired heuristic paradigm,” *Knowl Based Syst*, vol. 89, pp. 228–249, Nov. 2015, doi: 10.1016/j.knosys.2015.07.006.
- [305] **S. L. Zubaidi et al.**, “Hybridised artificial neural network model with slime mould algorithm: A novel methodology for prediction of urban stochastic water demand,” *Water (Switzerland)*, vol. 12, no. 10, Oct. 2020, doi: 10.3390/w12102692.

- [306] **S. Mirjalili, S. M. Mirjalili, and A. Lewis**, “Grey Wolf Optimizer,” *Advances in Engineering Software*, vol. 69, pp. 46–61, 2014, doi: 10.1016/j.advengsoft.2013.12.007.
- [307] **C. Liu, Q. Li, L. Wei, and C. Li**, “Wind power system based state estimation and measurement using weighted Grey Wolf Optimization,” *Computers and Electrical Engineering*, vol. 110, Sep. 2023, doi: 10.1016/j.compeleceng.2023.108797.
- [308] **H. Liu, Q. Yu, and Q. Wu**, “PID Control Model Based on Back Propagation Neural Network Optimized by Adversarial Learning-Based Grey Wolf Optimization,” *Applied Sciences (Switzerland)*, vol. 13, no. 8, Apr. 2023, doi: 10.3390/app13084767.
- [309] **X. Li, Q. Fu, Q. Li, W. Ding, F. Lin, and Z. Zheng**, “Multi-objective binary grey wolf optimization for feature selection based on guided mutation strategy,” *Appl Soft Comput*, vol. 145, Sep. 2023, doi: 10.1016/j.asoc.2023.110558.
- [310] **M. Ghalambaz, R. Jalilzadeh Yengejeh, and A. H. Davami**, “Building energy optimization using Grey Wolf Optimizer (GWO),” *Case Studies in Thermal Engineering*, vol. 27, Oct. 2021, doi: 10.1016/j.csite.2021.101250.
- [311] **X. D. Li, J. S. Wang, W. K. Hao, M. Wang, and M. Zhang**, “Multi-layer perceptron classification method of medical data based on biogeography-based optimization algorithm with probability distributions,” *Appl Soft Comput*, vol. 121, May 2022, doi: 10.1016/j.asoc.2022.108766.
- [312] **M. Thirunavukkarasu, Y. Sawle, and H. Lala**, “A comprehensive review on optimization of hybrid renewable energy systems using various optimization techniques,” Apr. 01, 2023, *Elsevier Ltd*. doi: 10.1016/j.rser.2023.113192.
- [313] **M. Wang et al.**, “An XGBoost-SHAP approach to quantifying morphological impact on urban flooding susceptibility,” *Ecol Indic*, vol. 156, Dec. 2023, doi: 10.1016/j.ecolind.2023.111137.
- [314] **J. Ngarambe, A. Irakoze, G. Y. Yun, and G. Kim**, “Comparative performance of machine learning algorithms in the prediction of indoor daylight illuminances,” *Sustainability (Switzerland)*, vol. 12, no. 11, Jun. 2020, doi: 10.3390/su12114471.
- [315] **Y. Bian, Y. Zhou, S. Yang, D. Lin, and Y. Ma**, “Using machine learning algorithm to predict lighting energy consumption of daylight-linked lighting systems from spatial daylight autonomy,” *Energy Build*, vol. 341, Aug. 2025, doi: 10.1016/j.enbuild.2025.115847.
- [316] **J. C. Nsangou, J. Kenfack, U. Nzotcha, P. S. Ngohe Ekam, J. Voufo, and T. T. Tamo**, “Explaining household electricity consumption using quantile regression,

- decision tree and artificial neural network,” *Energy*, vol. 250, Jul. 2022, doi: 10.1016/j.energy.2022.123856.
- [317] **R. Olu-Ajayi, H. Alaka, I. Sulaimon, F. Sunmola, and S. Ajayi**, “Building energy consumption prediction for residential buildings using deep learning and other machine learning techniques,” *Journal of Building Engineering*, vol. 45, Jan. 2022, doi: 10.1016/j.jobee.2021.103406.
- [318] **L. Ortega-Díaz, C. A. Fajardo, and G. Osma-Pinto**, “Performance of energy consumption prediction techniques in classrooms of an educational building in a warm tropical climate,” *Energy Build*, vol. 344, Oct. 2025, doi: 10.1016/j.enbuild.2025.115967.
- [319] **W. Cai, X. Wen, C. Li, J. Shao, and J. Xu**, “Predicting the energy consumption in buildings using the optimized support vector regression model,” *Energy*, vol. 273, Jun. 2023, doi: 10.1016/j.energy.2023.127188.
- [320] **S. Afzal, B. M. Ziapour, A. Shokri, H. Shakibi, and B. Sobhani**, “Building energy consumption prediction using multilayer perceptron neural network-assisted models; comparison of different optimization algorithms,” *Energy*, vol. 282, Nov. 2023, doi: 10.1016/j.energy.2023.128446.
- [321] **A. M. Fallah, E. Ghafourian, L. Shahzamani Sichani, H. Ghafourian, B. Arandian, and M. L. Nehdi**, “Novel Neural Network Optimized by Electrostatic Discharge Algorithm for Modification of Buildings Energy Performance,” *Sustainability (Switzerland)*, vol. 15, no. 4, Feb. 2023, doi: 10.3390/su15042884.
- [322] **S. Khastar, F. Bashirizadeh, J. Jafari-Asl, and N. Safaeian Hamzehkolaei**, “Predicting the cooling and heating loads of energy efficient buildings: a hybrid machine learning approach,” *Cluster Comput*, vol. 28, no. 5, Oct. 2025, doi: 10.1007/s10586-024-04993-4.
- [323] **M. R. Kaloop, F. Ahmad, P. Samui, E. Elbeltagi, J. W. Hu, and H. Wefki**, “Predicting energy consumption of residential buildings using metaheuristic-optimized artificial neural network technique in early design stage,” *Build Environ*, vol. 274, Apr. 2025, doi: 10.1016/j.buildenv.2025.112749.
- [324] **R. Wang, S. Lu, and W. Feng**, “A novel improved model for building energy consumption prediction based on model integration,” *Appl Energy*, vol. 262, Mar. 2020, doi: 10.1016/j.apenergy.2020.114561.

- [325] **R. Wang, S. Lu, and W. Feng**, “A three-stage optimization methodology for envelope design of passive house considering energy demand, thermal comfort and cost,” *Energy*, vol. 192, Feb. 2020, doi: 10.1016/j.energy.2019.116723.
- [326] **M. Gong, Y. Bai, J. Qin, J. Wang, P. Yang, and S. Wang**, “Gradient boosting machine for predicting return temperature of district heating system: A case study for residential buildings in Tianjin,” *Journal of Building Engineering*, vol. 27, Jan. 2020, doi: 10.1016/j.jobbe.2019.100950.
- [327] **L. Gao, T. Liu, T. Cao, Y. Hwang, and R. Radermacher**, “Comparing deep learning models for multi energy vectors prediction on multiple types of building,” *Appl Energy*, vol. 301, Nov. 2021, doi: 10.1016/j.apenergy.2021.117486.
- [328] **H. Guo, D. Duan, J. Yan, K. Ding, F. Xiang, and R. Peng**, “Machine Learning-Based Method for Detached Energy-Saving Residential Form Generation,” *Buildings*, vol. 12, no. 10, Oct. 2022, doi: 10.3390/buildings12101504.
- [329] **M. Zhussupbekov, S. A. Memon, S. A. Khawaja, K. Nazir, and J. Kim**, “Forecasting energy demand of PCM integrated residential buildings: A machine learning approach,” *Journal of Building Engineering*, vol. 70, Jul. 2023, doi: 10.1016/j.jobbe.2023.106335.
- [330] **S. Ngnamsie Njimbuom, K. Lee, H. Lee, and J. Kim**, “Predicting Site Energy Usage Intensity Using Machine Learning Models,” *Sensors*, vol. 23, no. 1, Jan. 2023, doi: 10.3390/s23010082.
- [331] **A. Worthy, M. Ashayeri, and N. Abbasabadi**, “Leveraging earth observational data products and machine learning to enhance urban building energy modeling (UBEM) with microclimate effects,” *Sustain Cities Soc*, vol. 130, Jul. 2025, doi: 10.1016/j.scs.2025.106544.
- [332] **H. Bazazzadeh, S. Hoseinzadeh, M. M. Mohammadi, and D. A. Garcia**, “AI-aided surrogate model for prediction of HVAC optimization strategies in future conditions in the face of climate change,” *Energy Reports*, vol. 13, pp. 1834–1845, Jun. 2025, doi: 10.1016/j.egy.2025.01.033.
- [333] **M. H. Mehraban, S. M. Sepasgozar, A. Ghomimoghadam, and B. Zafari**, “AI-enhanced automation of building energy optimization using a hybrid stacked model and genetic algorithms: Experiments with seven machine learning techniques and a deep neural network,” *Results in Engineering*, vol. 26, Jun. 2025, doi: 10.1016/j.rineng.2025.104994.

- [334] **S. G. Kangalli Uyar, B. K. Ozbay, and B. Dal**, “Interpretable building energy performance prediction using XGBoost Quantile Regression,” *Energy Build*, vol. 340, Aug. 2025, doi: 10.1016/j.enbuild.2025.115815.
- [335] **M. Fellah, S. Ouhaibi, N. Belouaggadia, and K. Mansouri**, “Harnessing machine learning for enhanced thermal insulation and energy efficiency in buildings worldwide,” *Results in Engineering*, vol. 25, Mar. 2025, doi: 10.1016/j.rineng.2025.104086.
- [336] **Y. Zhang, E. Li, J. Gu, K. Du, and J. Zhou**, “Residential building cooling load prediction with optimized KELM models and interpretability insights,” *Appl Therm Eng*, vol. 272, Aug. 2025, doi: 10.1016/j.applthermaleng.2025.126421.
- [337] **J. S. Chou and D. K. Bui**, “Modeling heating and cooling loads by artificial intelligence for energy-efficient building design,” *Energy Build*, vol. 82, pp. 437–446, 2014, doi: 10.1016/j.enbuild.2014.07.036.
- [338] **M. A. Mat Daut, M. Y. Hassan, H. Abdullah, H. A. Rahman, M. P. Abdullah, and F. Hussin**, “Building electrical energy consumption forecasting analysis using conventional and artificial intelligence methods: A review,” 2017, *Elsevier Ltd*. doi: 10.1016/j.rser.2016.12.015.
- [339] **A. S. Ahmad et al.**, “A review on applications of ANN and SVM for building electrical energy consumption forecasting,” 2014, *Elsevier Ltd*. doi: 10.1016/j.rser.2014.01.069.
- [340] **R. Chen, Y. S. Tsay, and S. Ni**, “An integrated framework for multi-objective optimization of building performance: Carbon emissions, thermal comfort, and global cost,” *J Clean Prod*, vol. 359, Jul. 2022, doi: 10.1016/j.jclepro.2022.131978.
- [341] **B. Kubwimana and H. Najafi**, “A Novel Approach for Optimizing Building Energy Models Using Machine Learning Algorithms,” *Energies (Basel)*, vol. 16, no. 3, Feb. 2023, doi: 10.3390/en16031033.
- [342] **G. Shi, S. Yao, J. Song, W. Bi, G. Qin, and P. Ni**, “Multi-performance collaborative optimization of existing residential building retrofitting in extremely arid and hot climate zone: A case study in Turpan, China,” *Journal of Building Engineering*, vol. 89, Jul. 2024, doi: 10.1016/j.jobe.2024.109304.
- [343] **D. A. Van Veldhuizen**, “Multiobjective evolutionary algorithms: classifications, analyses, and new innovations,” 1999.

- [344] **C. A. C. Coello and M. R. Sierra**, “A Study of the Parallelization of a Coevolutionary Multi-objective Evolutionary Algorithm,” in *Advances in Artificial Intelligence*, 2004, pp. 688–697. doi: [https://doi.org/10.1007/978-3-540-24694-7\\_71](https://doi.org/10.1007/978-3-540-24694-7_71).
- [345] **E. Zitzler, L. Thiele, M. Laumanns, C. M. Fonseca, and V. G. Da Fonseca**, “Performance assessment of multiobjective optimizers: An analysis and review,” Apr. 2003. doi: 10.1109/TEVC.2003.810758.
- [346] **O. R. Adegboye and E. Deniz Ülker**, “Hybrid artificial electric field employing cuckoo search algorithm with refraction learning for engineering optimization problems,” *Sci Rep*, vol. 13, no. 1, Dec. 2023, doi: 10.1038/s41598-023-31081-1.
- [347] **Y. Zhang, G. Chen, L. Cheng, Q. Wang, and Q. Li**, “Methods to balance the exploration and exploitation in Differential Evolution from different scales: A survey,” *Neurocomputing*, vol. 561, Dec. 2023, doi: 10.1016/j.neucom.2023.126899.

Derece	Okul/Program	Yıl
Doktora	Balıkesir Üniversitesi/ Mimarlık Bölümü	2025
Y. Lisans	Balıkesir Üniversitesi/ Mimarlık Bölümü	2021
Lisans	Balıkesir Üniversitesi/ Mimarlık Bölümü	2019
Lise	Batman Mevlana Anadolu Lisesi	2014

### Yayın Listesi

- [1] **R. Özlük, F. Aydın, and Y. Yıldız**, “Artificial intelligence algorithms, simulation tools and software for optimization of adaptive facades: A systematic literature review,” Jul. 15, 2025, *Elsevier Ltd.* doi: 10.1016/j.job.2025.112566. [**Tezden türetilmiştir**]
- [2] **R. Özlük, T. Göksal Özbalta, and K. Güngör**, “Assessment of student thermal comfort perception of spaces in education building with different ventilation strategies after COVID-19,” *Journal of Thermal Engineering*, vol. 11, no. 3, pp. 623–642, 2025, doi: 10.14744/thermal.0000935.
- [3] **R. Özlük and Y. Yıldız**, “Analyzing occupancy density with directional effect to optimize energy consumption in a university building using the response surface method,” *Journal of the Faculty of Engineering and Architecture of Gazi University*, vol. 40, no. 2, pp. 1059–1072, Feb. 2025, doi: 10.17341/gazimmfd.1455889.
- [4] **T. Çivici and R. Özlük**, “Potential Barriers to Sustainable Construction: A Model Proposal,” *Journal of Sustainable Construction Materials and Technologies*, vol. 5, no. 2, pp. 440–449, Oct. 2020, doi: 10.29187/jscmt.2020.48.
- [5] **“Resul özlük” and “Yusuf Yıldız,”** “Thermal Comfort and Daylight Performance of Kinetic Facade Elements: A MultiObjective Optimization Approach,” in *XIV.International Sinan Symposium*, Edirne, Apr. 2025, pp. 663–670.

- [6] **“Resul Özlük,” “Yusuf Yıldız,” and “Türkan Göksal Özbalta,”** “Taguchi tabanlı yanıt yüzey yöntemi kullanılarak enerji verimliliği ve ısı konforun optimize edilmesi: çok amaçlı optimizasyon yaklaşımı,” *4. Ulusal yapı fiziği ve çevre kontrolü kongresi*, İstanbul, Şubat. 2024.
- [7] **“Mustafa Serhan Ünlütürk” and “Resul Özlük,”** “Modern Ofis Tasarımının Günışığı Performansı Bağlamında Değerlendirilmesi: Mustafa Bey İş Merkezi Örneği,” in *Mimarlık Alanında Araştırmalar ve Değerlendirmeler*, vol. 1, Ankara: Gece Kitaplığı, 2025, pp. 135–150.