



BALIKESİR, TEMMUZ- 2026

ETİK BEYAN

Balıkesir Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak tarafımda hazırlanan “**Kamu Binalarında Hvac Sistemlerinde Enerji Verimliliği ve Optimizasyonu**” başlıklı tezde;

- Tüm bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- Kullanılan veriler ve sonuçlarda herhangi bir değişiklik 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.

Koray SANDAL

ÖZET

KAMU BİNALARINDA HVAC SİSTEMLERİNDE ENERJİ VERİMLİLİĞİ VE OPTİMİZASYONU

DOKTORA TEZİ

KORAY SANDAL

BALIKESİR ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ

MAKİNA MÜHENDİSLİĞİ ANABİLİM DALI

(TEZ DANIŞMANI: PROF. DR. NADİR İLTEN)

BALIKESİR, TEMMUZ - 2026

Bu çalışmada amaç, Balıkesir Büyükşehir Belediyesi Fen İşleri Dairesi Başkanlığı hizmet binasındaki Isıtma, Havalandırma ve İklimlendirme (HVAC) sistemlerinin enerji tüketimini, konfor optimizasyonu stratejilerinden yararlanarak tahmin etmektir. Çalışanlara uygulanan eşzamanlı ısı konfor anketleri ve cihaz ölçümleri ile gerçek memnuniyetsizlik düzeyleri (APD) belirlenmiş ve bu sonuçlar dikkate alınarak dinamik mevsimsel ısı konfor bantları hesaplanmıştır. Bina, DesignBuilder yazılımında modellenip gerçek fatura verileriyle kalibre edilmiştir. Doğrulan bu dijital ikiz üzerinde yürütülen fiziksel simülasyon senaryolarında; %90 kazan verimi ve 4,5 COP değerinin eşzamanlı uygulandığı durumda toplam enerji tüketiminde yüksek düzeyde makro tasarruf potansiyeli saptanmıştır. Söz konusu optimizasyon stratejileri kapsamında bina kazan verimi, soğutma performans katsayısı (COP), hava değişim oranı (ACH) ve iç ortam sıcaklık ayar noktaları dikkate alınarak Waikato Environment for Knowledge Analysis (WEKA) platformu üzerinde çok boyutlu veri setleri üretilmiş; Çok Katmanlı Algılayıcı (MLP) ve Destek Vektör Regresyonu (SMOreg) algoritmalarıyla öğrenme modelleri oluşturulmuştur. Sonuç olarak; hesaplanan hata metrikleri karşılaştırıldığında, toplam enerji tüketimi tahmininde SMOreg algoritmasının 2,4414 ortalama mutlak hata (MAE) ve 4,6326 kök ortalama kare hata (RMSE) ile MLP ağlarından daha kararlı sonuçlar verdiği kanıtlanmıştır.

ANAHTAR KELİMELER: Bina enerji simülasyonu, çok katmanlı algılayıcı, destek vektör regresyonu, enerji verimliliği, hvac optimizasyonu, ısı konfor, makine öğrenmesi.

ABSTRACT

ENERGY EFFICIENCY AND OPTIMIZATION IN HVAC SYSTEMS OF PUBLIC BUILDINGS

PH.D THESIS

KORAY SANDAL

BALIKESİR UNIVERSITY INSTITUTE OF SCIENCE

MECHANICAL ENGINEERING

(SUPERVISOR: PROF. DR. NADİR İLTEN)

BALIKESİR, JULY - 2026

The aim of this study is to predict the energy consumption of the Heating, Ventilation, and Air Conditioning (HVAC) systems in the service building of the Department of Public Works of Balıkesir Metropolitan Municipality by using comfort optimization strategies. Actual Percentage of Dissatisfied (APD) values were determined through simultaneous thermal comfort surveys and instrumental measurements conducted with building occupants, and dynamic seasonal thermal comfort bands were calculated based on these results. The building was modeled in the DesignBuilder software and calibrated using actual billing data. In the physical simulation scenarios conducted on this validated digital twin, a high-level macro saving potential in total energy consumption was determined when 90% boiler efficiency and a COP value of 4.5 were applied simultaneously. Multidimensional datasets were generated on the Waikato Environment for Knowledge Analysis (WEKA) platform based on these optimization strategies, considering boiler efficiency (0.70–0.95), cooling coefficient of performance (COP 2.5–4.0), air change rate (ACH 0.7–3.0), and indoor temperature setpoints (22–24 °C), and learning models were developed using Multilayer Perceptron (MLP) and Support Vector Regression (SMOreg) algorithms. As a result, comparing the calculated error metrics proved that the SMOreg algorithm yielded more stable results than MLP networks in predicting total energy consumption, with a Mean Absolute Error (MAE) of 2.4414 and a Root Mean Square Error (RMSE) of 4.6326.

KEYWORDS: Building energy simulation, multilayer perceptron, support vector regression, energy efficiency, hvac optimization, thermal comfort, machine learning.

İÇİNDEKİLER

Sayfa

ÖZET	i
İÇİNDEKİLER	iii
ŞEKİL LİSTESİ.....	v
TABLO LİSTESİ.....	vii
SEMBOL VE KISALTMALAR LİSTESİ	ix
ÖNSÖZ VE TEŞEKKÜR	xi
1. GİRİŞ	1
1.1 Isıl Konfor ve Değerlendirme Parametreleri	2
1.2 Isıl Konforun Değerlendirilmesi Yaklaşımları	3
1.3 Isıl Konforun Bina Enerji Yönetim Sistemleri ile İlişkisi	5
1.4 Isıl Konforu Etkileyen Faktörler.....	6
1.5 Binalarda Hvac Sistemleri ve Kontrol Yöntemleri.....	7
1.6 HVAC Sistemlerinin İşlevleri ve Temel Bileşenleri	8
1.7 Geleneksel ve Akıllı HVAC Kontrol Stratejileri	9
1.8 Literatür Özeti.....	10
2. MATERYAL VE YÖNTEM.....	20
2.1 Binanın Yapısal ve Mimari Özellikleri.....	20
2.2 Duvarlar	22
2.3 Pencereleler	25
2.4 İç Ortam Yük Profilleri ve Kullanım Senaryoları.....	26
2.5 İç Ortam Parametrelerinin Ölçümü ve Ölçüm Cihazı (Testo-480).....	28
2.6 İç Ortam Parametreleri ve Isıl Konfor Üzerindeki Etkileri	30
2.7 Isıl Konfor Saha Anketi Çalışmaları.....	32
2.7.1 Saha Anketinin Birinci Bölümü (Demografik ve Kişisel Veriler)	32
2.7.2 Saha Anketinin İkinci Bölümü (Bağlamsal Faktörler, Giyim Yalıtımı ve Metabolik Hız)..	33
2.7.3 Saha Anketinin Üçüncü Bölümü (Subjektif Değerlendirme ve Algı Endeksleri)	34
2.8 Bina Enerji Simülasyonunun Temel Prensipleri ve DesignBuilder Arayüzü	35
2.9 Dinamik Bina Enerji Modellenmesi: Modelleme ve Yapısal Özelliklerin İşlenmesi.....	38
2.10 Dinamik Bina Enerji Modellenmesi Model Kalibrasyonu ve Dijital İkiz	39
2.11 Optimizasyon Çalışmaları: Giriş	41
2.12 Optimizasyon Çalışmaları: Makine Öğrenmesi, WEKA, SMOreg ve MLP	42
2.13 Optimizasyon Çalışmaları: Problemin Tanımlanması	43
3. BULGULAR VE ANALİZ SONUÇLARI.....	45
3.1 Isıl Konfor Bulgularının Mevsimsel Analizi	45
3.2 Isıtma Dönemi (Kış) Isıl Konfor Bulguları.....	46

İÇİNDEKİLER (devam)

3.3 Soğutma Dönemi (Yaz) Isıl Konfor Bulguları	48
3.4 Geçiş Dönemleri (İlkbahar ve Sonbahar) Isıl Konfor Bulguları.....	50
3.5 Kişisel Faktörlerin Subjektif Isıl Konfor Algısına Etkisi	52
3.6 Cinsiyet Faktörünün Termal Algı Üzerindeki Etkisi	53
3.7 Yaş Faktörünün Termal Algı Üzerindeki Etkisi	55
3.8 Giyim Yalıtımı ve Davranışsal Adaptasyonun Isıl Konfor Algısına Etkisi.....	56
3.9 Metabolik Hızın Isıl Konfora Etkisi	57
3.10 Standart Konfor Modelleri ile Saha Algısı Arasındaki Farklılıklar	58
3.11 HVAC Enerji Verimliliği İyileştirme ve Optimizasyon Senaryoları.....	61
3.12 Isıtma Sistemi (Kazan) Verimlilik Senaryoları ve Enerji Tüketim Analizi.....	61
3.13 Soğutma Sistemi (Chiller COP) İyileştirme Senaryoları ve Enerji Tüketim Analizi	64
3.14 Havalandırma, ACH ve Fan Enerjisi İyileştirme Senaryoları	66
3.15 Sıcaklık Set Değerleri ve HVAC Enerji İyileştirme Senaryoları.....	67
3.16 Birleşik HVAC İyileştirme Senaryoları ve Sistemler Arası Etkileşim	68
3.17 Soğutma Enerjisi Tahmininde SMOREg ve MLP Modellerinin Karşılaştırılması.....	69
3.18 Isıtma Enerjisi Tahmininde SMOREg ve MLP Modellerinin Karşılaştırılması.....	79
3.19 Toplam Enerji Tüketimi Tahmininde SMOREg ve MLP Modellerinin Karşılaştırılması	90
3.20 SMOREg ve MLP Modellerinin Genel Performans Karşılaştırması.....	100
4. SONUÇLAR VE TARTIŞMA.....	107
5. KAYNAKLAR	110
EKLER.....	124
EK A: Termal Konfor Ölçüm Anketi	125
ETİK KURUL İZİN BELGESİ.....	126
ÖZGEÇMİŞ	Hata! Yer işareti tanımlanmamış.

ŞEKİL LİSTESİ

Sayfa

Şekil 2.1: Çalışma yapılan bina dış cephe	21
Şekil 2.2: Bina kat mimari görüntüsü	22
Şekil 2.3: Bina dış cephe pencere görüntüsü	26
Şekil 2.4: İkinci kat mimari plan görüntüsü	27
Şekil 2.5: Testo 480 ölçüm cihazı.....	28
Şekil 2.6: Saha ölçüm çalışmaları.....	30
Şekil 2.7: Designbuilder programı ekran görüntüsü	36
Şekil 2.8: Design builder programı model görüntüsü.....	37
Şekil 3.1: Kış döneminde giysi yalıtımının algı ve memnuniyete etkisi	53
Şekil 3.2: Cinsiyete göre mevsimsel memnuniyetsizlik analizi	54
Şekil 3.3: Mevsimsel termal duyum karşılaştırması	59
Şekil 3.4: Mevsimsel termal memnuniyetsizlik karşılaştırması	60
Şekil 3.5: Kazan modernizasyonu tasarruf potansiyeli.....	63
Şekil 3.6: Kazan verimine göre mevsimsel doğalgaz tüketimi değişimi	63
Şekil 3.7: COP değişimine bağlı soğutma enerjisi tüketimi	65
Şekil 3.8: COP değişiminin toplam enerji tüketimine etkisi	66
Şekil 3.9: Birleşik HVAC mekanik optimizasyon senaryoları	69
Şekil 3.10: Soğutma enerjisi tahmini için SMOREg modelinde eğitim verisinde gerçek ve tahmini değerlerin karşılaştırılması	74
Şekil 3.11: Soğutma enerjisi tahmini için SMOREg modeli eğitim verisi hata dağılımı	74
Şekil 3.12: Soğutma enerjisi tahmini için SMOREg test verisinde gerçek ve tahmini değerlerin karşılaştırılması	75
Şekil 3.13: Soğutma enerjisi tahmini için SMOREg test verisinde hata dağılımı	75
Şekil 3.14: Soğutma enerjisi tahmini için MLP modelinde eğitim verisi gerçek ve tahmini değerlerin karşılaştırılması	77
Şekil 3.15: Soğutma enerjisi tahmini için MLP modelinde eğitim verisi hata dağılımı.....	77
Şekil 3.16: Soğutma enerjisi tahmini için MLP modelinde test verisi gerçek ve tahmini değer dağılımı	78
Şekil 3.17: Soğutma enerjisi tahmini için MLP modelinde test verisi hata dağılımı	79
Şekil 3.18: Isıtma enerjisi tahmini için SMOREg modeli eğitim verisinde gerçek ve tahmini değerlerin karşılaştırılması	84
Şekil 3.19: Isıtma enerjisi tahmini için eğitim SMOREg modeli verisi hata dağılımı	84
Şekil 3.20: Isıtma enerjisi tahmini için SMOREg modeli test verisinde gerçek ve tahmini değerlerin karşılaştırılması	85
Şekil 3.21: Isıtma enerjisi tahmini için SMOREg modeli test verisi hata dağılımı.....	86
Şekil 3.22: Isıtma enerjisi tahmini için MLP modelinde eğitim verisi gerçek ve tahmini değer dağılımı	88
Şekil 3.23: Isıtma enerjisi tahmini için MLP modelinde eğitim verisi hata dağılımı	88
Şekil 3.24: Isıtma enerjisi tahmini için MLP modelinde test verisi gerçek ve tahmini değer dağılımı	89
Şekil 3.25: Isıtma enerjisi tahmini için MLP modelinde test verisi hata dağılımı.....	89
Şekil 3.26: Toplam enerji tüketimi tahmini için SMOREg modeli eğitim verisinde gerçek ve tahmini değerlerin karşılaştırılması	95
Şekil 3.27: Toplam enerji tüketimi tahmini için SMOREg modeli eğitim verisi hata dağılımı.....	95

ŞEKİL LİSTESİ (devam)

Sayfa

Şekil 3.28: Toplam enerji tüketimi tahmini için SMOreg modeli test verisinde gerçek ve tahmini değerlerin karşılaştırılması	96
Şekil 3.29: Toplam enerji tüketimi tahmini için SMOreg modeli test verisi hata dağılımı.	96
Şekil 3.30: Toplam enerji tüketimi tahmini için MLP modelinde eğitim verisi gerçek ve tahmini değer dağılımı.....	98
Şekil 3.31: Toplam enerji tüketimi tahmini için MLP modelinde eğitim verisi hata dağılımı.....	98
Şekil 3.32: Toplam enerji tüketimi tahmini için MLP modelinde test verisi gerçek ve tahmini değer dağılımı.....	99
Şekil 3.33: Toplam enerji tüketimi tahmini için MLP modelinde test verisi hata dağılımı.....	100
Şekil 3.34: Enerji tüketimi tahminlerinde SMOreg ve MLP modellerinin hata ölçütlerine göre karşılaştırılması	102
Şekil 3.35: Toplam enerji tüketimi tahmininde SMOreg ve MLP modellerinin eğitim ve test hata değerleri.....	103
Şekil 3.36: Isıtma enerjisi tüketimi tahmininde SMOreg ve MLP modellerinin eğitim ve test hata değerleri.....	104
Şekil 3.37: Soğutma enerjisi tüketimi tahmininde SMOreg ve MLP modellerinin eğitim ve test hata değerleri.....	105

TABLO LİSTESİ

Sayfa

Tablo 1.1: Isıl duyum skalası ölçeği.....	3
Tablo 2.1: Dış havaya açık duvar ve özellikleri	23
Tablo 2.2: Tavan üzeri açık duvar ve özellikleri	24
Tablo 2.3: Taban toprak temaslı yapısı ve özellikleri	25
Tablo 2.4: Testo-480 cihaz özellikleri.....	29
Tablo 2.5: Isıl duyum ölçeği yapısal dağılımı ve sayısal karşılıkları	35
Tablo 2.6: Bina kabuğu yapı elemanlarının ısıl özellikleri ve u değerleri	39
Tablo 2.7: Bina enerji modeli kalibrasyon sonuçları	40
Tablo 2.8: Karar Değişkenleri	44
Tablo 3.1: Mevsimsel iç ortam parametreleri ve PMV/PPD değerleri	46
Tablo 3.2: Kış döneminde ölçüm ve kullanıcı algısına dayalı ısıl konfor göstergeleri	48
Tablo 3.3: Yaz döneminde ölçüm ve kullanıcı algısına dayalı ısıl konfor göstergeleri	50
Tablo 3.4: İlkbahar döneminde ölçüm ve kullanıcı algısına dayalı ısıl konfor göstergeleri	51
Tablo 3.5: Sonbahar döneminde ölçüm ve kullanıcı algısına dayalı ısıl konfor göstergeleri	52
Tablo 3.6: Mevsimlere göre kabul edilen PMV aralıkları.....	60
Tablo 3.7: Soğutma enerjisi tahmini için SMOreg modelinde çekirdek fonksiyonlarının performans karşılaştırması	70
Tablo 3.8: Soğutma enerjisi tahmini için PUK çekirdekli SMOreg modelinde C hiperparametresinin performansa etkisi	71
Tablo 3.9: Soğutma enerjisi tahmini için PUK çekirdekli SMOreg modelinde sigma hiperparametresinin performansa etkisi	72
Tablo 3.10: Soğutma enerjisi tahmini için PUK çekirdekli SMOreg modelinde omega hiperparametresinin performansa etkisi	72
Tablo 3.11: Soğutma enerjisi tahmini için PUK çekirdekli SMOreg modelinde epsilon hiperparametresinin performansa etkisi	73
Tablo 3.12: Soğutma enerjisi tahmini için MLP ağ yapılarının performans karşılaştırması.....	76
Tablo 3.13: Isıtma enerjisi tahmini için SMOreg modelinde çekirdek fonksiyonlarının performans karşılaştırması	80
Tablo 3.14: Isıtma enerjisi tahmini için PUK çekirdekli SMOreg modelinde C hiperparametresinin performansa etkisi	81
Tablo 3.15: Isıtma enerjisi tahmini için PUK çekirdekli SMOreg modelinde sigma hiperparametresinin performansa etkisi	82
Tablo 3.16: Isıtma enerjisi tahmini için PUK çekirdekli SMOreg modelinde omega hiperparametresinin performansa etkisi	82
Tablo 3.17: Isıtma enerjisi tahmini için PUK çekirdekli SMOreg modelinde epsilon hiperparametresinin performansa etkisi	83
Tablo 3.18: Isıtma enerjisi tahmini için MLP ağ yapılarının performans karşılaştırması ...	87
Tablo 3.19: Toplam enerji tüketimi tahmini için SMOreg modelinde çekirdek fonksiyonlarının performans karşılaştırması	91
Tablo 3.20: Toplam enerji tüketimi tahmini için PUK çekirdekli SMOreg modelinde C hiperparametresinin performansa etkisi	92

TABLO LİSTESİ (devam)

Sayfa

Tablo 3.21: Toplam enerji tüketimi tahmini için PUK çekirdekli SMOREG modelinde sigma hiperparametresinin performansa etkisi.....	93
Tablo 3.22: Toplam enerji tüketimi tahmini için PUK çekirdekli SMOREG modelinde omega hiperparametresinin performansa etkisi.....	93
Tablo 3.23: Toplam enerji tüketimi tahmini için PUK çekirdekli SMOREG modelinde epsilon hiperparametresinin performansa etkisi.....	94
Tablo 3.24: Toplam enerji tüketimi tahmini için MLP ağ yapılarının performans karşılaştırması.....	97
Tablo 3.25: SVM/SMOREG ve MLP modellerinin tahmin parametrelerine göre eğitim verisi ve test verisi hata değerlerinin karşılaştırılması	101
Tablo 3.26: Toplam enerji tüketimi tahmini için SVM/SMOREG ve MLP modellerinin hata ölçütleri	103
Tablo 3.27: Isıtma enerjisi tüketimi tahmini için SVM/SMOREG ve MLP modellerinin hata ölçütleri	104
Tablo 3.28: Soğutma enerjisi tüketimi tahmini için SVM/SMOREG ve MLP modellerinin hata ölçütleri.....	105

SEMBOL VE KISALTMALAR LİSTESİ

A	: Alan (m ²)
ACH	: Saatlik hava değişim sayısı (Air Changes per Hour)
AHU	: Klima santrali / hava işleme ünitesi (Air Handling Unit)
AMV	: Gerçek Ortalama Oy (Actual Mean Vote)
ANN	: Yapay Sinir Ağı (Artificial Neural Network)
ARFF	: Özellik-İlişki Dosya Formatı (Attribute-Relation File Format)
ASHRAE	: Amerikan Isıtma, Soğutma ve İklimlendirme Mühendisleri Derneği (American Society of Heating, Refrigerating and Air-Conditioning Engineers)
BEMS	: Bina Enerji Yönetim Sistemleri (Building Energy Management Systems)
BEP	: Bina Enerji Performansı
C	: SMOreg düzenleme (ceza) hiperparametresi
COP	: Performans katsayısı (Coefficient of Performance)
CSV	: Virgülle Ayrılmış Değerler (Comma-Separated Values)
CV(RMSE)	: Kök Ortalama Kare Hatasının Değişim Katsayısı (Coefficient of Variation of the Root Mean Square Error)
DB	: DesignBuilder
DVM	: Dijital Veri Modeli
E	: Enerji tüketimi (kWh)
Ecool	: Soğutma enerjisi tüketimi (kWh)
Efan	: Fan enerji tüketimi (kWh)
Eheat	: Isıtma enerjisi tüketimi (kWh)
Epump	: Pompa enerji tüketimi (kWh)
EPW	: EnergyPlus Hava Durumu Dosyası (EnergyPlus Weather File)
Et	: Toplam enerji tüketimi (kWh)
HVAC	: Isıtma, Havalandırma ve Klima (Heating, Ventilation and Air Conditioning)
Icl	: Giysi ısı direnci (clo)
IoT	: Nesnelerin İnterneti (Internet of Things)
ISO	: Uluslararası Standardizasyon Örgütü (International Organization for Standardization)
M	: Metabolik aktivite düzeyi (met)
MAE	: Ortalama Mutlak Hata (Mean Absolute Error)
MAPE	: Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error)
MBE	: Ortalama Yanlılık Hatası (Mean Bias Error)
ML	: Makine Öğrenmesi (Machine Learning)
MLP	: Çok Katmanlı Algılayıcı (Multilayer Perceptron)
MSE	: Ortalama Kare Hatası (Mean Squared Error)
n	: Veri sayısı
NSGA-II	: Sıralamasız Baskın Genetik Algoritma II (Non-dominated Sorting Genetic Algorithm II)
P	: Güç
PID	: Oransal-İntegral-Türevsel Denetleyici (Proportional-Integral-Derivative)
PMV	: Tahmini Ortalama Oy (Predicted Mean Vote)
PPD	: Memnuniyetsizlerin Tahmini Yüzdesi (Predicted Percentage of Dissatisfied)
R²	: Determinasyon katsayısı
RH	: Bağıl nem (%)

SEMBOL VE KISALTMA LİSTESİ (devam)

RMSE	: Kök Ortalama Kare Hatası (Root Mean Square Error)
SET	: Standart Etkin Sıcaklık (Standard Effective Temperature)
SMOreg	: Sıralı Minimal Optimizasyon Regresyonu (Sequential Minimal Optimization Regression)
T	: Sıcaklık (°C)
Ta	: İç ortam hava sıcaklığı (°C)
Top	: Operatif sıcaklık (°C)
Tout	: Dış ortam hava sıcaklığı (°C)
Tr	: Ortalama ışıınım sıcaklığı (°C)
Tset	: Sıcaklık ayar noktası (°C)
Tset,c	: Soğutma sıcaklık ayar noktası (°C)
Tset,h	: Isıtma sıcaklık ayar noktası (°C)
TSV	: Termal Duyum Oyu (Thermal Sensation Vote)
V	: Hacim (m ³)
Va	: Hava hızı (m/s)
VAV	: Değişken Hava Hacimli Sistemler (Variable Air Volume)
WEKA	: Waikato Bilgi Analizi Ortamı (Waikato Environment for Knowledge Analysis)
η	: Verim
ηk	: Kazan verimi

ÖNSÖZ VE TEŞEKKÜR

Başta, tez çalışmam süresince değerli bilgi birikimi, yönlendirmeleri ve katkılarıyla bana rehberlik eden tez danışman hocam Prof. Dr. Nadir İLTEN'e derin saygı ve teşekkürlerimi sunarım. Ayrıca, çalışmam boyunca engin vizyonu, akademik tecrübesi ve yol gösterici desteğiyle katkılarını esirgemeyen Doç. Dr. İsmail CANER'e; analiz sürecindeki değerli yardım ve katkılarından dolayı Doç. Dr. Oğuzhan PEKTEZEL'e gönülden teşekkür ederim. Tez izleme komitemde yer alarak çalışmama değerli görüş ve önerileriyle katkı sağlayan Prof. Dr. Yusuf YILDIZ'a ve Dr. Öğr. Üyesi Veli Gökhan DEMİR'e teşekkür ederim. Eğitim hayatım boyunca bilgi ve tecrübeleriyle gelişimime katkı sağlayan tüm hocalarıma da saygı ve teşekkürlerimi sunarım.

Tez çalışmamın yürütülmesi sürecinde gerekli kolaylıkları sağlayan Balıkesir Büyükşehir Belediyesi'ne ve çalışma sürecinde desteklerini esirgemeyen değerli çalışma arkadaşlarıma teşekkür ederim.

Çalışma sürecinde karşılaştığım tüm zorluklarda yanımda olan, sabrı, desteği ve anlayışıyla bana güç veren sevgili eşim Kübra SANDAL'a; moral ve motivasyon kaynağım olan Uzun Kayra SANDAL ve Uzun Kutay SANDAL'a en içten teşekkürlerimi sunarım.

Beni bugünlere getiren aileme ve hayatım boyunca üzerimde emeği bulunan herkese içtenlikle teşekkür ederim.

Balıkesir, 2026

Koray Sandal

1. GİRİŞ

Binalarda enerji tüketiminin önemli bir bölümü ısıtma, soğutma, havalandırma ve iç ortam koşullarının sürdürülmesi için harcanmaktadır. Ticari ve kamu binalarında toplam enerji tüketiminin neredeyse yarısının Isıtma, Havalandırma ve İklimlendirme sistemlerinden kaynaklandığı belirtilmiştir (Shamsi et al., 2020; Yu et al., 2021). Bu nedenle HVAC sistemleri, kamu binalarında enerji verimliliği çalışmalarının temel bileşenlerinden biri olarak ele alınmaktadır. Bu sistemler yalnızca enerji tüketen mekanik donanımlar değil; aynı zamanda kullanıcıların ısı konforunu ve iç hava kalitesini doğrudan etkileyen yapılar olduğu belirtilmiştir (Jiang et al., 2024; Tuğal, 2025).

Kamu binalarında HVAC sistemlerinden beklenen temel işlev, kabul edilebilir iç ortam koşullarının sağlanması ve enerji tüketiminin azaltılması olarak bilinmektedir. Ancak enerji tasarrufu ile kullanıcı konforunun her zaman aynı yönde gelişmediği görülmektedir. Bina enerji tüketiminin azaltılması ile çevresel konforun artırılması, literatürde birbiriyle rekabet eden değişkenler olarak tanımlanmaktadır (Han et al., 2025; Jun and Fei, 2024). Bu nedenle kamu binalarında HVAC optimizasyonu, yalnızca enerji tüketiminin düşürülmesiyle değil, kullanıcı konforunun korunmasıyla birlikte değerlendirilmelidir.

Geleneksel HVAC kontrol yöntemlerinin manuel müdahalelere, sabit sıcaklık ayar noktalarına ve zaman çizelgelerine dayandığı belirtilmiştir (Jiang et al., 2024; Dey and Henze, 2024; Macarulla et al., 2017). Bu yaklaşımlar uygulanabilir olmakla birlikte, dış ortam koşullarındaki değişimleri, doluluk oranlarını ve kullanıcı beklentilerindeki farklılıkları her durumda karşılayamamaktadır. Uygun olmayan statik kontrol stratejileri, sensör arızaları, zayıf sistem tasarımı ve ekipman performans kayıpları nedeniyle HVAC sistemlerinde enerji israf edilebildiği rapor edilmiştir (Zhang et al., 2019). Bu durum, kamu binalarında enerji yönetiminin yalnızca ekipman verimliliğine değil, işletme ve kontrol stratejilerine de bağlı olduğunu göstermektedir.

Son yıllarda model öngörülü kontrol, adaptif kontrol, yapay sinir ağları ve makine öğrenmesi tabanlı yöntemlerin HVAC sistemlerinde enerji tasarrufu ve konfor dengesini geliştirmek amacıyla kullanıldığı belirtilmiştir (Afram and Janabi-Sharifi, 2017; Moon and Han, 2012; Tuğal, 2025; Villano et al., 2024). Bu tez çalışmasında, kamu binalarında HVAC sistemlerinin

enerji verimliliği ve optimizasyonu ele alınmış; enerji tüketimi ile kullanıcı konforu arasındaki dengenin değerlendirilmesi amaçlanmıştır.

1.1 Isıl Konfor ve Değerlendirme Parametreleri

Isıl konfor, bireyin bulunduğu termal çevreden duyduğu memnuniyet durumu olarak tanımlanmıştır (Fanger, 1970; ASHRAE, 2023). Bu durum; hava sıcaklığı, bağıl nem, radyasyon ısı ve hava hareketleri gibi çevresel değişkenlerden etkilenmektedir. Ancak ısı konfor yalnızca ölçülen fiziksel değerlerle açıklanamamaktadır. Kullanıcıların ortamı nasıl algıladığı ve bu koşullardan ne düzeyde memnun olduğu da değerlendirme sürecine dahil edilmelidir (Caner and İlten, 2020; Jiang et al., 2024).

Kamu binaları ve ofislerde iç ortam koşulları, çalışanların konforu ve çalışma verimliliği üzerinde doğrudan etkili olduğu ayrıca uygun olmayan sıcaklık koşullarının yorgunluk, dikkat azalması ve kullanıcı memnuniyetsizliği ile ilişkili olduğu belirtilmiştir (Lakhiar et al., 2024). Bu nedenle kamu binalarında ısı konfor, yalnızca sıcaklık değerleri üzerinden değil; kullanıcı algısı, iç hava kalitesi ve çalışma koşullarıyla birlikte değerlendirilmelidir.

Modern binalarda iç ortam koşullarının sağlanmasın büyük ölçüde HVAC sistemlerine bağlı olduğundan kullanıcıların ısı konforu ve iç hava kalitesi bu sistemlerden düzenlenmektedir. Bu yüzden bina enerji tüketiminde yüksek paya sahiptirler(Jiang et al., 2024; Shin et al., 2024). Bu nedenle HVAC sistemleri, kamu binalarında hem konfor hem de enerji verimliliği açısından temel bir inceleme alanı olarak ele alınmaktadır.

HVAC sistemlerinde enerji tüketiminin azaltılması ile kullanıcı konforunun korunması her zaman aynı anda kolay sağlanamamaktadır. Enerji tasarrufu hedeflendiğinde iç ortam koşullarında bozulma oluşabilmekte; konfor koşulları artırıldığında ise enerji tüketimi yükselmektedir (Jun and Fei, 2024).

Enerji tüketimi, iç hava kalitesi ve kullanıcı konforu birlikte ele alındığında, sistemlerin daha kontrollü ve verimli işletilmesi mümkün hale gelebilmektedir. Gelişmiş optimizasyon yaklaşımlarının enerji tüketimi ile kullanıcı memnuniyeti gibi farklı hedefleri aynı değerlendirme içinde dengelemek amacıyla kullanıldığı belirtilmiştir (Li et al., 2026). Bu çerçevede kamu binalarında HVAC enerji verimliliği, yalnızca tüketimi azaltmaya yönelik bir

konu değil; ısı konfor ve kullanıcı gereksinimleriyle birlikte değerlendirilmesi gereken bir optimizasyon problemi olarak ele alınmıştır.

Tablo 1.1: Isıl duyum skalası ölçeği

	Çok Soğuk	Soğuk	Biraz Soğuk	Normal	Biraz Sıcak	Sıcak	Çok Sıcak
Ashrae	-3	-2	-1	0	+1	+2	+3
Bedford	1	2	3	4	5	6	7

1.2 Isıl Konforun Değerlendirilmesi Yaklaşımları

Isıl konforun değerlendirilmesinde literatürde statik ve uyumsal yaklaşımlar kullanılmaktadır. Statik yaklaşımın temelinde, Fanger (1970) tarafından geliştirilen Tahmini Ortalama Oy (PMV) ve Tahmini Memnuniyetsizlik Yüzdesi (PPD) indeksleri yer almaktadır (Fanger, 1970). Bu yaklaşımda insan vücudu ile çevre arasındaki ısı dengesi esas alınmış olup değerlendirmeler Tablo1.1’de detayları sunulan ısı duyum skalası ölçeği (ASHRAE ve Bedford) baz alınarak yapılmaktadır. PMV ve PPD indeksleri, ISO 7730 ve ASHRAE 55 standartlarında kullanılan temel göstergeler arasında değerlendirilmiştir (ASHRAE, 2023; ISO, 2005).

PMV ve PPD modelleri, geleneksel ısı konfor değerlendirmelerinde yaygın biçimde kullanılmıştır (Caner and İlten, 2020). Bu modeller, özellikle mekanik olarak iklimlendirilen ve kullanıcıların çevre koşullarına müdahale imkanının sınırlı olduğu binalarda daha tutarlı sonuçlar verdiği belirtilmiştir (Mustapha et al., 2024). Ancak bu yaklaşım, standart kullanıcı kabulüne dayanmaktadır. Bu nedenle her kullanıcının aynı ortamı aynı şekilde algılayacağı varsayılmıştır.

$$PMV = [0,303 \exp(-0,036M) + 0,028] \times \left[\frac{(M-W) - 3,05 \times 10^{-3} [5733 - 6,99(M-W) - p_a]}{-0,42[(M-W) - 58,15] - 1,7 \times 10^{-5} M (5867 - p_a)} \right. \\ \left. - 0,0014M(34 - t_a) - 3,96 \times 10^{-8} f_{cl} [(t_{cl} + 273)^4 - (\bar{t}_r + 273)^4] \right] - f_{cl} h_c (t_{cl} - t_a) \quad (1.1)$$

$$t_{cl} = 35,7 - 0,028(M-W) - I_{cl} \left\{ \frac{3,96 \times 10^{-8} f_{cl} [(t_{cl} + 273)^4 - (\bar{t}_r + 273)^4]}{+ f_{cl} h_c (t_{cl} - t_a)} \right\} \quad (1.2)$$

$$h_c = \begin{cases} 2,38|t_{cl}-t_a|^{0,25}, & 2,38|t_{cl}-t_a|^{0,25} \geq 12,1\sqrt{v_{ar}}, \\ 12,1\sqrt{v_{ar}}, & 2,38|t_{cl}-t_a|^{0,25} < 12,1\sqrt{v_{ar}}. \end{cases} \quad (1.3)$$

$$f_{cl} = \begin{cases} 1,00 + 1,290I_{cl}, & I_{cl} \leq 0,078 \text{ m}^2 \cdot \text{K/W}, \\ 1,05 + 0,645I_{cl}, & I_{cl} > 0,078 \text{ m}^2 \cdot \text{K/W}. \end{cases} \quad (1.4)$$

$$PPD = 100 - 95 \exp(-0,03353 \text{ PMV}^4 - 0,2179 \text{ PMV}^2) \quad (1.5)$$

Statik modellerin bu sınırlılıklarına karşılık, uyumsal konfor yaklaşımı geliştirilmiştir. Bu yaklaşımda kullanıcılar yalnızca ortam koşullarına maruz kalan pasif bireyler olarak görülmemiştir. Pencere açma, fan kullanma, kıyafet değiştirme ve güneş kontrol elemanlarını ayarlama gibi davranışların ısı algıyı değiştirdiği belirtilmiştir (de Dear and Brager, 1998). Bu nedenle konfor sıcaklığının tek ve sabit bir değer olarak değil, dış ortam koşullarına göre değişen bir aralık olarak değerlendirilmesi gerektiği rapor edilmiştir (Nicol and Humphreys, 2002). Uyumsal yaklaşım ile özellikle doğal havalandırılmalı veya kullanıcı müdahalesine açık yapılarda daha esnek bir değerlendirme çerçevesi sunulmuştur.

Kamu binaları ve idari ofislerde değişken doluluk profilleri, farklı kullanıcı beklentileri ve dinamik dış iklim koşulları meydana geldiği izlenmiştir. Bu nedenle sabit sıcaklık ayar noktalarına dayalı HVAC işletme stratejileri her durumda yeterli sonuç üretmediği bildirilmiştir. Rasyonel modele dayanan sabit kontrol yaklaşımlarının, değişken iç ısı yüklerini ve bireysel termal tercihleri temsil etmede sınırlı kaldığı belirtilmiştir (Papadopoulos et al., 2019; Wang et al., 2022). Bu sınırlılık, kamu binalarında enerji israfına ve kullanıcı memnuniyetsizliğine yol açabilmektedir. HVAC sistemlerinin yalnızca sabit ayar değerleriyle değil, anlık çevresel veriler ve kullanıcı gereksinimleriyle birlikte yönetilmesi gerekmektedir.

Son yıllarda veri odaklı yöntemler, ısı konforun daha gerçekçi biçimde tahmin edilmesi için kullanılmaya başlanmıştır. Makine öğrenmesi algoritmalarıyla çevresel veriler, kullanıcı özellikleri ve termal algılar birlikte modellenmiştir (Alam et al., 2024). LSTM ve MLP gibi modellerin kişiselleştirilmiş termal konfor profilleri oluşturmak amacıyla kullanıldığı belirtilmiştir (Almadhor et al., 2025; Dai et al., 2017). Akıllı sensör ağları ve anlık kullanıcı geri bildirimleriyle desteklenen bu sistemler, HVAC kontrolünün daha esnek yürütülmesine olanak sağlamıştır. Bu çerçevede kamu binalarında ısı konfor, enerji tüketimi ve kullanıcı memnuniyeti birlikte ele alınması gereken bir optimizasyon problemi olarak değerlendirilmiştir.

1.3 Isıl Konforun Bina Enerji Yönetim Sistemleri ile İlişkisi

Bina Enerji Yönetim Sistemleri, binalarda enerji kullanımının ve iç ortam koşullarının izlenmesi, kontrol edilmesi ve iyileştirilmesi amacıyla kullanılan bütünleşik sistemler olarak tanımlanmıştır (Jeong and Wi, 2024). BEMS de sensörler ile bilgisayar arayüzleri birlikte çalıştığı ve böylece sıcaklık, hava kalitesi, doluluk ve ekipman çalışma durumu gibi verilerin sürekli olarak izlenebildiği belirtilmiştir. Toplanan verilerin HVAC sistemlerinin daha verimli işletilmesi için kullanılarak enerji maliyetlerinin azaltılması, ekipman arızalarının erken fark edilmesi ve bina enerji performansının iyileştirilmesi hedeflendiği belirtilmiştir (Boodi et al., 2018; Hossain et al., 2023; Mariano-Hernández et al., 2021).

Akıllı bina uygulamalarında BEMS altyapısı, iç ortam hava kalitesi ve ısı konfor koşullarını izleyen sensörlerden gelen veriler değerlendirilmektedir. Bu veriler, HVAC sistemlerinin çalışma biçimini doğrudan etkileyemektedir (Villano et al., 2024). Ortam sıcaklığı, karbondioksit düzeyi, hava debisi ve kullanıcı doluluğu gibi bilgiler, sistemin ne zaman ve ne düzeyde çalışması gerektiğini belirlemede kullanılmaktadır. Böylece bina içindeki konfor koşullarının korunması ve gereksiz enerji tüketiminin sınırlandırılması amaçlanılmaktadır.

Mevcut kamu ve ofis binalarında kullanılan BEMS altyapılarında çoğu zaman geleneksel kontrol yöntemleri uygulanmaktadır. Genellikle aç/kapa kontrol mantığına, PID denetleyicilere veya zaman çizelgelerine dayanılmaktadır (Savadkoohi, 2025). Sabit sıcaklık ayar noktaları ve durağan çalışma programları, değişen dış hava koşullarını ve kullanıcı ihtiyaçlarını her durumda karşılayabilmemektedir. Zayıf sistem tasarımı, sensör arızaları ve uygun olmayan kontrol stratejileri nedeniyle HVAC sistemlerinde harcanan enerjinin yaklaşık %15 ile %30 arasındaki kısmının boşa tüketilebildiği belirtilmiştir (Zhang et al., 2019). Bina enerji yönetiminde yalnızca ekipman seçiminin değil, kontrol stratejisinin de belirleyici olduğu gösterilmektedir.

Geleneksel otomasyon sistemlerinde iç ortam konforu çoğu zaman sabit sıcaklık değerleri üzerinden sağlanmaya çalışılmıştır. Ancak sabit set noktaları, binanın anlık doluluk durumunu, dış ortam sıcaklığını ve kullanıcı beklentilerini yeterli düzeyde temsil edilmemiştir. Bu nedenle bazı durumlarda sistemler gereğinden fazla çalışmakta ve enerji tüketimi artmaktadır. Bu yaklaşımın dinamik koşullara uyum sağlayamaması, kamu binalarında hem enerji kayıplarına hemde kullanıcı memnuniyetsizliğine yol açabilmektedir. (Chan and Ahn, 2024; Dey and Henze, 2024).

Bu sınırlılıkların azaltılması için BEMS yapısına gelişmiş kontrol stratejileri eklenilmiştir. Makine öğrenmesi, yapay sinir ağları, vekil modeller ve model öngörülü kontrol yaklaşımları bu amaçla kullanılmaktadır (Savadkoohi, 2025). Bu yöntemlerle sensörlerden gelen veriler değerlendirilmekte, iç ortam koşulları önceden tahmin edilmekte ve HVAC sistemlerinin çalışma düzeyi buna göre düzenlenilmektedir. Böylece kullanıcı konforu korunurken enerji tüketiminin azaltılması hedeflenilmektedir (Almadhor et al., 2025; Li et al., 2026).

Yapay zeka ve IoT destekli BEMS mimarileri, bina yönetimini daha esnek ve veri odaklı hale getirilmiştir. Bu sistemlerde iç ortam parametreleri ve kullanıcı tercihleri gerçek zamanlı olarak analiz edilebilmektedir (Zhao et al., 2020; Alam et al., 2024). Ayrıca enerji tüketimi ile ısıl konfor gibi farklı hedefler aynı anda değerlendirilebilmektedir. Bu nedenle kamu binalarında BEMS ve gelişmiş kontrol yaklaşımları, HVAC sistemlerinin daha verimli, daha kontrollü ve kullanıcı gereksinimlerine daha duyarlı biçimde işletilmesine katkı sağlayan temel araçlar olarak ele alınmıştır.

1.4 Isıl Konforu Etkileyen Faktörler

İç ortam ısıl konforu, hava sıcaklığı, ortalama radyan sıcaklık, bağıl nem ve hava hızı gibi çevresel değişkenler ile metabolik oran ve giysi yalıtımı gibi kişisel değişkenlerin birlikte etkisiyle şekillendirilmektedir (Fanger, 1970; ASHRAE, 2023; ISO, 2005). Bu değişkenler, insan vücudu ile çevre arasındaki ısı alışverişini belirlemekte ve kullanıcıların termal algısını doğrudan etkilemektedir. Hava sıcaklığı, nem, hava hareketi ve radyan sıcaklık değerlerindeki değişimler, özellikle kamu binalarında ısıtma ve soğutma sistemlerinin enerji tüketimiyle ilişkilendirilmektedir (Rupp et al., 2015; Jiang et al., 2024).

Kişisel faktörler de ısıl konfor değerlendirmesinde ayrı bir yer tutmaktadır. Metabolik oran kullanıcının aktivite düzeyini, giysi yalıtımı ise vücuttan çevreye gerçekleşen ısı kaybını sınırlayan etkiyi ifade etmektedir (Fanger, 1970; Alam et al., 2024). Giyim düzeyi, aktivite biçimi, yaş ve kullanıcı yoğunluğu gibi değişkenler, aynı ortam koşullarında farklı termal algıların oluşmasına neden olabilmektedir (Almadhor et al., 2026).

HVAC sistemlerinin işletilmesinde çevresel ve kişisel faktörlerin birlikte ele alınması gerektiği belirtilmiştir. Hava debisi, hava hızı, sıcaklık set değerleri ve mekanik havalandırma koşulları, hem iç hava kalitesini hem de enerji tüketimini etkilediği ifade edilmiştir.(Hoyt et al., 2015; Ren et al., 2026). Homojen olmayan hava dağılımları, kullanıcıların mekan içindeki konumuna

bağlı olarak farklı konfor düzeyleri oluşturabilmektedir (Azzazy et al., 2024; Alam et al., 2024). Bu nedenle kamu binalarında HVAC kontrolü, yalnızca sabit sıcaklık değerlerine göre değil, kullanıcı yoğunluğu, çevresel koşullar ve bölgesel hava dağılımı dikkate alınarak yürütülmelidir.

Makine öğrenmesi ve akıllı kontrol yaklaşımları, bu karmaşık etkileşimlerin daha esnek biçimde yönetilmesine olanak sağlamaktadır. Sensör verileri, kullanıcı özellikleri ve çevresel ölçümler birlikte işlenerek hem ısı konforunun korunması hem de HVAC kaynaklı enerji tüketiminin azaltılması hedeflenmektedir (Villano et al., 2024; Wu et al., 2023). Bu çerçevede çevresel ve kişisel faktörlerin birlikte değerlendirilmesiyle, kamu binalarında enerji verimliliği ve kullanıcı konforu arasında daha dengeli bir işletme yapısının kurulmasına katkı sağlanmaktadır.

1.5 Binalarda Hvac Sistemleri ve Kontrol Yöntemleri

Isıtma, havalandırma ve iklimlendirme sistemleri, ticari ve kamu binalarında iç hava kalitesinin düzenlenmesi ve uygun ısı konfor koşullarının sağlanması amacıyla kullanılmaktadır (Savadkoohi, 2025). Bu sistemlerde sıcaklık, nem ve hava akışı; dış hava koşulları, doluluk oranları ve iç termal yükler doğrultusunda yönetilmektedir (Mohamed et al., 2025). Modern binalarda HVAC sistemlerinin toplam enerji tüketiminin neredeyse yarısını oluşturduğu belirtilmiştir (Savadkoohi, 2025; Shamsi et al., 2020; Yu et al., 2021). Gerçek işletme koşullarında ise zayıf sistem tasarımı, sensör arızaları, ekipman performans kayıpları ve uygun olmayan kontrol stratejileri nedeniyle harcanan enerjinin %15 ile %30 arasındaki bölümünün israf edildiği ölçülmüştür (Zhang et al., 2019; Savadkoohi, 2025). Bu nedenle HVAC sistemlerinde enerji tüketimi ile iç ortam kalitesi birlikte değerlendirilmiştir.

Mevcut bina enerji yönetim sistemlerinde çoğunlukla kural tabanlı kontrol, aç-kapa kontrolü, PID denetleyiciler ve zaman çizelgesine dayalı işletme stratejileri kullanılmaktadır (Savadkoohi, 2025). Bu yöntemler basit ve uygulanabilir yapıda olsa da, değişen dış ortam koşullarına ve kullanıcı ihtiyaçlarına her zaman uyum sağlayamamaktadır. Sabit set noktalarına göre çalışan sistemlerin, özellikle ticari ve kamu binalarında aşırı soğutma, kesintisiz çalışma ve yüksek enerji tüketimi oluşturabildiği belirtilmiştir (Alam et al., 2024; Makawi et al., 2026). Bu durum, geleneksel kontrol yaklaşımlarının dinamik bina koşullarında sınırlı kaldığını göstermektedir.

Bu sınırlılıkların azaltılması amacıyla gelişmiş kontrol stratejileri bina kontrol süreçlerine eklenilmiştir. Model Öngörülü Kontrol, Yapay Sinir Ağları, Bulanık Mantık, makine öğrenmesi ve derin öğrenme tabanlı yöntemlerin HVAC sistemlerinde kullanılabildiği belirtilmiştir (Afram and Janabi-Sharifi, 2014; Savadkoobi, 2025; Almadhor et al., 2025; Islam et al., 2026). Bu yaklaşımlar, sensörlerden gelen verileri işleyerek iç ortam koşullarını tahmin etmekte ve sistemlerin çalışma düzeyini buna göre düzenlemektedir. Grup En Küçük Kareler Destek Vektör Makinesi ve NSGA II algoritmalarının birlikte kullanıldığı çalışmada, bina mekanik enerji tüketiminin %37.5 oranında azaltıldığı ve termal konforun %33.5 oranında iyileştirildiği gösterilmiştir (Alam et al., 2024).

Yeni nesil akıllı kontrol yaklaşımlarıyla enerji tüketimi, ısıl konfor ve iç hava kalitesi aynı değerlendirme yapısı içinde ele alınmıştır (Guo et al., 2025; Li et al., 2026). Bu nedenle HVAC sistemleri yalnızca sabit sıcaklık sağlayan mekanik donanımlar olarak değil, dış hava koşulları, kullanıcı profili, doluluk değişimi ve enerji tüketimi arasındaki ilişkiyi yöneten dinamik kontrol sistemleri olarak değerlendirilmiştir.

1.6 HVAC Sistemlerinin İşlevleri ve Temel Bileşenleri

HVAC sistemleri, binalarda iç hava kalitesinin düzenlenmesi ve uygun ısıl konfor koşullarının sağlanması amacıyla işletildiği belirtilmiştir. (Savadkoobi, 2025). Bu sistemler aracılığıyla mekan içindeki sıcaklık, nem, hava hareketi ve hava temizliği kontrol altında tutulduğu ifade edilmiştir (Jiang et al., 2024). İç ortam koşullarının standart sınırlar içinde korunması, kullanıcıların sağlığı, bilişsel dikkati ve çalışma verimliliği açısından etkili görülmüştür (Lakhia et al., 2024; Al-Horr et al., 2016; Li et al., 2026). Ancak bu konfor koşullarının sağlanarak, binaların operasyonel enerji tüketimi üzerinde doğrudan yük oluşturulmaktadır (Iddio et al., 2025; Jiang et al., 2024).

HVAC sistemleri; ısıtma ve soğutma üretim ekipmanları, dağıtım elemanları, terminal üniteler, sensörler ve aktüatörlerden oluşan bütünleşik bir yapı içinde çalışmaktadır. Kazanlar, soğutma grupları, ısı pompaları, fanlar, pompalar, hava kanalları, boru ağları, fan-coil üniteleri, klima santralleri ve değişken hava hacimli sistemler bu yapının başlıca bileşenleri arasında yer almaktadır (Savadkoobi, 2025; Fang et al., 2025; Dey and Henze, 2024; Vallianos and Kapsis, 2026). Yapılan simülasyon ve ölçümlerde, HVAC sistemlerine ait toplam enerji tüketiminin %60'tan fazlasının Klima Santralleri (AHU) ve bunlara bağlı çalışan elektrikli VAV kutularından kaynaklandığı hesaplanmıştır (Jiang et al., 2024).

Bina otomasyon sistemleri ile HVAC bileşenlerinin anlık koşullara göre yönetilmesi sağlanmaktadır. İç ortam sıcaklığı, bağıl nem, karbondioksit, aydınlık, doluluk, hava debisi ve üfleme havası sıcaklığı gibi veriler sensörler aracılığıyla izlenmektedir (Islam et al., 2026; Wu et al., 2023; Iddio et al., 2025). Bu veriler, IoT tabanlı ağlar ve kablosuz iletişim modülleri üzerinden kontrol merkezlerine aktarılmakta; ardından vanalar, damperler, pompalar ve diğer aktüatörler aracılığıyla mekanik sistemlere kontrol sağlanılmaktadır (Sung et al., 2019; Alam et al., 2025; Koşum and Özkan, 2025).

Bu yapı sayesinde HVAC sistemleri yalnızca sabit çalışan mekanik donanımlar olarak değil, ölçüm ve kontrol verilerine bağlı biçimde yönetilen dinamik enerji sistemleri olarak ele alınmıştır. Toplanan verilerin Bina Enerji Yönetim Sistemlerine aktarılmasıyla termostat ayarları, havalandırma rejimleri ve ekipman çalışma durumları otonom biçimde düzenlenebilmektedir (Jiang et al., 2024; Ortiz-Suarez et al., 2025). Böylece iç ortam konforundan ödün verilmeden sistem verimliliğinin artırılması ve enerji israfının azaltılması hedeflenilmektedir (Hwang et al., 2025; Villano et al., 2024).

1.7 Geleneksel ve Akıllı HVAC Kontrol Stratejileri

Binalardaki ısıtma, havalandırma ve iklimlendirme operasyonları çoğunlukla bina enerji yönetim sistemlerine entegre edilen geleneksel kontrol stratejileriyle yürütülmektedir (Savadkoohi, 2025). Mevcut bina stoklarında HVAC sistemlerinin işletimi büyük ölçüde sabit set noktalarına ve önceden belirlenmiş zaman çizelgelerine dayandırılmıştır (Lakhiar et al., 2024). Kural tabanlı aç-kapa kontrolleri ve oransal-integral-türevsel algoritmalar bu yapıda yaygın olarak kullanılmaktadır (Gholamzadehmir et al., 2020). Bu yöntemlerle, kararlı durum koşullarında uygulanabilir sonuçlar elde edilebilse de değişken dış hava koşullarına, doluluk profillerine ve kullanıcı beklentilerine yeterli düzeyde uyum sağlanamamaktadır (Behrooz et al., 2018; Savadkoohi, 2025).

Sabit set noktaları ile değişken çevre koşulları arasındaki uyumsuzluk, ticari ve kamu binalarında aşırı soğutma ve enerji israfı oluşturabilmektedir (Alam et al., 2024). Geri çekilme ve hedef set noktası sıcaklıklarının aynı değerde tutulduğu durumlarda, sistemlerin modülasyon yeteneğini kaybettiği ve cihazların gün boyunca aralıksız çalışmaya zorlandığı belirtilmiştir (Makawi et al., 2026). Bu nedenle geleneksel kontrol mekanizmalarının, HVAC sistemlerinin doğrusal olmayan ve çok değişkenli yapısını yönetmede sınırlı kaldığı değerlendirilmiştir (Zhang et al., 2019).

Bu sınırlılıkları azaltmak için gelişmiş kontrol stratejileri HVAC sistemlerine entegre edilmiştir. Model öngörülü kontrol, enerji tüketimini azaltmak ve kullanıcı konforunu korumak amacıyla gelecekteki sistem davranışlarını tahmin eden bir yaklaşım olarak kullanılmıştır (Drgona et al., 2020; Dey and Henze, 2024). Ancak bu yöntemlerin hesaplama yükü yüksek olduğundan, vekil modeller, makine öğrenmesi ve yapay zeka tabanlı algoritmalar kontrol döngülerine dahil edilmiştir (Villano et al., 2024; Savadkoobi, 2025). Bu modellerle enerji kullanım yoğunluklarının çok kısa sürede tahmin edilebildiği ve karmaşık fiziksel denklemlere bağımlılığın azaltıldığı gösterilmiştir (Vallianos and Kapsis, 2026).

Makine öğrenmesi tabanlı kontrol yaklaşımlarında çevresel ve fizyolojik veriler arasındaki doğrusal olmayan ilişkiler modellenmiştir (Alam et al., 2024). Karar ağaçları, destek vektör makineleri, yapay sinir ağları ve rastgele orman gibi algoritmalarla kişisel ısı konfor gereksinimlerinin tahmin edilebildiği belirtilmiştir (Alam et al., 2024). Grup En Küçük Kareler Destek Vektör Makinesi ve NSGA II algoritmalarının birlikte kullanıldığı çalışmada, bina mekanik enerji tüketiminin %37.5 oranında azaltıldığı ve ısı konforun %33.5 oranında iyileştirildiği gösterilmiştir (Alam et al., 2024). Ayrıca Ekstra Ağaç Regresörü gibi algoritmalarla HVAC enerji tüketiminin yüksek doğrulukla tahmin edilebildiği belirlenmiştir (Makawi et al., 2026).

Pekiştirmeli Öğrenme yaklaşımları da HVAC kontrolünde değerlendirilmiştir. Bu yöntemlerde sistem, fiziksel termal modele ihtiyaç duymadan çevreyle etkileşim kurarak kontrol politikalarını öğrenmektedir (Gao and Wang, 2023; Zhuang et al., 2023). Geleneksel kontrolün sabit ve tek yönlü yapısına karşılık, akıllı kontrol stratejileri enerji tüketimi ile kullanıcı konforu aynı değerlendirme içinde ele alınmıştır. Böylece HVAC kontrolü, yalnızca sıcaklık hedeflerinin korunmasına dayalı bir süreç olmaktan çıkarılmış; çevre koşulları, kullanıcı beklentileri ve enerji performansına birlikte yanıt veren bir karar yapısına dönüştürülmüştür (Dey and Henze, 2024; Jiang et al., 2024).

1.8 Literatür Özeti

Kamu binalarında HVAC sistemlerinin enerji verimliliği ve kullanıcı konforu açısından değerlendirilmesi, yalnızca ekipman performansının incelenmesiyle sınırlı olmayan çok boyutlu bir araştırma alanı olarak ele alınmıştır. Isı konfor literatüründe statik ve adaptif yaklaşımlar temel çerçeveyi oluşturduğu belirtilmiştir. Son yıllarda yayımlanan çalışmalar bu

iki yaklaşım kapsamında incelenerek değerlendirilmede kullanıcıların bireysel ısı algılarını içeren deney ve saha çalışmalarına odaklanılmıştır (Rupp et al., 2015). Adaptif ısı konfor yaklaşımı farklı binalardan elde edilen çok sayıda saha gözlemi üzerinden değerlendirilmiştir. Optimum iç ortam sıcaklığının iç ve dış ortam koşullarıyla ilişkili olduğu ve PMV modeli mekanik havalandırmalı binalar ile doğal havalandırmalı binalarda karşılaştırılmıştır. Doğal havalandırmalı binalarda kullanıcı memnuniyetinin daha geniş sıcaklık aralıklarını kabul edebildiği gösterilmiştir (de Dear and Brager 1998). Anketlere dayalı adaptif konfor yaklaşımıyla uygun konfor sıcaklığının, kabul edilebilir aralıklarının ve iç ortam sıcaklık değişim sınırlarının belirlenmesine katkı sağlanmıştır (Nicol and Humphreys, 2002).

Isıl konforun bina performansında ki rolü, iç ortam kalitesi ve kullanıcı memnuniyeti çalışmalarıyla geniş bir bağlamda ele alınmıştır. Dergiler de yayımlanan 300 den fazla çalışmayı inceleyerek kullanıcı verimliliğini etkileyen sekiz temel iç ortam faktörünü tanımlanmıştır (Al Horr et al., 2016). Geliştirilen Yönlendiriciler, İhtiyaçlar, Eylemler ve Sistemler (DNAs) modeli ile , kullanıcı davranışlarının enerji modellerine sistematik biçimde aktarılabilmesi amacıyla çok sayıda çalışma yönlendiriciler, ihtiyaçlar, eylemler ve sistemler başlıkları altında sınıflandırılmıştır. Kullanıcı davranışının enerji performansı ve konfor dengesi üzerinde ölçülebilir bir değişken olarak ele alınabileceğini gösterilmektedir (Hong et al., 2015). Farklı iklim ve bina tiplerinde yürütülen saha çalışmaları, kullanıcı konforunun mekansal, mevsimsel ve davranışsal etkenlere göre değiştiğini göstermektedir. Bir Sanayi tesisinde işçiler ile yapılan 1276 geçerli anket çalışması değerlendirilmiş, ortalama konfor sıcaklığı ile mevsimsel konfor sıcaklıklarının farkları hesaplanmıştır. Tercih edilen sıcaklığın ortalama konfor sıcaklığından daha düşük olduğu ve vantilatör kullanımının lojistik regresyonla tahmin edilebildiği belirtilmiştir (Kumar et al., 2021).

Enerji verimliliği ile kullanıcı konforunun birlikte yönetilmesinde, termostat sıcaklığı ayar noktalarının genişletilmesi önemli bir strateji olarak değerlendirilmektedir. EnergyPlus referans modelleriyle farklı iklim bölgelerinde ofis binaları incelenmiştir. Soğutma ve ısıtma sıcaklığı ayar noktalarının değiştirilmesinin enerji tüketimlerindeki etkisi gösterilmiştir. Kişisel kontrol ve tavan vantilatörü desteğiyle HVAC enerji tasarrufu sağlanabileceği belirtilmiştir (Hoyt et al., 2015). Kişisel konfor sistemlerindeki kullanıcı davranışlarına dayalı makine öğrenmesi modellerinin, ılıman iç ortam koşullarında geleneksel PMV ve adaptif modellere göre daha başarılı sonuç verdiği gösterilmiştir. (Kim et al., 2018).

Bina enerji performansının tahmini, makine öğrenmesi yöntemleri ve coğrafi veri altyapılarıyla birlikte değerlendirilmektedir. Binalara ait gerçek Enerji Kimlik Belgesi verileriyle makine öğrenmesi algoritmalarını karşılaştırılmıştır. Sonuçlara göre en başarılı olan tahmin modelinin XGBoost algoritması olduğu belirtilmiştir. Bina yaşı, ısıtma enerjisi ve yenilenebilir enerji kullanım oranı model sonucunu etkileyen başlıca değişkenler olarak belirtilmiştir (Sisman et al., 2025). Kent ölçeğinde belirlenen bölgedeki yalıtım ve ısı pompası optimizasyonları bina enerji modellemeleriyle ilişkilendirilmiştir (Abbasabadi et al., 2026). Belirtilen alandaki konutlarda pasif ısıtma ve soğutma sistemlerinin yaygınlaşmasını sınırlayan engeller teknik olarak incelenerek, eğitim ve mevzuat konularının güncellenmesi gerektiğini vurgulanmıştır (Kazemi and Kazemi, 2025).

İşletme aşamasında enerji yönetimi, geleneksel denetimlerden nesnelerin internet tabanlı sürekli izleme ve veri işleme sistemlerine doğru dönüşmektedir. Enerji tüketimini izleyen nesnelerin interneti destekli kontrol stratejileriyle binalarda HVAC enerji tasarrufu sağlanabildiği gösterilmiştir (Kumar et al., 2026). Sağlık merkezinde kullanılan hibrit HVAC sistemi modellenerek simüle edilip gerçek bina izleme verileriyle karşılaştırılarak yüksek bir uyumlulukla ($R^2 > 0.90$) doğrulanmıştır. (Rizzo, 2025). Mevcut okul binaları ile yeni okul projeleri karşılaştırılmıştır. Pasif ve aktif tasarım kararlarının okul binalarında genel enerji performansın da %30 ile %50 oranında iyileştirme sağlayabileceği gösterilmiştir. (Miran and Aziz, 2024). Havalandırma kanallarında metamateryal değişimi ile gürültü azaltımı ve hava dağıtımını değerlendirmelerinin HVAC sistemlerinde yalnızca enerji değil aynı zaman da iç ortam kalitesi yönüyle de ele alınması gerektiği gösterilmiştir (Fusaro et al., 2023).

HVAC sistemlerinin proaktif kontrolünde, kısa vadeli iç ortam sıcaklığı ve yük tahminleri önemli bir yer tutmaktadır. Hibrit derin öğrenme modeliyle sıcaklık tahminleri gerçekleştirilmiştir. Gerçek verilerle yapılan testlerde modelin hata değerlerini önemli ölçüde düşürerek 0.50 °C' nin altında bir ortalama mutlak hata (MAE) elde edildiği belirtilmiştir (Islam et al., 2026). Kısa vadeli yük tahminlerinde hibrit model kullanılmıştır. Akıllı Bina demonstratörü üzerinde yapılan değerlendirmeler ile modelin geleneksel yöntemlere kıyasla hata oranlarında %20'ye varan bir azalma ve 0.90 civarında bir belirtme katsayısı (R^2) elde edildiği belirtilmiştir (Tindall et al., 2025). Yapay sinir ağı tabanlı öngörülü kontrollerin binalardaki uygulanabilirliğinde yeterli tahmin doğruluğu için en az 1-4 aylık veriye ihtiyaç duyulduğunu, optimum kalibrasyon ve model doygunluğunun ise 2 ısıtma sezonuna ait veri büyüklüğüyle sağlandığını ifade edilmiştir. (Savadkoohi 2025).

Enerji tüketimi, iç hava kalitesi ve ısıl konfor arasındaki ilişkinin birlikte yönetilebilmesi için çok amaçlı optimizasyon algoritmalarından yararlanılmaktadır. Geliştirilen yöntem ile algoritma 40 nesil boyunca çalıştırılarak HVAC sisteminin operasyonel verimliliğinin artırılması hedeflenmiştir (Li et al., 2026). Aydınlatma ve iklimlendirme sistemlerinin bina ısı yükleri üzerindeki etkileşimini düzenleyen modeller geliştirilmiştir (Shengli et al., (2026). Nemli iklimlerde ısıl konforun, sıcaklık ile bağıl nemin birlikte etkisi nedeniyle daha karmaşık bir yapı kazandığı belirtilmektedir. HVAC enerji tüketimini azaltmak amacıyla geliştirilen modellerin kullanılabileceği ifade edilmiştir (Mohamed et al., 2025). HVAC sistemlerinin işletiminde kullanılan yöntemlerin dinamik çalışma koşullarına uyum sağlayarak kontrol kararlarının daha esnek biçimde üretilmesine katkı sunduğu belirtilmiştir (Azzi et al., 2025; Rigo-Mariani and Yakub, 2024).

Dijital İkiz teknolojileri, binalarda enerji verimliliği ve ısıl konforun birlikte yönetilebilmesi için fiziksel sistemler ile dijital modeller arasında sürekli veri akışı sağlayan bir yapı sunmaktadır. Bu teknolojilerin bina enerji performansı, kullanıcı konforu ve bakım süreçlerinde giderek daha önemli bir araç haline geldiği gösterilmiştir (Ba et al., 2025; Boukaf et al., 2024). Kısa vadeli enerji tüketimi tahminleri ile geleneksel yöntemlere kıyasla %15 civarında azaltarak %96'nın üzerinde bir tahmin doğruluğu (%2.5 - %4.3 MAPE) elde edilmiştir. (de las Morenas et al., 2025). Makine öğrenimi destekli dijital ikiz sistemlerinde fiziksel ve dijital ortamların eşzamanlı sensör verileri üzerinden birleştirilebildiği ortaya koyulmuştur. (Li and Hong, 2025). Dijital İkiz uygulamalarının işletme ve bakım süreçlerine katkısı, Net Sıfır Enerjili Binalar ve akıllı kampüs çalışmaları üzerinden de değerlendirilmektedir. Net Sıfır Enerjili Binaların işletme ve bakım aşamalarında sistem entegrasyonunun enerji yönetimi açısından önemli bir rol üstlendiğini ortaya koyulmuştur. (Liu et al., 2025). Merkezi iklimlendirme sistemleri için fiziksel varlıklar, sanal varlıklar, bağlantılar, veriler ve hizmetlerden oluşan beş boyutlu bir dijital ikiz çerçevesi önerilmiştir (Ma et al., 2025). Çoklu enerji yönetim sistemlerinde kullanılan algoritmalar ile maliyetlerin azaltılması, dijital ikiz yaklaşımının yalnızca bina ölçeğinde değil, endüstriyel enerji yönetimi problemlerinde de uygulanabildiğini gösterilmektedir (Bousnina and Guerassimoff, 2024; Xu and Liu, 2024). Veri merkezlerinde soğutma sistemlerinin dijital ikiz tabanlı olarak yönetilmesiyle toplam soğutma enerjisi tüketiminde %23,63 azalma sağlanılmıştır. Dijital ikiz yaklaşımının yalnızca bina ölçeğinde değil, yüksek enerji yoğunluğuna sahip soğutma sistemlerinde de uygulanabilir bir enerji yönetimi aracı olduğunu gösterilmektedir (Zhu and Lin, 2024).

Bina Enerji Yönetim Sistemlerinde veri yönetimi ve konfor tahmini, dijital ikiz mimarileriyle daha bütünleşik biçimde ele alınmaktadır. Geliştirilen modelde farklı modeller birleştirilmiştir. Az veri kullanılarak operasyonel durumların yüksek doğrulukla sınıflandırılabilirdiği gösterilmiştir (Hwang et al., 2025). Geliştirilen konut ölçekli sistemde modelin yüksek doğruluk elde ettiği ayrıca enerji tavsiye sisteminin ise kullanıcıların %80'inden olumlu geri dönüş aldığı belirtilmiştir. (Sayed et al., 2025). Gerçek zamanlı görselleştirme ile desteklenen bir dijital ikiz mimarisi geliştirilmiştir. Modelin termal konfor tahmininde geleneksel modellere kıyasla daha başarılı sonuçlar verdiği gösterilmiştir. (Gao et al., 2024).

ASHRAE Küresel Termal Konfor Veritabanı II kullanılarak dikkat tabanlı bir model geliştirilmiştir. Modelde termal duyum tahminlerinde %83,8 oranında yüksek doğruluk düzeyine ulaşılmıştır. Ayrıca model kararları, açıklanabilir yapay zeka teknikleriyle yorumlanabilir hale getirilmiştir (Almadhor et al., 2025). Isıl konfor ve enerji verimliliği optimizasyonunda çevresel, mekansal, akustik ve psikolojik değişkenlerin birlikte ele alınması gerekmektedir. PMV ve PPD endekslerinin nesnel ve öznel değerleri karşılaştırılmıştır ve bu değerlerin kabul edilebilir konfor sınırları içinde kaldığı belirtilmiştir (Lakhiar et al., 2024). Brezilya'nın yarı kurak iklim bölgesindeki eğitim yapılarında yürütülen çalışmada klima kullanımına rağmen kullanıcıların yüksek düzeyde ısı rahatsızlığı yaşadığı belirtilmiştir (Barbosa et al., 2024). Bir binada, ofis yönelimlerinin ısı konfor üzerindeki etkisi ölçümlerle incelenmiştir. Olumsuz koşullara sahip alanlar belirtilmiştir. Ayrıca akustik memnuniyet ile ısı konfor arasında güçlü bir ilişki bulunduğu ifade edilmiştir. (Mazandarani et al., 2026). İç hava kalitesinin genel kullanıcı konforundaki değişimin yaklaşık yarısını açıkladığı belirtilmiştir. Bu bulgu, ısı konfor değerlendirmelerinde sıcaklık değişkeninin tek başına yeterli olmadığı çoklu iç ortam faktörlerinin birlikte ele alınması gerektiği gösterilmiştir (Ruth et al., 2025). Akustik koşulların ısı algı üzerindeki etkisi, hem açık hem de kapalı mekan çalışmalarıyla desteklenmektedir. Açık alanlarda gürültü seviyesinin azaltılmasının ısı konforu iyileştirdiği, havalimanı terminallerinde ise yüksek ses düzeylerinin termal konfor oylarını düşürdüğü belirlenmiştir. (Lin et al., 2023; Yang et al., 2024). Kişisel ısı konfor tahminlerinde makine öğrenmesi yöntemleri, geleneksel konfor modellerinin sınırlı kaldığı bireysel farklılıkların daha ayrıntılı biçimde modellenmesine olanak sağlamaktadır. Ofis binalarında kişisel ısı konfor modellerinde farklı algoritmaların doğruluk değerleri gösterilmiştir (Alam et al., 2024).

Dış ortam ısı konfor indekslerinin yüksek doğruluk düzeylerinde raporlanması ile veri odaklı konfor yaklaşımlarının yalnızca bina içi ortamlarla sınırlı olmadığı gösterilmiştir. Söz konusu

yöntemlerin farklı ortamsal ölçeklerde ve değişken koşullarda da uygulanabilir olduğu ortaya koyulmaktadır (Elnabawi and Hamza, 2024). Geliştirilen nesnelerin internet tabanlı sistem ile kişisel ısı konfor verilerinin yüksek doğrulukla ($R^2=0,99$) izlenebileceğini gösterilmektedir (Alam et al., 2025).

Veri kalitesi ve kullanıcıların psikolojik algıları, ısı konfor modellerinin güvenilirliğini doğrudan etkilemektedir. Geniş bir veri tabanı üzerinden yapılan değerlendirmede, güvenilir bir ısı his modeli için gerekli olan örneklem sayısı 350 olarak belirlenmiştir (Chang et al., 2024). Nötr sıcaklık değerlerindeki ortamsal farklılıklar, değişik saha çalışmalarıyla desteklenmiştir (Mao et al., 2023; Azzazy et al., 2024).

Isı algının bilişsel fonksiyonlarının uzun vadeli konforla güçlü doğrusal ilişkiler kurduğu, yaş ve cinsiyetin anlamlı bir etkiye sahip olmadığı bildirilmiştir (Li et al., 2024). Anketlerin faktör analiziyle yapılandırılmasının çok boyutlu konfor ölçümlerinin güvenilirliğini arttırdığı değerlendirilmiştir (Luparelli et al., 2025). Hassas kullanıcı grupları ve farklı dış ortam koşulları, ısı konfor standartlarının tek tip kullanıcı profili üzerinden belirlenemeyeceğini göstermektedir. Hastane bekleme alanlarında hastaların ısı adaptasyon düzeyleri incelenerek farklı değerler belirlenmiştir (Zhen et al., 2025). Farklı bölgelerdeki hastane ziyaretçilerinin ısı algılarının istatistiksel modellerle farklılaştığı da bildirilmiştir (Yang et al., 2026).

Uygulamalı tasarım stratejileri, esnek sıcaklık ayar noktaları, pasif sistemler ve kişiselleştirilmiş çözümler üzerinden enerji konfor dengesine farklı katkılar sunmaktadır. Soğutma sıcaklık ayar noktasının artırılmasıyla HVAC enerji tüketiminde azalma sağlanabileceği belirlenmiştir (Iddio et al., 2025). Nijerya'nın Abuja kentindeki sıcak ve kurak tropikal savan ikliminde bulunan doğal havalandırmalı sınıflarda öğrencilerin ortamı konforlu bulması ve nötr sıcaklığın yüksek belirlenmesi ile coğrafi ve kültürel beklentilerin önemi gösterilmiştir (Mustapha et al., 2024). Japonya'daki ofis binalarında yürütülen izlemelerde, kullanıcıların çoğunluğu için ideal konfor aralığının belirlenmiştir. Malezya'daki kütüphane binalarında ise serbest giyim tercih eden kullanıcıların çoğunluğu konforlu hissederken, katı üniforma kullananlarda bu oran daha düşük kalmıştır. Kıyafet tercihi ve davranışsal adaptasyonun iç ortam konfor algısı üzerinde belirleyici olduğu gösterilmiştir (Maharjan and Rijal, 2026; Zaraa Allah et al., 2025).

Kişiselleştirilmiş bölgesel kontrol sistemleri ve mikroiklim odaklı uygulamalar, kullanıcıya yakın iklimlendirme stratejilerinin olanaklarını ve sınırlılıklarını göstermektedir. Lokal ısıtma uygulamalarının kullanıcı konforunu belirgin biçimde arttırdığına dair güçlü bulgular edilememiştir (Warthmann et al., 2025). Yerel konfor çözümlerinin özellikle kullanıcıya yakın mikroiklim koşullarında daha etkili sonuçlar verebileceği gösterilmiştir (Shin et al., 2024). Kısmi yük koşullarında ortaya çıkan aşırı soğutmayı azaltmak amacıyla yük oranına dayalı kademeli bir kontrol stratejisi önerilmiştir (Fang et al., 2025). Mimari kabukları güneş ışıını ile ilişkisi üzerinden solar ayarlı operatif sıcaklıkları değerlendirilmiştir (Song et al., 2025). Farklı havalandırma modları arasında rüzgar yakalayıcı entegre edilmiş ofislerin ısı konfor standartlarını daha iyi karşıladığını gösterilmiştir. (Khalid et al., 2025).

İklimsel bağlam ve hava sızıntıları, bina enerji modellemelerinde önemli sapma kaynakları arasında yer almaktadır. Farklı şehirlerdeki ölçüm istasyonları üzerinden kentsel ve kırsal alanlar arasındaki sıcaklık nem farklılıklarının bina yükleri üzerindeki etkisini incelenmiştir (Yang et al., 2024). Hava sızıntısı modellemesinde sabit ACH ve yalnızca hava sızdırmazlık testi kullanımının büyük sapmalar oluşturduğu ayrıca HVAC kalibrasyonu hata oranlarının indirildiği gösterilmiştir (Makawi et al., 2026). Kurak iklimlerde soğutmanın yıllık tüketimin %80,5 ini oluşturduğu, simulasyon optimizasyonu ile sıcaklık ayar noktası, ACH ve COP düzenlemelerinin tasarruf sağladığı gösterilmiştir (Alajmi, 2025).

Bina enerji sistemlerinin modellenmesi ve optimizasyonunda yüksek hesaplama maliyetlerini azaltmak amacıyla makine öğrenmesi ve derin öğrenme tabanlı vekil modellerin kullanımı yaygınlaşmaktadır. Makine öğrenmesi algoritmalarının daha çok enerji verimliliği ve HVAC kontrolü alanlarında, derin öğrenme mimarilerinin ise yenilenebilir enerji yönetiminde kullanıldığı belirtilmiştir (Villano et al., 2024). Karmaşık termal etkileşimlerin çözümlenmesinde süreçlerin makine öğrenmesi ile hızlandırılabildiği gösterilmiştir (Mao et al., 2025). Kullanılan verilerde en başarılı tahmin sonucu veren modelin SVM olduğu gösterilmiştir (Ozdemir and Pektezel 2026). Bina performansı simülasyonlarının oluşturduğu yüksek hesaplama yükü, iyileştirme senaryolarının çok amaçlı optimizasyonunda vekil modeller aracılığıyla azaltılabilmektedir. Ofis binasında vekil modellerle hesaplama süresi kısaltmış ve konfor iyileşmesi sağlanmıştır (Markarian et al., 2024). Belirtilen binalar için EnergyPlus tabanlı sentetik veriler kullanılarak enerji kullanım yoğunluğu ve iyileştirme maliyetleri modellenmiştir. Enerji tahminin de ve maliyet tahmininde öne çıkan algoritmalar belirtilmiştir (Shirzadi et al., 2025). Ufak ölçekli binalarda yapılan çalışmada, istatistiksel

filtreleme ve dönüştürme işlemleriyle enerji tahminlerinde sapmalar azaltılmıştır (Chinde et al., 2026). Sınırlı örneklem gruplarında hassas tahminler üreten algoritma gösterilmiştir. Örnekleme tekniklerinde tutarlı ve kesin sonuçlar sağlayanlar belirtilerek en başarılı kombinasyonun ise XGBoost–MIPT olduğu gösterilmiştir (Stevanović et al., 2024). Hibrit yaklaşımla optimizasyon süreleri doğruluk kaybı olmadan %64 oranında hızlandırılmıştır (Prina et al., 2024).

HVAC ve soğutma alt sistemlerinde karmaşık termodinamik süreçlerin veri odaklı modellerle temsil edilmesi giderek yaygınlaşmaktadır. Soğutma sistemlerinin performansı modellenmiş ve en yüksek sistem verimliliğinin elde edildiği akışkan belirtilmiştir (Pektezel 2025). Kontrol süreçlerinde vekil modellerin kullanılmasının öğrenme sürecini iyileştirdiği gösterilmiştir (Dey and Henze, 2024).

HVAC sistemlerinin ısıtma, soğutma ve enerji tüketim davranışları, makine öğrenmesi ve derin öğrenme algoritmalarıyla daha ayrıntılı biçimde modellenmektedir. Veri odaklı yaklaşımların enerji yükü tahminlerinde fiziksel simülasyonlara güçlü bir alternatif sunduğunu belirtilmiştir (Abdel-Jaber and Dirks, 2024; Jiang et al., 2024). HVAC kaynaklı enerji tüketimi analiz edilmiş ve optimizasyon senaryolarında tasarruf potansiyeli hesaplanmıştır (Ortiz-Suarez et al., 2025). Sınırlı veri koşullarında transfer öğrenme destekli hafif yapay sinir ağı modellerinin karbon emisyonu tahminlerinde etkili biçimde kullanılabileceği gösterilmiştir (Wang et al., 2025). Geliştirilen model ile çoklu enerji sistemi verileri kullanılarak enerji yüklerinin eşzamanlı tahmininde uygulanmıştır (Ahmed et al., 2025). Bununla birlikte yüksek doğruluk sağlayan veri odaklı modellerin sayısı artmasına rağmen, bina tasarım kararlarını doğrudan destekleyebilecek yorumlanabilir sınıflandırıcıların halen sınırlı olduğunu vurgulanmaktadır. (Abdel-Jaber and Dirks, 2024).

Makine öğrenmesi yöntemleri, bina enerji performansının ötesinde kentsel çevre, yenilenebilir enerji ve kaynak yönetimi alanlarına da genişlemektedir. Enerji tahmini için modeller test edilmektedir (Juliet et al., 2024). Yenilenebilir enerji sistemlerinde makine öğrenmesi uygulamalarının hata tespiti ve enerji optimizasyonun değerlendirilmiştir. (Kishore et al., 2024). WEKA tabanlı makine öğrenmesi modellerinin sensör verilerine dayalı kaynak yönetimi süreçlerinde etkili biçimde kullanılabileceğini gösterilmektedir (Koşum and Özkan, 2025). Isıtma ve soğutma yüklerinin tahmininde MLP tabanlı yapay sinir ağlarının kullanımı, sistematik derleme çalışmalarıyla desteklenmektedir (Ghritlahre and Verma, 2025).

Model başarısında hiperparametre ayarlarının belirleyici olması nedeniyle, tahmin süreçlerinde meta-sezgisel algoritmalarından giderek daha fazla yararlanılmaktadır. Konut binalarında ısıtma ve soğutma yüklerinin tahmin edilmesi amacıyla hibrit bir makine öğrenmesi modeli geliştirilmiştir (Khastar et al., 2025). Isıtma enerjisi yükü tahmininde algoritmalar karşılaştırılmış ve MLP yaklaşımının ısı enerjisi yükü tahmininde daha iyi sonuç verdiği gösterilmiştir (Barathula et al., (2024). Bina konfigürasyonları üzerinden WWPA-MLP regresyon modelinin hata metriklerini azalttığı belirtilmiştir (Alharbi et al., 2024). Bina soğutma yükünün tahmini amacıyla Çok Katmanlı Algılayıcı Regresyonu, Brown Bear Optimization Algorithm ve Non-Monopolize Search Algorithm ile ayrı ayrı hibritleştirilerek geliştirilen hibrit modelde yüksek tahmin performansı sağlandığı belirtilmiştir (Zeynalli and Eslami 2025). SSA-MLP hibrit yapısının doğrusal olmayan enerji verimliliği problemlerinde rekabetçi bir tahmin gücü sunduğunu bildirilmiştir (Eker et al., 2024). Soğutma yükü tahmininde bal prosuğu algoritması tabanlı model değerlendirilmiştir (Yang, 2024). MLP hiperparametrelerini daha dengeli ayarlanamsı ile tahmin başarısı arttırılmıştır (Tuğal, 2025). Zaman serisi tabanlı enerji tahminlerinde uzun vadeli bağımlılıkların modellenmesi önemli bir yer tutmaktadır. Ofis binalarında ısı yükü tahmini için model geliştirilmiştir (Wang et al., 2024). Uzun vadeli ısı yükü tahminleri için Cakmorfer modeli geliştirilmiştir. Geliştirilen modelin en yakın modele kıyasla daha başarılı tahmin sonuçları verdiği gösterilmiştir (Quanwei et al., 2025). Bina iklimlendirme sistemlerinde geliştirilen modelle yüksek tahmin doğruluğu ($R^2=0,9971$) elde edilmiştir. Geleneksel modellere göre hata oranlarını önemli ölçüde azaldığı belirtilmiştir (Zhou et al., 2024).

Kamu binalarında HVAC sistemlerinin enerji verimliliği ve optimizasyonu, güncel literatürde makine öğrenmesi, metamodelleme ve meta-sezgisel algoritmaların birlikte kullanıldığı çok katmanlı bir araştırma alanı olarak ele alınmaktadır. Bina enerji performans optimizasyonuna ilişkin akademik çalışmalarda simülasyon ve metamodel tabanlı çok amaçlı optimizasyon yaklaşımlarının çoğunlukla iklim koşulları üzerinden değerlendirildiği belirtilmiştir. (Reza-E-Rabbi et al., 2026). İncelenen çalışmalarda metamodel türleriyle enerji sistemleri arasında kesin eşleşme olmadığını ve standart hata analizlerine ihtiyaç duyulduğu belirtilmiştir. (Starke and da Silva, 2025). Adaptif metamodelleme ile güçlendirilmiş algoritmalar birleştirilerek daha iyi çözümler üretilerek hesaplama süresi azaltılmıştır (do Amaral et al., 2025).

Konut ve kırsal yapı ölçeğinde yürütülen optimizasyon çalışmaları, enerji-konfor dengesinin çok amaçlı bir problem olarak ele alınması gerektiğini göstermektedir. Farklı optimizasyon

yöntemlerini karşılaştırılarak ısıtma ve soğutma yükü tahminlerinde başarılı sonuçlar veren modeller belirtilmiştir (Abdelkader et al., 2025). Binalarda HVAC iyileştirme stratejileri simülasyonlarda oluşturulan sentetik veri seti üzerinden değerlendirilmiştir (Vallianos and Kapsis, 2026). Bir konutta vekil model ile analiz edilen enerji tüketimlerini tahmin etmede en başarılı algortima olarak Rastgele Orman tabanlı vekil model belirtilmiştir. (Jun and Fei, 2024). Seçilen konutlarda iç ortam form ve yapı cephesi parametrelerini optimize edilerek termal konforsuzluk ve enerji tüketimden azalmalar olduğu belirtilmiştir (Han et al., 2025). Dış ortam termal konforunun tahmin edilmesi amacıyla öğrenme modeli geliştirilmiştir. Modelin yüksek doğruluk düzeyine (%92,3) ulaşması veri odaklı tahmin yaklaşımlarının kentsel iklim adaptasyonu ve dış ortam konforu hesaplamalarında kullanılabileceği gösterilmiştir (Lei, 2024).

2. MATERYAL VE YÖNTEM

Kamu binalarına yönelik benzer çalışmalarda da yapıların mimari ve fiziksel niteliklerinin enerji performansı analizleri için başlangıç verisi olarak ele alındığı görülmektedir (Barbosa et al., 2024). Dinamik enerji tüketimlerinin hesaplanması ve bina termal modellerinin oluşturulması sürecinde DesignBuilder simülasyon yazılımının kullanıldığı literatürde belirtilmiştir (Makawi et al., 2026). Benzer saha çalışmalarında Testo 480 çok fonksiyonlu iklim analizörü aracılığıyla iç ortam koşullarının ölçüldüğü bildirilmiştir (Caner and İlten, 2020). Literatürde de kullanıcıların kişisel reaksiyonlarının anketler aracılığıyla sayısallaştırıldığı ve termal memnuniyet değerlendirmelerinde kullanıldığı belirtilmiştir (Abdul Rahim et al., 2024; Zarea Allah et al., 2025). Bu bütünlük veri yapısının, enerji verimliliğini artırmaya yönelik makine öğrenmesi süreçlerine aktarılması tasarlanmıştır (Alam et al., 2024; Savadkoobi, 2025; Sisman et al., 2025).

Araştırma kapsamında öncelikle incelemeye konu edilen kamu binasının mimari, fiziksel ve yapısal özellikleri değerlendirilmiştir. Bu aşamada binanın yapı kabuğu, kullanım biçimi, iç ortam koşulları ve iklimlendirme sistemiyle ilişkili temel bileşenler çalışma kapsamına alınmıştır. İç ortam fiziksel konfor parametrelerinin nesnel biçimde belirlenebilmesi için Testo-480 çok fonksiyonlu ölçüm cihazı kullanılarak yerinde ölçümler gerçekleştirilmiştir. Bu kapsamda hava sıcaklığı, bağıl nem, hava hızı ve ortalama radyan sıcaklık gibi fiziksel parametreler sahada kayıt altına alınmış; elde edilen veriler, binanın gerçek işletme koşullarındaki iç çevre performansının değerlendirilmesine temel oluşturulmuştur. Bu yöntemle, fiziksel ölçüm sonuçları ile kullanıcıların algısal değerlendirmeleri birlikte ele alınmıştır. Sahadan elde edilen nesnel ölçüm verileri ile anketlerden sağlanan öznel kullanıcı geri bildirimlerinin, HVAC operasyonlarını otonom biçimde optimize etmeye yönelik akıllı kontrol stratejilerine veri tabanı oluşturması amaçlanmıştır. Böylece materyal ve yöntem kurgusu; bina özelliklerinin incelenmesi, iç ortam ölçümlerinin yapılması, kullanıcı anketlerinin uygulanması ve elde edilen verilerin enerji verimliliği odaklı modelleme süreçlerinde değerlendirilmesi aşamalarından oluşturulmuştur.

2.1 Binanın Yapısal ve Mimari Özellikleri


Binaların teknik altyapısı ve mekanik donanım yerleşimleri işletme senaryoları çerçevesinde değerlendirilmiştir. Merkezi sistemle yönetilen yüksek performanslı eğitim yapılarında, havalandırma ve iklimlendirme ünitelerinin bölgesel termal kontrol sağlayacak biçimde

kurgulandığı tespit edilmiştir (Mazandarani et al., 2026). Binaların çatı katlarının sistem servisleri ve mekanik odalar için ayrıldığı, ısıtma için doğal gaz kazanlarının, soğutma için ise elektrik tahrikli grupların kullanıldığı belirtilmiştir (Caner and İlten, 2020; Alajmi, 2025). Mevcut kamu bina stokundaki bazı bloklarda HVAC tesisat altyapısının eski donanımlardan oluştuğu ve cihaz konumlandırmalarındaki bu eskilik durumunun genel enerji verimliliğini düşürdüğü gözlenmiştir (Barbosa et al., 2024).



Şekil 2.1: Çalışma yapılan bina dış cephe

Saha çalışmasına konu edilen Balıkesir Büyükşehir Belediyesi Fen İşleri Dairesi Başkanlığı hizmet binası, Altıeylül ilçesi Çayırhisar Mahallesi sınırları içerisinde, Yeni İzmir Yolu üzerinde yer almaktadır. Ulusal sürdürülebilirlik ilkeleri ile ASHRAE-55 ve ISO 7730 termal konfor standartlarıyla uyumlu biçimde tasarlanan yapının inşasına 2017 yılında başlanmış, bina 2018 yılında tam kapasiteyle kullanıma alınmıştır. Yapının mimari kurgusu, Marmara Bölgesi'nin karasal ve denizel iklim özelliklerini birlikte barındıran yerel iklim koşullarına uyum sağlayacak biçimde planlanmıştır. Bina içinde farklı mühendislik disiplinlerine ait idari ve teknik görevlerin eşzamanlı yürütülmesine olanak sağlayan bir mekansal düzenleme öngörülmüştür.



Şekil 2.2: Bina kat mimari görüntüsü

2.2 Duvarlar

Kamu binalarında dış havaya açık duvarlar, ısı yüklerinin yönetimi ve bina enerji performansının iyileştirilmesi açısından yapı kabuğunun temel bileşenleri arasında ele alınmıştır. Sürdürülebilirlik odaklı yeşil ofis tasarımlarında, bina içi güneş ısı kazançlarını azaltmak amacıyla çift cidarlı cephe sistemlerinin kullanıldığı saptanmıştır (Lakhia et al., 2024). Cephe yönelimlerinin de bu performans üzerinde etkili olduğu belirtilmiştir; doğrudan güneş ışınlamına maruziyetin azaltılması için binaların ağırlıklı olarak güney cepheli konumlandırıldığı, ofis alanlarının ise güneşten korunmak amacıyla kuzey ve doğu yönlerine yerleştirildiği gözlemlenmiştir (Lakhia et al., 2024).

Balıkesir Büyükşehir Belediyesi Fen İşleri Dairesi Başkanlığı hizmet binasının dış ortamla temas eden düşey yapı kabuğu, dinamik enerji simülasyonlarında ısı transferini denetleyen temel yapı bileşeni olarak değerlendirilmiştir. Marmara Bölgesi'nin karasal ve denizel iklim özelliklerini birlikte barındıran yerel koşullarına uyum sağlayacak biçimde projelendirilen yapı kabuğunun, dış ortam ile iç ortam arasında ısı bir sınır yüzeyi oluşturduğu belirtilmiştir. Binaların operasyonel süreçlerinde ASHRAE-55 ve ISO 7730 standartlarına uyumun hedeflendiği bildirilmiştir.

Yapısal bütünlüğün üst sınırını oluşturan tavan ve çatı sistemleri, iç mekan termal yükleri üzerinde etkili olan mimari bileşenler arasında tanımlanmıştır. Doğrudan güneş radyasyonuna ve dış hava koşullarına maruz kalan bu sistemlerin, üst kat hacimlerindeki HVAC operasyonlarını etkilediği belirtilmiştir. Modern iç mekan çevresel standartlarını karşılamaya yönelik mimari yaklaşımın sürdürülebilirlik ilkeleriyle ilişkilendirildiği raporlanmıştır.

Bina zemin kotunda yer alan ve toprakla doğrudan temas eden taban döşemesi, yerel termal koşulların iç mekana aktarılmasında sınır yüzeyi olarak ele alınmıştır. Zemin kaynaklı ısı kayıp ve kazançlarının, mekanik sistemlerin enerji harcama profillerini mevsimsel düzeyde değiştirdiği belirtilmiştir.

Dış havaya açık duvar yapısı beş farklı katmandan oluşacak şekilde tasarlanmıştır. Katman dizilimi ve bu katmanlara ait yapısal veriler (kalınlık (d), ısı iletkenlik hesap değeri (k) ve ısı iletkenlik direnci (R) detaylı olarak aşağıda verilmiştir:

Tablo 2.1: Dış havaya açık duvar ve özellikleri

	Yapı Eleman Kalınlığı d(m)	Isıl İletkenlik Hesap Değeri (W/mK)	Isıl İletkenlik Direnci R (m ² K/W)	Isı Geçirgenlik Katsayısı U (m ² K/W)
DUVAR:Dış Havaya Açık	4.1 Kireç harcı,kireç-çimento harcı	0,02	1	0,02
	4.1 Kireç harcı,kireç-çimento harcı	0,03	1	0,03
	10.3.2.2.1 Ekstrüde Polistiren Köpüğü - TS	0,05	0,03	1,667
	5.1.1 Donatılı	3	2,5	0,12
	4.2 Çimento harcı	0,03	1,6	0,019
TOPLAM			1,856	0,5387931

Bu beş katmanın birleşimi sonucunda dış duvar yapı elemanının toplam ısı iletkenlik direnci (R) 1,856 m²K/W ve dış duvar toplam ısı geçirgenlik katsayısı (U) 0,5387931 W/m²K (0,539 W/m²K) olarak hesaplanmıştır.

Binanın tavanüzeri açık çatı bölgesi, termal dengeyi sağlamak amacıyla yedi farklı katman kullanılarak oluşturulmuştur. İlgili katmanların detaylı verileri şu şekildedir:

Tablo 2.2: Tavan üzeri açık duvar ve özellikleri

	Yapı Eleman Kalınlığı d(m)	Isıl İletkenlik Hesap Değeri (W/mK)	Isıl İletkenlik Direnci R (m ² K/W)	Isı Geçirgenlik Katsayısı U (m ² K/W)
5.1.1 Donatılı	0,02	2,5	0,08	
4.2 Çimento harcı	0,01	1,6	0,063	
9.2.2.1.5 Polimer bitümlü su yalıtım örtüleri	0,002	0,19	0,011	
10.3.2.2.1 Ekstrüde Polistiren				
Tavan Üzeri Açık Köpüğü - TS	0,05	0,03	1,667	
9.2.2.1.5 Polimer bitümlü su yalıtım örtüleri	0,002	0,19	0,011	
9.2.2.1.5 Polimer bitümlü su yalıtım örtüleri	0,002	0,19	0,011	
3.1 Kum,çakıl,kırma taş (mıcır)	0,15	0,7	0,214	
TOPLAM			2,057	0,48614487

Tavan yapı elemanını oluşturan katmanların bütünleşik hesaplamasıyla çatının toplam ısı iletkenlik direnci (R) 2,057 m²K/W, toplam ısı geçirgenlik katsayısı (U) ise 0,48614487 W/m²K (0,486 W/m²K) olarak kaydedilmiştir.

Toprakla doğrudan temas halinde olan zemin yapısı, binanın iletim yoluyla gerçekleşen ısı kayıp ve kazançlarını yönetmek için toplam on katmandan meydana gelmektedir. Katman bileşenleri sırasıyla aşağıda listelenmiştir:

Tablo 2.3: Taban toprak temaslı yapısı ve özellikleri

	Yapı Eleman Kalınlığı d(m)	Isıl İletkenlik Hesap Değeri (W/mK)	Isıl İletkenlik Direnci R (m ² K/W)	Isı Geçirgenlik Katsayısı U (m ² K/W)
	4.2 Çimento harcı	0,08	1,6	0,05
	5.1.1 Donatılı	0,2	2,5	0,08
	3.1 Kum,çakıl,kırma taş (mıcır)	0,4	0,7	0,571
	5.1.1 Donatılı	0,6	2,5	0,24
Taban Toprak Temaslı	5.1.2 Donatısız	0,1	1,65	0,061
	9.2.2.1.1 Bitümlü karton	0,004	0,19	0,021
	9.2.3.2 PVC örtü	0,002	0,19	0,011
	9.2.2.1.1 Bitümlü karton	0,004	0,19	0,021
	5.1.2 Donatısız	0,1	1,65	0,061
	3.1 Kum,çakıl,kırma taş (mıcır)	0,3	0,7	0,429
TOPLAM			1,545	0,64724919

Bu on katmanın entegrasyonu sonucunda taban toprak temaslı yüzeyin toplam ısı iletkenlik direnci (R) 1,545 m²K/W ve toplam ısı geçirgenlik katsayısı (U) 0,64724919 W/m²K (0,647 W/m²K) olarak saptanmıştır.

2.3 Pencereleler

Kamu binalarının yapı kabuğunda yer alan pencereler ve diğer şeffaf yüzeyler, dış iklim koşulları ile iç mekan arasındaki ısıl etkileşimi yöneten yapı elemanları arasında değerlendirilmiştir. Bu yüzeylerin, toplam ısı kayıp ve kazanç senaryoları üzerinde doğrudan fiziksel etki oluşturduğu saptanmıştır (Mo et al., 2024). Özellikle soğutma yükünün baskın olduğu iklim bölgelerinde yer alan ofis ve idari yapılarda, pencere sistemleri ile camlama alanlarının genel HVAC enerji tüketim profilini değiştirdiği raporlanmıştır (Mujeebu and Ashraf, 2024).



Şekil 2.3: Bina dış cephe pencere görüntüsü


Bina enerji simülasyon modelinde, doğal aydınlatma ile dış ortam termal etkileşiminin kesişim noktası olan şeffaf yüzeylerin özellikleri kesin olarak tanımlanmıştır. Pencerelelerde dış ortamdan iç ortama doğru sırasıyla 4 mm kalınlığında yeşil renkli cam, 12 mm kalınlığında hava boşluğu ve tekrar 4 mm kalınlığında yeşil renkli cam bileşenlerinden oluşan çift cam profili kullanılmıştır. Bu pencere bileşenine ait toplam ısı geçirgenlik katsayısı, yani U değeri, $1,978 \text{ W/m}^2\text{K}$ olarak model veritabanına aktarılmıştır.

2.4 İç Ortam Yük Profilleri ve Kullanım Senaryoları

Binalarda HVAC sistemlerinin dinamik işletimi, iç ortam ısı yükleri ve mekansal kullanım senaryolarıyla ilişkilendirilmektedir (Savadkoohi, 2025). İnsanlar, aydınlatma sistemleri ve elektronik ekipmanlar tarafından üretilen iç ısı kazançları, binanın anlık ısıtma ve soğutma taleplerini doğrudan değiştirmektedir. Bu nedenle kullanıcı yoğunluğu, aydınlatma kullanımı ve ekipman yükleri, enerji modellemesinde temel iç yük bileşenleri olarak ele alınmıştır. İşletme saatlerinde oluşan yük dalgalanmalarının mekanik sistemleri gereksiz çalıştırabildiği ve enerji israfını artırabildiği belirtilmiştir (Hwang et al., 2025). Kullanıcı kaynaklı ısı kazançları, doluluk oranı ve fiziksel aktivite düzeyi üzerinden değerlendirilmiştir. Bina kullanıcılarının metabolik oranlarına bağlı olarak duyulur ve gizli ısı yaydığı belirtilmiştir (Fanger, 1970). Ofis ortamlarında bilgisayar kullanımı ve oturma gibi eylemler için metabolik oran çoğunlukla 1.1 met olarak alınmıştır (Lakhari et al., 2024). Referans ofis modellerinde kişi başına 19.92 m^2 kullanım alanı ve 130 W kullanıcı ısı kazancı tanımlanmıştır (Markarian et al., 2024). Aydınlatma sistemleri, görsel konfor sağlamalarının yanında ortama ısı kazancı ekleyen bir iç yük bileşeni olarak değerlendirilmiştir (Wu et al., 2024). Elektronik cihaz ve ekipman yükleri de HVAC performansını etkileyen iç yükler arasında değerlendirilmiştir. Bilgisayar, yazıcı ve sunucu gibi ofis donanımlarının çalışma süresince ortama ısı yaydığı, bu yüklerin merkezi iklimlendirme sistemlerinin baz talebini etkilediği belirtilmiştir (Hwang et al., 2025).

Referans ofis çalışmalarında elektrikli ekipman yükü 10.27 W/m^2 , başka bir ofis hücresinde ise 8.075 W/m^2 olarak tanımlanmıştır (Markarian et al., 2024; Stevanović et al., 2024).

İncelenen kamu binasında ise idari ve teknik faaliyet profili dikkate alınarak kullanımın hafta içi günlerinde 08:30 ile 17:30 saatleri arasında yoğunlaştığı belirlenmiştir. Bu çalışma düzenine göre yapılan mekansal analiz sonucunda kullanıcı yoğunluğu $0,055 \text{ kişi/m}^2$ olarak hesaplanmış ve simülasyon programındaki yük profillerine tanımlanmıştır. Yaz döneminde, haziran, temmuz ve ağustos aylarında yıllık izin ve tatil kullanımları nedeniyle aktif kullanıcı yoğunluğunun azaldığı varsayılmış; modelin operasyonel takvimi bu değişimi yansıtacak şekilde düzenlenmiştir. Saha incelemelerinde, incelenen ofis binasında $60 \times 60 \text{ cm}$ ebatlarında ve 36 W gücünde LED aydınlatma armatürlerinin kullanıldığı tespit edilmiştir. Bu donanım bilgileri esas alınarak binanın aydınlatma gücü yoğunluğu $5,06 \text{ W/m}^2$ olarak hesaplanmış ve modele aktarılmıştır. Aydınlatma kullanım senaryosu oluşturulurken yaz ve kış aylarındaki doğal aydınlatma farklılıkları dikkate alınmıştır. Bu nedenle aydınlatmanın en yoğun kullanıldığı dönemler, hafta içi 10:00-12:00 ve 14:00-16:00 saatleri olarak kurgulanmıştır.



Şekil 2.4: İkinci kat mimari plan görüntüsü

Fen İşleri Dairesi Başkanlığı binasında günlük faaliyetlerin yürütülmesi için bilgisayar, yazıcı ve fotokopi makinesi gibi ofis cihazlarının yoğun biçimde kullanıldığı gözlenmiştir. Bu cihazların şebekeden çektiği aktif güç ve iç ortama yaydığı duyulur ısı kazancı dikkate alınarak birim alan başına elektrikli cihaz tüketimi $44,67 \text{ W/m}^2$ olarak belirlenmiştir. Bu değer, dinamik

bina modelinin iç ısı kazançları kütüphanesine işlenmiştir. Tanımlanan iç ortam yük profilleri; 0,055 kişi/m² kullanıcı yoğunluğu, 5,06 W/m² aydınlatma gücü ve 44,67 W/m² ekipman gücü değerlerinden oluşturulmuştur. Bu girdiler, dış hava sıcaklığı, nem ve güneş radyasyonu gibi meteorolojik çevresel verilerle birlikte DesignBuilder motoru tarafından eşzamanlı olarak çözümlenmektedir. Böylece binanın iç ortam termal dengesi, HVAC mekanik enerji tüketimi ve kullanıcıları etkileyen ısıl konfor indeksleri (PMV-PPD) sayısal olarak simüle edilmiştir.

2.5 İç Ortam Parametrelerinin Ölçümü ve Ölçüm Cihazı (Testo-480)

İnsan vücudu ile çevresi arasındaki ısıl dengenin hesaplanmasında temel alınan hava sıcaklığı, bağıl nem, bölgesel hava hızı ve ortalama radyan sıcaklık verileri, saha ölçüm kampanyalarıyla elde edilerek analitik modellere aktarılmıştır (Caner and İlten, 2020; Alam et al., 2024). Söz konusu konfor indisleri, modern bina tasarımlarında uluslararası standartların merkezinde yer almaktadır (ASHRAE, 2023; ISO, 2005). Saha çalışmalarında iç ortam iklimsel parametrelerinin ölçülmesi amacıyla Testo 480 çok fonksiyonlu ölçüm cihazı kullanılmıştır. Bu cihaz aracılığıyla iç ortam hava sıcaklığı, glob sıcaklık, bağıl nem ve hava hızı verilerinin kayıt altına alındığı belirtilmiştir (Caner and İlten, 2020). Cihazın teknik donanımında, iç ortam hava sıcaklığını, bağıl nemi, hava hızını ve 150 mm çaplı glob termometre aracılığıyla radyan sıcaklığı eşzamanlı olarak ölçen problar yer almaktadır. Testo 480 cihazına ait sensör ölçüm aralıkları ve tolerans değerleri belgelenmiştir (Caner and İlten, 2020). ASHRAE 55 standardına göre oturarak çalışan veya eğitim gören kullanıcı profilleri için hava sıcaklığı ile hava hızı ölçümlerinin zemin seviyesinden itibaren 0.1, 0.6 ve 1.1 metre yüksekliklerde yapılması gerektiği belirtilmiştir (ASHRAE, 2023). Ayakta duran kullanıcılar için ölçüm noktaları 0.1, 1.1 ve 1.7 metre seviyeleri olarak tanımlanmıştır. Bu yüksekliklerin seçilmesinde iç ortamda oluşabilecek düşey sıcaklık katmanlaşmasının dikkate alındığı görülmektedir.



Şekil 2.5: Testo 480 ölçüm cihazı

Tablo 2.4: Testo-480 cihaz özellikleri

Parametre	Ölçüm aralığı	Hassasiyet
Sıcaklık	-20 to +70 °C	±0.5 °C
Bağıl nem	0 to 100 %RH	±(1.0 %RH + 0.7%) 0 to 90 %RH ±(1.4 %RH + 0.7%) 90 to 100 %RH
Küre sıcaklığı Ø 150mm	0 to +120 °C	±0.3 °C
Hava akım hızı	0 to +50 °C 0 to +5 m/sn +700 to +1100 hPa	±0.5 °C ±(0.03 m/sn +4%) ±3 hPa

Bina enerji modelinin gerçek işletme koşullarına uyarlanabilmesi ve çevresel performansın doğru biçimde analiz edilebilmesi için iç ortam parametrelerinin yerinde ve eşzamanlı olarak izlenmesi gerekli görülmüştür.

İç ortam hava sıcaklığı sensörünün -20 °C ile +70 °C arasında ölçüm yapabildiği ve ±0.5 °C toleransa sahip olduğu saptanmıştır. Bağıl nem probunun %0 ile %100 aralığını ölçebildiği belirtilmiştir. Bu sensöre ait hata payı, %0-90 aralığında ±(1.0 %RH + %0.7), %90-100 aralığında ise ±(1.4 %RH + %0.7) olarak verilmiştir. Ortalama radyan sıcaklığın belirlenmesinde kullanılan 150 mm çapındaki glob termometrenin 0 °C ile +120 °C arasında çalıştığı ve ±0.3 °C sapmayla veri ürettiği kaydedilmiştir (Sandal and İlten, 2025). Hava hızı ölçümleri ise 0 ile +5 m/s hız aralığında ve ±(0.03 m/s + %4) tolerans sınırları içinde gerçekleştirilmiştir. Veri toplama sürecinde ölçüm cihazlarının, dış duvarlardan kaynaklanabilecek radyasyon etkilerini azaltmak amacıyla dış cephelerden uzak; kullanıcı koltuklarına yakın olacak biçimde tripodlar üzerine sabitlendiği ve 1.1 metre yüksekliğe yerleştirilerek ofis içi oturma pozisyonunun temsil edildiği raporlanmıştır (Barbosa et al., 2024).



Şekil 2.6: Saha ölçüm çalışmaları

2.6 İç Ortam Parametreleri ve Isıl Konfor Üzerindeki Etkileri

İç ortam ısı konforu; hava sıcaklığı, bağıl nem, hava akım hızı ve ortalama radyant sıcaklık gibi çevresel değişkenler üzerinden değerlendirilmektedir (Fanger, 1970; ASHRAE, 2023; ISO, 2005). Bu parametreler, insan vücudu ile iç ortam arasındaki ısı alışverişini belirlemekte ve kullanıcıların termal algısını doğrudan etkilemektedir. PMV modelinde hava sıcaklığı, ortalama radyant sıcaklık, bağıl nem ve hava hızı temel çevresel bileşenler olarak ele alınmıştır (Caner and İlten, 2020; Li et al., 2024; Alam et al., 2025). İç ortam hava sıcaklığı, ısıtma ve soğutma yüklerinin belirlenmesinde ana değişkenlerden biri olarak değerlendirilmiştir. ASHRAE Standart-55 ve ISO 7730 çerçevesinde iklimlendirme sezonu için uygun iç ortam sıcaklık aralığının 22 °C ile 24 °C arasında tutulması gerektiği bildirilmiştir (Caner, 2020). Farklı iklim koşullarında ise kullanıcıların kabul edilebilir sıcaklık aralıklarının değişebildiği ve tropikal ofis ortamlarında bu aralığın 24.5 °C ile 28.0 °C'ye kadar genişleyebildiği belirtilmiştir (Lakhiar et al., 2024). Enerji simülasyonlarında ısıtma tasarım sıcaklığı 18 °C, soğutma tasarım sıcaklığı ise 26 °C olarak kullanılmıştır (Han et al., 2025). Bağıl nem, kullanıcıların termal algısını ve HVAC sistemlerinin gizli ısı yükünü etkileyen bir diğer çevresel parametre olarak tanımlanmıştır. ASHRAE Standart-55 kapsamında sağlıklı iç mekanlar için bağıl nemin %30 ile %60 arasında tutulması önerilmiş, ISO 7730 kapsamında üst sınırın %70'e kadar genişleyebildiği belirtilmiştir (Caner, 2020). Yüksek sıcaklık ve yüksek nem koşullarının birlikte görüldüğü ortamlarda terin buharlaşma kapasitesinin azaldığı ve kullanıcıların ortamı daha bunaltıcı algıladığı gösterilmiştir (Zhen et al., 2025; Abdul Rahim et al., 2024). Hava akım

hızı, vücut ile çevre arasındaki konvektif ısı transferini etkileyen temel değişkenlerden biri olarak değerlendirilmiştir. Soğutma sezonu için optimum hava akım hızının ASHRAE Standart-55'e göre 0.16 m/s, ISO 7730'a göre ise 0.19 m/s olduğu belirtilmiştir (Caner, 2020). Hava hareketinin yetersiz kaldığı ortamlarda konvektif soğuma sınırlanmakta; bu durum sıcaklık hissinin artmasına ve HVAC sistemlerinin daha yüksek kapasitede çalışmasına neden olabilmektedir (Abdul Rahim et al., 2024; Jun and Fei, 2024). Ortalama radyant sıcaklık, insan vücudu ile duvar, pencere ve tavan gibi çevre yüzeyler arasındaki ışıyım yoluyla gerçekleşen ısı alışverişini temsil etmektedir (Fanger, 1970; Jun and Fei, 2024). Bu değer, siyah glob termometre sıcaklığı, hava sıcaklığı ve lokal hava akım hızı kullanılarak hesaplanabilmektedir (Caner, 2020; Lakhia et al., 2024). Güneş ışıyımına maruz kalan çatı ve cam yüzeylerin ortalama radyant sıcaklığı artırabildiği, bu durumun hava sıcaklığı kontrol altında tutulsa bile termal konforsuzluk oluşturabildiği belirtilmiştir (Abdul Rahim et al., 2024; Lei, 2024).

Bu çalışmanın saha araştırmaları kapsamında, Balıkesir Büyükşehir Belediyesi Fen İşleri Dairesi Başkanlığı binasındaki iç ortam bağıl nem (RH) değişimleri, standartlara uygun olarak zeminden 1,1 m yükseklikte konumlandırılan Testo 480 çok fonksiyonlu termal konfor analizörü ile ölçülmüştür. Elde edilen saha verileri değerlendirildiğinde, iç ortam bağıl nem değerlerinin farklı termal zonlar ve mevsimsel geçişler kapsamında %34,90 ile %64,50 arasında değiştiği tespit edilmiştir. Elde edilen saha verileri mevsimsel olarak değerlendirildiğinde, ortalama hava akım hızlarının kış döneminde 0,06 m/s, ilkbahar döneminde 0,05 m/s, sonbahar döneminde 0,07 m/s ve yaz döneminde 0,09 m/s olarak gerçekleştiği belirlenmiştir. Ölçüm periyotları sırasında, yerel türbülans etkileri veya mekanik havalandırma sisteminin taze hava üfleme anlarındaki kısa süreli dalgalanmalar nedeniyle anlık hava hızı değerlerinde dönemsel artışlar gözlenmiştir. Bu kapsamda maksimum hava hızı kış döneminde 0,11 m/s, yaz döneminde ise 0,14 m/s seviyesine ulaşmıştır. Saha ölçümlerinden elde edilen bulgulara göre, incelenen ofis binasında ortalama radyant sıcaklık (T_{mrt}) değerleri mevsimsel olarak kış döneminde 21,11 °C, ilkbahar döneminde 22,96 °C, sonbahar döneminde 24,04 °C ve yaz döneminde 25,47 °C olarak belirlenmiştir. Ortalama radyant sıcaklık değerlerinin iç ortam hava sıcaklığı (T_a) ile yakın bir dağılım göstermesi, bina kabuğuna ait iç yüzey sıcaklıklarının ölçüm dönemleri boyunca büyük ölçüde dengeli seyrettiğine işaret etmektedir. Bu durum, incelenen hacimlerde belirgin bir radyant sıcaklık asimetrisinin oluşmadığını ve dış duvarlar ile şeffaf yüzeylerin ısıl performansının iç ortam konfor koşullarını desteklediğini göstermektedir.

2.7 Isıl Konfor Saha Anketi Çalışmaları

Literatürde, iç ortam fiziksel ölçümlerinin kullanıcı algısıyla birlikte değerlendirilmesi için benzer eşzamanlı saha anketlerinin uygulandığı görülmektedir (Caner and İlten, 2020). Bu çalışmalarda yaş, cinsiyet, boy, ağırlık, giysi ısıl direnci ve metabolik aktivite gibi değişkenler toplanmış; termal his değerlendirmelerinde ASHRAE 55 standardındaki yedi noktalı ölçeklerden yararlanılmıştır (Barbosa et al., 2024; Alam et al., 2025; Mustapha et al., 2024; Mazandarani et al., 2026). Böylece fiziksel ölçüm sonuçları ile kullanıcıların algısal tepkileri aynı değerlendirme yapısı içinde ele alınmıştır.

Araştırma sahasında, nesnel fiziksel ölçümlerle eşzamanlı olarak kullanıcıların öznel ısıl konfor değerlendirmeleri kayıt altına alınmıştır. Anket çalışmaları mesai saatleri içinde yüz yüze görüşme yöntemiyle yürütülmüş; form yapısı ASHRAE 55 ve ISO 7730 standartlarında belirtilen ilkeler doğrultusunda oluşturulmuştur. Bu çalışmada yürütülen saha anketleri, yaz, kış, ilkbahar ve sonbahar dönemlerini kapsayacak şekilde uygulanmıştır. Toplam 243 adet anket toplanmış ve her anket, aynı anda elde edilen bölgesel çevresel ölçüm verileriyle eşleştirilmiştir. Bu yöntemle, PMV-PPD gibi nesnel konfor indeksleri ile kullanıcıların gerçek termal algıları birlikte değerlendirilmiş; mekanik olarak iklimlendirilmiş kamu binasının gerçek kullanıcı deneyimi üzerinden analiz edilmesi amaçlanmıştır. Saha çalışmalarında kullanılan anket formu, katılımcıların ısıl konfora etki eden tüm kişisel ve çevresel duyarlılıklarını saptayabilmek amacıyla üç ana bölümden oluşacak şekilde tasarlanmıştır:

2.7.1 Saha Anketinin Birinci Bölümü (Demografik ve Kişisel Veriler)

Ofis binalarında yaş ve cinsiyet değişkenlerinin termal memnuniyet üzerinde farklılık oluşturabildiği gösterilmiştir (Choi et al., 2010; Indraganti et al., 2015). Erkek ve kadın kullanıcıların ortam sıcaklığına verdikleri tepkilerin değişebilmesi, cinsiyetin ısıl konfor değerlendirmelerinde bireysel bir parametre olarak ele alınmasına neden olmuştur (Karjalainen, 2007; Parsons, 2002). Bu nedenle fiziksel ortam koşulları standart sınırlar içinde kalsa bile, kullanıcı algısındaki farklılıkların ayrıca incelenmesi gerekmiştir.

Saha anketinin ilk bölümü, katılımcıların yaş, cinsiyet ve ısıl konfor algısını etkileyebilecek sağlık durumlarının belirlenmesi amacıyla yapılandırılmıştır. Bu çalışmada anketin giriş bölümünde, kullanıcıların termal algısında farklılık oluşturabilecek temel kişisel bilgiler toplanmıştır. Katılımcıların yaşı, cinsiyeti ve ısıl konfor toleransını etkileyebilecek sağlık durumları kayıt altına alınmıştır. Bu veriler, özellikle 30 yaş altı ve 30 yaş üstü bireyler ile

cinsiyet grupları arasında oluşabilecek algısal farklılıkların açıklanmasında kullanılmıştır. Kullanıcıların sahadaki gerçek konfor algısının değerlendirilebilmesi için bu değişkenlerin anket yoluyla belirlenmesi amaçlanmıştır.

2.7.2 Saha Anketinin İkinci Bölümü (Bağlamsal Faktörler, Giyim Yalıtımı ve Metabolik Hız)

Isıl konfor değerlendirmelerinde kullanılan Tahmini Ortalama Oy (PMV) indeksi, çevresel değişkenlerin yanında iki temel kişisel parametreye dayandırılmıştır. Bu parametreler metabolik hız (met) ve giysi yalıtım direnci (clo) olarak tanımlanmıştır (Fanger, 1970; Rupp et al., 2015). Literatürde standart ofis aktiviteleri için çoğunlukla 1.0, 1.1 veya 1.2 met aralığının kullanıldığı görülmektedir (Kim et al., 2024; Lakhia et al., 2024; Mazandarani et al., 2026; Song et al., 2025). Giysi yalıtımı, vücut ile çevre arasındaki ısı geçişini sınırlayan kişisel bir direnç bileşeni olarak değerlendirilmiştir. Uluslararası standartlarda 1 clo değerinin 0.155 m²K/W ısıl dirence karşılık geldiği belirtilmiştir (Schiavon and Lee, 2013). Giyim yalıtımındaki farklılıkların kullanıcıların optimum çalışma sıcaklığı beklentilerini yaklaşık 0.9 °C ile 2.5 °C arasında değiştirebildiği gösterilmiştir. Düşük clo değerine sahip kullanıcıların, ısıl beklentilerin karşılanamadığı koşullarda daha yüksek düzeyde bölgesel rahatsızlık bildirdiği belirtilmiştir. Literatürde yazlık giysiler için 0.65 clo, kışlık ofis giysileri için 1.0 clo değerlerinin kullanıldığı; oturma pozisyonunda ofis sandalyesinin toplam giysi yalıtımına 0.1 clo katkı sağladığı raporlanmıştır (Iddio et al., 2025; Song et al., 2025; Warthmann et al., 2025). Esnek giyim kurallarına sahip ortamlarda 0.59 ile 0.74 clo aralığında %76 termal kabul edilebilirlik elde edilirken, katı üniforma zorunluluğu bulunan gruplarda yalıtımın 0.75 ile 1.20 clo aralığında yoğunlaştığı ve memnuniyetin azaldığı belirlenmiştir (Zaraa Allah et al., 2025). PMV modelinde metabolik ısı üretimi, dış mekanik güç, giysi yüzey sıcaklığı ve giysi alan katsayısı gibi değişkenler matematiksel yapıya dahil edilmektedir (Jiang et al., 2024; Jun and Fei, 2024). Buna karşın, gerçek saha koşullarında bireysel metabolik hızların ve giysi yalıtım değerlerinin doğrudan ve yüksek doğrulukla belirlenmesi güç bir veri süreci olarak tanımlanmıştır (Jiang et al., 2024).

Anketin ikinci bölümü, katılımcıların ölçüm anındaki fiziksel durumlarını ve çalışma ortamına ilişkin bağlamsal koşulları tanımlamak üzere yapılandırılmıştır. Bu kapsamda katılımcıların termal zonda bulunma süreleri, çalışma alanları çevresinde lokal ısıtıcı veya soğutucu donanım bulunup bulunmadığı ve son bir saat içinde yürüttükleri faaliyet türleri kayıt altına alınmıştır. Metabolik hız değerleri, katılımcıların ölçüm anındaki fiziksel aktivite düzeyine göre

belirlenmiştir. Okuma, yazma ve bilgisayar kullanımı gibi masa başı ofis görevleri için 1.5 met referans katsayısı kullanılmıştır. Saha denetimi veya mekanik bakım-onarım gibi daha fazla fiziksel efor gerektiren teknik görevlerde ise metabolik hız 2.0 met olarak değerlendirilmiştir. Araştırma sahasında elde edilen anket yanıtları ISO 7730 standartları esas alınarak mevsimsel giyim profillerine dönüştürülmüştür. Yaz döneminde idari ofis çalışanları için 1.0 clo, koruyucu üniforma kullanan saha personeli için 1.2 clo değeri kullanılmıştır. Kış, ilkbahar ve sonbahar dönemlerinde ise iç mekan ofis çalışanları için 1.2 clo, dış ortam görevlerini sürdüren saha ekipleri için 1.5 clo değeri denklemlere aktarılmıştır. Bu nedenle anket verileri, standart simülasyon kabullerinin yerine kullanıcıların gerçek giyim ve aktivite durumlarını modele aktarmak için kullanılmıştır. Bu çerçevede, anketin ikinci bölümü Fanger modelinin kişisel parametreleri olan met ve clo değerlerinin saha koşullarına göre belirlenmesine hizmet etmiştir. Bu veriler sayesinde, aynı fiziksel ortam koşullarında farklı kullanıcı gruplarına ait mevsimsel ve bireysel değişimlerin ısı konfor modeline aktarılması sağlanmıştır. Bu demografik ve fizyolojik veri yapısı, öznel ısı konfor sonuçlarının HVAC optimizasyon süreçleriyle ilişkilendirilmesine veri sağlamıştır.

2.7.3 Saha Anketinin Üçüncü Bölümü (Subjektif Değerlendirme ve Algı Endeksleri)

Literatürde, öznel ısı konfor analizlerinde Isıl Duyum Oyu (TSV), Isıl Konfor Oyu (TCV), Isıl Tercih Oyu (TPV) ve Isıl Kabul Edilebilirlik Oyu (TAV) gibi göstergelerden yararlanıldığı belirtilmiştir (Azzazy et al., 2024; Mao et al., 2024; Mustapha et al., 2023). Bu göstergeler, (PMV) ve (PPD) gibi teorik indekslerin saha koşullarındaki karşılıklarını sınamak için kullanılmaktadır. Bazı çalışmalarda anket sonuçları, operatif sıcaklık veya standart etkin sıcaklık (SET) gibi çevresel değişkenlerle birlikte değerlendirilmiştir (Mustapha et al., 2023; Zhen et al., 2025).

Saha anketinin üçüncü bölümü, bina kullanıcılarının ölçüm anındaki fiziksel çevre koşullarına yönelik öznel değerlendirmelerini sayısallaştırmak amacıyla tasarlanmıştır. Bu bölümde, kullanıcıların anlık ısıl duyumları ve mevcut ortam koşullarını kabul etme düzeyleri değerlendirilmiştir. Katılımcıların termal algısını ölçmek için Fanger tarafından geliştirilen ve (-3) “çok soğuk” ile (+3) “çok sıcak” arasında değişen yedi noktalı ısıl duyum ölçeği kullanılmıştır. Bu ölçek aracılığıyla “Çalışma ortamınızın sıcaklığını şu anda nasıl değerlendiriyorsunuz?” ve “Mevcut çalışma ortamı koşulları sizin için kabul edilebilir mi?” sorularına verilen yanıtlar sayısal hale getirilmiştir. Bu öznel yanıtlar, Gerçek Ortalama Oy (AMV) ve Gerçek Memnuniyetsizlik Yüzdesi (APD) değerlerinin hesaplanmasında


kullanılmıştır. Anket kapsamında yalnızca sıcaklık algısı değil, kullanıcıların ısı tercihleri ve ortam kabul edilebilirliği de sorgulanmıştır. Katılımcılardan ortamın daha sıcak, daha serin veya mevcut haliyle kalması yönündeki tercihlerini belirtmeleri istenmiştir. Kabul edilebilirlik değerlendirmesi ise evet/hayır biçiminde sınıflandırılmıştır. Ayrıca hava hareketinin durgun, hoş veya rahatsız edici hava akımı olarak algılanması ile aydınlatma düzeyinin yeterliliği de aynı bölümde kayıt altına alınmıştır. Böylece iç ortam kalitesi, yalnızca sıcaklık hissiyle değil, hava hareketi ve aydınlatma algısıyla birlikte değerlendirilmiştir.

Tablo 2.5: Isıl duyum ölçeği yapısal dağılımı ve sayısal karşılıkları

Isıl Algı Düzeyi	İngilizce Karşılığı	ASHRAE Ölçeği	Bedford Ölçeği
Çok soğuk	Cold	-3	1
Soğuk / Serin	Cool	-2	2
Biraz soğuk / Hafif serin	Slightly cool	-1	3
Normal / Nötr / Konforlu	Neutral / Comfortable	0	4
Biraz sıcak / Hafif ılık	Slightly warm	+1	5
Sıcak / Ilık	Warm	+2	6
Çok sıcak	Hot	+3	7

2.8 Bina Enerji Simülasyonunun Temel Prensipleri ve DesignBuilder Arayüzü

Dinamik bina enerji simülasyonları, fiziksel yapıların termal yüklerini ve HVAC sistem performanslarını değişken işletme koşulları altında hesaplamak amacıyla kullanılmaktadır (Abbasabadi et al., 2026; Rizzo, 2025). Bu süreçte ısıtma ve soğutma enerji talepleri; iç ortam aydınlatma yükleri, mekanik havalandırma, iklimlendirme sistemleri ve enerji akışlarıyla birlikte değerlendirilmiştir (Makawi et al., 2026; Yang et al., 2024). Bina enerji performansı analizlerinde yaygın biçimde kullanılan EnergyPlus simülasyon motorunun, ısı dengesi hesaplarına dayalı olarak çalıştığı ve yüksek doğrulukta sonuçlar üretebildiği belirtilmiştir (Rizzo, 2025; Chinde et al., 2026; Reza-E-Rabbi et al., 2026).




Şekil 2.7: Designbuilder programı ekran görüntüsü

EnergyPlus simülasyonununda iç ortam termal koşullarının korunması için ortama eklenmesi veya ortamdan uzaklaştırılması gereken ısı miktarını dinamik biçimde hesaplanmaktadır (Rizzo, 2025). Simülasyonların fiziksel gerçekliği temsil edebilmesi için bina geometrisi, yapı malzemeleri, şeffaf ve opak yüzey özellikleri, iç ısı kazançları, kullanıcı doluluk profilleri ve yerel meteorolojik veriler modele tanımlanmaktadır (Rizzo, 2025; Yang et al., 2024). Böylece pasif yapı bileşenleri ile aktif HVAC sistemleri aynı hesaplama ortamında birlikte ele alınmaktadır. EnergyPlus'ın metin tabanlı IDF formatıyla çalışması ve doğrudan kullanıcı dostu bir grafik arayüz sunmaması nedeniyle, görsel modelleme ortamı sağlayan yardımcı yazılımlara ihtiyaç duyulmuştur (Rizzo, 2025). Bu kapsamda DesignBuilder yazılımı, EnergyPlus altyapısı üzerine kurulu grafik arayüzlü bir modelleme platformu olarak kullanılmıştır (Jiang et al., 2024; Reza-E-Rabbi et al., 2026). DesignBuilder arayüzü sayesinde bina geometrisi, sınır koşulları, malzeme özellikleri, iç yükler ve HVAC sistem girdileri daha görsel ve parametrik bir ortamda tanımlanabilmektedir (Alajmi, 2025; Jun and Fei, 2024). DesignBuilder içinde HVAC sistemleri basit, kompakt ve detaylı konfigürasyon seçenekleriyle tanımlanabilmektedir (Makawi et al., 2026). Soğutma kapasitesi ve hava akış debisi gibi mekanik parametrelerin EnergyPlus tarafından otomatik boyutlandırılabilirdiği ya da kullanıcı tarafından manuel olarak girilebildiği belirtilmiştir (Makawi et al., 2026). Ayrıca 'ZoneHVAC: IdealLoadsAirSystem' modülünün,

ortamların iklimlendirme taleplerini ve enerji tüketim performansını simüle etmek amacıyla kullanıldığı raporlanmıştır (Jun and Fei, 2024). Bina enerji modelinin doğruluğunu artırmak için coğrafi konum, bina yönelimi, geometrik ölçüler, pencere-duvar oranı, kullanıcı yoğunluğu, aydınlatma ve ekipman güç yoğunlukları ile termostat set noktaları gibi parametreler modele aktarılmıştır (Alajmi, 2025). Bununla birlikte, DesignBuilder yazılımının dinamik sıcaklık kontrolü ve histerezis mekanizması bakımından bazı sınırlılıklar gösterebildiği belirtilmiştir (Makawi et al., 2026).

Bu nedenle çalışmada, DesignBuilder arayüzüne dışarıdan ek teknik varsayım yapılmadan, kaynaklarda açık biçimde verilen EnergyPlus temelli simülasyon ilkeleri ve modelleme bileşenleri esas alınmıştır.



Şekil 2.8: Design builder programı model görüntüsü

2.9 Dinamik Bina Enerji Modellenmesi: Modelleme ve Yapısal Özelliklerin İşlenmesi

Dinamik bina enerji simülasyonlarında, fiziksel yapının dijital ortamda gerçeğe yakın biçimde temsil edilmesi temel modelleme aşamalarından biri olarak kabul edilmiştir (Abbasabadi et al., 2026). Bu kapsamda mimari proje verileri, geometrik boyutlar ve çevresel yönelim bilgileri simülasyon arayüzlerine aktarılmaktadır. EnergyPlus hesaplama motoru tabanlı DesignBuilder arayüzünde, yapı geometrisi ve yönelim bilgileri enerji modelinin ilk veri katmanını oluşturmaktadır (Alajmi, 2025). Bazı çalışmalarda üç boyutlu bina geometrilerinin Revit ortamında oluşturulduğu ve daha sonra DesignBuilder simülasyon modülüne aktarıldığı raporlanmıştır (Jun and Fei, 2024). Bu aktarım sonrasında, binanın gerçek çalışma koşullarını temsil edebilmesi için model üzerinde operasyonel düzenlemeler yapılmıştır. Böylece BIM tabanlı geometrik model ile enerji simülasyon ortamı arasında veri sürekliliği sağlanmıştır. Sanal enerji modelinin doğru çalışabilmesi için dış duvar, çatı, zemin döşemesi, iç bölme duvarları ve pencere bileşenleri yazılıma tanımlanmıştır (Alajmi, 2025; Makawi et al., 2026). Şeffaf yüzeylere ait ısı ve ışık geçirgenlik özellikleri, pencere-duvar oranları ve gölgeleme bileşenleri de model girdileri arasında yer almıştır (Alajmi, 2025). Termal zonlama ise iç ortam ısı dinamiklerinin hesaplanabilmesi için temel sınır koşulu olarak değerlendirilmiştir. Referans ofis modellerinde katların çekirdek ve çevre zonlara ayrıldığı; farklı bina tiplerinde ise çok sayıda termal zon tanımlandığı belirtilmiştir (Markarian et al., 2024; Shirzadi et al., 2025). İklimlendirme operasyonlarının mekansal ölçekte değerlendirilebilmesi için iç hacimler, HVAC sistemlerinin etki alanlarına göre termal zonlara ayrılmıştır (Alajmi, 2025). Her bir mekanik soğutma ünitesinin kendi şartlandırılmış zonuyla eşleştirilebildiği ve ölçülen iç ortam sıcaklıklarının ilgili sistem bölgesiyle ilişkilendirildiği bildirilmiştir (Makawi et al., 2026).

Sanal modelin gerçeğe en yakın termal davranışı sergileyebilmesi için, binayı çevreleyen kabuk elemanlarının (duvar, çatı, zemin ve pencereler) katman dizilimleri ve ısı özellikleri (kalınlık, ısı iletkenlik ve ısı direnç değerleri) DesignBuilder malzeme veritabanına titizlikle tanımlanmıştır. Yapının ısıtma ve soğutma yüklerini doğrudan etkileyen Toplam Isı Geçirgenlik Katsayıları (U değerleri), kullanılan her bir yapı bileşeni için aşağıda Tablo 2.6' da detaylandırılmıştır.

Tablo 2.6: Bina kabuğu yapı elemanlarının ısı özellikleri ve u değerleri

Yapı Elemanı	Malzeme Bileşenleri(Dıştan İçe Doğru Katmanlar)	U Değeri(W/m ² K)
Dış Duvar	Kireç harcı (0,02 m), kireç-çimento harcı (0,03 m), XPS yalıtım (0,05 m), donatılı beton (3 m)*, çimento harcı	0,539
Çatı	Kum/çakıl/mıcır (0,15 m), su yalıtım örtüleri, XPS yalıtım (0,05 m), çimento harcı, donatılı beton	0,486
Taban / Zemin	Kum/çakıl (0,30 m), donatısız beton, PVC örtü, bitümlü karton, donatılı beton, çimento harcı vb.	0,647
Pencere	Çift cam: 4 mm yeşil cam + 12 mm hava boşluğu + 4 mm yeşil cam	1,978

2.10 Dinamik Bina Enerji Modellenmesi Model Kalibrasyonu ve Dijital İkiz

Binaların operasyonel performansının iyileştirilmesi amacıyla, fiziksel sistemleri sanal ortamda eşzamanlı temsil eden dijital ikiz mimarileri geliştirilmiştir. Bu süreç; veri toplama, model oluşturma, simülasyon analizi ve doğrulama iterasyonu aşamaları üzerinden yapılandırılmıştır (Liu et al., 2025). Bina enerji optimizasyonunda dijital ikizlerin, Yapı Bilgi Modellemesi platformları ve gerçek zamanlı sensör verileriyle birlikte kullanıldığı belirtilmiştir (Villano et al., 2024). Bu veri akışı sayesinde binanın anlık termal tepkileri sanal ortamda simüle edilmiş ve enerji tüketiminin azaltılmasına yönelik daha gerçekçi işletme sonuçları elde edilmiştir (Villano et al., 2024). Simülasyon modellerinin gerçek bina davranışını temsil edebilmesi için kalibrasyon süreçleri yürütülmüştür. Bu kapsamda sanal enerji modelinden elde edilen ısı talepleri, iç ortam sıcaklıkları ve HVAC sistem davranışları; elektrik faturaları, aktif güç kayıtları ve sayaç verileriyle karşılaştırılmıştır (Rizzo, 2025). Modelin fiziksel ortamla uyumu, ASHRAE Guideline 14 standardında tanımlanan Ölçüm ve Doğrulama prosedürleriyle sınanmıştır (Chinde et al., 2026). Kalibrasyon sürecinde sensör ağlarından ve sistem günlüklerinden elde edilen operasyonel veriler dijital modele aktarılmıştır. Böylece modelin tahmin sonuçlarının mevcut saha koşullarıyla uyumlu hale getirilmesi amaçlanmıştır (Liu et al., 2025). Bu süreç yalnızca fiziksel parametrelerin ayarlanmasıyla sınırlı kalmamış; Çoklu Doğrusal Regresyon, Yapay Sinir Ağları ve Destek Vektör Makineleri gibi veri odaklı yöntemlerle de desteklenmiştir (Starke and da Silva, 2025). Model doğruluğunun değerlendirilmesinde istatistiksel hata göstergeleri kullanılmıştır. Dinamik simülasyonlarda ve algoritma performans testlerinde Kök Ortalama Kare Hata (RMSE), Ortalama Mutlak Hata (MAE), Ortalama Mutlak Yüzde Hata (MAPE), Ortalama Sapma Hatası (MBE), Kök Ortalama Kare Hatanın Değişim Katsayısı (CVRMSE), Normalize Edilmiş Ortalama Sapma Hatası

(NMBE) ve Kök Ortalama Kare Hata Varyasyon Katsayısı (CVR-MSE) gibi metriklerden yararlanılmıştır (Islam et al., 2026; Savadkoobi, 2025; Sisman et al., 2025; Chinde et al., 2026; Starke and da Silva, 2025; Wang et al., 2024). Kalibrasyon başarısı, ASHRAE 14 kılavuzunda belirtilen tolerans sınırlarıyla karşılaştırılmıştır. Modelin geçerli sayılabilmesi için NMBE değerinde %10, CV-RMSE değerinde ise %15 sınırları kabul edilebilir eşikler olarak alınmıştır (Fang et al., 2025). Bu eşiklere ulaşıldığında, oluşturulan dijital modelin enerji performansı değerlendirmelerinde güvenilir bir referans araç olarak kullanılabileceği belirtilmiştir (Makawi et al., 2026).

Bu çalışmada model doğruluk onayı; ASHRAE Guideline 14, IPMVP ve FEMP tarafından tanımlanan istatistiksel hata kısıtlarına dayandırılmıştır. ASHRAE Guideline 14'e göre, kalibre edilmiş bir modelde aylık bazda MBE değerinin %5, CVRMSE değerinin ise %15'in altında olması beklenmiştir. Kalibrasyon işlemi, Fen İşleri Dairesi Başkanlığı binasına ait dört yıllık geçmiş gerçek aylık/mevsimsel doğalgaz ve elektrik tüketim faturaları kullanılarak gerçekleştirilmiştir. Simülasyon modeli ile gerçek veriler arasındaki karşılaştırmalı analiz sonuçlarına göre model oldukça yüksek bir hassasiyete ulaşmıştır.

Tablo 2.7: Bina enerji modeli kalibrasyon sonuçları

Parametre	Gerçek Veri(Saha / Fatura)	Simülasyon Sonucu	Hata Payı(MBE %)
Yıllıkelektrik tüketimi (kWh)	806.177	807.627	+%0,18
Yıllıkdoğalgaztüketimi (kWh)	732.835	770.965	+%5,20
Kış dönemi iç ortam sıcaklığı (°C)	21,22	22,34	+%5,28
Yaz dönemi iç ortam sıcaklığı (°C)	25,78	27,15	+%5,31

Sonuç olarak; binanın yıllık elektrik tüketiminde yalnızca +%0,18, doğalgaz tüketiminde ise kabul edilebilir limitlere çok yakın olan +%5,20'lik bir sapma tespit edilmiştir. İç ortam hava sıcaklıklarındaki mevsimsel farklılıklar da standartların öngördüğü hata limitleri içerisinde kalmış ve bina enerji simülasyon modelinin gerçek enerji davranışını güvenilir bir şekilde temsil ettiği ispatlanmıştır.

2.11 Optimizasyon Çalışmaları: Giriş

HVAC operasyonlarının yönetiminde kalibre edilmiş dinamik enerji modelleri ve sahadan elde edilen ampirik veriler, çok amaçlı optimizasyon süreçlerinin temel dijital altyapısı olarak değerlendirilmiştir. Bu süreçlerde enerji tüketiminin azaltılması ve bina kullanıcılarının ısı konfor düzeyinin korunması birlikte ele alınmıştır (Li et al., 2026; Zhang et al., 2026). Literatürde enerji tüketimini minimize etme hedefi ile ısı konforu artırma veya rahatsızlık oranını azaltma hedefinin birbiriyle çeliştiği belirtilmiştir (Lin et al., 2022; Ouanes and Sriti, 2024). Bu nedenle HVAC sistemlerinde enerji tasarrufu ve kullanıcı konforunu aynı değerlendirme yapısı içinde ele alan optimizasyon yaklaşımları kullanılmıştır (Fang et al., 2025). Enerji verimliliği ve iç ortam termal konforu, bina performansında eşzamanlı olarak iyileştirilmesi gereken iki temel hedef olarak tanımlanmıştır (Jun and Fei, 2024). Bu hedeflerin dengelenmesi için kalibre edilmiş dinamik bina enerji simülasyonlarından yararlanılmıştır (Han et al., 2025; Markarian et al., 2024). Böylece gerçek saha verileriyle desteklenen enerji modelleri üzerinden, sistemin termal davranışı sanal ortamda daha gerçekçi biçimde temsil edilmiştir (Villano et al., 2024). Çok amaçlı optimizasyon problemlerinin çözümünde Pareto tabanlı sezgisel ve meta-sezgisel algoritmalar kullanılmıştır. ANN-MOGA, NSGA-II ve PSO gibi yöntemlerin HVAC enerji-konfor dengesini kurmak amacıyla uygulandığı raporlanmıştır (Fu et al., 2025; Hosamo et al., 2022; Li et al., 2026; Zhang et al., 2026). Karşılaştırmalı çalışmalarda NSGA-II algoritmasının çözüm çeşitliliği ve Pareto cephesine yakınsama kapasitesi bakımından öne çıktığı belirtilmiştir (Jun and Fei, 2024). Optimizasyon süreçlerinde yıllık enerji talebi, enerji kullanım yoğunluğu, PMV tabanlı termal konfor düzeyi, rahatsızlık süresi oranı ve ilk yatırım maliyeti gibi performans göstergeleri amaç fonksiyonlarına dahil edilmiştir (Han et al., 2025; Jun and Fei, 2024). Bina yönelimi, yalıtım kalınlığı, pencere-duvar oranı ve HVAC sıcaklık ayar noktaları gibi karar değişkenleri, belirlenen alt ve üst sınırlar arasında optimize edilmiştir (Han et al., 2025; Markarian et al., 2024). Makine öğrenmesi destekli optimizasyon yaklaşımlarında GLSSVM ve NSGA-II algoritmalarının birlikte kullanıldığı modellerle bina enerji tüketiminin %37.5 oranında azaltıldığı, ısı konforun ise %33.5 oranında artırıldığı gösterilmiştir (Alam et al., 2024). Mekanik sistem düzeyinde ise yalnızca sıcaklık set noktaları değil, soğutulmuş su besleme sıcaklıkları ve kısmi yük koşulları da optimizasyon sürecine dahil edilmiştir (Fang et al., 2025). Ayrıca SSA, MGO ve ENTGWO gibi arama stratejileri, yapay sinir ağı tabanlı öngörü modellerinin performansını artırmak için değerlendirilmiştir (Eker et al., 2024; Tuğal, 2025).

2.12 Optimizasyon Çalışmaları: Makine Öğrenmesi, WEKA, SMOREg ve MLP

Bina enerji tüketimi ve iç ortam ısı konforunun tahmin edilmesinde, çevresel ve fizyolojik değişkenler arasındaki doğrusal olmayan ilişkileri modelleyebilen makine öğrenmesi algoritmaları kullanılmıştır (Alam et al., 2024). Bu kapsamda Destek Vektör Makineleri (SVM) ve Yapay Sinir Ağları (NN/ANN) tabanlı tahmin modellerinden yararlanılmıştır. Destek Vektör Regresyonu (SVR), istatistiksel öğrenme teorisine dayalı ve yapısal risk minimizasyonu ilkesiyle çalışan bir yöntem olarak tanımlanmıştır (Ozdemir and Pektezel, 2025). Regresyon problemlerinde Sıralı Minimal Optimizasyon (Sequential Minimal Optimization- SMO) algoritmasının kullanıldığı ve doğrusal olmayan ilişkilerin çekirdek fonksiyonları aracılığıyla yüksek boyutlu özellik uzaylarına taşındığı belirtilmiştir (Shevade et al., 2000). SMOREg algoritması, SVM yapısına dayalı doğrusal olmayan regresyon problemlerinin çözümünde kullanılan bir tahmin yöntemi olarak değerlendirilmiştir (Koşum and Özkan, 2025). Bu algorithmada, eğitim verilerinden türetilen regresyon fonksiyonunun oluşturulması için destek vektörlerine ait ağırlıklar yinelemeli olarak güncellenmektedir. Çok Katmanlı Algılayıcı (Multilayer Perceptron - MLP), girdi katmanı, bir veya daha fazla gizli katman ve çıktı katmanından oluşan ileri beslemeli bir yapay sinir ağı modeli olarak tanımlanmıştır (Ozdemir and Pektezel, 2025; Pektezel, 2025). Gizli katman çıktıları, çıktı katmanı değerleri bağıntılarla hesaplanmıştır (Tuğal, 2025). Ağırlık ve sapma terimleri, model hatasını azaltmak amacıyla güncelleme kuralı üzerinden düzenlenmiştir (Tuğal, 2025). Eğitim süreçlerinde sigmoid, ReLU ve hiperbolik tanjant gibi doğrusal olmayan aktivasyon fonksiyonlarından yararlanılmıştır (Tuğal, 2025; Zeynalli and Eslami, 2025). Makine öğrenmesi modellerinin eğitim, test ve doğrulama aşamaları, genelleme kapasitesinin değerlendirilebilmesi için bağımsız alt veri setleri üzerinden yürütülmektedir (Ozdemir and Pektezel, 2025). Literatürde veri setlerinin çoğunlukla %80 eğitim ve %20 doğrulama/test olarak ayrıldığı; farklı çalışmalarda %70 eğitim, %15 doğrulama, %15 test veya %90 eğitim, %10 test oranlarının da kullanıldığı belirtilmiştir (Alam et al., 2024; Tuğal, 2025; Zeynalli and Eslami, 2025). Tahmin modellerinin başarısı, Kök Ortalama Kare Hata (RMSE), Ortalama Mutlak Hata (MAE), Ortalama Kare Hata (MSE) ve Belirleyicilik Katsayısı (R^2) gibi performans göstergeleriyle değerlendirilmiştir (de las Morenas et al., 2025; Islam et al., 2026; Ozdemir and Pektezel, 2025). R^2 katsayısının 1'e yaklaşması modelin gerçek verilerle uyumunun arttığını, RMSE ve MAE değerlerinin küçülmesi ise tahmin sapmalarının azaldığını göstermektedir (Zeynalli and Eslami, 2025).

Veri odaklı tahmin ve vekil modelleme süreçlerinde, karmaşık veri setlerinin işlenmesi ve makine öğrenmesi algoritmalarının uygulanması amacıyla WEKA (Waikato Environment for Knowledge Analysis) yazılım altyapısından yararlanılmıştır (The University of Waikato, 2020).

WEKA arayüzü; veri ön işleme, model kurma ve performans değerlendirme aşamalarını aynı çalışma ortamında birleştiren açık kaynaklı bir analiz platformu olarak kullanılmıştır (Koşum and Özkan, 2025). Simülasyonlardan elde edilen çevresel ve yapısal parametrelerin yazılıma aktarılmasında ARFF (Attribute-Relation File Format) veri formatından yararlanılmıştır (Koşum and Özkan, 2025). WEKA tabanlı modelleme sürecinde verilerde %70 eğitim, %30 test oranı kullanılmıştır.

2.13 Optimizasyon Çalışmaları: Problemin Tanımlanması

HVAC sistemlerinin operasyonel optimizasyonu, enerji tüketiminin azaltılması ile iç ortam ısı konforunun artırılması hedeflerini birlikte ele alan çok amaçlı bir problem olarak değerlendirilmiştir (Jun and Fei, 2024). Enerji tasarrufu ile kullanıcı konforu arasındaki ilişkinin HVAC yönetiminde temel problem alanı olduğu belirtilmiştir (Lin et al., 2022). Bu nedenle optimizasyon süreçlerinde bağımlı değişkenler, operasyonel enerji tüketiminin düşürülmesi ve ısı konforunun iyileştirilmesi biçiminde sınıflandırılmıştır (Hosamo et al., 2022; Ouanes and Sriti, 2024). Çok amaçlı yapılarda toplam enerji tüketimi, iç ortam hava kalitesi, yıllık enerji talebi, enerji kullanım yoğunluğu, pik elektrik yükleri, tahmini ortalama oy ve rahatsızlık süresi oranı temel amaç göstergeleri olarak kullanılmıştır (Han et al., 2025; Jun and Fei, 2024; Markarian et al., 2024). Optimizasyon problemlerinde kullanılan bağımsız karar değişkenleri, mekanik sistem işletmesi ve bina ölçeğindeki tasarım parametreleri üzerinden tanımlanmıştır. Chiller çıkış suyu sıcaklıkları 7-15 °C, su pompası frekansları 35-50 Hz, fan devir hızları, kompresör rotasyonları ve cihazların aç-kapa durumları karar mekanizmasına dahil edilmiştir (Zhang et al., 2025; Zhu and Lin, 2024). Bina ölçeğinde ise dış duvar ve çatı ısı dirençleri veya U-değerleri, güneş ısı kazan katsayısı, pencere-duvar oranı, bina yönelimi, hava sızma oranı, ısıtma verimi ve soğutma performans katsayısı temel değişkenler olarak ele alınmıştır (Han et al., 2025; Jun and Fei, 2024; Markarian et al., 2024).

Bu çalışma kapsamında Balıkesir'deki kamu binasına uyarlanan optimizasyon senaryolarında, HVAC sistem performansını etkileyen temel işletme değişkenleri belirli aralıklarda değerlendirilmiştir. Bu doğrultuda soğutma performans katsayısı (COP) için 2,5-4,0, kazan verimi için 0,70-0,95, sıcaklık ayar noktası için 22-24 °C ve hava değişim oranı (ACH) için 0,7-3,0 aralıkları kullanılmıştır. Bu değişkenler üzerinden yürütülen senaryolarla, enerji tüketiminin azaltılması ve iç ortam ısı konforunun korunması hedefleri birlikte ele alınmıştır. Böylece optimizasyon süreci, literatürde tanımlanan genel karar değişkenleri ve kısıt

yapılarının yanı sıra, incelenen kamu binasının işletme koşullarına uyarlanmış parametre aralıkları üzerinden değerlendirilmiştir.

Tablo 2.8 Karar Değişkenleri

Karar Değişkeni	Alt Sınır	Üst Sınır
Soğutma Performans Katsayısı (COP)	2,5	4,0
Kazan Verimi	0,70	0,95
Sıcaklık Ayar Noktası (Set Point)	22	24
Hava Değişim Oranı (ACH)	0,7	3,0

3. BULGULAR VE ANALİZ SONUÇLARI

3.1 Isıl Konfor Bulgularının Mevsimsel Analizi

Balıkesir Büyükşehir Belediyesi Fen İşleri Dairesi Başkanlığı hizmet binasında Testo-480 ölçüm cihazı ve eşzamanlı anket uygulamalarıyla elde edilen ısı konfor verileri, yaz, kış, ilkbahar ve sonbahar dönemleri üzerinden değerlendirilmiştir. Bu değerlendirmede, Fanger'in PMV-PPD modeliyle hesaplanan teorik konfor sonuçları ile kullanıcıların Gerçek Ortalama Oy (AMV) ve Gerçek Memnuniyetsizlik Yüzdesi (APD) değerleri karşılaştırılmıştır. Böylece sensör temelli nesnel ölçümler ile kullanıcı algısına dayalı öznel veriler aynı analiz yapısı içinde ele alınmıştır.

Kış döneminde ortalama iç ortam sıcaklığı 21.22 °C, bağıl nem oranı ise %46.60 olarak kaydedilmiştir. Bu koşullarda PMV değeri -0.21, PPD oranı ise %5.9 olarak hesaplanmış ve sensör verilerine göre ortamın konfor sınırları içinde kaldığı belirlenmiştir. Kullanıcı anketlerinde ise AMV değeri -0.8 düzeyinde gerçekleşmiş, APD oranı %18.5 olarak bulunmuştur. Bu sonuç, kış döneminde nesnel ölçümlerin konforlu koşulları işaret etmesine karşın, kullanıcıların ortamı hafif serin algıladığını göstermiştir.

Yaz döneminde ortalama iç ortam sıcaklığı 25.78 °C, bağıl nem oranı ise %40.18 olarak ölçülmüştür. Aynı dönemde PMV değeri -0.04, PPD oranı ise %5.0 olarak hesaplanmış ve mekanik sistemlerin teorik konfor hedeflerini karşıladığı görülmüştür. Buna karşılık, kullanıcı anketlerinden elde edilen AMV değeri +0.58 düzeyine yükselmiş ve APD oranı %12.0 olarak belirlenmiştir. Düşük giysi yalıtımına sahip 0.5 clo grubunda ise APD oranı %36.7'ye kadar çıkmıştır. Bu bulgu, yaz döneminde bazı kullanıcı gruplarında hafif sıcaklık algısının belirginleştiğini göstermektedir.

Geçiş dönemlerinde nesnel ve öznel konfor göstergeleri arasındaki fark daha sınırlı kalmıştır. İlkbaharda ortalama iç ortam sıcaklığı 23.06 °C, bağıl nem oranı %62.72, PMV değeri +0.36 ve AMV değeri +0.69 olarak hesaplanmıştır. Sonbaharda ise ortalama sıcaklık 23.75 °C, bağıl nem oranı %40.07, PMV değeri +0.39 ve AMV değeri +0.35 olarak belirlenmiştir. Bu sonuçlar, geçiş aylarında teorik konfor tahminleri ile kullanıcı algısının daha uyumlu bir profil oluşturduğunu göstermiştir.

Mevsimsel analizler, standart sıcaklık ayar noktalarının her kullanıcı grubu için aynı algısal sonucu üretmediğini ortaya koymuştur. Giysi yalıtımı, yaş, cinsiyet ve mevsimsel beklentiler, kullanıcıların ısı duyumlarını değiştirmiştir. Çalışanların giysi yalıtımı değerlerindeki değişimlerin optimum çalışma sıcaklığı beklentilerinde yaklaşık 0.9 °C ile 2.5 °C arasında kaymaya neden olduğu belirlenmiştir. Bu nedenle kamu binasında ısı konforu yalnızca PMV-PPD indeksleriyle değil, AMV ve APD gibi kullanıcı algısına dayalı göstergelerle birlikte değerlendirilmesi gerekli görülmüştür.

Tablo 3.1: Mevsimsel iç ortam parametreleri ve PMV/PPD değerleri

Kriter	Minimum				Maksimum				Ortalama			
	kış	bahar	güz	yaz	kış	bahar	güz	yaz	kış	bahar	güz	yaz
İç Ortam Sıcaklığı (°C)	19,6	22,8	22	24,7	23,4	23,40	25,5	26,4	21,22	23,06	23,75	25,78
Bağıl Nem (%)	37,2	61,6	36,9	34,9	63	64,50	43,1	43,8	46,60	62,72	40,07	40,18
Hava Hızı (m/s)	0,05	0,03	0,03	0,06	0,11	0,08	0,14	0,14	0,06	0,05	0,07	0,09
Ortalama Radyant Sıcaklık (°C)	18,6	22,5	22,8	23,3	23,2	23,50	26,1	26,8	21,11	22,96	24,04	25,47
Operatif Sıcaklık (°C)	19,1	22,65	22,4	24	23,3	23,45	25,8	26,6	21,17	23,01	23,90	25,63
PMV	-0,69	0,26	0,01	-0,89	0,42	0,48	0,84	0,3	-0,21	0,36	0,37	-0,04
PPD (%)	15,0	6,4	5,0	21,7	8,7	9,8	19,9	6,9	5,9	7,7	7,8	5,0

3.2 Isıtma Dönemi (Kış) Isıl Konfor Bulguları

Kamu binasında kış aylarını kapsayan ısıtma sezonunda, Testo 480 cihazı ile iç ortam fiziksel parametreleri ölçülmüş ve eşzamanlı anketlerle kullanıcıların ısı algıları değerlendirilmiştir. Ölçüm sonuçlarına göre iç ortam hava sıcaklığı 19.6 °C ile 23.4 °C arasında değişmiş, ortalama değer 21.22 °C olarak belirlenmiştir. Aynı dönemde ortalama radyant sıcaklık 21.11 °C, bağıl nem %46.60 ve hava akım hızı 0.06 m/s olarak ölçülmüştür. Bu veriler üzerinden hesaplanan

Tahmini Ortalama Oy (PMV) -0.21, Tahmini Memnuniyetsizlik Yüzdesi (PPD) ise %5.9 olarak bulunmuştur. Sensör temelli sonuçlar, kış döneminde iç ortam koşullarının standart konfor sınırları içinde kaldığını göstermiştir.

Kullanıcı anketlerinden elde edilen sonuçlar, nesnel ölçümlerden farklı bir algısal tablo ortaya koymuştur. Aynı iç ortam koşullarında Gerçek Ortalama Oy (AMV) -0.80 düzeyinde gerçekleşmiş ve kullanıcıların ortamı hafif serin algıladığı belirlenmiştir. Gerçek Memnuniyetsizlik Yüzdesi (APD) ise %18.5 olarak hesaplanmıştır. Bu fark, PMV modelinin kış koşullarında ortamı konforlu olarak değerlendirmesine karşın, kullanıcıların aynı ortamı daha serin algılayabildiğini göstermektedir.

Kış dönemindeki öznel memnuniyetsizlik, demografik gruplara göre değişmiştir. Kadın çalışanlarda AMV değeri -1.0, APD oranı ise %26.1 olarak belirlenmiş; bu grubun ortamı erkek çalışanlara göre daha serin algıladığı görülmüştür. Otuz yaş üzerindeki çalışanlarda memnuniyetsizlik oranı %22.1'e yükselirken, 30 yaş ve altındaki çalışanlarda AMV değeri 0, APD oranı ise %5 düzeyinde kalmıştır. Ayrıca 1.0 clo giysi yalıtımına sahip kullanıcıların dahi -1.81 AMV değeriyle serin algısı bildirdiği belirlenmiştir.

Kış dönemi bulguları, merkezi HVAC sistemlerinde uygulanan standart sıcaklık ayarlarının tüm kullanıcı gruplarında aynı konfor algısını oluşturmadığını göstermektedir. Bu nedenle ısıtma sezonunda yalnızca PMV ve PPD değerlerine dayalı değerlendirme yapılması yeterli görülmemiştir. Kullanıcı gruplarından elde edilen AMV ve APD sonuçlarının da işletme stratejilerine dahil edilmesi gerektiği anlaşılmıştır. Bu kapsamda, özellikle kadın ve ileri yaş gruplarında gözlenen serinlik algısının azaltılabilmesi için kış mesai saatlerinde ısıtma set noktalarının yeniden değerlendirilmesi veya bölgesel ısıtma kontrollerinin dikkate alınması önerilmiştir.

Tablo 3.2: Kış döneminde ölçüm ve kullanıcı algısına dayalı ısı konfor göstergeleri

Parameter Ölçüm			Algılanan			
	Ort. PMV	Konfor	Ort. PPD	Katılımcı	AMV	Konfor APD
Tümü	-0,21	Konforlu/uygun	5,9	65	-0,8	Hafif Serin 18,5
Erkek	-0,20	Konforlu/uygun	5,8	49	-0,73	Hafif Serin 16,2
Kadın	-0,26	Konforlu/uygun	6,4	16	-1	Hafif Serin 26,1
clo 1,0	-0,39	Konforlu/uygun	8,2	37	-1,81	Serin 67,5
clo0,6	0,08	Konforlu/uygun	5,1	19	0,42	Konforlu/uygun 8,7
clo0,5	-0,10	Hafif Serin	5,2	9	0,78	Ilık 17,8
≤30 Yaş	0,04	Konforlu/uygun	5,0	6	0	Konforlu/uygun 5
>30 Yaş	-0,24	Serin	6,2	59	-0,9	Hafif Serin 22,1

3.3 Soğutma Dönemi (Yaz) Isıl Konfor Bulguları

Kamu binasında yaz dönemi soğutma çalışmalarına ait ısı konfor koşulları, Testo 480 ölçüm cihazından elde edilen fiziksel çevre verileri ve eşzamanlı kullanıcı anketleriyle değerlendirilmiştir. Ölçüm sonuçlarına göre iç ortam hava sıcaklığı 24,7 °C ile 26,4 °C arasında değişmiş ve ortalama 25,78 °C olarak belirlenmiştir. Aynı dönemde bağıl nem %34,9 ile %43,8 aralığında ölçülmüş, ortalama değer %40,18 olarak hesaplanmıştır. Ortalama radyant sıcaklık 25,47 °C, operatif sıcaklık 25,63 °C ve hava akım hızı 0,09 m/s düzeyinde gerçekleşmiştir.

Nesnel ölçümlere dayalı hesaplamalarda yaz dönemi ortalama Tahmini Ortalama Oy (PMV) değeri -0,04 olarak bulunmuş ve bu değer nötr ısı algı bölgesine karşılık gelmiştir. Aynı dönemde Tahmini Memnuniyetsizlik Yüzdesi (PPD) ortalama %5,0 düzeyinde kalmıştır. PMV değerinin -0,89 ile 0,3 arasında değiştiği, en yüksek PPD değerinin ise %21,7 olduğu belirlenmiştir. Bu sonuçlara göre cihaz ölçümleri, yaz dönemi iç ortam koşullarının genel olarak konfor sınırları içinde kaldığını göstermiştir.

Toplam 65 personelden elde edilen anket sonuçları, ölçüm temelli değerlendirmelerden farklı bir kullanıcı algısı ortaya koymuştur. Kullanıcı beyanlarına göre Gerçek Ortalama Oy değeri 0,58 olarak hesaplanmış ve bu değer hafif ılık algısına karşılık gelmiştir. Gerçek Memnuniyetsizlik Yüzdesi ise %12,0 olarak belirlenmiştir. Böylece teknik ölçümlerin nötr

konfor koşullarını işaret etmesine karşın, kullanıcı algısının yaz döneminde hafif sıcak yöne kaydığı görülmüştür.

Alt grup analizlerinde cinsiyet değişkeninin yaz döneminde kış aylarındaki kadar belirgin bir farklılık oluşturmadığı görülmüştür. Erkek personelde AMV 0,59 , kadın personelde ise AMV 0,56 olarak hesaplanmıştır. Bu değerler, her iki grupta da algının hafif ılık bölgede yoğunlaştığını göstermektedir. Buna karşılık yaş değişkeni yaz döneminde daha belirgin bir ayrışma oluşturmuştur. Otuz yaş üstü çalışanlarda AMV 0,17 düzeyinde kalmış ve bu grup ortamı konforlu/uygun sınıra yakın algılamıştır. Otuz yaş ve altı çalışanlarda ise AMV 0,63 olarak gerçekleşmiş ve genç kullanıcıların ortamı daha sıcak algıladığı belirlenmiştir.

Giysi yalıtımı (clo) yaz dönemi kullanıcı algısında en belirgin farklılığı oluşturan değişkenlerden biri olmuştur. Standart yazlık ofis kıyafeti olarak değerlendirilen 0,6 clo değerine sahip kullanıcı grubunda AMV 0,03 olarak hesaplanmış ve ortamın büyük ölçüde nötr algılandığı belirlenmiştir. Aynı grupta APD oranı %5,0 düzeyinde kalmış ve bu değer teorik PPD sonucuyla uyumlu bir görünüm sunmuştur. Buna karşılık 0,5 clo değerine sahip daha ince giysili kullanıcı grubunda AMV 1,23'e yükselmiş ve algı sıcak/ılık bölgeye kaymıştır. Bu grupta APD oranının %36,7'ye ulaşması, yaz döneminde ısı tatmininin belirli kullanıcı gruplarında sağlanamadığını göstermiştir.

Bu bulgular, soğutma döneminde mekanik sistemlerin cihaz ölçümleri açısından nötr konfor koşullarını sağladığını; ancak kullanıcı algısının yaş ve giysi yalıtımı gibi kişisel değişkenlere bağlı olarak farklılaşabildiğini göstermektedir. Özellikle daha ince giyinen kullanıcı grubunda yüksek AMV ve APD değerlerinin oluşması, kullanıcıların ortamdaki sıcaklık hissine uyum sağlamaya çalıştığını; buna rağmen algısal konforun tam olarak sağlanamadığını ortaya koymuştur. Bu nedenle yaz dönemi ısı konfor değerlendirmelerinde yalnızca PMV ve PPD indekslerine bağlı kalınmaması, AMV, APD, yaş grubu ve giysi yalıtımı gibi kullanıcı temelli göstergelerin birlikte değerlendirilmesi gerekmektedir.

Tablo 3.3: Yaz döneminde ölçüm ve kullanıcı algısına dayalı ısı konfor göstergeleri

Parametre Ölçüm		Algılanan					
	PMV ortalaması	Konfor	Ort. PPD	Katılımcı	AMV	Konfor	APD
Genel	-0,04	Konforlu/ Nötr	5,0	65	0,58	Hafif Sıcak	12,0
Erkek	-0,05	Konforlu/ Nötr	5,1	49	0,59	Hafif Sıcak	12,3
Kadın	0,00	Konforlu/ Nötr	5	16	0,56	Hafif Sıcak	11,6
clo 1,0	0,00	Konforlu/ Nötr	0	0	0,00	Konforlu/ Nötr	0
clo0,6	-0,04	Konforlu/ Nötr	5,0	35	0,03	Konforlu/ Nötr	5,0
clo0,5	-0,04	Konforlu/ Nötr	5,0	30	1,23	Hafif Sıcak	36,7
≤30 Yaş	-0,05	Konforlu/ Nötr	5,0	59	0,63	Hafif Sıcak	13,3
>30 Yaş	0,08	Konforlu/ Nötr	5,1	6	0,17	Konforlu/ Nötr	5,6

3.4 Geçiş Dönemleri (İlkbahar ve Sonbahar) Isıl Konfor Bulguları

Balıkesir Büyükşehir Belediyesi hizmet binasında ilkbahar ve sonbahar dönemlerine ait ısı konfor koşulları, Testo 480 cihazı ile elde edilen fiziksel ölçümler ve eşzamanlı anket verileri üzerinden değerlendirilmiştir. İlkbahar döneminde dış ortam ortalama hava sıcaklığı yaklaşık 16,6 °C, sonbahar döneminde ise 10,0 °C olarak belirlenmiştir. Bu geçiş aylarında ısıtma ve soğutma sistemlerinin tamamen devre dışı bırakıldığına veya yalnızca doğal havalandırma ile elde edilmiş ayrı bir veri setine ilişkin kaynaklarda yeterli bilgi bulunmamaktadır. Sonbaharda dış ortam sıcaklıklarının düşmesiyle birlikte ısıtma sisteminin aktif olduğu ve bazı durumlarda iç ortam sıcaklığını hedeflenen düzeyin üzerine çıkararak algısal farklılıklara yol açtığı belirtilmiştir.

İlkbahar ölçümlerinde iç ortam hava sıcaklığı 22,8 °C ile 23,40 °C arasında değişmiş ve ortalama 23,06 °C olarak kaydedilmiştir. Bağıl nem ortalama %62,72, hava akım hızı ise 0,05 m/s düzeyinde ölçülmüştür. Bu veriler üzerinden hesaplanan Tahmini Ortalama Oy (PMV) değeri +0,36, Tahmini Memnuniyetsizlik Yüzdesi (PPD) ise %7,7 olarak belirlenmiştir. Anketlerden elde edilen Gerçek Ortalama Oy (AMV) +0,69, Gerçek Memnuniyetsizlik Yüzdesi (APD) ise %15,0 olarak hesaplanmıştır. Bu değerler, ilkbaharda nesnel ölçümlerin konfor

sınırlarına yakın olduğunu; ancak kullanıcı algısının daha ılık yöne kaydığını göstermiştir. Düşük giysi yalıtımına sahip kullanıcıların daha fazla rahatsızlık bildirdiği de belirlenmiştir.

Tablo 3.4: İlkbahar döneminde ölçüm ve kullanıcı algısına dayalı ısı konfor göstergeleri

Parametre Ölçülen		Algılanan					
	Ortalama PMV	Konfor	Ort. PPD	Katılımcı	AMV	Konfor	APD
Tümü	0,39	Konforlu/ Nötr	8,1	59	0,69	Hafif sıcak	15,0
Erkek	0,35	Konforlu/ Nötr	7,5	48	0,60	Hafif sıcak	12,5
Kadın	0,37	Konforlu/ Nötr	7,8	11	1,09	Hafif sıcak	30,0
clo 1,0	0	Konforlu/ Nötr	0	0	0	Konforlu Nötr	/ 0
clo0,6	0,35	Konforlu/ Nötr	7,5	31	0,10	Konforlu Nötr	/ 5,2
clo0,5	0,37	Konforlu/ Nötr	7,8	28	1,36	Hafif sıcak	43,4
≤30 Yaş	0,36	Konforlu/ Nötr	7,6	7	0,14	Konforlu Nötr	/ 5,4
>30 Yaş	0,36	Konforlu/ Nötr	7,6	52	0,72	Hafif sıcak	15,9

Sonbahar döneminde iç ortam hava sıcaklığı 22,0 °C ile 25,5 °C arasında değişmiş ve ortalama 23,75 °C olarak ölçülmüştür. Bağıl nem ortalama %40,07, hava akım hızı ise 0,07 m/s düzeyinde gerçekleşmiştir. Sensör verileri üzerinden PMV değeri +0,37, PPD oranı ise %7,8 olarak hesaplanmıştır. Aynı dönemde 54 kullanıcıdan elde edilen anketlerde AMV değeri +0,35, APD oranı ise %7,5 olarak bulunmuştur. Bu yakınlık, sonbahar döneminde cihaz tabanlı konfor tahminleri ile kullanıcı algısının büyük ölçüde uyumlu olduğunu göstermektedir.


Geçiş dönemleri birlikte değerlendirildiğinde, ilkbaharda kullanıcı algısının teorik PMV değerlerine göre daha ılık yönde sapma gösterdiği, sonbaharda ise PMV ve AMV değerlerinin birbirine oldukça yaklaştığı görülmüştür. İlkbaharda özellikle ince giysi yalıtımına sahip kullanıcı gruplarında memnuniyetsizlik artmış; sonbaharda ise genel dağılım standart konfor göstergeleriyle daha paralel ilerlemiştir. Bu nedenle geçiş mevsimlerinde ısı konfor değerlendirmesinin yalnızca PMV ve PPD değerleriyle değil, AMV, APD, giysi yalıtımı, yaş ve cinsiyet gibi kullanıcı temelli değişkenlerle birlikte yürütülmesi gerektiği anlaşılmıştır.

Tablo 3.5: Sonbahar döneminde ölçüm ve kullanıcı algısına dayalı ısı konfor göstergeleri

Parametre Ölçülen		Algılanan					
	Ortalama PMV	Konfor	Ort. PPD	Katılımcı	AMV	Konfor	APD
Tümü	0,39	Konforlu/ Nötr	8,2	54	0,35	Konforlu/ Nötr	7,5
Erkek	0,36	Konforlu/ Nötr	7,7	48	0,48	Konforlu/ Nötr	9,8
Kadın	0,41	Konforlu/ Nötr	8,5	6	-0,67	Hafif soğuk	14,4
clo 1,0	0,35	Konforlu/ Nötr	7,5	36	0,17	Konforlu/ Nötr	5,6
clo0,6	0,44	Konforlu/ Nötr	9,0	13	0,69	Konforlu/ Nötr	15,0
clo0,5	0,32	Konforlu/ Nötr	7,1	5	0,80	Hafif sıcak	18,5
≤30 Yaş	0,55	Konforlu/ Nötr	11,3	4	0,50	Hafif sıcak	10,2
>30 Yaş	0,35	Konforlu/ Nötr	7,5	50	0,34	Konforlu/ Nötr	7,4

3.5 Kişisel Faktörlerin Subjektif Isıl Konfor Algısına Etkisi

Geleneksel standartlarda cinsiyet, yaş, vücut kitle indeksi veya benzeri demografik özelliklerin PMV denkleminde doğrudan katsayı olarak eklendiğine ilişkin veri bulunmamaktadır (Al Horr et al., 2016; Kim et al., 2018). Bu nedenle mekanik olarak şartlandırılmış ofis ortamlarında, teorik PMV tahminleri ile kullanıcıların Gerçek Ortalama Oy (AMV) değerleri arasında sapmalar oluşabilmektedir. Balıkesir Büyükşehir Belediyesi Fen İşleri Dairesi Başkanlığı ofis binasında elde edilen saha verileri, cinsiyet, yaş, giysi yalıtımı ve fiziksel aktivite düzeyi gibi kişisel faktörlerin teorik konfor öngörülerini ile gerçek kullanıcı algısı arasındaki farkların açıklanmasında ayrı olarak değerlendirilmesi gerektiğini göstermiştir (Şekil 3.1).




Şekil 3.1 Kış döneminde giysi yalıtımının algı ve memnuniyete etkisi

3.6 Cinsiyet Faktörünün Termal Algı Üzerindeki Etkisi

Bina kullanıcılarının ısı konfor algısında cinsiyet değişkeninin etkisi, fizyolojik yapı, giyim alışkanlıkları ve davranışsal uyum biçimleriyle birlikte değerlendirilmiştir. Literatürde kadın kullanıcıların, optimum kabul edilen çevre koşullarından sapmalara erkeklere kıyasla daha duyarlı tepki verebildiği; özellikle serin ve soğuk çalışma ortamlarında daha yüksek memnuniyetsizlik bildirdiği belirtilmiştir (Al Horr et al., 2016; Rupp et al., 2015). Bu farklılık, deri yüzeyi alanı, cilt sıcaklığı ve bazal metabolizma özellikleriyle ilişkilendirilmiştir (Rupp et al., 2015). Bazı çalışmalarda kadınların daha yüksek bazal metabolizma hızına bağlı olarak aynı ortamı daha sıcak algılayabildiği de raporlanmıştır (Lakhiar et al., 2024). Hamilelik döneminde östrojen ve progesteron hormonlarındaki artışın bazal metabolizma hızını %15 ile %20 oranında yükseltebildiği belirtilmiştir (Yang et al., 2026). Giyim alışkanlıkları da cinsiyete bağlı termal algı farklılıklarını etkileyen bir değişken olarak ele alınmıştır. Erkek personelin kıyafet seçimlerinin daha çok dış ortam koşullarına göre şekillendiği, kadın kullanıcıların giysi tercihlerinde ise sosyal etkinlikler, kurumsal imaj ve moda eğilimlerinin daha fazla etkili olabildiği belirtilmiştir (Allah et al., 2025). Ofis ortamlarında kadın çalışanların bazı dönemlerde erkeklere göre daha düşük veya farklı giysi yalıtımı değerlerine sahip olabildiği; bu durumun ısı ıduyum üzerinde değişken etki oluşturduğu saptanmıştır (Schiavon and Lee,

2013). Bu nedenle giysi yalıtımı (clo), cinsiyet grupları arasındaki ısı algı farklılıklarının yorumlanmasında dikkate alınmıştır.



Şekil 3.2: Cinsiyete göre mevsimsel memnuniyetsizlik analizi

Kış dönemine ait saha verileri, cinsiyet farklılığının ısıtma sezonunda daha belirgin hale geldiğini göstermiştir. Cihaz ölçümlerine dayalı genel PMV değeri -0,21 ile konforlu/uygun aralıkta hesaplanmasına karşın, kadın kullanıcıların Gerçek Ortalama Oy (AMV) değeri -1,00 ve Gerçek Memnuniyetsizlik Yüzdesi (APD) %26,1 olarak belirlenmiştir. Aynı fiziksel koşullarda erkek kullanıcıların AMV değeri -0,73, APD oranı ise %16,2 olarak ölçülmüştür. Bu dağılım, kadın kullanıcıların kış koşullarında ortamı erkeklere göre daha serin algıladığını göstermiştir. Yaz döneminde cinsiyete bağlı algı farkı daha sınırlı kalmıştır. Erkek kullanıcıların AMV değeri 0,59, kadın kullanıcıların AMV değeri ise 0,56 olarak hesaplanmış; her iki grup da ortamı hafif ılık düzeyde değerlendirmiştir. Memnuniyetsizlik oranları erkeklerde %12,3, kadınlarda %11,6 olarak belirlenmiş ve iki grup arasında yakın bir dağılım oluşmuştur. Bu sonuç, soğutma döneminde cinsiyet gruplarının ısı tepkilerinin birbirine yaklaştığını; ısıtma döneminde ise kadın kullanıcıların serinlik algısının daha belirgin hale geldiğini göstermiştir (Şekil 3.3).

3.7 Yaş Faktörünün Termal Algı Üzerindeki Etkisi

Bina kullanıcılarının ısı konfor algısını etkileyen kişisel değişkenlerden biri yaş faktörüdür. Yaşın ilerlemesiyle birlikte vücut sıcaklığını düzenleme kapasitesinde değişimler oluşabilmekte ve bu durum termal çevreye verilen tepkileri farklılaştırabilmektedir. Fanger'ın konfor modelini yaşlı bireyler üzerinde sınavan çalışmalarda, ileri yaş grubunda bazal metabolizma hızının ve genel metabolik aktivitenin genç kullanıcılara göre daha düşük olduğu ölçülmüştür (Rupp et al., 2015). Bununla birlikte, ilk değerlendirmelerde yaş değişkeninin konfor algısı üzerinde belirgin bir fark oluşturmadığı belirtilmiştir (Rupp et al., 2015). Yaş grupları arasındaki farklılıklar yalnızca fizyolojik tepkilerle sınırlı değildir. Yaşlı kullanıcıların, nötr konfor durumuna ulaşabilmek için genç kullanıcılara göre daha yüksek ortam sıcaklıklarını tercih edebildiği belirtilmiştir (Rupp et al., 2015). Buna karşın, uzun vadeli ısı konfor değerlendirmelerinin yalnızca biyolojik duyarlılıkla değil, algısal ve bilişsel süreçlerle de ilişkili olduğu değerlendirilmiştir (Li et al., 2024). Bu nedenle yaş faktörünün özellikle kısa süreli termal his oylarında daha belirgin etkiler oluşturabildiği anlaşılmaktadır. Adaptif davranışlar da yaşa bağlı olarak değişebilmektedir. Yaşlı bireylerin yaz aylarında serinlemek için pencere ve kapı açıklıklarını yönettiği, kış aylarında ise ısı kaybını azaltmak amacıyla daha fazla giysi katmanı tercih ettiği belirtilmiştir (Rupp et al., 2015). Bu davranışların, azalan metabolik ısı üretimini dengelemeye yönelik bir uyum biçimi olduğu değerlendirilmiştir. Ancak mevcut kaynaklarda hücresel yaşlanma, kas kütlesi kaybı veya nörolojik termal sinyal işleme süreçlerinin ısı algısına etkisini açıklayan ayrıntılı sayısal veri bulunmamaktadır.

Saha çalışmasında kullanıcılar “30 yaş ve altı” ile “30 yaş üstü” olmak üzere iki grupta değerlendirilmiştir. Kış döneminde 30 yaş ve altındaki kullanıcıların Gerçek Ortalama Oy (AMV) değeri 0 olarak hesaplanmış ve memnuniyetsizlik oranı (APD) %5,0 düzeyinde kalmıştır. Buna karşılık 30 yaş üstü çalışanlarda AMV değeri -0,90'a düşmüş, APD oranı ise %22,1'e yükselmiştir. Bu sonuç, ileri yaş grubunun kış koşullarında ortamı daha serin algıladığını ve nötr konfor için daha yüksek sıcaklık beklentisine sahip olabileceğini göstermektedir. Yaz döneminde ise yaş grupları arasında ters yönlü bir eğilim ortaya çıkmıştır. Soğutma sezonunda 30 yaş üstü kullanıcıların AMV değeri 0,17, APD oranı ise %5,6 olarak belirlenmiş ve bu grup ortamı konforlu sınıra yakın algılamıştır. Buna karşılık 30 yaş ve altındaki kullanıcıların AMV değeri 0,63'e yükselmiş, APD oranı ise %13,3 olarak hesaplanmıştır. Bu bulgu, genç kullanıcıların yaz döneminde aynı fiziksel ortamı daha sıcak algıladığını göstermektedir. Yaş değişkeninin mevsimlere göre farklı yönlerde etki göstermesi,

sabit sıcaklık ayar noktalarının tüm kullanıcı gruplarında aynı ısıl memnuniyeti sağlamayabileceğini ortaya koymaktadır.

3.8 Giyim Yalıtımı ve Davranışsal Adaptasyonun Isıl Konfor Algısına Etkisi

İnsan bedeni ile fiziksel çevre arasındaki ısı transferinin düzenlenmesinde giyim yalıtımı (clo) ve davranışsal adaptasyon mekanizmaları belirleyici kişisel değişkenler arasında değerlendirilmiştir. Standart modellerde (1 clo), (0.155 m²K/W) ısıl dirence eşdeğer kabul edilmiştir. Bu nedenle kullanıcıların fiziksel aktivite düzeyleriyle ilişkili metabolik ısı üretimi ve kıyafet katmanlarıyla sağlanan yalıtım, iç ortam ısıl konforunun yorumlanmasında birlikte ele alınmıştır. Giyim düzeyinin değiştirilebilmesi, ofis kullanıcıları için temel davranışsal uyum yollarından biri olarak tanımlanmıştır. İnce ve uzun kollu bir kazağın giyim kombinasyonuna eklenmesiyle yalıtımın yaklaşık (0.25 clo) artabildiği ve bu değişimin optimum operatif sıcaklığı 1.5 °C'ye kadar kaydırabildiği belirtilmiştir. Saha ölçümlerinde, kullanıcıların adaptif konfor sınırlarında kalabilmesi için kıyafetlerini (0.47 clo) ile (1.32 clo) aralığında ayarlayabilmesi gerektiği raporlanmıştır. Bu bulgu, sabit sıcaklık ayarlarının farklı giyim düzeylerine sahip kullanıcılar için aynı konfor sonucunu üretmeyebileceğini göstermektedir. Davranışsal adaptasyon yalnızca kıyafet değişimiyle sınırlı değildir. Termostat set noktalarının değiştirilmesi, pencere veya kapıların açılıp kapatılması, gölgeliklerin ayarlanması ve yerel ısıtıcı ya da fan kullanımı, kullanıcıların termal rahatsızlığı azaltmak için başvurduğu temel müdahaleler arasında yer almıştır. Bu tür davranışlar, kullanıcıların kendi ısıl çevreleri üzerinde kontrol algısı geliştirmesine ve daha geniş bir sıcaklık aralığını kabul edilebilir bulmasına katkı sağlamaktadır. Bununla birlikte, mevcut kaynaklarda ASHRAE 55 adaptif konfor modelinin spesifik matematiksel formüllerine veya farklı bir standart adaptasyon katsayısına ilişkin veri bulunmamaktadır.

Saha verileri, giyim yalıtımının yalnızca sabit bir model girdisi değil, aynı zamanda kullanıcı rahatsızlığını yansıtan davranışsal bir gösterge olarak da okunabileceğini göstermiştir. Kış döneminde 0.6 clo yalıtım değerine sahip kullanıcılar ortamı nötre yakın algılamış; AMV değeri 0,42 ve APD oranı %8,7 olarak belirlenmiştir. Buna karşılık 1.0 clo değerine sahip daha kalın giyimli grupta AMV -1,81'e düşmüş ve APD %67,5'e yükselmiştir. Bu sonuç, ortamı serin algılayan kullanıcıların kıyafet yalıtımını artırarak uyum sağlamaya çalıştığını; ancak bu davranışın ısıl tatmini sağlamada yeterli olmadığını göstermektedir. Yaz döneminde de benzer bir uyum sınırlılığı gözlenmiştir. 0.6 clo giyim değerine sahip kullanıcılar ortamı nötr algılamış; AMV 0,03 ve APD %5,0 olarak hesaplanmıştır. Buna karşılık 0.5 clo değerine sahip daha ince

giyimli kullanıcı grubunda AMV 1,23'e yükselmiş ve APD %36,7 olmuştur. Bu durum, yaz döneminde sıcaklık hissini azaltmak amacıyla daha ince giyinen kullanıcıların da yeterli ısı tatmine ulaşamadığını göstermektedir.

3.9 Metabolik Hızın Isıl Konfora Etkisi

Bina kullanıcılarının ısı konfor algısını etkileyen temel kişisel parametrelerden biri metabolik hız (met) olarak tanımlanmıştır. Metabolik hız, fiziksel aktivite düzeyine bağlı olarak insan vücudunda üretilen içsel ısı miktarını ifade etmektedir (Jiang et al., 2024). Fanger'in Tahmini Ortalama Oy (PMV) modeli ve ısı dengesi yaklaşımında, metabolik oran ile dış çevreye karşı yapılan efektif mekanik iş arasındaki fark, vücudun net içsel ısı üretimi olarak ele alınmıştır (Jiang et al., 2024; ASHRAE, 2023). ASHRAE 55 standardında 1 met değerinin 58.15 W/m² enerji üretimine karşılık geldiği belirtilmiştir (ASHRAE, 2023). Metabolik hızın doğrudan ölçülmesi güç olduğundan, saha çalışmalarında ISO 7730, ISO 8996 ve ASHRAE 55 standartlarında yer alan aktivite tablolarından yararlanılmıştır (Lakhiar et al., 2024; Zaraa Allah et al., 2024). Bu tablolarda uyku hali 0.7 met, sessiz oturma 1.0 met, klavyede yazı yazma 1.1 met ve rahat ayakta durma 1.2 met olarak sınıflandırılmıştır. Düz zeminde yürüme eyleminin ise hıza bağlı olarak 2.0 ile 3.8 met arasında değiştiği rapor edilmiştir (ASHRAE, 2023). Metabolik ısı üretiminin termal duyum üzerinde belirgin etkisi olduğu görülmüştür. Regresyon ve korelasyon analizlerinde metabolik hız ile termal his arasında güçlü pozitif ilişki bulunmuş ve Pearson korelasyon katsayısı ($r = 0.809$) olarak hesaplanmıştır (Zaraa Allah et al., 2024). Fiziksel aktivite arttıkça vücutta üretilen ısı yükselmekte; bu durum aynı iç ortamın farklı kullanıcı grupları tarafından daha sıcak algılanmasına neden olabilmektedir. Bu nedenle hareketsiz masa başı personeli ile hareketli saha personelinin aynı sıcaklık koşullarında farklı ısı beklentiler geliştirebildiği belirlenmiştir.


Yürütülen saha çalışmasında, idari personel ile teknik personelin aktivite düzeyleri ayrı değerlendirilmiştir. Kamu binası koşullarında masa başı işler yaklaşık 1.5 met, saha denetimi gibi fiziksel efor içeren teknik işler ise 2.0 met değeriyle değerlendirilmiştir. Masa başında oturarak çalışan, okuma veya çizim yapan kullanıcılar daha düşük metabolik üretim grubunda; sahaya çıkan, ayakta çalışan veya fiziksel efor harcayan teknik personel ise daha yüksek metabolik üretim grubunda ele alınmıştır. Yüksek met değerine sahip kullanıcıların kış aylarında düşük sıcaklıklara karşı daha dirençli olduğu; yaz aylarında ise iç ortam sıcaklıklarını daha sıcak ve bunaltıcı algılayabildiği değerlendirilmiştir. Sonuç olarak cinsiyet, yaş, giyim yalıtımı ve fiziksel aktivite düzeyi gibi kişisel parametrelerin, nesnel PMV tahminleri ile

kullanıcıların gerçek algısı arasında sapma oluşturabildiği görülmüştür. Bu nedenle enerji tüketimi ve ısı konfor optimizasyonunda yalnızca standart çevresel koşulların değil, heterojen kullanıcı memnuniyetsizliğini temsil eden APD profillerinin de dikkate alınması gerekmektedir. Bu yaklaşım, kişisel faktörlerden kaynaklanan farklılıkların mevsimsel konfor bandı veya tolerans aralığı olarak matematiksel kısıt fonksiyonlarına aktarılmasına olanak sağlamaktadır.

3.10 Standart Konfor Modelleri ile Saha Algısı Arasındaki Farklılıklar


Bina içi ısı konforun değerlendirilmesinde ASHRAE 55 ve ISO 7730 standartları temel referans olarak kullanılmıştır (Nicol and Humphreys, 2002). Bu standartların matematiksel altyapısı, sabit çevresel koşullar altında yürütülen laboratuvar ölçümlerine ve teorik tahmin modellerine dayanmaktadır. Ancak gerçek bina ortamlarında yapılan saha anketleri, rasyonel indekslerle kullanıcıların öznel ısı algıları arasında sistematik farklar oluşabildiğini göstermiştir (Nicol and Humphreys, 2002). Bu farkın temel nedeni, kullanıcıların fiziksel çevreye verdikleri davranışsal adaptasyon tepkileri ve ortam üzerindeki kontrol olanaklarıyla ilişkilendirilmiştir (Nicol and Humphreys, 2002). Pencere açma, perde ayarlama, kişisel fan kullanma veya giysi düzeyini değiştirme gibi müdahaleler, kullanıcıların kabul edilebilir sıcaklık aralığını genişletebilmektedir. Buna karşılık merkezi kontrollü binalarda statik sıcaklık ayarları kişisel adaptasyon olanaklarını sınırlamakta; bu nedenle cihaz ölçümleri standart sınırlar içinde olsa bile kullanıcı algısı teorik tahminlerden sapabilmektedir.

Saha çalışmasında, Testo-480 cihazı ile ölçülen fiziksel çevre verilerinden elde edilen PMV değerleri ile anketlerden hesaplanan Gerçek Ortalama Oy (AMV) değerleri mevsimsel termal duyum karşılaştırması bağlamında değerlendirilmiştir (Şekil 3.3). Fiziksel PMV dağılımının çoğunlukla nötr değer çevresinde toplandığı, AMV dağılımının ise daha geniş bir yayılım gösterdiği belirlenmiştir. PMV ile AMV arasında mevsime ve kişisel değişkenlere bağlı olarak yaklaşık 0,6 birimlik sistematik kayma tespit edilmiştir. Bu durum, standart ölçüm sonuçlarının binayı tüm mevsimlerde konforlu göstermesine rağmen, kullanıcı temelli APD değerlerinin sahadaki gerçek memnuniyetsizlik düzeyini daha görünür hale getirdiğini ortaya koymuştur.



Şekil 3.3: Mevsimsel termal duyum karşılaştırması

Mevsimsel termal memnuniyetsizlik karşılaştırmasını gösteren sonuçlar, bu sapmanın yönünü açık biçimde göstermiştir (Şekil 3.4). Kış döneminde ortalama PMV -0,21 ve PPD %5,9 iken, AMV -0,80 ve APD %18,5 olarak hesaplanmıştır. Yaz döneminde PMV -0,04 ve PPD %5,0 düzeyinde kalmış; buna karşılık AMV 0,58 ve APD %12,0 olarak belirlenmiştir. İlkbaharda PMV 0,39 ve PPD %8,1 iken, AMV 0,69 ve APD %15,0 düzeyine yükselmiştir. Sonbaharda ise PMV 0,39 ile AMV 0,35 değerleri birbirine yaklaşmış; APD %7,5 ile PPD değerinin %8,2 altında kalmıştır.



Şekil 3.4: Mevsimsel termal memnuniyetsizlik karşılaştırması

Aynı PMV değerlerinin farklı mevsimlerde farklı AMV sonuçları üretmesi, ısıl konforun tek bir sabit hedef değerle temsil edilemeyeceğini göstermiştir. Bu nedenle bina enerji modellerinde kullanıcıların kabul edilebilir bulunduğu PMV ve AMV örtüşme bölgeleri esas alınarak mevsime özgü konfor bantları, mevsimlere göre kabul edilen PMV aralıklarını detaylandıran tablo çerçevesinde tanımlanmıştır (Tablo 3.6).

Tablo 3.6: Mevsimlere göre kabul edilen PMV aralıkları

Dönem	PMV Aralığı
Kış	$-0,5 \leq PMV \leq +0,3$
İlkbahar	$-0,3 \leq PMV \leq +0,5$
Yaz	$-0,2 \leq PMV \leq +0,7$
Sonbahar	$-0,3 \leq PMV \leq +0,5$

Bu bantlar, optimizasyon sürecinde enerji tüketimi azaltılırken kullanıcı konforunun gerçekçi sınırlar içinde tutulması için kısıt fonksiyonu olarak değerlendirilmiştir. Bu mevsimsel tolerans bantları, kullanıcıların adaptif sınırlarını yansıtan saha temelli bir konfor yaklaşımı olarak ele

alınmıştır. Böylece enerji tüketimi minimize edilirken, PMV değerlerinin kullanıcı algısıyla uyumlu kabul edilebilir aralıkların dışına çıkması sınırlandırılmıştır.

3.11 HVAC Enerji Verimliliği İyileştirme ve Optimizasyon Senaryoları

Kamu binalarında HVAC sistemlerinden kaynaklanan operasyonel enerji tüketiminin azaltılması için dinamik bina simülasyonları ile makine öğrenmesi algoritmalarının birlikte kullanıldığı kontrol ve iyileştirme senaryoları geliştirilmiştir (Savadkoohi et al., 2022). Bu senaryolar, binanın fiziksel davranışını sayısal ortama aktaran vekil modeller ve yapay sinir ağı tabanlı tahmin yaklaşımları üzerine kurgulanmıştır (Markarian et al., 2024; Savadkoohi, 2025). Böylece iklimlendirme sistemlerinin gereğinden fazla çalışmasını önlemeye yönelik enerji tüketim eğilimleri önceden hesaplanmış ve uygun işletme stratejileri belirlenmeye çalışılmıştır. İyileştirme senaryolarında enerji tasarrufu ile iç ortam ısı konforu arasındaki karşıt ilişki, çok amaçlı optimizasyon problemi olarak ele alınmıştır (Jun and Fei, 2024).


Enerji tüketimi azaltılırken kullanıcı memnuniyetsizliğinin artmaması için enerji-konfor dengesi, senaryo temelli sayısal analizlerle değerlendirilmiştir (Almadhor et al., 2025). Bu kapsamda, kullanıcıların termal tatmininin standart sınırlar içinde korunması ve eşzamanlı olarak daha düşük güç tüketiminin sağlanması için uygun çalışma bölgeleri araştırılmıştır (Almadhor et al., 2025). Optimizasyon senaryolarının etkisini değerlendirmek için karşılaştırmalı analiz yaklaşımı kullanılmıştır. Binanın mevcut işletme profilini veya geleneksel zamanlanmış kontrol stratejilerini temsil eden baz model, performans kıyaslamalarında referans kabul edilmiştir (Savadkoohi et al., 2022). Tahmin algoritmalarıyla yönetilen optimizasyon senaryoları, bu referans model üzerinden belirlenen performans göstergeleriyle karşılaştırılmış ve HVAC işletimindeki iyileşme düzeyi sayısal olarak incelenmiştir (Savadkoohi et al., 2022).

3.12 Isıtma Sistemi (Kazan) Verimlilik Senaryoları ve Enerji Tüketim Analizi


Kamu binalarında kış dönemindeki ısı yükünün karşılanmasında kullanılan merkezi ısıtma kazanlarının enerji tüketimi ile dış ortam hava sıcaklığı arasında doğrudan bir ilişki bulunduğu dinamik simülasyon analizleriyle gösterilmiştir. Dış ortam sıcaklığı arttıkça ısıtma sistemlerinin enerji talebinin düzenli biçimde azaldığı belirtilmiştir (Savadkoohi et al., 2022). Geleneksel bina yönetiminde kazanların çalışma ve durma periyotları çoğunlukla 06:00-18:00 saatleri arasına sabitlenen zamanlanmış kontrol stratejileriyle yürütülmektedir (Savadkoohi et al., 2022). Kazan çalışma sürelerinin dış hava koşullarına uyarlanamaması, gerçek ısıtma gereksinimi ile enerji tüketimi arasında sapmalara neden olmaktadır. Isıtma talebinin

karşılanamadığı saatlerde iç ortam konforu korunamamakta; tüketimin talebi aştığı dönemlerde ise mekan gereğinden fazla ısıtılmaktadır. Bu durum operasyonel enerji kaybı oluşturmaktadır (Savadkoochi et al., 2022). Dinamik bina enerji simülasyonları ve vekil modellerle yürütülen çalışmalarda, ısıtma bataryaları ve tesisat donanımlarının ana enerji kaynağı olarak doğalgaz kullandığı modeller oluşturulmuştur (Markarian et al., 2024; Chinde et al., 2026).

Tez çalışmamız kapsamında oluşturulan bina enerji modelinde mevcut durum (baz model) incelendiğinde, ısıtma ihtiyacını karşılayan kazan sisteminin verimliliğinin yaklaşık %45 düzeyinde olduğu ve bu düşük performansın yıllık 770.965 kWh doğalgaz tüketimine neden olduğu belirlenmiştir. Kazan modernizasyonu tasarruf potansiyelini değerlendirmek amacıyla, kazan verimliliğinin %50'den başlayarak %95'e kadar %5'lik artış dilimleri halinde modellendiği optimizasyon senaryoları kurgulanmış ve fosil yakıt tüketimindeki değişimler saatlik bazda hesaplanmıştır (Şekil 3.5). Verimliliğin yalnızca %50'ye çıkarılması durumunda doğalgaz tüketimi 693.869 kWh'ye düşmüş ve mevcut duruma göre %10,00 oranında tasarruf sağlanmıştır. Verimliliğin %95 düzeyine ulaşması halinde ise yıllık tüketim 365.194 kWh'ye gerilemiş; baz modele göre %52,63 oranında, yani 405.771 kWh düzeyinde tasarruf potansiyeli elde edilmiştir. Kazan verimine göre mevsimsel doğalgaz tüketimi değişimi incelendiğinde ise, aylık dağılımda en yüksek tasarrufların ocak, şubat ve aralık aylarında gerçekleştiği; bu aylarda sırasıyla 68.140 kWh, 68.424 kWh ve 76.934 kWh tasarruf hesaplandığı tespit edilmiştir (Şekil 3.6).



Şekil 3.5: Kazan modernizasyonu tasarruf potansiyeli



Şekil 3.6: Kazan verimine göre mevsimsel doğalgaz tüketimi değişimi

3.13 Soğutma Sistemi (Chiller COP) İyileştirme Senaryoları ve Enerji Tüketim Analizi


Kamu binalarında yaz döneminde oluşan soğutma talebinin karşılanmasında kullanılan merkezi soğutma gruplarının operasyonel verimliliği, Performans Katsayısı (COP) üzerinden değerlendirilmiştir (Alajmi, 2025; Markarian et al., 2024). COP, sistemin sağladığı faydalı soğutma çıktısının, bu işlemi gerçekleştirmek için tüketilen elektriksel girdi enerjisine oranı olarak tanımlanmıştır (Alajmi, 2025). Bu değerin artması, soğutma sisteminin termodinamik verimliliğinin yükselmesiyle ilişkilendirilmiştir. Chiller sistemlerinde COP düzeyinin artırılmasıyla doğrudan soğutma enerjisi ihtiyacının düştüğü; buna bağlı olarak binanın toplam elektrik tüketiminde ve tepe yüklerinde de azalma sağlandığı belirtilmiştir (Alajmi, 2025; Markarian et al., 2024).

Tez çalışması kapsamında geliştirilen modelde, chiller sisteminin enerji performansını ifade eden performans katsayısı (COP) ile binanın toplam elektrik enerjisi tüketimi birbirinden ayrıştırılarak değerlendirilmiştir. COP, sistem tarafından sağlanan faydalı soğutma enerjisinin chiller tarafından tüketilen elektrik enerjisine oranı olarak tanımlanmıştır. Bina toplam elektrik tüketimi ise soğutma sistemi tüketimine aydınlatma, ofis ekipmanları, havalandırma ve diğer operasyonel elektrik yüklerinin eklenmesiyle hesaplanmıştır. Ayrıca soğutma sistemi tüketimi kapsamında, COP değerine bağlı chiller tüketiminin yanı sıra pompa, fan ve diğer yardımcı bileşenlerin tüketimleri de dikkate alınmıştır.


Mevcut işletme koşullarını temsil eden baz modelde chiller COP değeri yaklaşık 5,0 olarak kabul edilmiştir. Bu koşulda yıllık soğutma sistemi elektrik tüketimi 132.459,16 kWh, binanın yıllık toplam elektrik tüketimi ise 807.627,26 kWh olarak hesaplanmıştır. Chiller COP değerinin 2,0–5,0 aralığında 0,1 birimlik artışlarla değiştirildiği hassasiyet analizlerinde, performans katsayısındaki değişimin soğutma sistemi ve bina toplam elektrik tüketimi üzerindeki etkisi saatlik olarak incelenmiştir (Şekil 3.8). COP değerinin 2,0 olduğu düşük verimli işletme senaryosunda yıllık soğutma sistemi elektrik tüketiminin 281.325,52 kWh'ye, binanın toplam elektrik tüketiminin ise 956.493,62 kWh'ye yükseldiği belirlenmiştir (Şekil 3.9). Bu değerler, baz modele kıyasla toplam elektrik tüketiminde %18,43 oranında artış meydana geldiğini göstermektedir.

COP değerindeki her 0,1 birimlik artış sonucunda elde edilen marjinal enerji tasarrufu incelendiğinde, performans artışının azalan marjinal fayda eğilimi gösterdiği belirlenmiştir. Simülasyon sonuçlarına göre COP değerinin 2,0'dan 2,1'e yükseltilmesiyle yıllık 11.139,65

kWh enerji tasarrufu sağlanırken, COP değerinin 4,9'dan 5,0'a çıkarılmasıyla elde edilen ek tasarruf 1.909,65 kWh olarak hesaplanmıştır. Bu bulgular, özellikle COP değeri 3,0'ın altında olan düşük performanslı soğutma gruplarında gerçekleştirilecek verimlilik iyileştirmelerinin, yüksek performanslı sistemlerde yapılacak eşdeğer artışlara kıyasla daha yüksek marjinal enerji tasarrufu sağlayabileceğini göstermektedir.



Şekil 3.7: COP değişimine bağlı soğutma enerjisi tüketimi



Şekil 3.8: COP değişiminin toplam enerji tüketimine etkisi

3.14 Havalandırma, ACH ve Fan Enerjisi İyileştirme Senaryoları

Kamu binalarında iç ortam hava kalitesinin standartlara uygun düzeyde korunabilmesi için sağlanan taze hava miktarı ve saatteki hava değişim sayısı (ACH), HVAC sistemlerinin elektriksel yük profili üzerinde belirleyici bir değişken olarak ele alınmıştır (Li et al., 2026). Dış havanın filtrelenmesi, şartlandırılması ve iç mekana aktarılması sırasında klima santralleri ve aspiratör sistemleri üzerinden yüksek düzeyde elektrik enerjisi tüketilmektedir. Gelişmiş bina enerji modellerinde, klima santralleri ve elektrikli değişken hava debili terminal ünitelerinin toplam HVAC enerji tüketiminin %60'ından fazlasını oluşturduğu hesaplanmıştır (Jiang et al., 2024). Taze hava debilerinin yalnızca hava kalitesini artırmak amacıyla sürekli yüksek tutulması, mekanik sistemlerin ısı yükünü artırmakta ve enerji-konfor dengesinde sapmalara neden olabilmektedir (Li et al., 2026). Bu nedenle havalandırma debisi, sabit bir işletme girdisi olarak değil, iç ortam gereksinimlerine göre düzenlenmesi gereken dinamik bir kontrol değişkeni olarak değerlendirilmiştir.

Tez çalışmamız kapsamında oluşturulan bina enerji modelinde, havalandırma debisinin sabit tutulması yerine dinamik bir işletme girdisi olarak optimize edilmesi hedeflenmiştir. Bu doğrultuda, hizmet binasının operasyonel simülasyonlarında saatlik hava değişim oranı (ACH)

0,7 ile 3,0 aralığında değerlendirilmiştir. ACH değerinin gereksinim dışı saatlerde veya düşük doluluk oranlarında alt sınırlara ($0,7 \text{ h}^{-1}$) çekilmesiyle fan motorlarının ve şartlandırma ünitelerinin elektrik tüketiminde belirgin iyileştirmeler sağlanmıştır. Söz konusu havalandırma ve fan enerjisi optimizasyonu, tek başına bir parametre olmanın ötesinde, soğutma ve ısıtma senaryolarıyla birleştirilerek tezin bütünlük HVAC iyileştirme kurgusuna entegre edilmiştir.

3.15 Sıcaklık Set Değerleri ve HVAC Enerji İyileştirme Senaryoları


Bina enerji yönetiminde iç ortam ısıtma ve soğutma sıcaklık set değerleri (set point), HVAC donanımlarının elektrik tüketimini doğrudan etkileyen temel operasyonel parametreler arasında tanımlanmıştır. Bu parametrelerin özellikle soğutma grupları, terminal fanları ve sirkülasyon pompalarının çalışma yükleri üzerinde belirleyici olduğu belirtilmiştir. İklimlendirme senaryolarında, aktif ısıtma veya soğutma gereksiniminin oluşmadığı serbest sıcaklık aralığını ifade eden ölü bant kavramı matematiksel modellere dahil edilmiştir. Bu serbest aralığın genişletilmesiyle mekanik sistemlerin aktif çalışma sürelerinin azaltıldığı, terminal ünitelerindeki hava debilerinin tasarım minimumlarına kadar indirildiği ve kompresör ile fan yüklerinin belirgin biçimde hafifletildiği analiz edilmiştir (Hoyt et al., 2015). Dar sıcaklık ayar noktalarının ise iklimlendirme sistemlerini daha uzun süre çalışmaya zorladığı ve gereksiz termodinamik yükler oluşturduğu değerlendirilmiştir. Yapay zeka destekli dinamik optimizasyon çalışmalarında, enerji israfının azaltılması ve sistemin iç ortam termodinamik yüklerine daha hızlı yanıt verebilmesi amacıyla sıcaklık set noktalarının algoritmik biçimde düzenlendiği senaryolar kurgulanmıştır. Bu kapsamda ısıtma set noktalarının $19\text{--}20 \text{ }^{\circ}\text{C}$, soğutma set noktalarının ise $24\text{--}25 \text{ }^{\circ}\text{C}$ bandında regüle edildiği rapor edilmiştir (Savadkoobi et al., 2022).

Tez çalışmamız kapsamında oluşturulan bina enerji modelinde, mekanik sistemlerin gereksiz çalışmasını önlemek ve termodinamik yükleri hafifletmek amacıyla iç ortam sıcaklık ayar noktaları (set point) dinamik bir karar değişkeni olarak optimizasyon sürecine dahil edilmiştir. İncelenen kamu binasının gerçek işletme koşullarına uyarlanan senaryolarda sıcaklık set değerleri $22 \text{ }^{\circ}\text{C}$ ile $24 \text{ }^{\circ}\text{C}$ arasında sınırlandırılarak optimize edilmiştir. İç ortam sıcaklığının bu belirlenen esnek aralıkta kontrol edilmesi, ısıtma ve soğutma sistemlerinin aşırı iklimlendirme yapmasını engellemiş ve cihazların aktif çalışma sürelerini optimize etmiştir. Sıcaklık set değerlerinin bu şekilde iyileştirilmesi, tekil bir strateji olmanın ötesinde tezin bütünlük HVAC iyileştirme kurgusuna entegre edilerek sistemler arası etkileşimle birlikte değerlendirilmiştir.

3.16 Birleşik HVAC İyileştirme Senaryoları ve Sistemler Arası Etkileşim

Bina enerji yönetiminde HVAC alt sistemlerinin operasyonel performansını artırmak için, özellikle mekanik iyileştirme stratejileri bağlamında ısı üretimi ve soğutma grubu verimliliğinin birlikte değerlendirildiği birleşik senaryolar ele alınmıştır (Li et al., 2026). Dinamik işletme koşullarında mekanik sistemler birbirinden bağımsız çalışmadığından, tekil müdahalelerin bazı durumlarda sistemin genel termodinamik dengesinde yetersiz kalabildiği belirtilmiştir. Bu nedenle enerji tüketiminin azaltılmasında, binanın mekanik ısıtma ve soğutma bileşenlerinin performanslarının aynı optimizasyon yapısı içinde bütünleşik bir mekanik iyileştirme olarak ele alınması gerektiği raporlanmıştır (Li et al., 2026; Markarian et al., 2024).

Tez çalışmamız kapsamında oluşturulan birleşik senaryo matrislerinde, havalandırma debisi (ACH) ve sıcaklık ayar noktaları (set değerleri) bu optimizasyon kurgusunun dışında bırakılarak doğrudan mekanik iyileştirme odaklı bir yaklaşım benimsenmiştir. Bu doğrultuda sistemin ısıtma kazanı verimi ve soğutma grubu (chiller COP) bileşenleri eşzamanlı olarak değerlendirilmiştir. Baz modelde toplam HVAC enerji tüketimi, elektrik ve doğalgaz birlikte olmak üzere 1.578.593 kWh olarak hesaplanmıştır. Kazan veriminin %50, COP değerinin 2,0 olduğu Senaryo 1’de toplam tüketim 1.650.362 kWh’ye yükselmiş ve baz modele göre %4,55 oranında tüketim dezavantajı oluşmuştur. Kademeli mekanik iyileştirme senaryolarında enerji tüketiminin belirgin biçimde azaldığı tespit edilmiştir (Şekil 3.9). Kazan veriminin %65 ve COP değerinin 3,0 olarak tanımlandığı Senaryo 2’de toplam enerji tüketimi 1.412.261 kWh’ye düşmüş ve baz modele göre %10,54 tasarruf sağlanmıştır. Kazan veriminin %80, COP değerinin 4,0 olduğu Senaryo 3’te toplam tüketim 1.273.195 kWh’ye gerilemiş ve iyileşme oranı %19,35 olmuştur. Yüksek verimli mekanik sistem kabul edilen Senaryo 4’te ise %90 kazan verimi ve 4,5 COP değeriyle toplam yıllık enerji tüketimi 1.212.014 kWh’ye düşmüş, baz modele göre %23,22 oranında azalma elde edilmiştir. Bu sonuçlar, ACH ve set değerlerinden bağımsız olarak yalnızca ısıtma ve soğutma donanımlarında yapılacak eşzamanlı bir mekanik iyileştirmenin bile kamu binalarında yüksek düzeyde enerji tasarrufu sağlayabildiğini göstermektedir.



Şekil 3.9: Birleşik HVAC mekanik optimizasyon senaryoları

3.17 Soğutma Enerjisi Tahmininde SMOreg ve MLP Modellerinin Karşılaştırılması

Yaz döneminde binalarda oluşan yüksek soğutma yüklerinin ve buna bağlı elektrik tüketiminin doğru biçimde tahmin edilmesi, enerji verimliliği ve sürdürülebilir bina yönetimi açısından temel bir gereksinim olarak ele alınmıştır (Yang, 2024; Zeynalli and Eslami, 2025). Geleneksel hesaplama yöntemleri ve kural tabanlı yaklaşımlar, bina işletme süreçlerinde ortaya çıkan doğrusal olmayan termodinamik ilişkileri çözümlemede sınırlı kalmaktadır (Yang, 2024). Bu nedenle yapay zeka ve veri madenciliği tabanlı makine öğrenmesi algoritmaları, soğutma enerjisi tahmini için kullanılmaya başlanmıştır. Bina Enerji Yönetim Sistemlerine (BEMS) entegre edilen veri odaklı tahmin yaklaşımları, iç ortam termal konforu korunurken mekanik soğutma donanımlarının elektrik tüketimini azaltmaya yönelik biçimde kurgulanmıştır (Alharbi et al., 2024). Fiziksel tabanlı ayrıntılı bina enerji simülasyonlarının yüksek hesaplama yükünü azaltmak amacıyla makine öğrenmesi algoritmaları vekil model olarak yapılandırılmıştır. Bu modeller, ana simülasyon araçlarının termodinamik davranışlarını öğrenerek daha hızlı ve düşük hesaplama maliyetli enerji tahminleri üretebilmektedir (Vallianos and Kapsis, 2026; Markarian et al., 2024). Mimari ve enerji veri setlerinin işlenmesinde sınıflandırma ve regresyon analizleri için Waikato Environment for Knowledge Analysis (WEKA) gibi yazılım

platformlarından yararlanılmıştır (Abdel-Jaber and Dirks, 2024). Bu kapsamda, Çok Katmanlı Algılayıcı (MLP) yapay sinir ağları ile Destek Vektör Regresyonu (SVR) temelli SMOREg algoritmaları soğutma enerjisi tahmininde karşılaştırmalı olarak değerlendirilmiştir (Mottahedin et al., 2024). MLP ağları, çok boyutlu veri setlerinde bulunan doğrusal olmayan ilişkileri girdi, gizli ve çıktı katmanları arasındaki nöron bağlantıları üzerinden modelleyebilmektedir (Yang, 2024; Zeynalli and Eslami, 2025). Destek vektör tabanlı yaklaşımlar ise yüksek boyutlu verilerdeki karmaşık örüntüleri belirlenen hata tolerans sınırları içinde haritalayarak regresyon problemlerinde kullanılmaktadır (Islam et al., 2026). Bu nedenle SMOREg ve MLP algoritmaları, farklı matematiksel yapılara sahip iki veri odaklı tahmin yöntemi olarak ele alınmıştır. Algoritmaların tahmin başarıları Belirlilik Katsayısı (R^2), Ortalama Mutlak Hata (MAE) ve Kök Ortalama Kare Hatası (RMSE) metrikleri üzerinden karşılaştırılmıştır (Zeynalli and Eslami, 2025; Tuğal, 2025). Bu karşılaştırmada amaç, algoritmalarından birinin mutlak üstünlüğünü göstermek değil; belirli bir soğutma yükü veri setinde hangi modelin daha iyi genelleme yaptığını ve aşırı öğrenmeden ne ölçüde kaçınabildiğini belirlemektir. Model başarısı, R^2 değerinin 1'e yaklaşması ve MAE ile RMSE değerlerinin düşük seviyelerde kalması üzerinden değerlendirilmiştir.

Tablo 3.7: Soğutma enerjisi tahmini için SMOREg modelinde çekirdek fonksiyonlarının performans karşılaştırması

Model No	Kernel Fonksiyonu	Eğitim MAE	Eğitim RMSE	Test MAE	Test RMSE
1	Normalized Polynomial Kernel	6,7437	9,6154	7,2447	10,4621
2	Polynomial Kernel	2,2338	3,0005	2,2544	2,8889
3	Pearson VII Universal Kernel (PUK)	0,1134	0,1425	1,9612	2,8527
4	Radial Basis Function Kernel	9,3548	12,0188	11,4303	13,3268

SMOREg modelinde kullanılan çekirdek fonksiyonları karşılaştırıldığında, test verisi üzerinde en düşük RMSE değerinin Pearson VII Universal Kernel (PUK) ile elde edildiği görülmektedir. PUK çekirdeği eğitim aşamasında, 0,1134 MAE ve 0,1425 RMSE üretirken; test aşamasında 1,9612 MAE ve 2,8527 RMSE değerlerine ulaşmıştır. Polynomial Kernel test RMSE değeri bakımından yakın sonuç verse de, PUK çekirdeğinin daha düşük hata düzeyi sağlaması nedeniyle soğutma enerjisi tahmininde daha uygun çekirdek fonksiyonu olarak

değerlendirilebilir. Radial Basis Function Kernel ise yüksek test RMSE değeri nedeniyle bu veri setinde daha zayıf bir tahmin performansı göstermiştir.

Tablo 3.8: Soğutma enerjisi tahmini için PUK çekirdekli SMOreg modelinde C hiperparametresinin performansa etkisi

Hiperparametre Değer	Eğitim MAE	Eğitim RMSE	Test MAE	Test RMSE
2	0,1024	0,1095	1,9719	2,8597
2,5	0,1024	0,1095	1,9719	2,8597
3	0,1024	0,1095	1,9719	2,8597
3,5	0,1024	0,1095	1,9719	2,8597
4	0,1024	0,1095	1,9719	2,8597
4,5	0,1024	0,1095	1,9719	2,8597
5	0,1024	0,1095	1,9719	2,8597
0,1	1,9623	4,5451	3,1855	6,0934
10	0,1024	0,1095	1,9719	2,8597
5,8	0,1024	0,1095	1,9719	2,8597
7	0,1024	0,1095	1,9719	2,8597
12	0,1024	0,1095	1,9719	2,8597

C hiperparametresine ilişkin sonuçlar incelendiğinde, 2 ile 12 arasındaki değerlerde eğitim ve test performanslarının değişmediği görülmektedir. Bu aralıkta test MAE değeri 1,9719 ve test RMSE değeri 2,8597 olarak sabit kalmıştır. Buna karşılık C=0,1 değerinde test MAE 3,1855’e, test RMSE ise 6,0934’e yükselmiştir. Bu bulgu, çok düşük C değerinin modelin genelleme başarısını zayıflattığını; 2 ve üzerindeki değerlerde ise model performansının bu veri seti için kararlı hale geldiğini gösterilmektedir.

Tablo 3.9: Soğutma enerjisi tahmini için PUK çekirdekli SMOREg modelinde sigma hiperparametresinin performansa etkisi

	Hiperparametre Değer	Eğitim MAE	Eğitim RMSE	Test MAE	Test RMSE
sigma	1	0,8551	0,9404	20,2136	42,0422
	2	0,8630	0,9334	7,5479	16,3794
	3	1,0559	1,4198	3,9105	7,7617
	4	1,1919	1,9216	2,9871	5,6318
	5	1,3619	2,1590	2,6607	4,6638
	5,5	1,4631	2,3394	2,7302	5,2751

Sigma hiperparametresi model performansı üzerinde belirgin bir etki oluşturmuştur. Sigma değeri 1’den 5’e çıkarıldığında test RMSE değeri 2,8597’den 0,4688’e düşmüş, test MAE değeri ise 1,9719’dan 0,3470’a gerilemiştir. En düşük test hatası sigma=5 değerinde elde edilmiştir. Sigma=6 değerinde test RMSE’nin 0,5999’a yükselmesi, modelin optimum davranışının sigma=5 çevresinde oluştuğunu göstermektedir. Bu nedenle soğutma enerjisi tahmininde PUK çekirdeği için sigma=5 değeri daha uygun bir ayar olarak değerlendirilmiştir.

Tablo 3.10: Soğutma enerjisi tahmini için PUK çekirdekli SMOREg modelinde omega hiperparametresinin performansa etkisi


	Hiperparametre Değer	Eğitim MAE	Eğitim RMSE	Test MAE	Test RMSE
omega	0,2	0,1016	0,1128	1,2633	1,7398
	0,5	0,1731	0,2900	0,4523	0,5928
	0,8	0,2179	0,3560	0,3973	0,5176
	1	0,2440	0,3987	0,3470	0,4688
	1,1	0,2563	0,4163	0,3769	0,5061
	1,4	0,3059	0,4789	0,3921	0,5399
	1,7	0,3369	0,5313	0,4361	0,6260
	2	0,3599	0,5646	0,4567	0,6601

Omega hiperparametresi için elde edilen sonuçlar, modelin test hatasının omega değerine duyarlı olduğunu göstermektedir. Omega=0,2 değerinde test RMSE 1,7398 iken, omega=1 değerinde bu hata 0,4688'e düşmüştür. Omega değerinin 1'in üzerine çıkarılmasıyla test RMSE yeniden artmış ve omega=2 değerinde 0,6601'e ulaşmıştır. Bu dağılım, omega=1 değerinin soğutma enerjisi tahmini için en düşük test hatasını sağladığını göstermektedir.

Tablo 3.11: Soğutma enerjisi tahmini için PUK çekirdekli SMOreg modelinde epsilon hiperparametresinin performansa etkisi


Hiperparametre Değer	Eğitim MAE	Eğitim RMSE	Test MAE	Test RMSE
0,00001	0,2140	0,3754	0,3798	0,5210
0,0001	0,2167	0,3783	0,3800	0,5141
epsilon 0,001	0,2440	0,3987	0,3470	0,4688
0,01	0,6279	0,7057	0,8009	1,0600
0,1	6,2566	6,7813	5,4910	6,2166

Epsilon hiperparametresi sonuçlarına göre en düşük test RMSE değeri 0,4688 ile epsilon=0,001 ayarında elde edilmiştir. Epsilon değerinin 0,00001 ve 0,0001 olduğu durumlarda test RMSE sırasıyla 0,5210 ve 0,5141 olarak hesaplanmıştır. Epsilon=0,01 değerinde test RMSE 1,0600'a, epsilon=0,1 değerinde ise 6,2166'ya yükselmiştir. Bu sonuçlar, epsilon değerinin gereğinden fazla artırılmasının model hatasını belirgin biçimde yükselttiğini; epsilon=0,001 değerinin ise bu veri seti için daha dengeli bir tahmin yapısı oluşturduğunu göstermektedir.




Şekil 3.10: Soğutma enerjisi tahmini için SMOREg modelinde eğitim verisinde gerçek ve tahmini değerlerin karşılaştırılması

Eğitim verisi üzerinde gerçek ve tahmini değerlerin birbirine oldukça yakın seyrettiği görülmektedir. Tahmin dizisinin genel eğilimi gerçek değerleri takip etmiş, yüksek ve düşük soğutma enerjisi değerlerinde belirgin bir yön sapması oluşmamıştır. Bu durum, modelin eğitim verisindeki örüntüleri yüksek doğrulukla öğrendiğini göstermektedir.




Şekil 3.11: Soğutma enerjisi tahmini için SMOREg modeli eğitim verisi hata dağılımı

Eğitim verisi hata dağılımında sapmaların büyük bölümünün sıfır çevresinde toplandığı görülmektedir. Hata değerlerinin sınırlı bir bantta kalması, modelin eğitim aşamasında sistematik bir aşırı veya eksik tahmin eğilimi üretmediğini göstermektedir.



Şekil 3.12: Soğutma enerjisi tahmini için SMOreg test verisinde gerçek ve tahmini değerlerin karşılaştırılması

Test hata dağılımında sapmaların genel olarak sınırlı kaldığı ve sıfır çevresinde yoğunlaştığı görülmektedir. Bazı gözlemlerde hata değerleri artmış olsa da, dağılım genelinde belirgin bir sistematik yönelme oluşmamıştır.




Şekil 3.13: Soğutma enerjisi tahmini için SMOreg test verisinde hata dağılımı

Soğutma enerjisi tahmini için yapılan hiperparametre denemelerinde en düşük test hataları PUK çekirdekli SMOreg modelinde $\sigma=5$, $\omega=1$ ve $\epsilon=0,001$ ayarlarında elde edilmiştir.

Tablo 3.12: Soğutma enerjisi tahmini için MLP ağ yapılarının performans karşılaştırması


Model No	Ağ Yapısı	Eğitim MAE	Eğitim RMSE	Test MAE	Test RMSE
1	4-2-1	0,5644	0,7469	0,6004	0,7247
2	4-2-2-1	0,5223	0,7091	0,4934	0,6232
3	4-2-2-2-1	0,5568	0,7664	0,5774	0,7069
4	4-12-5-7-1	0,4680	0,6545	0,5348	0,6705
5	4-3-2-1	0,4634	0,6500	0,4691	0,5919
6	4-12-12-4-1	0,4841	0,6722	0,5793	0,7342
7	4-4-2-1	0,4538	0,6335	0,4862	0,6181
8	4-4-3-2-1	0,4819	0,6843	0,5289	0,6740
9	4-2-4-2-1	0,5623	0,7637	0,5570	0,6871
10	4-20-20-10-1	0,5085	0,7227	0,6197	0,7891
11	4-2-3-2-1	0,5761	0,7813	0,5852	0,7140
12	4-1-1-1	1,2682	1,6365	1,2269	1,6233
13	4-25-1	0,3448	0,4761	0,4005	0,5302
14	4-3-1	0,4503	0,6090	0,4713	0,6051
15	4-4-1	0,3532	0,4716	0,3601	0,4803

MLP modellerinde farklı ağ yapılarının eğitim ve test performansları karşılaştırıldığında, tüm modellerin yüksek tahmin başarısı ürettiği görülmektedir. En düşük test hatası 4-4-1 ağ yapısında elde edilmiştir. Bu modelde, test MAE değeri 0,3601 ve test RMSE değeri 0,4803 olarak hesaplanmıştır. 4-25-1 ağ yapısı da 0,5302 test RMSE değeriyle yakın bir performans göstermiştir; ancak 4-4-1 mimarisinin hem MAE hem de RMSE bakımından daha düşük hata üretmesi nedeniyle soğutma enerjisi tahmininde daha dengeli sonuç verdiği değerlendirilmiştir.




Şekil 3.14: Soğutma enerjisi tahmini için MLP modelinde eğitim verisi gerçek ve tahmini değerlerin karşılaştırılması

Eğitim verisi üzerinde gerçek ve tahmini değerlerin genel olarak birbirine yakın ilerlediği görülmektedir. Tahmin serisi, düşük ve yüksek soğutma enerjisi değerlerinde gerçek veri eğilimini büyük ölçüde takip etmiştir. Bu durum, MLP modelinin eğitim veri setindeki doğrusal olmayan ilişki yapısını öğrenebildiğini göstermektedir.




Şekil 3.15: Soğutma enerjisi tahmini için MLP modelinde eğitim verisi hata dağılımı

Eđitim verisi hata dađılımında sapmaların b y k b l m  sıfır  evresinde toplanmıřtır. Hata deđerlerinin  ođunlukla dar bir bant i inde kalması, modelin eđitim ařamasında sistematik bir ařırı tahmin veya eksik tahmin eđilimi  retmediđini g stermektedir.



řekil 3.16: Sođutma enerjisi tahmini i in MLP modelinde test verisi ger ek ve tahmini deđer dađılımı

Test verisi  zerinde tahmini deđerlerin ger ek deđerlere olduk a yakın bir dađılım sergilediđi g r lmektedir. Model, eđitim ařamasında  đrendiđi iliřki yapısını bađımsız test verisine aktarabilmiř ve genel eđilim korunmuřtur.



Şekil 3.17: Soğutma enerjisi tahmini için MLP modelinde test verisi hata dağılımı

Test hata dağılımı incelendiğinde, sapmaların genel olarak sınırlı kaldığı ve sıfır çevresinde yoğunlaştığı görülmektedir. Bazı gözlemlerde hata büyüklüğü artmış olsa da dağılım genelinde belirgin bir yönlü sapma oluşmamıştır. Bu durum, MLP modelinin test verisi üzerinde dengeli bir tahmin performansı gösterdiğini ortaya koymaktadır. Eğitim ve test hatalarının birbirine yakın seyretmesi, seçilen ağ yapısının genelleme kapasitesinin güçlü olduğunu göstermektedir.

3.18 Isıtma Enerjisi Tahmininde SMOreg ve MLP Modellerinin Karşılaştırılması

Kış döneminde ortaya çıkan dinamik ısıtma yüklerinin ve buna bağlı enerji ya da doğalgaz tüketiminin doğru tahmin edilmesi, akıllı ısıtma sistemlerinin yönetimi ve enerji tasarrufu stratejilerinin geliştirilmesi açısından gerekli görülmüştür (Wang et al., 2024). Geleneksel matematiksel denklemlerin, binalardaki karmaşık termodinamik ilişkileri açıklamada sınırlı kalması nedeniyle yapay zeka ve veri madenciliği tabanlı makine öğrenmesi algoritmalarından yararlanılmıştır (Wang et al., 2024). Ayrıntılı bina enerji simülasyonlarının yüksek hesaplama maliyetini azaltmak amacıyla, sistem davranışını öğrenen veri odaklı vekil modeller geliştirilmiştir (Markarian et al., 2024). Bu modellerin, iç ortam ısı konforu korunurken mekanik ısıtma sistemlerinin enerji tüketimini azaltmaya yönelik hızlı tahminler üretebildiği belirtilmiştir (Markarian et al., 2024; Stevanović et al., 2024). Tahminsel vekil modellerin

oluşturulmasında, Waikato Environment for Knowledge Analysis (WEKA) yazılımı üzerinden çalıştırılan Çok Katmanlı Algılayıcı (MLP) yapay sinir ağları ile Destek Vektör Regresyonu tabanlı SVR/SMOreg algoritmaları kullanılmıştır (Abdel-Jaber and Dirks, 2024). MLP ağları, gizli katmanlar ve aktivasyon fonksiyonları aracılığıyla doğrusal olmayan veri örüntülerini modelleyebilmekte; destek vektör tabanlı yaklaşımlar ise yüksek boyutlu veri setlerinde güçlü bir regresyon alternatifi sunmaktadır (Islam et al., 2026; Tuğal, 2025; Wang et al., 2024). SMOreg ve MLP algoritmalarının kış sezonundaki tahmin başarıları karşılaştırılırken; modellerin genelleme kapasitesi, Belirlilik Katsayısı (R^2), Ortalama Mutlak Hata (MAE) ve Kök Ortalama Kare Hatası (RMSE) temel performans göstergeleri üzerinden değerlendirilmiştir (Abdel-Jaber and Dirks, 2024; Zeynalli and Eslami, 2025). Model başarısı, R^2 değerinin yükselmesi ve MAE ile RMSE değerlerinin düşmesi üzerinden yorumlanmıştır.

Tablo 3.13: Isıtma enerjisi tahmini için SMOreg modelinde çekirdek fonksiyonlarının performans karşılaştırması

Model No	Kernel Fonksiyonu	Eğitim MAE	Eğitim RMSE	Test MAE	Test RMSE
1	Normalized Polynomial Kernel	56,1177	87,8220	62,4511	103,3047
2	Polynomial Kernel	17,2005	24,8775	19,7974	31,5198
3	Pearson VII Universal Kernel (PUK)	0,8551	0,9404	20,2136	42,0422
4	Radial Basis Function Kernel	92,4355	111,7300	99,5429	123,5314

Isıtma enerjisi tahmini için kullanılan SMOreg modelinde çekirdek fonksiyonları karşılaştırıldığında, test verisi üzerinde en düşük RMSE değerinin Polynomial Kernel ile elde edildiği görülmektedir. Polynomial Kernel, eğitim aşamasında 17,2005 MAE ve 24,8775 RMSE üretirken; test aşamasında 19,7974 MAE ve 31,5198 RMSE değerlerine ulaşmıştır. PUK çekirdeği eğitim verisinde oldukça düşük hata değerleri üretmesine rağmen, test RMSE değerinin 42,0422 düzeyine yükselmesi, bu ilk ayarda genelleme başarısının Polynomial Kernel'e göre daha zayıf kaldığını göstermektedir. Normalized Polynomial Kernel ve Radial Basis Function Kernel ise yüksek test RMSE değerleri nedeniyle bu veri setinde daha sınırlı performans sergilemiştir.

Tablo 3.14: Isıtma enerjisi tahmini için PUK çekirdekli SMOreg modelinde C hiperparametresinin performansa etkisi

	Hiperparametre	Değer	Eğitim MAE	Eğitim RMSE	Test MAE	Test RMSE
C		2	0,8551	0,9404	20,2136	42,0422
		2,5	0,8551	0,9404	20,2136	42,0422
		3	0,8551	0,9404	20,2136	42,0422
		3,5	0,8551	0,9404	20,2136	42,0422
		4	0,8551	0,9404	20,2136	42,0422
		4,5	0,8551	0,9404	20,2136	42,0422
		5	0,8551	0,9404	20,2136	42,0422
		0,1	18,5538	37,3907	33,9660	68,1019
		10	0,8551	0,9404	20,2136	42,0422
		7	0,8551	0,9404	20,2136	42,0422
		12	0,8551	0,9404	20,2136	42,0422

C hiperparametresine ilişkin sonuçlar incelendiğinde, 2 ile 12 arasındaki değerlerde eğitim ve test performanslarının değişmediği görülmektedir. Bu aralıkta test MAE değeri 20,2136 ve test RMSE değeri 42,0422 olarak sabit kalmıştır. Buna karşılık C=0,1 değerinde test MAE 33,9660'a, test RMSE ise 68,1019'a yükselmiştir. Bu sonuç, çok düşük C değerinin modelin tahmin kararlılığını zayıflattığını; 2 ve üzerindeki değerlerde ise C parametresinin bu veri seti için ek bir iyileştirme üretmediğini göstermektedir.

Tablo 3.15: Isıtma enerjisi tahmini için PUK çekirdekli SMOREG modelinde sigma hiperparametresinin performansa etkisi

	Hiperparametre Değer	Eğitim MAE	Eğitim RMSE	Test MAE	Test RMSE
sigma	1	0,8551	0,9404	20,2136	42,0422
	2	0,8630	0,9334	7,5479	16,3794
	3	1,0559	1,4198	3,9105	7,7617
	4	1,1919	1,9216	2,9871	5,6318
	5	1,3619	2,1590	2,6607	4,6638
	5,5	1,4631	2,3394	2,7302	5,2751

Sigma hiperparametresi, PUK çekirdekli SMOREG modelinin test performansı üzerinde belirgin bir etki oluşturmuştur. Sigma değeri 1’den 5’e çıkarıldığında test RMSE değeri 42,0422’den 4,6638’e düşmüş, test MAE değeri ise 20,2136’dan 2,6607’ye gerilemiştir. En düşük test RMSE sigma=5 değerinde elde edilmiştir. Sigma=5,5 değerinde test RMSE’nin 5,2751’e yükselmesi, modelin optimum performansının sigma=5 çevresinde oluştuğunu göstermektedir. Bu nedenle ısıtma enerjisi tahmini için PUK çekirdeğinde sigma=5 ayarı daha uygun bir hiperparametre değeri olarak değerlendirilmektedir.

Tablo 3.16: Isıtma enerjisi tahmini için PUK çekirdekli SMOREG modelinde omega hiperparametresinin performansa etkisi


	Hiperparametre Değer	Eğitim MAE	Eğitim RMSE	Test MAE	Test RMSE
omega	0,2	0,8832	0,9566	11,7615	26,0696
	0,5	1,0994	1,6478	3,3511	6,9135
	0,8	1,2659	2,0424	2,8521	5,1789
	1	1,3619	2,1590	2,6607	4,6638
	1,1	1,3914	2,2097	2,7282	4,8551
	1,4	1,5367	2,3460	2,8227	5,4948
	1,7	1,6225	2,5346	2,9413	6,1286
	2	1,7599	2,6987	3,3061	6,8338

Omega hiperparametresine ait sonuçlar, test hatasının omega değerine duyarlı olduğunu göstermektedir. Omega=0,2 değerinde test RMSE 26,0696 iken, omega=1 değerinde bu değer 4,6638'e düşmüştür. Omega değerinin 1'in üzerine çıkarılmasıyla test RMSE yeniden artmış ve omega=2 değerinde 6,8338'e ulaşmıştır. Bu dağılım, omega=1 değerinin ısıtma enerjisi tahmini için en düşük test hatasını sağladığını göstermektedir. Eğitim hatalarının sınırlı artış göstermesine karşın test hatasındaki belirgin düşüş, omega ayarının modelin genelleme kapasitesini doğrudan etkilediğini göstermektedir.

Tablo 3.17: Isıtma enerjisi tahmini için PUK çekirdekli SMOreg modelinde epsilon hiperparametresinin performansa etkisi


Hiperparametre Değer	Eğitim MAE	Eğitim RMSE	Test MAE	Test RMSE
0,00001	1,1780	2,2775	2,4178	4,4340
0,0001	1,1737	2,2923	2,4190	4,3505
0,001	1,3914	2,2097	2,7282	4,8551
0,01	4,6260	5,4078	6,2780	10,5292
0,1	46,8219	52,6327	53,6580	61,0819

Epsilon hiperparametresi sonuçlarına göre en düşük test RMSE değeri 4,3505 ile epsilon=0,0001 ayarında elde edilmiştir. Epsilon=0,00001 değerinde test RMSE 4,4340; epsilon=0,001 değerinde ise 4,8551 olarak hesaplanmıştır. Epsilon değerinin 0,01'e yükselmesiyle test RMSE 10,5292'ye, 0,1 değerinde ise 61,0819'a çıkmıştır. Bu sonuçlar, epsilon değerinin fazla artırılmasının model hatasını belirgin biçimde yükselttiğini; epsilon=0,0001 değerinin ise bu veri seti için daha dengeli bir tahmin yapısı oluşturduğunu göstermektedir.




Şekil 3.18: Isıtma enerjisi tahmini için SMOREg modeli eğitim verisinde gerçek ve tahmini değerlerin karşılaştırılması

Eğitim verisi üzerinde gerçek ve tahmini değerlerin genel olarak birbirine yakın seyrettiği görülmektedir. Tahmin serisi, düşük ve yüksek ısıtma enerjisi değerlerinde gerçek veri eğilimini büyük ölçüde takip etmiştir. Bu durum, modelin eğitim veri setindeki örüntüleri başarılı biçimde öğrendiğini göstermektedir.




Şekil 3.19: Isıtma enerjisi tahmini için eğitim SMOREg modeli verisi hata dağılımı

Eđitim verisi hata dađılımında sapmaların b y k b l m  sıfır  evresinde toplanmıřtır. Bu dađılım, modelin eđitim ařamasında sistematik bir ařır  tahmin veya eksik tahmin eđilimi  retmediđini g stermektedir.



řekil 3.20: Isıtma enerjisi tahmini i in SMOreg modeli test verisinde ger ek ve tahmini deđerlerin karřılařtırılması

Test verisi  zerinde tahmini deđerlerin genel eđilimi ger ek deđerlerle uyumlu g r nmektedir. Model, eđitim ařamasında  đrendiđi iliřki yapısını bađımsız test verisine aktarabilmiř ve bir ok g zlemde ger ek deđerlere yakın tahminler  retmiřtir.




Şekil 3.21: Isıtma enerjisi tahmini için SMOreg modeli test verisi hata dağılımı

Test hata dağılımında sapmaların çoğunlukla sınırlı kaldığı, ancak bazı gözlemlerde hata büyüklüğünün belirgin biçimde arttığı görülmektedir.

Tablo 3.18: Isıtma enerjisi tahmini için MLP ağ yapılarının performans karşılaştırması


Model No	Ağ Yapısı	Eğitim MAE	Eğitim RMSE	Test MAE	Test RMSE
1	4-2-1	2,3893	3,2491	2,9279	4,5227
2	4-2-2-1	2,5107	3,4009	3,0536	4,5158
3	4-2-2-2-1	2,8448	3,8271	3,5501	5,5828
4	4-12-5-7-1	3,7106	4,6428	4,3802	7,3253
5	4-3-2-1	2,6497	3,5556	3,2714	5,8237
6	4-12-12-4-1	3,0703	4,1240	4,0597	7,6345
7	4-4-2-1	2,6114	3,5216	3,3612	5,3411
8	4-4-3-2-1	5,0681	6,5131	6,1071	9,6293
9	4-2-4-2-1	3,3144	4,4122	3,9586	6,3780
10	4-20-20-10-1	3,4786	4,5580	4,5310	8,0403
11	4-2-3-2-1	2,7384	3,7218	3,4390	5,3352
12	4-1-1-1	15,3028	18,8327	16,8556	23,3436
13	4-25-1	3,3238	4,1410	4,0660	5,5732
14	4-3-1	2,3109	3,1479	3,1117	4,3524
15	4-4-1	2,3262	3,1766	2,8669	4,4708

Isıtma enerjisi tahmini için farklı MLP ağ yapıları karşılaştırıldığında, tüm modellerde yüksek tahmin başarısı elde edildiği görülmektedir. Test RMSE değeri bakımından en başarılı sonuç 4-3-1 ağ yapısında hesaplanmıştır. Bu modelde test korelasyon katsayısı 0,9998, test MAE değeri 3,1117 ve test RMSE değeri 4,3524 olarak belirlenmiştir. Buna karşılık 4-4-1 ağ yapısı, test MAE değerinde 2,8669 ile daha düşük hata üretmiş; ancak test RMSE değeri 4,4708 düzeyinde kalmıştır. Bu nedenle model seçimi yapılırken RMSE ölçütü esas alındığında 4-3-1 mimarisi, MAE ölçütü dikkate alındığında ise 4-4-1 mimarisi öne çıkmaktadır.




Şekil 3.22: Isıtma enerjisi tahmini için MLP modelinde eğitim verisi gerçek ve tahmini değer dağılımı

Eğitim verisi üzerinde gerçek ve tahmini değerlerin genel eğilimi birbirine yakın seyretmiştir. Model, düşük ve yüksek ısıtma enerjisi değerlerinde veri setinin ana değişim yapısını izleyebilmiştir.




Şekil 3.23: Isıtma enerjisi tahmini için MLP modelinde eğitim verisi hata dağılımı

Eğitim verisi hata dağılımında sapmaların önemli bir bölümü sıfır çevresinde toplanmıştır. Bu dağılım, modelin eğitim aşamasında genel olarak dengeli bir tahmin davranışı oluşturduğunu göstermektedir.



Şekil 3.24: Isıtma enerjisi tahmini için MLP modelinde test verisi gerçek ve tahmini değer dağılımı

Test verisi üzerinde tahmini değerlerin genel olarak gerçek değerleri izlediği görülmektedir. Model, eğitim aşamasında öğrendiği ilişki yapısını bağımsız test verisine aktarabilmiş ve birçok gözlemde gerçek değerlere yakın tahminler üretmiştir.



Şekil 3.25: Isıtma enerjisi tahmini için MLP modelinde test verisi hata dağılımı

Test hata dağılımında sapmaların çoğunlukla sınırlı bir bant içinde kaldığı görülmektedir. Buna rağmen bazı gözlem noktalarında hata değerlerinin belirgin biçimde arttığı tespit edilmiştir. Bu dağılım, modelin test verisi üzerinde sistematik bir yönlü sapma üretmediğini; ancak uç değerlere yakın örneklerde tahmin hassasiyetinin azaldığını göstermektedir.

3.19 Toplam Enerji Tüketimi Tahmininde SMOreg ve MLP Modellerinin Karşılaştırılması

Kamu binalarında toplam enerji tüketiminin doğru öngörülmesi, ısıtma, soğutma ve havalandırma sistemleri ile fan, pompa ve aydınlatma gibi yardımcı alt bileşenlerin birlikte değerlendirilmesini gerektirmektedir. Bu nedenle toplam enerji tüketimi tahmini, sürdürülebilir bina yönetimi ve enerji verimliliği stratejileri açısından temel analiz alanlarından biri olarak ele alınmıştır (Ortiz-Suarez et al., 2025; Abdel-Jaber and Dirks, 2024). Fiziksel bina dinamikleri, çevresel değişkenler ve kullanıcı doluluk oranları arasındaki doğrusal olmayan termodinamik ilişkilerin geleneksel mühendislik yaklaşımlarıyla yeterli düzeyde çözümlenememesi nedeniyle, Bina Enerji Yönetim Sistemlerine (BEMS) entegre edilebilecek yapay zeka tabanlı tahmin modelleri geliştirilmiştir (Hwang et al., 2025). Bu modeller, iç ortam termal konforu korunurken bina genelindeki mekanik ve elektriksel enerji kayıplarının azaltılması ve işletme planlamasına veri sağlanması amacıyla kurgulanmıştır (Wang et al., 2024). Ayrıntılı fiziksel bina simülasyonlarının yüksek hesaplama maliyeti ve zaman gereksinimi oluşturmaları nedeniyle, sistemlerin tüketim davranışını öğrenebilen vekil modellerden yararlanılmıştır (Vallianos and Kapsis, 2026). Bu kapsamda Waikato Environment for Knowledge Analysis (WEKA) platformu üzerinden çalıştırılan Çok Katmanlı Algılayıcı (MLP) ve Destek Vektör Regresyonu temelli SMOreg algoritmaları öne çıkarılmıştır (Abdel-Jaber and Dirks, 2024). MLP ağları, çok boyutlu veri setlerinde yer alan doğrusal olmayan değişken ilişkilerini gizli katmanlar, aktivasyon fonksiyonları ve geri yayılım algoritmaları aracılığıyla modelleyebilmektedir (Yang, 2024; Pektezel, 2025). SMOreg mekanizmaları ise yüksek boyutlu ve karmaşık örüntüler içeren veri setlerinde ilişkileri önceden tanımlanmış hata tolerans sınırları içinde optimize ederek toplam enerji tüketimi gibi çok değişkenli regresyon problemleri için kararlı bir tahmin altyapısı sunmaktadır (Islam et al., 2026). SMOreg ve MLP algoritmaları, farklı matematiksel yapılara sahip olmaları nedeniyle toplam enerji tüketimi tahmininde karşılaştırmalı olarak değerlendirilmiştir. Bu karşılaştırmada modellerin genelleme kapasiteleri ve aşırı öğrenme eğilimleri istatistiksel göstergeler üzerinden incelenmiştir. Tahmin edilen değerler ile gerçek veriler arasındaki varyansı açıklayan Belirlilik Katsayısı (R^2), tahmin hatalarının mutlak büyüklüğünü gösteren Ortalama Mutlak Hata (MAE) ve büyük

sapmaları karesel olarak değerlendiren Kök Ortalama Kare Hatası (RMSE) temel kıyaslama metrikleri olarak kullanılmıştır (Abdel-Jaber and Dirks, 2024; Vallianos and Kapsis, 2026). Model başarımı, algoritmalar arasında kesin bir üstünlük kurmaktan çok, R^2 değerinin 1'e yaklaşması ve MAE ile RMSE hata oranlarının düşürülmesi üzerinden yorumlanmıştır.

Tablo 3.19: Toplam enerji tüketimi tahmini için SMOREG modelinde çekirdek fonksiyonlarının performans karşılaştırması

Model No	Kernel Fonksiyonu	Eğitim MAE	Eğitim RMSE	Test MAE	Test RMSE
1	Normalized Polynomial Kernel	50,9704	81,0179	56,8312	95,4306
2	Polynomial Kernel	17,9580	26,0435	19,7096	31,5068
3	Pearson VII Universal Kernel (PUK)	0,8326	0,9020	19,8903	40,7417
4	Radial Basis Function Kernel	85,3693	104,2918	89,4308	113,6280

Toplam enerji tüketimi tahmini için SMOREG modelinde kullanılan çekirdek fonksiyonları karşılaştırıldığında, başlangıç ayarları altında en düşük test RMSE değerinin Polynomial Kernel ile elde edildiği görülmektedir. Polynomial Kernel, eğitim aşamasında, 17,9580 MAE ve 26,0435 RMSE üretirken; 19,7096 MAE ve 31,5068 RMSE değerlerine ulaşmıştır.

Tablo 3.20: Toplam enerji tüketimi tahmini için PUK çekirdekli SMOreg modelinde C hiperparametresinin performansa etkisi

Hiperparametre	Değer	Eğitim MAE	Eğitim RMSE	Test MAE	Test RMSE
c	2	0,8326	0,9020	19,8903	40,7417
	2,5	0,8326	0,9020	19,8903	40,7417
	3	0,8326	0,9020	19,8903	40,7417
	3,5	0,8326	0,9020	19,8903	40,7417
	4	0,8326	0,9020	19,8903	40,7417
	4,5	0,8326	0,9020	19,8903	40,7417
	5	0,8326	0,9020	19,8903	40,7417
	0,1	17,3585	36,1976	31,5223	64,6560
	10	0,8326	0,9020	19,8903	40,7417
	7	0,8326	0,9020	19,8903	40,7417
	12	0,8326	0,9020	19,8903	40,7417

C hiperparametresine ilişkin sonuçlar incelendiğinde, 2 ile 12 arasındaki değerlerde eğitim ve test performanslarının değişmediği görülmektedir. Bu aralıkta test MAE değeri 19,8903 ve test RMSE değeri 40,7417 olarak sabit kalmıştır. Buna karşılık C=0,1 değerinde test MAE 31,5223'e, test RMSE ise 64,6560'a yükselmiştir.

Tablo 3.21: Toplam enerji tüketimi tahmini için PUK çekirdekli SMOreg modelinde sigma hiperparametresinin performansa etkisi

Hiperparametre Değer Eğitim MAE Eğitim RMSE Test MAE Test RMSE					
sigma	1	0,8326	0,9020	19,8903	40,7417
	2	0,8737	0,9595	7,4136	15,8410
	3	1,1009	1,5410	4,0515	7,7944
	4	1,2371	2,0551	3,0378	5,4865
	5	1,4376	2,3498	2,8192	4,9456
	6	1,7682	2,6815	3,2392	6,0874

Sigma hiperparametresi, toplam enerji tüketimi tahmininde test hataları üzerinde belirgin bir değişim oluşturmuştur. Sigma değeri 1’den 5’e çıkarıldığında test RMSE değeri 40,7417’den 4,9456’ya düşmüş, test MAE değeri ise 19,8903’ten 2,8192’ye gerilemiştir. En düşük test RMSE değeri sigma=5 ayarında elde edilmiştir. Sigma=6 değerinde test RMSE’nin 6,0874’e yükselmesi, modelin optimum performansının sigma=5 çevresinde oluştuğunu göstermektedir. Bu nedenle PUK çekirdekli SMOreg modelinde sigma=5 ayarı, toplam enerji tahmini için daha uygun bir hiperparametre değeri olarak değerlendirilmiştir.

Tablo 3.22: Toplam enerji tüketimi tahmini için PUK çekirdekli SMOreg modelinde omega hiperparametresinin performansa etkisi


Hiperparametre Değer Eğitim MAE Eğitim RMSE Test MAE Test RMSE					
omega	0,2	0,8770	0,9489	11,7436	25,3018
	0,5	1,1496	1,8207	3,3442	6,7827
	0,8	1,3405	2,2077	2,9415	4,9229
	1,1	1,3952	2,4180	2,6346	4,5949
	1,2	1,4597	2,3933	2,6892	4,7047
	1,4	1,5678	2,4876	2,8869	4,9754
	1,7	1,6461	2,5832	2,9771	5,1265
	2	2,8384	2,7792	3,3199	6,1445

Omega hiperparametresine ait sonuçlar, test hatasının bu parametreye duyarlı olduğunu göstermektedir. Omega=0,2 değerinde test RMSE 25,3018 iken, omega=1,1 değerinde bu değer 4,5949'a düşmüştür. Omega değerinin 1,1 üzerine çıkarılmasıyla test RMSE yeniden artmış ve omega=2 değerinde 6,1445'e ulaşmıştır. Bu dağılım, omega=1,1 değerinin toplam enerji tüketimi tahmini için en düşük test RMSE değerini sağladığını göstermektedir.

Tablo 3.23: Toplam enerji tüketimi tahmini için PUK çekirdekli SMOreg modelinde epsilon hiperparametresinin performansa etkisi


Hiperparametre Değer	Eğitim MAE	Eğitim RMSE	Test MAE	Test RMSE
0,00001	1,1271	2,4550	2,4716	4,5003
0,0001	1,2276	2,4020	2,4414	4,6326
0,001	2,3952	2,4180	2,6346	4,5949
0,01	4,7040	5,5182	6,0527	10,3177
0,1	51,6597	57,1422	58,5710	64,9084

Epsilon hiperparametresi sonuçlarına göre en düşük test RMSE değeri 4,5003 ile epsilon=0,00001 ayarında elde edilmiştir. Epsilon=0,0001 değerinde test RMSE 4,6326, epsilon=0,001 değerinde ise 4,5949 olarak hesaplanmıştır. Epsilon değerinin 0,01'e yükselmesiyle test RMSE 10,3177'ye, 0,1 değerinde ise 64,9084'e çıkmıştır. Bu sonuçlar, epsilon değerinin fazla artırılmasının model hatasını belirgin biçimde yükselttiğini; düşük epsilon düzeylerinde ise toplam enerji tahmini için daha kararlı bir tahmin yapısı oluştuğunu göstermektedir.




Şekil 3.26: Toplam enerji tüketimi tahmini için SMOREg modeli eğitim verisinde gerçek ve tahmini değerlerin karşılaştırılması

Eğitim verisi üzerinde gerçek ve tahmini değerlerin genel olarak birbirine yakın seyrettiği görülmektedir. Tahmin serisi, düşük ve yüksek toplam enerji tüketimi değerlerinde gerçek veri eğilimini büyük ölçüde takip etmiştir. Bu durum, modelin eğitim veri setindeki örüntüleri başarılı biçimde öğrendiğini göstermektedir.




Şekil 3.27: Toplam enerji tüketimi tahmini için SMOREg modeli eğitim verisi hata dağılımı

Eğitim verisi hata dağılımında sapmaların büyük bölümü sıfır çevresinde toplanmıştır. Bu dağılım, modelin eğitim aşamasında sistematik bir aşırı tahmin veya eksik tahmin eğilimi üretmediğini göstermektedir.



Şekil 3.28: Toplam enerji tüketimi tahmini için SMOreg modeli test verisinde gerçek ve tahmini değerlerin karşılaştırılması

Test verisi üzerinde tahmini değerlerin genel eğilimi gerçek değerlerle uyumlu görünmektedir. Model, eğitim aşamasında öğrendiği ilişki yapısını bağımsız test verisine aktarabilmiş ve birçok gözlemlerde gerçek değerlere yakın tahminler üretebilmiştir.



Şekil 3.29: Toplam enerji tüketimi tahmini için SMOreg modeli test verisi hata dağılımı


Test hata dağılımında sapmaların çoğunlukla sınırlı kaldığı, ancak bazı gözlemlerde hata büyüklüğünün belirgin biçimde arttığı görülmektedir. Özellikle yüksek hata üreten gözlem noktaları, modelin bağımsız test verisinde tüm aralığı aynı hassasiyetle temsil edemediğini

göstermektedir. Buna rağmen hata dağılımında tek yönlü ve sürekli bir sapma eğilimi belirgin değildir. Bu nedenle modelin test verisi üzerinde genel olarak dengeli, fakat bazı uç değerlerde daha hassas ayar gerektiren bir tahmin davranışı sergilediği değerlendirilmektedir.

Tablo 3.24: Toplam enerji tüketimi tahmini için MLP ağ yapılarının performans karşılaştırması


Model No	Ağ Yapısı	Eğitim MAE	Eğitim RMSE	Test MAE	Test RMSE
1	4-2-1	3,5905	4,3772	3,5111	5,2972
2	4-2-2-1	3,4902	4,4030	3,3911	4,7942
3	4-2-2-2-1	3,6476	4,7934	3,7747	5,5984
4	4-12-5-7-1	3,9037	5,1479	4,8854	7,5171
5	4-3-2-1	3,3366	4,4308	4,5534	7,5853
6	4-12-12-4-1	3,8583	5,2280	4,8191	7,6871
7	4-4-2-1	3,2987	4,3605	3,7656	5,1203
8	4-4-3-2-1	4,5042	6,3416	5,8197	9,1731
9	4-2-4-2-1	4,2312	5,5025	4,5239	7,0972
10	4-20-20-10-1	3,8915	5,2861	5,0986	7,8203
11	4-2-3-2-1	3,6187	4,7194	3,7806	5,4279
12	4-1-1-1	13,5705	16,6561	14,6040	21,6426
13	4-25-1	3,4780	4,2840	4,1750	5,4178
14	4-3-1	3,1587	3,9503	3,5253	4,9493
15	4-4-1	3,4675	4,2190	3,5522	5,2854

Toplam enerji tüketimi tahmini için farklı MLP ağ yapıları karşılaştırıldığında, test verisi üzerinde en düşük hata değerinin 4-2-2-1 ağ yapısında elde edildiği görülmektedir. Bu modelde, test MAE değeri 3,3911 ve test RMSE değeri 4,7942 olarak hesaplanmıştır. 4-3-1 ağ yapısı 4,9493 test RMSE değeriyle yakın bir performans göstermiştir; ancak 4-2-2-1 modeli hem MAE hem de RMSE bakımından daha düşük hata ürettiğinden toplam enerji tüketimi tahmininde daha dengeli bir yapı sunmuştur.




Şekil 3.30: Toplam enerji tüketimi tahmini için MLP modelinde eğitim verisi gerçek ve tahmini değer dağılımı

Eğitim verisi üzerinde tahmini değerlerin genel eğilimi gerçek değerlerle uyumlu bir seyir izlemiştir. Model, düşük ve yüksek toplam enerji tüketimi değerlerinde veri setinin ana değişim yapısını büyük ölçüde takip edebilmiştir. Buna karşılık bazı gözlem noktalarında tahmini değerlerin gerçek değerlerden ayrıştığı görülmektedir.




Şekil 3.31: Toplam enerji tüketimi tahmini için MLP modelinde eğitim verisi hata dağılımı

Eğitim verisi hata dağılımında sapmaların önemli bir bölümü sıfır çevresinde toplanmıştır. Bu dağılım, modelin eğitim aşamasında genel olarak dengeli bir tahmin davranışı oluşturduğunu göstermektedir. Bazı hata değerlerinin daha yüksek düzeylere ulaşması ise belirli gözlem noktalarında yerel tahmin sapmalarının oluştuğunu göstermektedir.



Şekil 3.32: Toplam enerji tüketimi tahmini için MLP modelinde test verisi gerçek ve tahmini değer dağılımı

Test verisi üzerinde tahmini değerlerin genel olarak gerçek değerlere yakın seyrettiği görülmektedir. Model, eğitim aşamasında öğrendiği ilişki yapısını bağımsız test verisine aktarabilmiş ve birçok gözlemde gerçek değerlere yakın tahminler üretmiştir. Buna rağmen bazı yüksek toplam enerji tüketimi değerlerinde sapmaların arttığı belirlenmiştir. Bu sonuç, modelin genel genelleme kapasitesinin yüksek olduğunu; ancak uç değerlere yakın örneklerde hata büyüklüğünün artabildiğini göstermektedir.



Şekil 3.33: Toplam enerji tüketimi tahmini için MLP modelinde test verisi hata dağılımı

Test hata dağılımında sapmaların çoğunlukla sınırlı bir bant içinde kaldığı görülmektedir. Bununla birlikte bazı gözlem noktalarında hata değerleri belirgin biçimde artmıştır. Dağılım genelinde sürekli ve tek yönlü bir sapma eğilimi oluşmamıştır. Bu durum, modelin test verisi üzerinde dengeli bir tahmin davranışı sergilediğini; ancak geniş değişim aralığına sahip örneklerde tahmin hassasiyetinin azaldığını göstermektedir.

3.20 SMOreg ve MLP Modellerinin Genel Performans Karşılaştırması

Bina enerji yönetim sistemlerinde (BEMS), ısıtma, soğutma ve toplam enerji tüketimi profillerinin tahmin edilmesi amacıyla geliştirilen yapay zeka tabanlı algoritmalar, veri odaklı vekil model yaklaşımı içinde değerlendirilmiştir. Geleneksel mühendislik simülasyonlarından farklı olarak Çok Katmanlı Algılayıcı (MLP) ve Destek Vektör Regresyonu tabanlı (SMOregSVR) modellerinin, mevsimsel yük değişimleri ve çevresel termodinamik değişkenlerden kaynaklanan doğrusal olmayan veri yapılarını çözümlemede yüksek uyum kapasitesi gösterdiği belirtilmiştir (Abdel-Jaber and Dirks, 2024; Yang, 2024). MLP ağları, çok boyutlu girdi matrislerinde yer alan gizli örüntüleri aktivasyon fonksiyonları ve nöron katmanları aracılığıyla işleyerek yaz ve kış dönemlerindeki dinamik soğutma ve ısıtma taleplerini modelleyebilmektedir (Yang, 2024; Zeynalli and Eslami, 2025). Buna karşılık destek vektör mekanizmaları, yüksek boyutlu veri setlerindeki sapmaları önceden tanımlanmış hata tolerans sınırları içinde optimize ederek enerji tüketimi regresyonlarında kararlı bir tahmin yapısı sunmaktadır (Abdel-Jaber and Dirks, 2024). Vekil modellerin kamu binalarındaki enerji yönetimine uygulanabilirliği; geçmiş veri kalitesi, doluluk oranlarındaki beklenmedik


değişimler ve hiperparametre ayarlarının uygunluğu ile ilişkilendirilmiştir (Tuğal, 2025; Khastar et al., 2025). Öğrenme oranı, gizli katman sayısı ve optimizasyon fonksiyonu gibi bileşenlerin doğru yapılandırılması, tahmin başarımını doğrudan etkilemektedir. Bu nedenle model performansı yalnızca algoritma türüyle değil, veri setinin yapısı ve hiperparametre düzeniyle birlikte yorumlanmalıdır. Tahmin modellerinin güvenilirliği, Belirlilik Katsayısı (R^2), Ortalama Mutlak Hata (MAE) ve Kök Ortalama Kare Hatası (RMSE) gibi istatistiksel metriklerle değerlendirilmiştir (Zeynalli and Eslami, 2025; Abdel-Jaber and Dirks, 2024). Bu karşılaştırmada amaç, algoritmalar arasında kesin bir üstünlük kurmak değil, incelenen bina dinamiklerine daha iyi genelleme sağlayan model yapısını belirlemektir. Bu kapsamda R^2 değerinin 1'e yaklaşması, MAE ve RMSE değerlerinin ise düşmesi model başarımının temel göstergeleri olarak ele alınmıştır.

Tablo 3.25: SVM/SMOreg ve MLP modellerinin tahmin parametrelerine göre eğitim verisi ve test verisi hata değerlerinin karşılaştırılması

Tahmin Parametresi	Model	Optimum Ayar / Ağ Yapısı	Eğitim MAE	Eğitim RMSE	Test MAE	Test RMSE
Toplam enerji tüketimi	SVM / SMOreg	PUK Kernel, (C=12), (sigma=5), (omega=1,1), (epsilon=0,0001)	1,2276	2,4020	2,4414	4,6326
Toplam enerji tüketimi	MLP	4-2-2-1	3,4902	4,4030	3,3911	4,7942
Isıtma enerjisi	SVM / SMOreg	PUK Kernel, (C=12), (sigma=5), (omega=1), (epsilon=0,00001)	1,1780	2,2775	2,4178	4,4340
Isıtma enerjisi	MLP	4-4-1	2,3262	3,1766	2,8669	4,4708
Soğutma enerjisi	SVM / SMOreg	PUK Kernel, (C=12), (sigma=5), (omega=1), (epsilon=0,001)	0,2440	0,3987	0,3470	0,4688
Soğutma enerjisi	MLP	4-4-1	0,3532	0,4716	0,3601	0,4803

SVM/SMOreg ve MLP modellerinin toplam enerji tüketimi, ısıtma enerjisi ve soğutma enerjisi tahminlerindeki hata değerleri karşılaştırıldığında, tüm tahmin parametrelerinde SVM/SMOreg modelinin daha düşük test MAE ve test RMSE değerleri ürettiği görülmektedir. Toplam enerji tüketiminde SVM/SMOreg modeli 2,4414 test MAE ve 4,6326 test RMSE değerleriyle MLP modelinden daha düşük hata üretmiştir. Isıtma enerjisinde iki modelin test RMSE değerleri birbirine oldukça yakın olmakla birlikte, SVM/SMOreg modeli 4,4340 test RMSE ile daha

düşük hata düzeyinde kalmıştır. Soğutma enerjisi tahmininde ise iki model arasındaki fark sınırlı düzeyde gerçekleşmiş; SVM/SMOreg modeli 0,3470 test MAE ve 0,4688 test RMSE değerleriyle daha başarılı sonuç vermiştir.




Şekil 3.34: Enerji tüketimi tahminlerinde SMOreg ve MLP modellerinin hata ölçütlerine göre karşılaştırılması

Enerji tüketimi tahminlerinin farklı hata değerlerine göre karşılaştırıldığı grafikte, SVM/SMOreg modelinin eğitim ve test verilerinde genel olarak daha düşük hata değerleri ürettiği görülmektedir. Toplam enerji ve ısıtma enerjisi tahminlerinde hata değerleri soğutma enerjisine göre daha yüksek düzeydedir. Bu durum, toplam enerji ve ısıtma enerjisi verilerinin daha geniş değişim aralığına sahip olmasıyla ilişkilendirilebilir. Soğutma enerjisi tahmininde ise iki modelin hata değerleri birbirine yakın seyretmiş, ancak SVM/SMOreg modeli sınırlı da olsa daha düşük test hatası üretilmiştir.

Tablo 3.26: Toplam enerji tüketimi tahmini için SVM/SMOreg ve MLP modellerinin hata ölçütleri

Tahmin Parametresi	Model	Optimum Ayar / Ağ Yapısı	Eğitim MAE	Eğitim RMSE	Test MAE	Test RMSE
Toplam enerji tüketimi	SVM / SMOreg	PUK Kernel, (C=12), (sigma=5), (omega=1,1), (epsilon=0,00001)	1,2276	2,4020	2,4414	4,6326
Toplam enerji tüketimi	MLP	4-2-2-1	3,4902	4,4030	3,3911	4,7942

Toplam enerji tüketimi tahmininde SVM/SMOreg modeli, eğitim ve test verilerinde MLP modeline göre daha düşük hata değerleri üretmiştir. SVM/SMOreg modelinde test MAE 2,4414 ve test RMSE 4,6326 olarak hesaplanırken, MLP modelinde bu değerler sırasıyla 3,3911 ve 4,7942 düzeyinde gerçekleşmiştir. Test RMSE değerleri arasındaki fark sınırlı olsa da, test MAE değerindeki daha belirgin düşüş SVM/SMOreg modelinin toplam enerji tüketimi tahmininde daha dengeli bir hata dağılımı sunduğunu gösterilmektedir.




Şekil 3.35: Toplam enerji tüketimi tahmininde SMOreg ve MLP modellerinin eğitim ve test hata değerleri

Toplam enerji tüketimi tahmini grafiğinde, SVM/SMOreg modelinin eğitim MAE ve eğitim RMSE değerlerinde MLP modeline göre daha düşük hata ürettiği görülmektedir. Test verilerinde de aynı eğilim korunmuştur. MLP modelinin test RMSE değeri SVM/SMOreg modeline yakın olmakla birlikte, test MAE değerinin daha yüksek olması, ortalama hata büyüklüğü açısından SVM/SMOreg modelinin daha avantajlı olduğunu gösterilmektedir.

Tablo 3.27: Isıtma enerjisi tüketimi tahmini için SVM/SMOreg ve MLP modellerinin hata ölçütleri

Tahmin Parametresi	Model	Optimum Ayar / Ağ Yapısı	Eğitim MAE	Eğitim RMSE	Test MAE	Test RMSE
Isıtma enerjisi	SVM / SMOreg	PUK Kernel, (C=12), (sigma=5), (omega=1), (epsilon=0,00001)	1,1780	2,2775	2,4178	4,4340
Isıtma enerjisi	MLP	4-4-1	2,3262	3,1766	2,8669	4,4708

Isıtma enerjisi tahmininde SVM/SMOreg ve MLP modellerinin test RMSE değerleri birbirine oldukça yakın sonuçlar üretmiştir. SVM/SMOreg modelinde test RMSE 4,4340, MLP modelinde ise 4,4708 olarak hesaplanmıştır. Test MAE açısından SVM/SMOreg modeli 2,4178 değeriyle MLP modelinin 2,8669 değerinden daha düşük hata üretmiştir. Bu nedenle ısıtma enerjisi tahmininde iki modelin genel performansı yakın görünmekle birlikte, ortalama mutlak hata düzeyi bakımından SVM/SMOreg modelinin daha başarılı olduğu gösterilmiştir.




Şekil 3.36: Isıtma enerjisi tüketimi tahmininde SMOreg ve MLP modellerinin eğitim ve test hata değerleri

Isıtma enerjisi tüketimi tahminine ait grafikte, eğitim verilerinde SVM/SMOreg modelinin daha düşük MAE ve RMSE değerleri ürettiği görülmektedir. Test verilerinde iki model arasındaki RMSE farkı oldukça sınırlıdır. Buna karşın test MAE değerinde SVM/SMOreg modeli daha düşük hata verdiğinden, modelin bağımsız test verisinde ortalama sapmaları daha iyi kontrol ettiği değerlendirilmektedir.

Tablo 3.28: Soğutma enerjisi tüketimi tahmini için SVM/SMOreg ve MLP modellerinin hata ölçütleri

Tahmin Parametresi	Model	Optimum Ayar / Ağ Yapısı	Eğitim MAE	Eğitim RMSE	Test MAE	Test RMSE
Soğutma enerjisi	SVM / SMOreg	PUK Kernel, (sigma=5), (omega=1), (epsilon=0,001)	0,2440	0,3987	0,3470	0,4688
Soğutma enerjisi	MLP	4-4-1	0,3532	0,4716	0,3601	0,4803

Soğutma enerjisi tahmininde SVM/SMOreg ve MLP modelleri birbirine çok yakın test performansı göstermiştir. SVM/SMOreg modelinde test MAE 0,3470 ve test RMSE 0,4688 olarak hesaplanırken, MLP modelinde test MAE 0,3601 ve test RMSE 0,4803 olarak elde edilmiştir. Hata değerleri arasındaki fark düşük olmakla birlikte, SVM/SMOreg modelinin hem MAE hem de RMSE bakımından daha düşük sonuç vermesi, soğutma enerjisi tahmininde sınırlı düzeyde üstünlük sağladığını gösterilmektedir.



Şekil 3.37: Soğutma enerjisi tüketimi tahmininde SMOreg ve MLP modellerinin eğitim ve test hata değerleri

Soğutma enerjisi tüketimi grafiğinde her iki modelin de düşük hata değerleri ürettiği görülmektedir. Eğitim ve test hataları arasındaki farkın sınırlı kalması, modellerin soğutma enerjisi veri setinde güçlü bir genelleme davranışı sergilediğini göstermektedir. SVM/SMOreg modeli tüm hata metriklerinde MLP modelinden daha düşük değerler üretmiş olsa da, iki model arasındaki farkın sınırlı olmasıyla soğutma enerjisi tahmininde her iki yaklaşımın da yüksek tahmin kapasitesine sahip olduğu gösterilmektedir.

Toplam enerji tüketimi tahmin grafiklerinden elde edilen bulgular, SVM/SMOreg ve MLP modellerinin eğitim ve test veri setlerinde genel olarak tutarlı tahmin davranışı sergilediğini göstermektedir. Tahmin dağılımlarında gerçek değerlere yakınlık korunmuş, hata dağılımlarında ise sapmalar çoğunlukla sınırlı aralıkta kalmıştır. Buna rağmen belirli gözlemlerde daha yüksek sapmaların görülmesi, toplam enerji tüketimi tahmininde model performansının gözlem bazlı olarak da incelenmesi gerektiğini göstermektedir. Bu çerçevede grafikler, modellerin yalnızca sayısal hata değerleriyle değil, dağılım karakterleriyle de karşılaştırılmasına olanak sağlamaktadır.

4. SONUÇLAR VE TARTIŞMA

Kamu binalarında HVAC sistemlerinin enerji verimliliği ve optimizasyonuna yönelik yürütülen bu tez çalışmasında; iç ortam ısı konforu, operasyonel enerji tüketimi ve makine öğrenmesi tabanlı vekil modeller bütünleşik bir yaklaşımla değerlendirilmiştir. Elde edilen saha bulguları ve dinamik simülasyon çıktıları, standart mekanik işletme kabullerinin gerçek kullanıcı deneyimlerini tam olarak yansıtmadığını ve binalarda çevresel/kişisel değişkenlere uyum sağlayabilen veri odaklı kontrol stratejilerine ihtiyaç duyulduğunu göstermektedir. Bu bölümde, araştırma sahasından ve algoritmik analizlerden elde edilen özgün tez bulguları öncelikle kendi içinde özetlenmiş; ardından literatürde yer alan güncel ve referans niteliğindeki çalışmalarla doğrudan karşılaştırılarak tezin akademik literatürdeki yeri tartışılmıştır.

Tez çalışması kapsamında elde edilen mevsimsel ısı konfor bulguları incelendiğinde, standart teorik modeller ile saha algısı arasında belirgin bir sapma olduğu tespit edilmiştir. Saha ölçümlerine göre kış döneminde Tahmini Ortalama Oy (PMV) değeri -0,21 ve Tahmini Memnuniyetsizlik Yüzdesi (PPD) %5,9 hesaplanmasına karşın, kullanıcı anketlerinden elde edilen Gerçek Ortalama Oy (AMV) -0,80 ve Gerçek Memnuniyetsizlik Yüzdesi (APD) %18,5 olarak gerçekleşmiştir. Yaz döneminde ise PMV -0,04 ve PPD %5,0 iken, kullanıcıların AMV değeri 0,58 ve APD oranı %12,0 olarak belirlenmiştir. Bu durum, PMV modeli ile gerçek AMV duyumu arasında sahadaki kişisel faktörlere bağlı olarak yaklaşık 0,6 birimlik sistematik bir kayma oluşturmuştur. Ayrıca alt grup analizlerinde; kış aylarında kadın kullanıcıların APD oranının %26,1'e ve 30 yaş üstü personelin APD oranının %22,1'e ulaştığı; yaz döneminde ise ince giyinen (0,5 clo) grupta rahatsızlık oranının %36,7'ye kadar çıktığı hesaplanmıştır.

Elde edilen bu özgün bulgular literatürdeki çalışmalarla karşılaştırıldığında; standart rasyonel konfor indekslerinin (ASHRAE 55, ISO 7730) iç ortamı konforlu olarak değerlendirmesine karşın kullanıcı algısında oluşan bu sistematik kayma, Nicol ve Humphreys (2002) tarafından ifade edilen "rasyonel indeksler ile davranışsal adaptasyon tepkileri arasındaki uyumsuzluk" bulgularıyla doğrudan örtüşmektedir. Nicol ve Humphreys (2002), standartların sabit çevresel koşullara dayanması nedeniyle kişisel kontrol olanaklarını tam yansıtamadığını bildirmiştir. Yaş ve cinsiyete bağlı olarak saha anketlerinde elde edilen yüksek APD oranları ise, Rupp vd. (2015) tarafından Fanger modelinin özellikle yaşlı bireyler ve kadın kullanıcılar üzerindeki sınırlılıklarını vurgulayan çalışmalarını metodolojik olarak doğrulamaktadır. Son olarak, yaz döneminde giyim düzeyine (0,5 clo) bağlı olarak tespit edilen %36,7'lik yüksek

memnuniyetsizlik oranı, Schiavon ve Lee (2013) ile Zaraa Allah vd. (2025)'nin giyim yalıtımının ve davranışsal adaptasyonun termal algı üzerinde belirleyici bir fiziksel sınır oluşturduğuna dair literatürdeki çıkarımlarını güçlü biçimde desteklemektedir.

Kamu binası için oluşturulan dijital ikiz modelinde; kazan verimliliği, soğutma performans katsayısı (COP), sıcaklık ölü bandı (deadband) ve hava değişim oranı (ACH) üzerinden birleşik optimizasyon senaryoları simüle edilmiştir. Tez bulgularına göre; kazan veriminin %90'a ve chiller COP değerinin 4,5 seviyesine çıkarıldığı, sıcaklık set noktalarının 22-24 °C esnek aralığında sınırlandırıldığı ve ACH oranının dinamik kontrol edildiği bütünleşik HVAC senaryosunda, yıllık baz modele (1.578.593 kWh) kıyasla %23,22 oranında (1.212.014 kWh'ye düşen) toplam enerji tasarrufu elde edilmiştir. Ayrıca yalnızca ısıtma kazanı modernizasyonu senaryosunda %52,63 düzeyinde doğalgaz kazanımı saptanmıştır.

Tezden elde edilen bu optimizasyon çıktıları literatür ile kıyaslandığında; ulaşılan %23,22'lik birleşik tasarruf oranının, Alam vd. (2024) tarafından makine öğrenmesi destekli GLSSVM ve NSGA-II algoritmaları kullanılarak HVAC mekanik enerji tüketiminde elde edilen %37,5 oranındaki tasarruf potansiyeliyle uyumlu bir iyileştirme bandında yer aldığı görülmektedir. İç ortam set değerlerinin 22-24 °C ölü bant aralığına esnetilmesiyle kazanılan termodinamik hafifleme, Hoyt vd. (2015)'nin "ölü bant sınırlarının genişletilmesiyle mekanik cihazların aktif çalışma sürelerinin azaltıldığına" yönelik simülasyon bulgularıyla birebir paralellik içermektedir. Keza bu yaklaşım, Savadkoohi vd. (2022)'nin ısıtma set noktalarını 19–20 °C ve soğutma noktalarını 24–25 °C olarak regüle ettiği kontrol algoritmalarıyla operasyonel anlamda örtüşmektedir. Tez kapsamında Hava Değişim Oranının (ACH) tek başına sağladığı spesifik tasarruf yüzdesini literatürdeki tekil ACH iyileştirmeleriyle doğrudan sayısal olarak kıyaslayan bir değerlendirme yapılamamaktadır; kaynak dökümünde bu doğrultuda bir karşılaştırma verisi yer almamaktadır. Ancak Li vd. (2026)'nin taze hava debisindeki dinamik düzenlemelerin chiller kompresörleri ve kazan grupları üzerindeki yükü hafiflettiğine yönelik değerlendirmesi, tezdeki ACH modülasyonu mantığıyla fiziksel tutarlılık göstermektedir.

Tez kapsamında HVAC operasyonlarının enerji tüketim profilini tahmin etmek amacıyla Çok Katmanlı Algılayıcı (MLP) ve Destek Vektör Regresyonu (SMOreg) yapay zeka algoritmaları WEKA platformunda eğitilmiş ve performansları test edilmiştir. Tez bulgularına göre; toplam enerji tüketimi tahmininde PUK çekirdekli ve hiperparametre optimizasyonu (C=12, sigma=5) yapılmış SMOreg modeli (MAE: 2,4414, RMSE: 4,6326), en iyi ağ yapısına sahip (4-2-2-1)

MLP modelinden (MAE: 3,3911, RMSE: 4,7942) daha kararlı ve düşük hata üreten bir yapı sergilemiştir. Isıtma enerjisinde SMOREg'in RMSE değeri (4,4340), MLP modeline (4,4708) göre sınırlı düzeyde daha düşük hesaplanırken; soğutma enerjisinde de SMOREg (MAE: 0,3470, RMSE: 0,4688), MLP ağından (MAE: 0,3601, RMSE: 0,4803) oransal olarak daha başarılı bir genelleme kapasitesi göstermiştir.

Bu algoritmik bulgular literatür ile karşılaştırıldığında; SMOREg/SVR yaklaşımının toplam enerji ve ısıtma yükü tahminlerinde gösterdiği üstünlük, Barathula vd. (2024) tarafından belirtilen RBF çekirdekli SVR modellerinin ısı yükü tahminindeki yüksek doğruluk başarılarını metodolojik olarak doğrulamaktadır. Aynı zamanda İslam vd. (2026) ile Abdel-Jaber ve Dirks (2024)'in destek vektör mekanizmalarının yüksek boyutlu termodinamik verilerde sapmaları önceden tanımlanmış tolerans sınırları içinde optimize edebildiğine yönelik tespitleri, tezde SMOREg'in MLP'ye kıyasla daha stabil hata dağılımı sunmasının teorik altyapısıyla bütünüyle uyushmaktadır. Öte yandan tez çalışmasında, SMOREg ile yarışan MLP modellerinin de (özellikle ısıtma tahmininde 4,4708 RMSE gibi) oldukça yakın ve kabul edilebilir hata metriklerine ulaştığı görülmüştür. Bu durum, literatürde Zeynalli ve Eslami (2025) ile Tuğal (2025) tarafından ifade edilen "gizli katman ve hiperparametrelerin optimize edilmesiyle MLP ağlarının rekabetçi sonuçlar elde edebileceği" argümanı ile tutarlılık oluşturmaktadır. Sonuç itibarıyla her iki vekil model de (surrogate model), Markarian vd. (2024) ile Stevanović vd. (2024) tarafından vurgulanan "karmaşık bina enerji simülasyonlarının yüksek hesaplama maliyetlerini düşürerek güvenilir tahminler üretme" görevini yüksek doğrulukla sağlamıştır.

Sonuç olarak, bu tez çalışması kapsamında ulaşılan sayısal ve algısal bulgular, kamu binalarında mekanik sistemlere entegre edilen statik sıcaklık ayar noktalarının ve geleneksel PMV-PPD indekslerinin, heterojen kullanıcı profillerini temsil etmede yetersiz kaldığını açıkça ortaya koymuştur. Literatür bulgularıyla desteklenen bu durum, enerji verimliliğinin ancak dinamik konfor bantları ve davranışsal adaptasyon kısıtları ile optimize edilebileceğini kanıtlamaktadır. Tezin birleşik HVAC senaryo kurgusu ve WEKA tabanlı yüksek doğruluklu SMOREg/MLP enerji tahmin modelleri, literatürdeki güncel dijital ikiz (digital twin) ve makine öğrenmesi uygulamalarıyla çok güçlü bir metodolojik uyum sergilemektedir. Bireysel memnuniyetsizlik oranlarının (APD) matematiksel kısıt fonksiyonlarına dönüştürülmesiyle oluşturulan bu veri odaklı tahmin altyapısı, akıllı bina enerji yönetim sistemlerinin otonomizasyon sürecine uygulanabilir ve somut bir akademik katkı sunmaktadır.

5. KAYNAKLAR

- Abbasabadi, N., Moroseos, T. F., Ashayeri, M., and Meek, C.** (2026). AI-Enhanced Urban Building Energy Modeling for Health-Driven Decarbonization in Vulnerable Communities. *Engineering*. <https://doi.org/10.20944/preprints202604.1576.v1>
- Abdel-Jaber, F., and Dirks, K. N.** (2024). A Review of Cooling and Heating Loads Predictions of Residential Buildings Using Data-Driven Techniques. *Buildings*, 14(3), 752. <https://doi.org/10.3390/buildings14030752>
- Abdul Rahim, S. N., Zakaria, M. A., Yasin, M. N., and Hanipah, M. H.** (2024). Thermal comfort of student in classroom with elevated set point air-conditioner temperature: Objective and subjective measurement. *IOP Conference Series: Earth and Environmental Science*, 1347(1), 012035. <https://doi.org/10.1088/1755-1315/1347/1/012035>
- Afram, A., & Janabi-Sharifi, F.** (2014). Theory and applications of HVAC control systems—A review of model predictive control (MPC). *Building and Environment*, 72, 343–355. <https://doi.org/10.1016/j.buildenv.2013.11.016>
- Afram, A., & Janabi-Sharifi, F.** (2017). Artificial neural network (ANN) based model predictive control (MPC) and optimization of HVAC systems: A state of the art review and case study of a residential HVAC system. *Energy and Buildings*, 141, 96–113. <https://doi.org/10.1016/j.enbuild.2017.02.012>
- Ahmed, Z., Jamil, M., and Ali Khan, A.** (2025). A Novel Multi-Task Learning-Based Approach to Multi-Energy System Load Forecasting. *IEEE Open Access Journal of Power and Energy*, 12, 209-219. <https://doi.org/10.1109/OAJPE.2025.3559336>
- Al Horr, Y., Arif, M., Kaushik, A., Mazroei, A., Katafygiotou, M., and Elsarrag, E.** (2016). Occupant productivity and office indoor environment quality: A review of the literature. *Building and Environment*, 105, 369-389. <https://doi.org/10.1016/j.buildenv.2016.06.001>
- Alajmi, A. F.** (2025). Quantifying energy use intensity and peak demand in a hot-arid residential building: Insights from four years of high-resolution monitoring. *Energy Reports*, 14, 2204-2216. <https://doi.org/10.1016/j.egyr.2025.08.052>
- Alam, N., Zaki, S. A., Ahmad, S. A., Azizan, A., Singh, M. K., Rijal, H. B., and Othman, N. B.** (2025). Application of Internet of Things in assessing personal thermal comfort incorporating spatial parameters in air-conditioned office. *Advances in Building Energy Research*, 19(5), 660-687. <https://doi.org/10.1080/17512549.2025.2539120>
- Alam, N., Zaki, S. A., Ahmad, S. A., Singh, M. K., Azizan, A., and Othman, N.** (2024). Machine learning approach for predicting personal thermal comfort in air conditioning offices in Malaysia. *Building and Environment*, 266, 112083. <https://doi.org/10.1016/j.buildenv.2024.112083>

KAYNAKLAR DİZİNİ (devam)

- Alharbi, A. H., Khafaga, D. S., Zaki, A. M., El-Kenawy, E.-S. M., Ibrahim, A., Abdelhamid, A. A., Eid, M. M., El-Said, M., Khodadadi, N., Abualigah, L., and Saeed, M. A.** (2024). Forecasting of energy efficiency in buildings using multilayer perceptron regressor with waterwheel plant algorithm hyperparameter. *Frontiers in Energy Research*, 12, 1393794. <https://doi.org/10.3389/fenrg.2024.1393794>
- Almadhor, A., Ghazouani, N., Bouallegue, B., Kryvinska, N., Alsubai, S., Krichen, M., Hejaili, A. A., and Sampedro, G. A.** (2025). Digital twin based deep learning framework for personalized thermal comfort prediction and energy efficient operation in smart buildings. *Scientific Reports*, 15(1), 24654. <https://doi.org/10.1038/s41598-025-10086-y>
- Almady, S. S., Abdel-Sattar, M., Al-Sager, S. M., Al-Hamed, S. A., and Aboukarima, A. M.** (2024b). Employing an Artificial Neural Network Model to Predict Citrus Yield Based on Climate Factors. *Agronomy*, 14(7), 1548. <https://doi.org/10.3390/agronomy14071548>
- Amaral, J. V. S. D., Miranda, R. D. C., Montevechi, J. A. B., Santos, C. H. D., and Brito, F. D. O.** (2025). Adaptive metamodeling-based simulation optimisation. *Journal of the Operational Research Society*, 76(6), 1156-1176. <https://doi.org/10.1080/01605682.2024.2415474>
- ANSI/ASHRAE Standard 55-2023.**
- ASHRAE.** (2014). ASHRAE guideline 14-2014: Measurement of energy, demand, and water savings.
- Azzazy, S., Ghaffarianhoseini, A., GhaffarianHoseini, A., Naismith, N., Doan, D. T., and Hollander, J. B.** (2025). The significance of indoor thermal comfort on occupants' perception: In university buildings in Auckland, New Zealand. *Building Research & Information*, 53(1-2), 19-39. <https://doi.org/10.1080/09613218.2024.2344072>
- Azzi, A., Abid, M., Hanif, A., Bensag, H., Tabaa, M., Hachimi, H., & Youssfi, M.** (2025). A hybrid control strategy combining reinforcement learning and MPC-LSTM for energy management in building. *Energies*, 18(17), Article 4783. <https://doi.org/10.3390/en18174783>
- Ba, L., Tangour, F., El Abbassi, I., and Absi, R.** (2025). Analysis of Digital Twin Applications in Energy Efficiency: A Systematic Review. *Sustainability*, 17(8), 3560. <https://doi.org/10.3390/su17083560>
- Barathula, S., Kandasamy, R., Fok, P. J. Y., Wong, T. N., Leong, K. C., and Srinivasan, K.** (2024). Heat load prediction in flow boiling using boiling-induced vibrations aided with machine learning. *International Journal of Heat and Mass Transfer*, 232, 125890. <https://doi.org/10.1016/j.ijheatmasstransfer.2024.125890>
- Barbosa, E. F. T., Labaki, L. C., Castro, A. P. A. S., and Lopes, F. S. D.** (2024). Energy Efficiency and Thermal Comfort Analysis in a Higher Education Building in Brazil. *Sustainability*, 16(1), 462. <https://doi.org/10.3390/su16010462>

KAYNAKLAR DİZİNİ (devam)

- Behrooz, F., Mariun, N., Marhaban, M. H., Mohd Radzi, M. A., & Ramli, A. R.** (2018). Review of control techniques for HVAC systems—Nonlinearity approaches based on fuzzy cognitive maps. *Energies*, 11(3), Article 495. <https://doi.org/10.3390/en11030495>
- Boodi, A., Beddiar, K., Benamour, M., Amirat, Y., & Benbouzid, M.** (2018). Intelligent systems for building energy and occupant comfort optimization: A state of the art review and recommendations. *Energies*, 11(10), Article 2604. <https://doi.org/10.3390/en11102604>
- Boukaf, M., Fadli, F., and Meskin, N.** (2024). A Comprehensive Review of Digital Twin Technology in Building Energy Consumption Forecasting. *IEEE Access*, 12, 187778-187799. <https://doi.org/10.1109/ACCESS.2024.3498107>
- Bousnina, D., and Guerassimoff, G.** (2024). Optimal energy management in smart energy systems: A deep reinforcement learning approach and a digital twin case-study. *Smart Energy*, 16, 100163. <https://doi.org/10.1016/j.segy.2024.100163>
- Caner, I., and Ilten, N.** (2020). Evaluation of occupants' thermal perception in a university hospital in Turkey. *Proceedings of the Institution of Civil Engineers - Engineering Sustainability*, 173(8), 414-428. <https://doi.org/10.1680/jensu.19.00059>
- Chan, J. Y., & Ahn, J.** (2024). Spatial distribution and transient responses of the thermal environment in an office space equipped with a standing-type air conditioner. *International Journal of Air-Conditioning and Refrigeration*, 32, Article 5. <https://doi.org/10.1007/s44189-024-00050-2>
- Chang, C., Li, X., Duanmu, L., Sun, B., and Ju, H.** (2024). Analysis of the impact of indoor thermal comfort data characteristics on dataset quality. *Energy and Buildings*, 310, 114079. <https://doi.org/10.1016/j.enbuild.2024.114079>
- Cherif, H., and Belhadj, J.** (2024). Metamodel-based on meta-heuristic design optimization of renewable energy microgrid. *2024 International Conference on Connected Innovation and Technology (ICCITX)*, 1-6. <https://doi.org/10.1109/ICCITX61791.2024.11070430>
- Chinde, V., Chintala, R., Kim, J., Chapin, A., Xiong, J., Fleming, K., and Ball, B. L.** (2026). Surrogate model evaluation and building energy benchmarking for commercial buildings. *Energy and Buildings*, 355, 117033. <https://doi.org/10.1016/j.enbuild.2026.117033>
- Choi, J.-H., Aziz, A., & Loftness, V.** (2010). Investigation on the impacts of different genders and ages on satisfaction with thermal environments in office buildings. *Building and Environment*, 45(6), 1529–1535. <https://doi.org/10.1016/j.buildenv.2010.01.004>
- Dai, C., Zhang, H., Arens, E., & Lian, Z.** (2017). Machine learning approaches to predict thermal demands using skin temperatures: Steady-state conditions. *Building and Environment*, 114, 1–10. <https://doi.org/10.1016/j.buildenv.2016.12.005>
- de Dear, R. J.** (1998a). *Developing an Adaptive Model of Thermal Comfort and Preference*.
- de Dear, R. J.** (1998b). *Developing an Adaptive Model of Thermal Comfort and Preference*.

KAYNAKLAR DİZİNİ (devam)

- De Las Morenas, J., Belmonte, L. M., and Morales, R.** (2025). Designing an AI-driven digital twin architecture for building energy prediction. *Journal of Building Engineering*, 113, 113966. <https://doi.org/10.1016/j.jobbe.2025.113966>
- Dey, S., and Henze, G. P.** (2024). Reinforcement Learning Building Control: An Online Approach With Guided Exploration Using Surrogate Models. *ASME Journal of Engineering for Sustainable Buildings and Cities*, 5(1), 011005. <https://doi.org/10.1115/1.4064842>
- Drgoňa, J., Arroyo, J., Cupeiro Figueroa, I., Blum, D. H., Arendt, K., Kim, D., Ollé, E. P., Oravec, J., Wetter, M., Vrabie, D. L., & Helsen, L.** (2020). All you need to know about model predictive control for buildings. *Annual Reviews in Control*, 50, 190–232. <https://doi.org/10.1016/j.arcontrol.2020.09.001>
- Eker, E., Atar, Ş., Şevgin, F., and Tuğal, İ.** (2024). Optimization of Non-Linear Problems Using Salp Swarm Algorithm and Solving the Energy Efficiency Problem of Buildings with Salp Swarm Algorithm-based Multi-Layer Perceptron Algorithm. *ELECTRICA*, 24(2), 436-449. <https://doi.org/10.5152/electrica.2024.23193>
- Elnabawi, M. H., and Hamza, N.** (2024). Review on Gaps and Challenges in Prediction Outdoor Thermal Comfort Indices: Leveraging Industry 4.0 and ‘Knowledge Translation’. *Buildings*, 14(4), 879. <https://doi.org/10.3390/buildings14040879>
- Eslami, B., and M. Zeynalli, S. M. Z.** (2025). Integrating multi-layer perceptron regression with innovative optimization for accurate building cooling load prediction, *Advances in Engineering and Intelligence Systems*, (Online First). <https://doi.org/10.22034/aeis.2025.504074.1283>
- European Committee for Standardization.** (2012). Indoor environmental input parameters for design and assessment of energy performance of buildings addressing indoor air quality, thermal environment, lighting and acoustics (English version).
- Fang, Z., Zhang, F., Feng, X., Xu, X., Mao, Z., Zhao, L., Wang, Q., and Wu, W.** (2025). Variable chilled water supply temperature regulation strategy guided by thermal comfort studies. *Thermal Science and Engineering Progress*, 67, 104179. <https://doi.org/10.1016/j.tsep.2025.104179>
- Fanger, P. O.** (1970). Thermal comfort: Analysis and applications in environmental engineering. Danish Technical Press.
- Fu, C., Chen, K., Xu, Y., Ming, D., Ye, R., Wu, Y., and Sun, L.** (2025). Collaborative optimal operation control of HVAC systems based on multi-agent. *Frontiers in Energy Research*, 13, 1609210. <https://doi.org/10.3389/fenrg.2025.1609210>
- Fusaro, G., D’Auria, S., & D’Orazio, D.** (2023). Multiphysical numerical analysis for acoustic metamaterials in ventilated ducts. *INTER-NOISE and NOISE-CON Congress and Conference Proceedings*, 268(4), 4931–4942. https://doi.org/10.3397/IN_2023_0699

KAYNAKLAR DİZİNİ (devam)

- Gao, C., & Wang, D.** (2023). Comparative study of model-based and model-free reinforcement learning control performance in HVAC systems. *Journal of Building Engineering*, 74, Article 106852. <https://doi.org/10.1016/j.jobe.2023.106852>
- Gao, Q., Chu, Y., Peng, Z., Jin, Y., Ji, X., Ji, S., Ping, S., Xie, X., Zhu, X., and Yue, Y.** (2024). Smart Building Management System based on Digital Twin: A Case Study on Real-Time Environmental Monitoring and Thermal Comfort Prediction. *2024 IEEE International Symposium on Parallel and Distributed Processing with Applications (ISPA)*, 2157-2163. <https://doi.org/10.1109/ISPA63168.2024.00294>
- Gholamzadehmir, M., Del Pero, C., Buffa, S., Fedrizzi, R., & Aste, N.** (2020). Adaptive-predictive control strategy for HVAC systems in smart buildings—A review. *Sustainable Cities and Society*, 63, Article 102480. <https://doi.org/10.1016/j.scs.2020.102480>
- Ghritlahre, H. K., and Verma, M.** (2025). Solar air heaters performance prediction using multi-layer perceptron neural network— A systematic review. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, 47(1), 7682-7699. <https://doi.org/10.1080/15567036.2021.1923869>
- Guo, F., Ham, S. W., Kim, D., & Moon, H. J.** (2025). Deep reinforcement learning control for co-optimizing energy consumption, thermal comfort, and indoor air quality in an office building. *Applied Energy*, 377, Article 124467. <https://doi.org/10.1016/j.apenergy.2024.124467>
- Han, X., Fang, T., Wang, Y., Wang, Z., and Xu, J.** (2025a). Multi-objective optimization of passive design parameters for rural residences based on GA-BP-NSGA-II: A case study of cold regions in China. *Journal of Building Engineering*, 112, 113624. <https://doi.org/10.1016/j.jobe.2025.113624>
- Han, X., Fang, T., Wang, Y., Wang, Z., and Xu, J.** (2025b). Multi-objective optimization of passive design parameters for rural residences based on GA-BP-NSGA-II: A case study of cold regions in China. *Journal of Building Engineering*, 112, 113624. <https://doi.org/10.1016/j.jobe.2025.113624>
- Hong, T., D'Oca, S., Turner, W. J. N., and Taylor-Lange, S. C.** (2015). An ontology to represent energy-related occupant behavior in buildings. Part I: Introduction to the DNAs framework. *Building and Environment*, 92, 764-777. <https://doi.org/10.1016/j.buildenv.2015.02.019>
- Hosamo, H. H., Tingstveit, M. S., Nielsen, H. K., Svennevig, P. R., & Svidt, K.** (2022). Multiobjective optimization of building energy consumption and thermal comfort based on integrated BIM framework with machine learning-NSGA II. *Energy and Buildings*, 277, Article 112479. <https://doi.org/10.1016/j.enbuild.2022.112479>
- Hossain, J., Kadir, A. F. A., Hanafi, A. N., Shareef, H., Khatib, T., Baharin, K. A., & Sulaima, M. F.** (2023). A review on optimal energy management in commercial buildings. *Energies*, 16(4), Article 1609. <https://doi.org/10.3390/en16041609>

KAYNAKLAR DİZİNİ (devam)

- Hoyt, T., Arens, E., and Zhang, H.** (2015). Extending air temperature setpoints: Simulated energy savings and design considerations for new and retrofit buildings. *Building and Environment*, 88, 89-96. <https://doi.org/10.1016/j.buildenv.2014.09.010>
- Hwang, J., Kim, J., and Yoon, S.** (2025). DT-BEMS: Digital twin-enabled building energy management system for information fusion and energy efficiency. *Energy*, 326, 136162. <https://doi.org/10.1016/j.energy.2025.136162>
- Iddio, E., Wang, L., Zhang, H., and Wong, N. H.** (2025). The effects of indoor living walls on occupant thermal comfort in office buildings. *Science and Technology for the Built Environment*, 31(4), 398-414. <https://doi.org/10.1080/23744731.2025.2460371>
- Indraganti, M., Ooka, R., & Rijal, H. B.** (2015). Thermal comfort in offices in India: Behavioral adaptation and the effect of age and gender. *Energy and Buildings*, 103, 284–295. <https://doi.org/10.1016/j.enbuild.2015.05.042>
- International Organization for Standardization.** (2005). Ergonomics of the thermal environment—Analytical determination and interpretation of thermal comfort using calculation of the PMV and PPD indices and local thermal comfort criteria (ISO Standard No. 7730:2005). <https://www.iso.org/standard/39155.html>
- Islam, M. B., Guerrieri, A., Gravina, R., Rizzo, L., Scopelliti, G., D’Agostino, V., and Fortino, G.** (2026). ATM-SB: An indoor temperature prediction approach for smart buildings based on deep learning. *Future Generation Computer Systems*, 181, 108431. <https://doi.org/10.1016/j.future.2026.108431>
- Jeong, S., & Wi, Y.-M.** (2024). Research on development and implementation of integrated energy management system for buildings. *Journal of Electrical Engineering & Technology*, 19(8), 5393–5405. <https://doi.org/10.1007/s42835-024-01870-3>
- Jiang, K., Shi, T., Yu, H., Mahyuddin, N., and Lu, S.** (2024). A systematic review of multi-output prediction model for indoor environment and heating, ventilation, and air conditioning energy consumption in buildings. *Indoor and Built Environment*, 33(9), 1574-1604. <https://doi.org/10.1177/1420326X241258678>
- Juliet, A. H., Malathi, P., and Legapriyadharshini, N.** (2024). Smart Forecasting: Harnessing Machine Learning for Accurate CO2 Emission Predictions. *2024 11th International Conference on Reliability, Infocom Technologies and Optimization (Trends and Future Directions) (ICRITO)*, 1-7. <https://doi.org/10.1109/ICRITO61523.2024.10522152>
- Jun, H., and Fei, H.** (2024). Research on multi-objective optimization of building energy efficiency based on energy consumption and thermal comfort. *Building Services Engineering Research and Technology*, 45(4), 391-411. <https://doi.org/10.1177/01436244241240066>

KAYNAKLAR DİZİNİ (devam)

- Karjalainen, S.** (2007). Gender differences in thermal comfort and use of thermostats in everyday thermal environments. *Building and Environment*, 42(4), 1594–1603. <https://doi.org/10.1016/j.buildenv.2006.01.009>
- Kazemi, M., and Kazemi, A.** (2025). Barriers to the adoption of passive heating and cooling systems in residential building design: Case study of Iran. *Energy Efficiency*, 18(8), 104. <https://doi.org/10.1007/s12053-025-10393-3>
- Khalid, A., Dahlan, N. D., Bin Abas, M. F., Bin Ahmad, K. A., and Shahidan, M. F.** (2025). The impact of wind catchers on thermal comfort and indoor air quality: An analysis of subtropical climate for summer and winter. *Indoor and Built Environment*, 34(4), 838-867. <https://doi.org/10.1177/1420326X251323242>
- Khastar, S., Bashirizadeh, F., Jafari-Asl, J., and Safaeian Hamzehkolaei, N.** (2025). Predicting the cooling and heating loads of energy efficient buildings: A hybrid machine learning approach. *Cluster Computing*, 28(5), 323. <https://doi.org/10.1007/s10586-024-04993-4>
- Kim, J., Zhou, Y., Schiavon, S., Raftery, P., and Brager, G.** (2018). Personal comfort models: Predicting individuals' thermal preference using occupant heating and cooling behavior and machine learning. *Building and Environment*, 129, 96-106. <https://doi.org/10.1016/j.buildenv.2017.12.011>
- Kim, S., Jin, D., Yeol Yun, B., Nam, J., and Kim, S.** (2024). Assessing thermal comfort in wooden buildings: A visual perceptual analysis through physiological characterization. *Energy and Buildings*, 324, 114918. <https://doi.org/10.1016/j.enbuild.2024.114918>
- Kishore, P. S. V., Rajesh, J., Jayaram, N., and Halder, S.** (2024). A Survey of Machine Learning Applications in Renewable Energy Sources. *IETE Journal of Research*, 70(2), 1389-1406. <https://doi.org/10.1080/03772063.2022.2143439>
- Koşum, M. F., and Özkan, A. O.** (2025). Analysis of the effect of environmental data collected through the WSN on plant development by the WEKA program. *Turkish Journal of Engineering*, 9(2), 202-210. <https://doi.org/10.31127/tuje.1532313>
- Kumar, S., Kumar, A., Sharma, S.K.** (2026). Energy Auditing practices for HVAC Systems: An IoT-based Approaches. *International Journal of Research and Technology*, 14(S1), 599-607. <https://doi.org/10.64882/ijrt.v14.iS1.1069>
- Kumar, S., Mathur, A., Singh, M. K., and Rana, K. B.** (2021). Adaptive thermal comfort study of workers in a mini-industrial unit during summer and winter season in a tropical country, India. *Building and Environment*, 197, 107874. <https://doi.org/10.1016/j.buildenv.2021.107874>
- Lakhiar, M. T., Sanmargaraja, S., Olanrewaju, A., Lim, C. H., Ponniah, V., and Mathalamuthu, A. D.** (2024). Evaluating and comparing objective and subjective thermal comfort in a malaysian green office building: A case study. *Case Studies in Thermal Engineering*, 60, 104614. <https://doi.org/10.1016/j.csite.2024.104614>

KAYNAKLAR DİZİNİ (devam)

- Lei, Y.** (2025). Construct a deep meta-learning model for accurate outdoor thermal comfort prediction and its application. *International Journal of Environmental Science and Technology*, 22(12), 11173-11194. <https://doi.org/10.1007/s13762-024-06099-1>
- Li, H., Chen, Y., Li, Y., Yang, S., Zou, Y., and Wang, L.** (2025). Requirement of minimum air change rate for different pollutant emission rate levels of decoration material in a renovated office. *Journal of Building Engineering*, 101, 111928. <https://doi.org/10.1016/j.jobbe.2025.111928>
- Li, H., and Hong, T.** (2025). A digital twin platform for building performance monitoring and optimization: Performance simulation and case studies. *Building Simulation*, 18(6), 1561-1579. <https://doi.org/10.1007/s12273-025-1290-2>
- Li, P., Zhao, X., Gao, N., Luo, M., and Shi, X.** (2024). Influencing factors of long-term thermal comfort in office buildings. *Building Simulation*, 17(11), 2043-2061. <https://doi.org/10.1007/s12273-024-1179-5>
- Li, W., Wang, X., Chen, S., Sun, X., Wu, H., and Zhang, J.** (2026). Built environment control based on multi-objective optimization algorithm: Optimizing thermal comfort, indoor air quality and HVAC energy efficiency. *Energy and Built Environment*, S2666123326000279. <https://doi.org/10.1016/j.enbenv.2026.03.003>
- Lin, D., Li, T., Chen, Z., and Li, L.** (2025). Effects of interactions between thermal and acoustic environments on subjective comfort evaluations in outdoor public spaces. *Journal of Asian Architecture and Building Engineering*, 24(1), 367-382. <https://doi.org/10.1080/13467581.2023.2292069>
- Liu, Z., Li, M., and Ji, W.** (2025). Development and application of a digital twin model for Net zero energy building operation and maintenance utilizing BIM-IoT integration. *Energy and Buildings*, 328, 115170. <https://doi.org/10.1016/j.enbuild.2024.115170>
- Luparelli, A., Kyprianou, I., Papadopoulos, P., and Carlucci, S.** (2024). *Design and Validation of Thermal Comfort Questionnaire Using Exploratory and Confirmatory Factor Analyses*. SSRN. <https://doi.org/10.2139/ssrn.4936352>
- Ma, N., Li, W., Jiang, C., Sun, X., and Zhang, J.** (2025). Development of digital twin system for central air-conditioning based on BIM. *Journal of Building Engineering*, 111, 113171. <https://doi.org/10.1016/j.jobbe.2025.113171>
- Macarulla, M., Casals, M., Forcada, N., & Gangoellés, M.** (2017). Implementation of predictive control in a commercial building energy management system using neural networks. *Energy and Buildings*, 151, 511–519. <https://doi.org/10.1016/j.enbuild.2017.06.027>
- Maharjan, B., and Rijal, H. B.** (2026). Optimal thermal comfort and thermal preferences ranges for office occupants in Japan. *IOP Conference Series: Earth and Environmental Science*, 1582(1), 012041. <https://doi.org/10.1088/1755-1315/1582/1/012041>

KAYNAKLAR DİZİNİ (devam)

- Makawi, M. A., Budaiwi, I. M., Abdou, A. A., and Al-Homoud, M. S.** (2026). Air-leakage modelling for accurate prediction of energy consumption in centrally air-conditioned houses in hot climates. *Advances in Building Energy Research*, 1-23. <https://doi.org/10.1080/17512549.2026.2646207>
- Mao, R., Lan, Y., Liang, L., Yu, T., Mu, M., Leng, W., and Long, Z.** (2025). Rapid CFD Prediction Based on Machine Learning Surrogate Model in Built Environment: A Review. *Fluids*, 10(8), 193. <https://doi.org/10.3390/fluids10080193>
- Mao, Y., Zhu, K., Zheng, Z., and Fang, Z.** (2024). Evaluation of the thermal comfort in different commercial buildings in Guangzhou. *Indoor and Built Environment*, 33(2), 391-413. <https://doi.org/10.1177/1420326X231199639>
- Mariano-Hernández, D., Hernández-Callejo, L., Zorita-Lamadrid, A., Duque-Pérez, O., & Santos García, F.** (2021). A review of strategies for building energy management system: Model predictive control, demand side management, optimization, and fault detect & diagnosis. *Journal of Building Engineering*, 33, Article 101692. <https://doi.org/10.1016/j.jobe.2020.101692>
- Markarian, E., Qiblawi, S., Krishnan, S., Divakaran, A., Ramalingam Rethnam, O., Thomas, A., and Azar, E.** (2024). Informing building retrofits at low computational costs: A multi-objective optimisation using machine learning surrogates of building performance simulation models. *Journal of Building Performance Simulation*, 1-17. <https://doi.org/10.1080/19401493.2024.2384487>
- Mazandarani, M., Ting, D. S.-K., and Stagner, J. A.** (2026). Thermal Comfort Assessment in Faculty Offices of a High-Performance Educational Building in Canada: A Mixed-Methods Approach. *Indoor Air*, 2026(1), 9639599. <https://doi.org/10.1155/ina/9639599>
- Miran, F. D., and Aziz, S. Q.** (2025). Comparative assessment of thermal comfort and energy performance in current and prototype school buildings in Erbil's hot semiarid climate. *Journal of Asian Architecture and Building Engineering*, 1-21. <https://doi.org/10.1080/13467581.2025.2604355>
- Mohamed, Y. M., Fahd, S. M., P, I. A. T., and S, M. Y.** (2025). A Double Deep Q Network Approach to Control HVAC Systems. *2025 1st International Conference on Smart and Intelligent Systems (SISCON)*, 1-6. <https://doi.org/10.1109/SISCON66686.2025.11409099>
- Moon, J. W., & Han, S.-H.** (2012). A comparative study between thermostat/hygrometer-based conventional and artificial neural network-based predictive/adaptive thermal controls in residential buildings. *Journal of Asian Architecture and Building Engineering*, 11(1), 169–176. <https://doi.org/10.3130/jaabe.11.169>

KAYNAKLAR DİZİNİ (devam)

- Mottahedin, P., Chahkandi, B., Moezzi, R., Fathollahi-Fard, A. M., Ghandali, M., and Gheibi, M.** (2024). Air quality prediction and control systems using machine learning and adaptive neuro-fuzzy inference system. *Heliyon*, 10(21), e39783. <https://doi.org/10.1016/j.heliyon.2024.e39783>
- Mustapha, T. D., Hassan, A. S., Khozaei, F., and Onubi, H. O.** (2024). Examining thermal comfort levels and ASHRAE Standard-55 applicability: A case study of free-running classrooms in Abuja, Nigeria. *Indoor and Built Environment*, 33(1), 8-22. <https://doi.org/10.1177/1420326X231177430>
- Nicol, J. F., and Humphreys, M. A.** (2002). Adaptive thermal comfort and sustainable thermal standards for buildings. *Energy and Buildings*, 34(6), 563-572. [https://doi.org/10.1016/S0378-7788\(02\)00006-3](https://doi.org/10.1016/S0378-7788(02)00006-3)
- Ortiz-Suarez, L. A., Perez-Tellez, F., Ruiz-Vanoye, J. A., Trejo-Macotella, F. R., Simancas-Acevedo, E., Rodríguez Flores, J., Diaz-Parra, O., and Ortiz De La Peña, M. L.** (2025). Modelling and Comparison of Machine-Learning Algorithms for Energy Consumption Prediction in Smart Buildings. *Computación y Sistemas*, 29(2). <https://doi.org/10.13053/cys-29-2-5663>
- Ouanes, S., & Sriti, L.** (2024). Regression-based sensitivity analysis and multi-objective optimisation of energy performance and thermal comfort: Building envelope design in hot arid urban context. *Building and Environment*, 248, Article 111099. <https://doi.org/10.1016/j.buildenv.2023.111099>
- Ozdemir, S. N., and Pektezel, O.** (2026). A CFD-driven machine learning approach for predicting PEM electrolyzer performance. *Fuel*, 405, 136479. <https://doi.org/10.1016/j.fuel.2025.136479>
- Papadopoulos, S., Kontokosta, C. E., Vlachokostas, A., & Azar, E.** (2019). Rethinking HVAC temperature setpoints in commercial buildings: The potential for zero-cost energy savings and comfort improvement in different climates. *Building and Environment*, 155, 350–359. <https://doi.org/10.1016/j.buildenv.2019.03.062>
- Parsons, K. C.** (2003). *Human thermal environments: The effects of hot, moderate, and cold environments on human health, comfort, and performance* (2. ed). Taylor and Francis.
- Pektezel, O.** (2025). Parametric analysis of a three-stage cascade refrigeration system for ultra-low temperature applications and performance prediction using multilayer perceptron algorithm. *Science and Technology for the Built Environment*, 31(7), 723-747. <https://doi.org/10.1080/23744731.2025.2523204>
- Prina, M. G., Dallapiccola, M., Moser, D., and Sparber, W.** (2024). Machine learning as a surrogate model for EnergyPLAN: Speeding up energy system optimization at the country level. *Energy*, 307, 132735. <https://doi.org/10.1016/j.energy.2024.132735>

KAYNAKLAR DİZİNİ (devam)

- Quanwei, T., Guijun, X., and Wenju, X.** (2025). Cakformer: Transformer model for long-term heat load forecasting based on Cauto-correlation and KAN. *Energy*, 324, 135460. <https://doi.org/10.1016/j.energy.2025.135460>
- Ren, J., Fang, Z., Zhang, X., Zou, Q., and Chen, Y.** (2026). Progress and challenges of the development of design weather parameters for building air-conditioning system: A literature review. *Renewable and Sustainable Energy Reviews*, 231, 116780. <https://doi.org/10.1016/j.rser.2026.116780>
- Reza-E-Rabbi, Sk., Bhuiyan, M. A., Zhang, G., Dodampegama, S., and Atapattu, K.** (2026). Simulation- and Metamodel-Based Multi-Objective Optimization for Sustainable Building Retrofit Across Climatic Conditions. *Materials*, 19(8), 1649. <https://doi.org/10.3390/ma19081649>
- Rigo-Mariani, R., & Yakub, A.** (2024). Decision tree variations and online tuning for real-time control of a building in a two-stage management strategy. *Energies*, 17(11), Article 2730. <https://doi.org/10.3390/en17112730>
- Rizzo, A.** (2025). Simulation and validation of a hybrid geothermal-aerothermal HVAC system in a primary care centre in Paterna using EnergyPlus and building monitoring system data, Yüksek Lisans Tezi, Università degli Studi di Padova, Dipartimento di Ingegneria Industriale, 97 (yayımlanmamış). <https://hdl.handle.net/20.500.12608/107561> (Erişim Tarihi: 02 Mayıs 2026).
- Rupp, R. F., Vásquez, N. G., and Lamberts, R.** (2015). A review of human thermal comfort in the built environment. *Energy and Buildings*, 105, 178-205. <https://doi.org/10.1016/j.enbuild.2015.07.047>
- Ruth, O., Kuga, K., and Ito, K.** (2025). Subjective and Objective Measurement of Indoor Environmental Quality and Occupant Comfort in a Multinational Graduate Student Office. *Environments*, 12(4), 117. <https://doi.org/10.3390/environments12040117>
- Sandal, K., and Ilten, N.** (2025). Field Study On Thermal Comfort Of Office Workers: Integration Of Measured Data And Occupant Perceptions. *Engineering Sciences*.
- Savadkoohi, M.** (2025). An advanced control strategy for optimizing HVAC system performance in non-residential buildings, Doktora Tezi, Universitat Politècnica de Catalunya, Departament d'Enginyeria Civil i Ambiental, 183 (yayımlanmamış). <https://hdl.handle.net/10803/696188> (Erişim Tarihi: 02 Mayıs 2026).
- Sayed, A. N., Bensaali, F., Himeur, Y., Dimitrakopoulos, G., and Varlamis, I.** (2025). Enhancing building sustainability: A Digital Twin approach to energy efficiency and occupancy monitoring. *Energy and Buildings*, 328, 115151. <https://doi.org/10.1016/j.enbuild.2024.115151>
- Schiavon, S., and Lee, K. H.** (2013). Dynamic predictive clothing insulation models based on outdoor air and indoor operative temperatures. *Building and Environment*, 59, 250-260. <https://doi.org/10.1016/j.buildenv.2012.08.024>

KAYNAKLAR DİZİNİ (devam)

- Shamsi, M. H., Ali, U., Mangina, E., & O'Donnell, J.** (2020). A framework for uncertainty quantification in building heat demand simulations using reduced-order grey-box energy models. *Applied Energy*, 275, Article 115141. <https://doi.org/10.1016/j.apenergy.2020.115141>
- Shevade, S. K., Keerthi, S. S., Bhattacharyya, C., & Murthy, K. R. K.** (2000). Improvements to the SMO algorithm for SVM regression. *IEEE Transactions on Neural Networks*, 11(5), 1188–1193. <https://doi.org/10.1109/72.870050>
- Shengli, L., Dantong, L., Yuan, J., and Ding, Y.** (2026). Energy optimization strategies for high-rise buildings: A simulation-driven approach. *Building and Environment*, 298, 114625. <https://doi.org/10.1016/j.buildenv.2026.114625>
- Shin, M., Shin, Y., Kim, Y., and Cho, H.** (2024). Investigation of drivers' thermal comfort based on selective cooling seats with air conditioner in summer using biosignals and subjective survey. *Building and Environment*, 250, 111199. <https://doi.org/10.1016/j.buildenv.2024.111199>
- Shirzadi, N., Lau, D., and Stylianou, M.** (2025). Surrogate Modeling for Building Design: Energy and Cost Prediction Compared to Simulation-Based Methods. *Buildings*, 15(13), 2361. <https://doi.org/10.3390/buildings15132361>
- Sisman, S., Kara, A., and Aydinoglu, A. C.** (2025). Leveraging spatial data infrastructure for machine learning based building energy performance prediction. *PLOS One*, 20(10), e0335531. <https://doi.org/10.1371/journal.pone.0335531>
- Song, B., Yang, L., and Bai, L.** (2025a). Field experimental study of the impact of solar radiation on the thermal comfort of occupants near the glazing area in an office building. *Energy and Buildings*, 332, 115422. <https://doi.org/10.1016/j.enbuild.2025.115422>
- Song, B., Yang, L., and Bai, L.** (2025b). Field experimental study of the impact of solar radiation on the thermal comfort of occupants near the glazing area in an office building. *Energy and Buildings*, 332, 115422. <https://doi.org/10.1016/j.enbuild.2025.115422>
- Starke, A. R., and Da Silva, A. K.** (2025). A review on the applicability of machine learning techniques to the metamodeling of energy systems. *Numerical Heat Transfer, Part B: Fundamentals*, 86(2), 214-243. <https://doi.org/10.1080/10407790.2023.2280208>
- Stevanović, S., Dashti, H., Milošević, M., Al-Yakoob, S., and Stevanović, D.** (2024). Comparison of ANN and XGBoost surrogate models trained on small numbers of building energy simulations. *PLOS ONE*, 19(10), e0312573. <https://doi.org/10.1371/journal.pone.0312573>
- Sung, W.-T., Hsiao, S.-J., & Shih, J.-A.** (2019). Construction of indoor thermal comfort environmental monitoring system based on the IoT architecture. *Journal of Sensors*, 2019, Article 2639787. <https://doi.org/10.1155/2019/2639787>
- Tindall, J. R., Rogage, K., and Doukari, O.** (2025). Optimising deep learning for smart building energy prediction: A particle swarm approach with real-world validation. *Journal of Building Engineering*, 116, 114652. <https://doi.org/10.1016/j.job.2025.114652>

KAYNAKLAR DİZİNİ (devam)

- Tuğal, İ.** (2025). Energy efficiency in building: Entropy-based Grey Wolf Optimization for improved MLP performance. *Energy Reports*, 13, 4247-4260. <https://doi.org/10.1016/j.egyr.2025.03.048>
- Vallianos, H., and Kapsis, C.** (2026). Surrogate models for evaluating HVAC retrofit options in multi-unit residential buildings. *Energy and Buildings*, 355, 117060. <https://doi.org/10.1016/j.enbuild.2026.117060>
- Villano, F., Mauro, G. M., and Pedace, A.** (2024). A Review on Machine/Deep Learning Techniques Applied to Building Energy Simulation, Optimization and Management. *Thermo*, 4(1), 100-139. <https://doi.org/10.3390/thermo4010008>
- Wang, Y., Wang, Q., and Zhang, S.** (2025). A Lightweight Multi-Layer Perceptron Approach for Carbon Emission Prediction of Public Buildings Under Low-Dimensional Data Scenarios. *Buildings*, 15(24), 4508. <https://doi.org/10.3390/buildings15244508>
- Wang, Y., Zhan, C., Li, G., and Ren, S.** (2024). Comparison of algorithms for heat load prediction of buildings. *Energy*, 297, 131318. <https://doi.org/10.1016/j.energy.2024.131318>
- Warthmann, A., Syndicus, M., Frisch, J., and Van Treeck, C.** (2025). Local personalized heating in a field study—Suggestions for implementation of personalized environmental control systems in real offices. *Building and Environment*, 281, 112935. <https://doi.org/10.1016/j.buildenv.2025.112935>
- Xu, W., and Liu, S.** (2024). Novel economic models for advancing urban energy management and transition: Simulation of urban energy system in digital twin. *Sustainable Cities and Society*, 101, 105154. <https://doi.org/10.1016/j.scs.2023.105154>
- Yang, J.** (2024). Accurate cooling load estimation using multi-layer perceptron machine learning models. *Signal, Image and Video Processing*, 18(11), 7711-7727. <https://doi.org/10.1007/s11760-024-03422-8>
- Yang, L., Chen, Z., and Zhen, M.** (2024). Effects of thermal-acoustic interaction on airport terminal's indoor thermal comfort: A case study in cold region of China. *Journal of Building Engineering*, 86, 108834. <https://doi.org/10.1016/j.jobbe.2024.108834>
- Yang, X., Xia, W., and Zhen, M.** (2026). Thermal comfort of pregnant women in cold-region hospitals: Differences by conception method. *Building and Environment*, 293, 114355. <https://doi.org/10.1016/j.buildenv.2026.114355>
- Yang, X., Yao, L., and Peng, L. L. H.** (2024). Impacts of urban air temperature and humidity on building cooling and heating energy demand in 15 cities of eastern China. *Energy*, 288, 129887. <https://doi.org/10.1016/j.energy.2023.129887>
- Yu, K.-H., Chen, Y.-A., Jaimes, E., Wu, W.-C., Liao, K.-K., Liao, J.-C., Lu, K.-C., Sheu, W.-J., & Wang, C.-C.** (2021). Optimization of thermal comfort, indoor quality, and energy-saving in campus classroom through deep Q learning. *Case Studies in Thermal Engineering*, 24, Article 100842. <https://doi.org/10.1016/j.csite.2021.100842>

KAYNAKLAR DİZİNİ (devam)

- Zaraa Allah, M. R., Kamar, H. M., Wong, K. Y., and Hatif, I. H. (2025).** Exploring the impact of dress codes on thermal comfort and workplace satisfaction in tropical climates. *Theoretical and Applied Climatology*, 156(4), 203. <https://doi.org/10.1007/s00704-025-05435-w>
- Zhang, C., Xue, X., Zhao, Y., Zhang, X., & Li, T. (2019).** An improved association rule mining-based method for revealing operational problems of building heating, ventilation and air conditioning (HVAC) systems. *Applied Energy*, 253, Article 113492. <https://doi.org/10.1016/j.apenergy.2019.113492>
- Zhang, S., Lei, X., Shan, X., Li, T., and Wu, W. (2026).** Optimization of an MPC Controller Based on a Hybrid Cooling Load Prediction Model and Experimental Validation in HVAC Systems. *Buildings*, 16(6), 1269. <https://doi.org/10.3390/buildings16061269>
- Zhao, Y., Genovese, P. V., & Li, Z. (2020).** Intelligent thermal comfort controlling system for buildings based on IoT and AI. *Future Internet*, 12(2), Article 30. <https://doi.org/10.3390/fi12020030>
- Zhen, M., Liu, J., Xia, W., Sun, M., Dong, Q., Li, Y., and Liang, H. (2025).** Thermal comfort differences among patients with different orthopedic diseases: A case study of Shaanxi Provincial People's Hospital, China. *Building and Environment*, 283, 113407. <https://doi.org/10.1016/j.buildenv.2025.113407>
- Zhou, M., Wang, L., Hu, F., Zhu, Z., Zhang, Q., Kong, W., Zhou, G., Wu, C., and Cui, E. (2024).** ISSA-LSTM: A new data-driven method of heat load forecasting for building air conditioning. *Energy and Buildings*, 321, 114698. <https://doi.org/10.1016/j.enbuild.2024.114698>
- Zhu, H., and Lin, B. (2024).** Digital twin-driven energy consumption management of integrated heat pipe cooling system for a data center. *Applied Energy*, 373, 123840. <https://doi.org/10.1016/j.apenergy.2024.123840>
- Zhuang, D., Gan, V. J. L., Duygu Tekler, Z., Chong, A., Tian, S., & Shi, X. (2023).** Data-driven predictive control for smart HVAC system in IoT-integrated buildings with time-series forecasting and reinforcement learning. *Applied Energy*, 338, Article 120936. <https://doi.org/10.1016/j.apenergy.2023.120936>

EKLER

EKLER

EK A: Termal Konfor Ölçüm Anketi

TERMAL KONFOR ÖLÇÜM DEĞERLENDİRME ANKETİ							
Termal Konfor Cihazı Kurulum Saati:							
Çalışma Alanı/Bölüm:							
Tarih:				Ölçüm Saati:			
Yaş:				Cinsiyet:			
Herhangi Bir Sağlık Problemi Olup Olmadığı:							
Dış Hava Sıcaklığı °C:				Dış Hava Nemi %:			
Çalışma ortamında Isıtma veya soğutmayı etkileyen cihazlar ve sayıları (klima,fan,aydınlatma,bilgisayar,cnc vb.)							
Tipi						Sayısı	
Ne kadar süredir çalışma ortamında bulunulduğu?							
15dk		15-30 dk		30-60dk		1 saatten fazla	
Son 1 saattir bulunulan iş tipi/tipleri? (Farklı aktiviteler için süreye bağlı metabolik hız hesaplanacaktır)							
Ofis Aktiviteleri							
Ashrae 55 Appendix A-(Oturmuş,okuyan,yazan ; Yazıcı; Oturmuş-dosyalayan; Ayakta-dosyalayan;Dolanın;Kaldırın/ambalajlayan)							
Mesleki Aktiviteler							
Ashrae 55 Appendix A-(Oturmuş,yoğun uzuv hareketi; Makinede ağır iş; 50 kg taşıma)							
Çalışma ortamının termal açıdan değerlendirilmesi?							
Hafif Sıcak Sıcak Ilık Konforlu Uygun Hafif Serin Serin Soğuk							
Çalışma Ortamı Koşullarının Kabul Edilebilir Olup Olmadığı?							
Kabul Edilebilir:				Kabul Edilemez:			
Cihaz Okumaları:							
Sıcaklık °C:				B.Nem %:			
Radyant °C:				Hava Hızı (m/s):			
PMV:				PPD:			

ETİK KURUL İZİN BELGESİ

Evrak Tarih ve Sayısı: 14.02.2024-E.352286

T.C.
BALIKESİR ÜNİVERSİTESİ
FEN VE MÜHENDİSLİK BİLİMLERİ ETİK KOMİSYONU
ONAY BELGESİ

Balıkesir Üniversitesi Mühendislik Fakültesi. Makine Mühendisliği Anabilim Dalı Öğretim Üyesi Doç. Dr. Nadir İLTEN'in danışmanlığını yürütmüş olduğu; 201912604003 numaralı Doktora programı öğrencisi Koray SANDAL'ın "Kent Merkezlerindeki Binaların Enerji Etkin İyileştirilmesine Bağlı Enerji Tasarruf Potansiyelinin Modellenmesi" başlıklı tez çalışmasının uygulamaların yürütülmek için etik kurul onay belgesi isteği komisyonumuzca değerlendirilmiş ve etik açıdan uygun bulunmuştur. 31.01.2024

Komisyon Başkanı
Prof. Dr. Zafer ASLAN

Prof. Dr. Baki ÇİÇEK
Üye

Prof. Dr. Türkan GÖKSAL ÖZBALTA
Üye

Prof. Dr. Nursen AZİZOĞLU
Üye

Prof. Dr. Ruhan BENLİKAYA
Üye