



**MAKİNE ÖĞRENİMİ ALGORİTMALARI ÜZERİNDEN BİNA ENERJİ
PERFORMANSI TAHMİNLEME MODELİ**

Merve ERTOSUN YILDIZ

**DOKTORA TEZİ
MİMARLIK ANA BİLİM DALI**

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

EKİM 2023

ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Merve ERTOSUN YILDIZ

17/10/2023

MAKİNE ÖĞRENİMİ ALGORİTMALARI ÜZERİNDEN BİNA ENERJİ PERFORMANSI TAHMİNLEME MODELİ

(Doktora Tezi)

Merve ERTOSUN YILDIZ

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Ekim 2023

ÖZET

Bina sektöründe, artan nüfusun yanı sıra sosyal talep ve hızlı kentleşme gibi diğer faktörler nedeniyle enerji talebinin büyük ölçüde arttığı açıktır. Binalara uygulanan enerji verimliliği konusu, günümüzün uluslararası enerji politikalarının temel unsurlarından biridir. Özellikle konut sektöründe olmak üzere yapı üretimi ve kullanım süreci boyunca ihtiyaç duyulan enerji talebindeki belirsizliklerle çözüm getirmesi gerekmektedir. Enerji performansı için güvenilir tahmin yöntemlerinin geliştirilmesi, binalarda enerji verimliliğinin sağlanmasında önemli ve öncelikli bir araştırma alanı olarak görülmelidir. Veriye dayalı öğrenme imkânı sunan makine öğrenimi bina enerji talep tahminlerinde ortaya çıkan belirsizliklerle başa çıkmak için uygulanan güncel bir yaklaşımdır. Bu doğrultuda, Türkiye 3. İklim bölgesinde yer alan konutların ısıtma ve soğutma yüklerini tahmini sağlayan ve makine öğrenimi algoritmalarına dayanan bir model önerisi geliştirilmiştir. Araştırmada önce simülasyon programları aracılığı ile konut tipi üzerinden duvar katmanları, plan tipi, yönlenme durumu, pencere tipi değiştirilerek 12960 tane senaryo oluşturulmuş ve çalışmanın ilk aşaması tamamlanmıştır. Daha sonra bu veri seti ön işlemlerden geçirilerek ısıtma yük tahmini için 8602; soğutma yük tahmini için 9617 adet örnekleme düşürülmüştür. Tahmin modelleri geliştirilirken, doğrusal regresyon, karar ağaçları, destek vektör makineleri ve yapay sinir ağı algoritmaları uygulanmıştır. En iyi tahmin performansını gösteren yapay sinir ağı modeli ısıtma ve soğutma yükleri için tahmin modeli olarak geliştirilmiştir. Nihai model ısıtma yükü için % 90 doğruluk; soğutma yükü için % 98 doğrulukla çalışmıştır. Model performansı, oluşturulan farklı senaryolar ile sınanmış ve doğrulanmıştır. Bu araştırma makine öğrenimi aracılığı ile enerji performansına yönelik tahminlerin, -yeterli veri sağlandığında- yüksek doğrulukla sonuçlanabileceğini ve erken tasarım evresinde tüm proje paydaşlarına yol göstericilabileceğini göstermektedir.

Bilim Kodu : 80111

Anahtar Kelimeler : Bina enerji performansı, sürdürülebilirlik, mimarlıkta makine öğrenimi, karar ağacı, yapay sinir ağı,

Sayfa Adedi : 148

Danışman : Prof. Dr. Figen BEYHAN

A PREDICTIVE MODEL FOR BUILDING ENERGY PERFORMANCE BASED ON MACHINE LEARNING ALGORITHMS

(Ph. D. Thesis)

Merve ERTOSUN YILDIZ

GAZİ UNIVERSITY

GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

October 2023

ABSTRACT

In the building sector, it is clear that energy demand has increased substantially due to the growing population as well as other factors such as social demand and rapid urbanization. The issue of energy efficiency applied to buildings is one of the critical elements of today's international energy policies. It is necessary to resolve the uncertainties in the energy demand needed throughout the building production and utilization process, especially in the housing sector. Developing reliable prediction methods for energy performance should be considered a vital and prioritized research area in ensuring energy efficiency in buildings. Machine learning offers data-driven learning and it is a current approach to deal with uncertainties in building energy demand forecasting. Accordingly, a model proposal based on machine learning algorithms has been developed to estimate the heating and cooling loads of residential buildings in the 3rd climate zone of Turkey. The first stage of the study was completed by creating 12960 scenarios by changing wall layers, plan type, orientation status, and window type through simulation programs. Then, this data set was pre-processed and reduced to 8602 samples for heating load estimation and 9617 samples for cooling load estimation. While developing prediction models, linear regression, decision trees, support vector machine, and artificial neural network algorithms were applied. The artificial neural network model with the best prediction performance was developed as a prediction model for heating and cooling loads. The final model worked with 90% accuracy for the heating load and 98% for the cooling load. The model performance was tested and verified with different scenarios. That research shows when accurate parameters and sufficient data are provided, predictions of energy performance through machine learning can result in high accuracy and guide all project stakeholders in the early design phase.

Science Code : 80111

Key Words : Building energy performance, energy efficient building design, machine learning, decision tree, artificial neural network

Page Number : 148

Supervisor : Prof. Dr. Figen BEYHAN

TEŞEKKÜR

Lisans hayatımdan bugüne desteği hep benimle olan, akademik tecrübesinden çok şey öğrendiğim, kıymetli hocam Prof. Dr. Figen BEYHAN'a sevgisi, özverisi, değerli fikirleri, önerileri ve paylaşımlarımız için minnettarım.

Tez çalışmam boyunca, araştırmalarımın ilerlemesi ve gelişmesi hususunda değerli görüşleri ve geri bildirimleri için Doç. Dr. Gülsu ULUKAVAK HARPUTLUGİL' e ve Prof. Dr. Cüneyt KURTAY'a çok teşekkür ederim. Ayrıca, kıymetli katkı ve yorumları için saygıdeğer jüri üyelerim Prof. Dr. Arzuhan Burcu GÜLTEKİN ve Prof. Dr. Gamze YÜCEL IŞILDAR hocalarım ile çalışma süresince kıymetli katkıları ve destekleri için Doç. Dr. Muhammed Kürşad UÇAR ve Doç Dr. Adem TEKEREK hocalarıma şükran duyarım.

Sıkıntıları ve mutlulukları bir arada yaşadığımız, kıymetlilerim, meslektaşlarım, Esmâ, Ayşenur, Rüya, Güneş ve tüm arkadaşlarım ile hem meslektaşım, hem kardeşim Tuba Nur'a destekleri, sabırları ve yol göstericilikleri için çok teşekkür ederim.

Hayatım boyunca her koşulda yanımda olan, annem Hülya ERTOSUN, babam Murat ERTOSUN, abim Fırat Emre ERTOSUN ve biriciğim Elif Pınar ERTOSUN ile tüm yakınlarıma sonsuz güvenleri ve destekleri için çok teşekkürler.

Bu yolu birlikte yürüdüğümüz ve birlikte büyüdüğümüz, hayat ortağım, en büyük desteğim yol arkadaşım canım Akif ile doktora sürecimizde ailemize katılan, koşulsuz sevgiyi, sabrı ve sabırsızlığı da birlikte öğrendiğimiz, umut ışığımız Elif Ece'mize tezimi adamak isterim.

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT.....	v
ÇİZELGELERİN LİSTESİ.....	ix
ŞEKİLLERİN LİSTESİ.....	xi
SİMGELER VE KISALTMALAR.....	xiv
1. GİRİŞ.....	1
2. BİNA ENERJİ PERFORMANSI.....	11
2.1. Yasal Düzenlemeler	11
2.2. Bina Enerji Performansını Etkileyen Parametreler	17
2.2.1. Çevreye ilişkin parametreler	18
2.2.2. Kullanıcıya ilişkin parametreler	21
2.2.3. Aktif sistemlere ilişkin parametreler	22
2.2.4. Binaya ilişkin parametreler	23
2.3. Enerji Performansı Belirleme/Tahminleme Yöntemleri	32
2.3.1. Beyaz kutu modelleri	34
2.3.2. Kara kutu modelleri.....	35
2.3.3. Gri kutu modelleri	36
3. MAKİNE ÖĞRENİMİ İLE ENERJİ PERFORMANSI TAHMİNLEMESİ	39
3.1. Makine Öğrenimi İçin Tahminleme Süreci.....	39
3.1.1. Makine öğrenimi modeli için girdi verilerinin ön işleme süreci	42
3.2. Makine Öğrenimi ile Bina Enerji Performansı Tahminine Yönelik Literatür Araştırmaları	44
3.3. Makine Öğrenimi ile Enerji Performans Tahmini için Kullanılan Modeller	53

Sayfa

3.3.1. İstatistiksel regresyonlar	53
3.3.2. Karar ağaçları	54
3.3.3. Destek vektör makineleri	56
3.3.4. Yapay sinir ağları	57
3.4. Makine Öğrenimi Tahmin Performansı Değerlendirme Metrikleri	59
4. MATERYAL VE YÖNTEM.....	61
4.1. Çalışmanın Veri Toplama Yöntemi	63
4.2. Veri Setinin Oluşturulması.....	64
4.3. Bina Tasarım Senaryolarının Oluşturulması	64
4.3.1. Senaryolara yönelik verilerin oluşturulması	77
4.4. Tahmin Modelinde Girdi Verileri ve Ön İşleme Süreci	84
4.5. Isıtma ve Soğutma Yükleri için Tahmin Modelinin Geliştirilmesi	88
4.5.1. Yazılım programı seçimi	89
4.5.2. Soğutma yükü tahmin modeli geliştirilmesi.....	89
4.5.3. Isıtma yükü tahmin modeli geliştirilmesi	104
4.6. Nihai Tahmin Modelinin Sınanması ve Değerlendirme.....	118
4.6.1. Soğutma yükü YSA modelinin sınanması	123
4.6.2. Isıtma yükü YSA modelinin sınanması.....	126
5. SONUÇ VE ÖNERİLER.....	129
ÖZGEÇMİŞ.....	147

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 2.1. Türkiye’de enerji verimliliği ile ilgili başlıca yasal düzenlemeler	13
Çizelge 2.2. TS 825’te derece gün bölgeleri	16
Çizelge 2.3. Bina enerji performansına etki eden parametreler	18
Çizelge 2.4. Farklı iklim bölgelerine göre bina formları	24
Çizelge 2.5. İklim bölgelerine göre tercih edilebilecek yapı kabukları	30
Çizelge 2.6. İklim bölgesine göre saydam yüzey tasarımında dikkat edilmesi gereken kriterler	31
Çizelge 2.7. Bina enerji tahminleme yöntemleri	34
Çizelge 2.8. Bina enerji tahmin model tekniklerinin karşılaştırılması.....	38
Çizelge 3.1. Literatür araştırmaları analizi	51
Çizelge 3.2. LR modeli ile yapılan tahminleme çalışmaları	54
Çizelge 3.3. Karar ağaçları modeli ile yapılan tahminleme çalışmaları	56
Çizelge 3.4. SVM modeli ile yapılan tahminleme çalışmaları	57
Çizelge 3.5. Yapay sinir ağları modeli ile yapılan tahminleme çalışmaları	59
Çizelge 4.1. Senaryolar için belirlenen duvar katmanları.....	66
Çizelge 4.2. Ana duvar malzemesi tuğla olan alternatif dış duvar konstrüksiyonları ve U değerleri.....	67
Çizelge 4.3. Ana duvar malzemesi gazbeton olan alternatif dış duvar konstrüksiyonları ve U değerleri.....	69
Çizelge 4.4. Ana duvar malzemesi bims olan alternatif dış duvar konstrüksiyonları ve U değerleri.....	71
Çizelge 4.5. Ana duvar malzemesi beton blok olan alternatif dış duvar konstrüksiyonları ve U değerleri.....	73
Çizelge 4.6. Senaryolar için belirlenen saydamlık oranları	75
Çizelge 4.7. Senaryolar için belirlenen pencere tipleri	75

Çizelge	Sayfa
Çizelge 4.8. Senaryolar için belirlenen yönlenme durumları	76
Çizelge 4.9. Simülasyonu yapılacak olan alternatif senaryolar	78
Çizelge 4.10. Microsoft Excel üzerinde hazırlanan parametre-sonuç tablo örneği	83
Çizelge 4.11. Belirlenen girdi verileri.....	84
Çizelge 4.12. Isıtma yükü için yaklaşımlara ait aykırılık hesabında kullanılan eşik değerler.....	87
Çizelge 4.13. Soğutma için yaklaşımlara ait aykırılık hesabında kullanılan eşik değerler.....	87
Çizelge 4.14. Makine öğrenimi için hazırlanan veri seti	88
Çizelge 4.15. Doğrusal regresyon modelinin tahmin sonuçları.....	92
Çizelge 4.16. Karar ağaçları modelinin tahmin sonuçları.....	94
Çizelge 4.17. Destek vektör makineleri modellerinin tahmin sonuçları.....	96
Çizelge 4.18. Yapay sinir ağı modellerinin tahmin sonuçları.....	98
Çizelge 4.19. Soğutma yükü tahmin modellerinin tahmin sonuçları.....	100
Çizelge 4.20. Doğrusal regresyon modelinin ısıtma yükü tahmin sonuçları	107
Çizelge 4.21. Karar ağaçları modelinin ısıtma yükü tahmin sonuçları.....	109
Çizelge 4.22. Destek vektör makineleri modellerinin tahmin sonuçları.....	111
Çizelge 4.23. Yapay sinir ağı modellerinin tahmin sonuçları.....	113
Çizelge 4.24. Soğutma yükü tahmin modellerinin tahmin sonuçları.....	115
Çizelge 4.25. Nihai modellerin sınanması için belirlenen senaryolar	119
Çizelge 4.26. Design Builder ile elde edilen çıktı verileri.....	120
Çizelge 4.27. Girdi ve çıktı verilerini oluşturan parametreler	121
Çizelge 4.28. Sınama modeli için hazırlanan girdi verileri	122
Çizelge 4.29. Soğutma yüküne ilişkin tahmin sonuçları ve gerçek değerler	125
Çizelge 4.30. Isıtma yüküne ilişkin tahmin sonuçları ve gerçek değerler	127

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 1.1. Nihai enerji tüketiminin sektörlere dağılımı	2
Şekil 1.2. Tez akış şeması	9
Şekil 2.1. Türkiye -derece gün bölgelerine göre iller	19
Şekil 2.2. Bina kabuğu ve iç mekân konforunu etkileyen iklimsel parametreler	19
Şekil 2.3. Gölgenin istendiği (A) ve istenmediği (B) durumlara göre yapı aralıkları ..	25
Şekil 2.4. Farklı iklim bölgelerine göre yapı aralıkları ve yerleşim önerisi	25
Şekil 2.5. Farklı iklim bölgelerine göre önerilen yapı yönlendirmeleri	26
Şekil 2.6. Farklı iklim bölgelerine göre yapı oran ve formları	27
Şekil 3.1. Makine öğrenimi ile bina enerji performansı tahmininin şematik gösterimi..	41
Şekil 3.2. Çapraz doğrulama modeli.....	42
Şekil 3.3. Girdi, çıktı katmanı ve gizli katmandan oluşan yapay sinir ağı modeli	58
Şekil 4.1. Yöntem akış diyagramı.....	62
Şekil 4.2. Senaryolar için belirlenen plan tipi geometrileri	65
Şekil 4.3. Senaryolara ait enerji performans değerlerine ulaşma adımları	77
Şekil 4.4. JEPlus yazılımı çalışma konsepti.....	79
Şekil 4.5. Dikdörtgen plan tipi için Design Builder ara yüzü.....	80
Şekil 4.6. JEPlus çalışma ekranı	80
Şekil 4.7. JEPlus output dosya ve içerikleri.....	83
Şekil 4.8. Ki kare tablosu.....	86
Şekil 4.9. MATLAB import sekmesi ile verilerin aktarımı	90
Şekil 4.10. MATLAB eklentisi arayüzü	90
Şekil 4.11. Soğutma tahmini için verilerin bölünmesi.....	91

Şekil	Sayfa
Şekil 4.12. Doğrusal regresyon modelinde gerçek değer ve tahmin sonuçlarının karşılaştırılması	92
Şekil 4.13. DR’da en iyi tahmin çizgisi ve gerçek değerlerin yayılımı	93
Şekil 4.14. Karar Ağacı modelinde gerçek değer ve tahmin sonuçlarının karşılaştırılması	95
Şekil 4.15. KA’nda en iyi tahmin çizgisi ve gerçek değerlerin yayılımı	95
Şekil 4.16. Destek Vektör Makinesi modelinde gerçek değer ve tahmin sonuçlarının karşılaştırılması	97
Şekil 4.17. SVM’de en iyi tahmin çizgisi ve gerçek değerlerin yayılımı	97
Şekil 4.18. YSA modelinde gerçek değer ve tahmin sonuçlarının karşılaştırılması.....	99
Şekil 4.19. YSA’da en iyi tahmin çizgisi ve gerçek değerlerin yayılımı.....	99
Şekil 4.20. MATLAB’ de soğutma yükü YSA model ağı yapısı	101
Şekil 4.21. Önerilen YSA soğutma modeli.....	102
Şekil 4.22. Eğitim, validasyon ve test regresyonu	103
Şekil 4.23. Soğutma yükü en iyi tahmin performans dağılımı	104
Şekil 4.24. MATLAB import sekmesi ile ısıtma yükü için verilerin aktarımı	105
Şekil 4.25. MATLAB eklentisi arayüzü	106
Şekil 4.26. Isıtma tahmini için verilerin bölünmesi	106
Şekil 4.27. DR modelinde gerçek değer ve tahmin sonuçlarının karşılaştırılması	108
Şekil 4.28. DR’da en iyi tahmin çizgisi ve gerçek değerlerin yayılımı	108
Şekil 4.29. Karar Ağacı modelinde gerçek değer ve tahmin sonuçlarının karşılaştırılması	110
Şekil 4.30. KA’nda en iyi tahmin çizgisi ve gerçek değerlerin yayılımı	110
Şekil 4.31. SVM ısıtma tahmin modelinde gerçek değer ve tahmin sonuçlarının karşılaştırılması	112
Şekil 4.32. SVM’de en iyi tahmin çizgisi ve gerçek değerlerin yayılımı	112

Şekil	Sayfa
Şekil 4.33. Yapay sinir ağları modelinde gerçek değer ve tahmin sonuçlarının karşılaştırılması	114
Şekil 4.34. YSA'da en iyi tahmin çizgisi ve gerçek değerlerin yayılımı.....	114
Şekil 4.35. MATLAB ısıtma yükü YSA modeli.....	116
Şekil 4.36. Önerilen yapay sinir ağı ısıtma yükü tahmin modeli.....	116
Şekil 4.37. Isıtma yükü YSA modeli eğitim, validasyon ve test regresyonu.....	117
Şekil 4.38. Isıtma yükü en iyi tahmin performans dağılımı.....	118
Şekil 4.39. Sınama verilerinin MATLAB a aktarılması	123
Şekil 4.40. Fonksiyonun MATLAB üzerinde uygulanması	124
Şekil 4.41. Isıtma yükü tahmin değeri ve gerçek değer karşılaştırılması	128
Şekil 4.42. Isıtma yükü tahmin değeri ve gerçek değer karşılaştırılması.....	128

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler

Açıklamalar

°C	Santigrat Derece
cm	Santimetre
kW	Kilowatt
kWh	Kilowattsaat
m	Metre
m²	Metrekare
mm	Milimetre

Kısaltmalar

Açıklamalar

AB	Avrupa Birliği
ABD	Amerika Birleşik Devletleri
ANN	Artificial Neural Network
DR	Doğrusal Regresyon
DT	Decision Tree
DNN	Deep Neural Network
DVM	Destek Rektör Makinesi
EKB	Enerji Kimlik Belgesi
ETKB	Enerji ve Tabii Kaynaklar Bakanlığı
EUI	Enerji Kullanım Yoğunluğu
HVAC	Isıtma Soğutma ve Havalandırma Sistemi
KA	Karar Ağacı
LR	Lineer Regresyon
MAE	Ortalama Mutlak Hata
MAPE	Ortalama Mutlak Yüzde Hata
MLR	Doğrusal Regresyon

Kısaltmalar**Açıklamalar****MSE**

Ortalama Karesel Hata

PCA

Temel Bileşen Analizi

R

Korelasyon Katsayısı

RF

Random Forest

RMSE

Ortalama Karekök Hata

 R^2

Mutlak Değişim Yüzdesi/Açıklayıcılık Katsayısı

SVM

Support Vector Machine

YSA

Yapay Sinir Ağları


1. GİRİŞ

Dünyada ekonomik büyüme, nüfus artışı, kentleşme, dijitalleşme gibi gelişmeler enerji tüketiminde büyük oranda artışa neden olmaktadır. Bu artışla birlikte, enerji kaynakları hızla tükenmekte ve iklim değişikliği, küresel ısınma gibi önemli çevresel problemler ortaya çıkmaktadır. Ayrıca milyonlarca yılda oluşmuş fosil yakıtların tüketiminin önemli miktarda artması, dünyanın ekolojik dengesi üzerinde ciddi problemler yaratmıştır. Son yüzyılda çeşitli insan etkileri ile havadaki ısıyı tutan karbondioksit ve diğer sera gazlarının önemli ölçüde artması ve kentleşmenin de etkisiyle yeryüzünde ve atmosferin alt katmanlarında sıcaklık artışı, yani küresel ısınma görülmektedir. Dünyadaki hava kirliliğinin %24'üne, sulardaki kirlenmenin %40'ına ve sera gazı salımının %50'sine yapı sektörü neden olmaktadır (Gültekin and Karaca, 2017). Ayrıca, temiz su kaynaklarının %17'si, orman ürünlerinin %25'i ve enerji kaynaklarının %40'ı yapı sektörü tarafından tüketilmektedir (Gültekin ve Farahbakhsh, 2016; Gültekin and Yavaşbatmaz, 2013).

Kentlerde yaşayan nüfusun artmasına paralel olarak bina üretimindeki hızlı artış ve kullanıcı odaklı konfor gereksiniminin artması, ulaşım sistemlerinin modernleşmesi sonucu kentler, küresel ısınmanın ana kaynağını teşkil etmektedir. Dahası, kentleşme sonucu enerji tüketiminin artmasına bağlı olarak enerjide dışa bağımlı ülkelerde enerji arz güvenliğine ve ekonomik sorunlar meydana gelmektedir. Türkiye' de tüketilen enerji kaynaklarının yaklaşık %72'si ithal edilmekte ve oran gün geçtikçe artmaktadır (Akova ve Beyhan, 2015). Türkiye, enerji tüketim değerleri incelendiğinde, son yıllarda enerji verimliliği alanında gösterdiği gelişmelere rağmen, enerji ihtiyacı fazla olan ülkelere dendir. Enerji arz güvenliği konusunda ise henüz kendine yetebilen bir ülke değildir. Yapı stoklarının enerji verimliliğinin düşük olduğu ya da enerji verimli olmadığı ülkelerde, “gayri safi milli hâsıla başına tüketilen enerji miktarı” olarak adlandırılan enerji yoğunluğunun yüksek olması bilimsel verilere dayandırılarak ortaya çıkarılmaktadır (Akova ve Beyhan, 2015). Türkiye' de yapı sektörünün GayriSafi Yurt İçi Hasıladaki payı son yıllarda ortalama % 4,7 seviyelerindedir. Bu doğrultuda, sektörün milli gelire olan katkısını arttırabilmesi için yapı üretim sürecinde de verimliliğinin artırılmasına ihtiyaç vardır. Enerjide dışa bağımlı bir ülke olan Türkiye için yapı sektöründe ve kentsel kullanım alanlarında enerji tüketimini düşürmeden bir kalkınma düşünmek mümkün değildir.

Uzun fiziksel ömre sahip ve kullanım süresi boyunca önemli miktarda enerji tüketen binalar, çok geniş ürün ve hizmet aralığını kapsaması sebebiyle iklim değişikliğine yönelik politika ve programlarda öncelikli çalışma alanı olarak değerlendirilmektedir. Avrupa Birliği'ne bağlı ve tüm gelişmiş ülkelerde iklim değişikliğiyle mücadeleyle yönelik eylemlerin başında binalarda enerji verimliliğinin artırılması gelmektedir. IEA 2018 verilerine göre, Türkiye'de konut ve konut dışı sektörler de dâhil olmak üzere büyüyen bina sektörü ülkenin nihai enerji tüketiminin yaklaşık %34' ünden sorumludur (International Energy Agency, 2021). Sadece konut bina stokunun 2050 yılı itibariyle toplamda %50' nin üzerinde büyümesi beklenmektedir. Bu nedenle, bina sektörü iklim değişikliği ile mücadele kapsamında başrollerde yer almaktadır.

Enerji ve Tabii Kaynaklar Bakanlığı tarafından hazırlanan Türkiye Ulusal Enerji Raporu 2022'ye göre Bina Sektörü; Mesken ve Hizmetler kategorilerinin toplamı olarak, 2020 yılında %40,1'lik pay ile nihai enerji tüketiminde öncü kategoridedir (Şekil 1.1).



Şekil 1.1. Nihai enerji tüketiminin sektörlere dağılımı (T.C. Enerji ve Tabii Kaynaklar Bakanlığı, 2022)

Türkiye İstatistik Kurumu verilerine göre Türkiye'de 2017 yılı itibariyle bulunan 9,1 milyon adet binanın yaklaşık %87'si konut nitelikli binalardan oluşturmakta olup, hane sayısı ise 22 milyonun üzerindedir. Yapı kullanma izni istatistiklerine göre Türkiye'nin bina stokuna her yıl 100.000'den fazla yeni bina eklenmektedir (T.C. Enerji ve Tabii Kaynaklar Bakanlığı, 2021). Bu veriler, Türkiye'de bina sayısının hızla artmakta olduğunu göstermekte ve

binalarda enerji verimliliği önlemlerinin en doğru ve hızlı şekilde alınması gerekliliğini ortaya koymaktadır.

Çevreye insan eliyle verilen zararlar neticesinde ozon tabakasının incelmesi ve sera etkisine yol açan gazların salımı sebebiyle; sürdürülebilir, yeşil, enerji etkin bina gibi tanımlamaların sıklıkla duyulduğu *çevreye duyarlı bina/sürdürülebilir bina* anlayışındaki çalışmalar artmıştır. Yasal düzenlemeler ve sürdürülebilir bina anlayışı, bina tasarımında ve iyileştirilmesinde etkin önlemlerin alınarak enerji ve çevre konusunda daha hassas adımların atılmasını sağlamıştır. Bu bağlamda, yer seçimi, bina konumu, biçimi, yönlenmesi, bina kabuğunun optik ve termofiziksel özellikleri gibi enerji etkin, sürdürülebilir bir yapıyı çevre oluşturmada etkili olan tasarım parametrelerinin belirlenmesi ve bu değişkenlerin sağlayacağı bina optimum performans değerlerine ulaşılmasında bağlayıcı yasal faktörler ortaya çıkmıştır. Bina enerji performansını belirleyen bu faktörler, kentsel ölçekten başlayarak yapı ölçeğine ulaşan süreçte yerel imkânların değerlendirilmesi ve tasarım kriterlerinde ve üst ölçek kent planlarından alt ölçekte yapılaşma koşullarını belirleyen bölgesel planlara kadar her aşamada dikkate alınması gerekmektedir.

Araştırma problemi

Bina sektöründe, artan nüfusun yanı sıra sosyal talep ve hızlı kentleşme gibi diğer faktörler nedeniyle enerji talebinin büyük ölçüde arttığı açıktır. Binalara uygulanan enerji verimliliği konusu, günümüzün uluslararası enerji politikalarının temel unsurlarından biridir. Binaların enerji talebine ilişkin ayrıntılı ampirik verilerin sınırlı oluşu, etkili politika, ürün geliştirme ve yayılımının veriye dayalı bilimsel olarak gerçekleştirilmesini zorlaştırmaktadır. Ulusal sürdürülebilir kalkınma ve dekarbonizasyon planları gelişme gösterdikçe, hükümetler ve tüm kuruluşlar, gerek müdahale programları gerek destek modelleme çalışmaları yapabilmek, gerekse geçmiş uygulamaları değerlendirebilmek ve geleceğe yönelik tahminler yapabilmek için deneysel verilere ihtiyaç duymaktadır (Hamilton vd., 2017). Buna paralel olarak, enerji tüketiminin yaklaşık %35'inden sorumlu olan bina sektöründe enerji yönetimi ile ilgili birtakım uygulamalar yürütülmektedir. Bu uygulamaların yapı üretimi ve kullanım süreci boyunca ihtiyaç duyulan enerji talebindeki belirsizliklerle çözüm getirmesi gerekliliğinden ötürü, enerji performansı için güvenilir tahmin yöntemlerinin geliştirilmesi, binalarda enerji verimliliğinin sağlanmasında önemli ve öncelikli bir araştırma alanı olarak görülmelidir. Özellikle ısıtma, aydınlatma ve çeşitli ekipmanın en yoğun kullanıldığı alanlar

olarak belirlenen konut sektörü ile hastane, ofis, otel, okul, restoran, alışveriş, spor merkezleri gibi binaları kapsayan üçüncül sektör yapılarında birtakım araştırmalar ve uygulamalar nihayetinde, önemli enerji tasarruf potansiyellerini barındırdıkları görülmüştür (Harputlugil ve Ulukavak Harputlugil, 2016). Ancak, Türkiye’de konutların enerji performansına yönelik sınırlamaları ve süreçlerin bağlayıcılığına hizmet eden yasal mevzuatın beklenen enerji ve çevresel performansları sağladığı hususu belirsiz kalmaktadır.

Bina enerji tüketimini tahmin etmenin bir yolu fiziksel simülasyon tekniklerine dayanmaktadır. Bu durumda, EnergyPlus ve DOE-2 gibi araçlar sıklıkla kullanılır. Bu yöntemin dezavantajlarından biri, bu araçları kullanmak için kullanıcıların malzemeler, çatılar, pencereler, ısıtma, havalandırma ve iklimlendirme (HVAC) sistemleri, binanın geometrisi, termal ayarlar, kullanıcı yükleri, aydınlatma, ekipman ve hava koşulları gibi çok kapsamlı bilgilere sahip olma gerekliliğidir. Uzun işlem süreleri ve her bilgiye ulaşmanın zorluğu nedeniyle, bu araçlar bina enerji tüketimi incelemeleri için yetersiz kalmaktadır (Pham vd., 2020).

Endüstri 4.0 gibi teknolojik gelişmeler her sektörde olduğu gibi bina sektöründe de yerini almaya başlamıştır. Veriye dayalı öğrenme imkânı sunan makine öğrenimi bina enerji talep tahminlerinde ortaya çıkan belirsizliklerle başa çıkmak için uygulanan güncel bir yaklaşımdır. Değişkenleri barındıran veri tabanı ve girdi verileriyle bir model yeterince eğitildiyse, bina tasarım parametrelerini değiştirerek binanın enerji talebini belirlemek oldukça hızlı ve güvenilir sonuç vermektedir (Zhao vd., 2019; Seyedzadeh vd., 2018; Tsanas ve Xifara, 2012).

Bu doğrultuda,

- Enerji verimliliği hususunda önemli bir potansiyele sahip olduğu kabul edilen konut sektöründe enerji etkin ve sürdürülebilir özellikte konut tasarımı ve iyileştirme potansiyellerine yönelik çalışmalara ve
- Mimarlar öncelikli olmak üzere tüm süreç paydaşlarına hizmet etmek amacıyla,

proje ön tasarım sürecinde, proje paydaşlarına yol göstererek binaların enerji performansının değerlendirilmesine olanak sağlayan makine öğrenimi algoritmalarına dayanan bir model önerisi sunmak bu tez çalışmasının araştırma problemi olarak kabul edilmiştir.

Araştırmanın amacı

Binalarda enerji verimliliğinin bir ülkenin enerji politikasının önemli önceliklerinden olduğu dikkate alındığında, yenilenemeyen enerji kullanımı, fosil yakıt kaynaklı enerji tüketimine karşı, konutların enerji tüketimini tahmin etmede yüksek doğruluk oranıyla ısıtma ve soğutma yükleri için gerekli enerji miktarını tahmin edebilen, enerji tasarrufu için erken bina tasarımını kolaylaştıran, etkili ve hızlı bir sonuç alınabilen makine öğrenimi yönteminin geliştirilmesi hedeflenmiştir. Bu yöntemin;

- Yeni tasarlanacak konutlar için binanın enerji yükü tahmini ile erken tasarım aşamasında alınan kararların enerji verimliliği açısından optimum performans gösteren konutların üretilmesi ve sürdürülebilir çevrelerin sağlanmasına,
- Mevcut konut stokunun enerji verimliliğinin artırılmasına yönelik olarak yapılacak iyileştirme süreçlerinde alınan kararların performans tahmininde hızlı ve yüksek doğruluklu sonuçların analizi ile optimum faydanın elde edilebileceği sonuçlara ulaşılmasına hizmet etmesi amaçlanmıştır.

Araştırma sorusu

Binalarda enerji verimliliğinin sağlanması amacıyla tasarım süreçlerinin erken aşamasında bina enerji performans tahmini için hızlı ve yüksek doğruluk oranı ile makine öğrenim algoritmaları kullanılarak bir model geliştirilmesi mümkün müdür?

Araştırma sorusunun cevabına ulaşmak amacıyla aşağıda yer alan alt araştırma sorularının da cevapları araştırılmıştır:

- Tasarım sürecinde alınan kararlar bina enerji performansını nasıl etkiler?
- Bina enerji performansının belirlenmesinde kullanılan yöntemler nelerdir?
- Makine öğrenim algoritmaları kullanılarak nasıl tahminleme modeli geliştirilebilir?
- Makine öğrenimiyle tahminleme sürecinde gerekli olan veri setleri nasıl hazırlanır?

Sınırlılıklar ve varsayımlar

Çalışma süreci aşağıdaki sınırlılıklar ve varsayımlar ile tamamlanmıştır:

- Senaryolar konut işlevine sahip kare, dikdörtgen ve L plan olmak üzere üç plan tipi üzerinden yürütülmüştür.
- Senaryolar oluşturulurken,
 - Yapı kabuğu cephe ile sınırlandırılmış ve cephe yüzeyi üzerinden parametreler çalışılmıştır.
 - Saydamlık oranı %20, % 60 ve % 100 olarak üç tip ile sınırlandırılmıştır.
 - Opak yüzeyler, tuğla, bims, gaz beton ve beton blok olmak üzere 4 tip duvar malzemesi, XPS, EPS ve taş yünü olmak üzere 3 tip yalıtım malzemesi, alçı esaslı, çimento esaslı, ahşap esaslı, doğal taş kaplama ve çimento sıva olmak üzere 5 tip dış cephe kaplama malzemesi üzerinden toplamda 60 tip olarak sınırlandırılmıştır.
 - Saydam yüzeyleri oluşturan pencere tipleri PVC doğramalı hava tabakalı çift camlı pencere olmak üzere cam özellikleri, low-e cam, reflekte cam ve solar cam ile sınırlandırılmıştır.
 - Binaların sırasıyla doğu, batı, kuzey, güney, kuzeydoğu, güneybatı, güneydoğu ve kuzeydoğu yönelmelerine sahip olduğu varsayılmıştır.
- Design Builder’da simüle edilen binaların:
 - Bulunduğu topografyanın eğimsiz olduğu varsayılmıştır.
 - Etrafında çevresel etkileri engelleyecek herhangi bir bina olmadığı varsayılmıştır.
 - Taban ve tavan döşemelerinin geçirimsiz olduğu varsayılmıştır.
 - İç iklimi için ısıtma ve soğutma sistemi 7/24 çalışacak şekilde ayarlandığı varsayılmıştır.
 - HVAC sisteminin Fan Coil sistem olduğu varsayılmıştır.
 - Isıtma döneminde iç mekân sıcaklığı 22 °C, ısıtma sisteminin iç mekân sıcaklığını sağladığı üst sınır değer ise 18 °C olduğu varsayılmıştır.
 - Soğutma dönemi için iç mekân sıcaklığı 25 °C, soğutma sisteminin iç mekân sıcaklığını sağladığı üst değer ise 28 °C olduğu varsayılmıştır.
 - Mekanik havalandırma sisteminin bulunmadığı varsayılmıştır.
 - İçinde 4 kişinin yaşadığı ve bu kişilerin aktivite düzeyi normal dinlenme olduğu varsayılmıştır.


- Kullanıcılarının giysi düzeylerinin mevsimlik giysi değeri olan 1 clo olduğu varsayılmıştır.
- İçinde iç mekân sıcaklığını etkileyebilecek iç kazanım faktörlerinin olmadığı varsayılmıştır.
- Makine öğreniminde kullanılan veri setini oluşturmak için simülasyon programı (Design Builder+ JEPlus) üzerinden elde edilen ısıtma soğutma yükleri, gerçek değerler olarak kabul edilmiştir.

Araştırmanın önemi

Makine öğrenimi modelleri oluşturmak için küçük veri örneklerinin kullanılması, görülmeyen veriler üzerinde doğru bir genelleme yapmayarak düşük model performansları elde edilmesine neden olmaktadır. Literatürde yer alan, bina enerji tahminine yönelik modeller çoğunlukla kısıtlı veri örneği veya tek bir veri kümesi etrafında geliştirilmiştir. Bu durum enerji performans tahmini için modellerin daha kısıtlı genelleştirmeler yapmasına hizmet eder. Mevcut yöntemlerin yalnızca küçük bir kısmı, nitelikli sonuç performansları için modeli eğitmek üzere bir veri kümesinde 1000'den fazla bina kullanmıştır. Oysaki makine öğrenimi modellerinin doğruluk tahmini, eğitim algoritmasına ve bir modeli eğitmek için kullanılan veri kümesinin kalitesine ve miktarına bağlıdır. Tahmin oluşturmak için karşılaştırma algoritmaları arasından en iyi algoritmayı seçerken, algoritmaları aynı veri kümesi üzerinde değerlendirmek aynı derecede önemlidir, aksi takdirde bir algoritmanın diğerinden daha iyi olduğu sonucuna varılamaz. Ayrıca, enerji performansı bağlamında nitelikli ve mevzuat gerekliliklerine cevap verecek binaların üretiminde erken tasarım aşamasında enerji tüketimine dair değerlendirmelerin yapılarak tasarım kararlarının alınması son derece önemli olmasına rağmen, literatürde binanın erken tasarım aşamasında bina enerji tüketimini tahmin etmek için makine öğrenimi tekniklerinin tasarlanması ve uygunluğunun araştırılmasına odaklanan az sayıda çalışma bulunmaktadır. Enerji tahminine ilişkin mevcut çalışmalar konut dışı binalara ve saatlik yüke odaklanması sebebiyle tez çalışmasında konut binaları hedeflenmiştir. Başka bir deyişle, bu araştırma konut binalarının yıllık bina ısıtma-soğutma yüklerini tahmin etmeye ve öngörmeye odaklanmıştır. Diğer çalışmalardan farklı olarak, konut binalarının geniş bir dağılımını kapsayan 12960 senaryo örnekleminde oluşan büyük bir veri kümesi kullanılmıştır. Senaryoların sayısı göz önünde bulundurulduğunda, yerinde ölçüm ve manuel hesaplama ile enerji performansı belirleme yöntemlerini

kullanmak güvenilir olmaz. Bu nedenle, makine öğrenimine girecek girdi verilerini oluşturmak için ön adımı oluşturan veri setinin hazırlanması aşamasında, simülasyona dayalı hesaplamalar yönteminin kullanılması tercih edilmiştir. 12960 veri örneği üzerinden ısıtma yükü tahmini için 8602; soğutma yükü tahmini için ise 9617 veri örneği kullanılmıştır. Hazırlanan veri setinde yer alan örneklem sayısının azaltılması, tahmin performans kalitesinin artırılması amacıyla veri ön işleme sürecine girmiş olmasıdır. Belirtilen noktaları ve boşlukları göz önünde bulundurarak, konutların enerji tüketimi tahmini için çok katmanlı bir yapay sinir ağı modeli önerilmiştir. Ayrıca, önerilen model, destek vektör makinesi (SVM), rastgele orman (RF), karar ağacı (DT), doğrusal regresyon (LR) gibi çeşitli makine öğrenme modelleriyle karşılaştırılarak elde edilmiştir.

Özetle bu araştırma, eğitilmesi hızlı olan ve aynı zamanda bina enerji tüketimi hakkında doğru bilgi sağlayan bir model geliştirmeyi amaçlamaktadır. Bu model, bina tasarımcısının bir binanın belirlenen parametrelerini girerek ısıtma ve soğutma yükü talep tahmini yapmasını sağlar. Araştırmada, 2. bölüm enerji performansına ilişkin temel kavramlar ve mevzuatlar üzerinden yürütülmektedir. 3. bölümde, makine öğrenmesi ve makine öğrenmesi ile enerji performansına yönelik literatür çalışmaların incelenmesini sunulmaktadır. Bölüm 4, araştırmanın materyal ve yöntem ve yöntemin uygulama aşamalarını sunmaktadır. Son olarak 5. Bölümde, araştırmanın sonuç ve öneriler kısmı yer almaktadır (Şekil 1.2).



Şekil 1.2. Tez akış şeması

2. BİNA ENERJİ PERFORMANSI

Binalarda enerji performansı, “binanın fonksiyonuna bağlı olarak ısıtma, soğutma, havalandırma, aydınlatma, sıcak su gibi standart ihtiyaçlarını karşılamak için yeni binalarda öngörülen ve mevcut binalarda ölçülen, enerji tüketimini referans alan ve bina performansının düzeyini açıklayan nümerik bir gösterge”(Akt., Atmaca, 2016) dir. Bina sektöründe enerji verimliliği, bir binanın ısı, akustik, görsel, iç mekân hava kalitesi gibi iç mekân konfor koşullarını aynı seviyede muhafaza ederek genel enerji tüketimini azaltmak anlamına gelmektedir (T.C. Çevre Şehircilik ve İklim Değişikliği Bakanlığı 2016a).

Enerji verimliliğinde en önemli gösterge enerji yoğunluğu iken, en önemli ilke ise enerji tasarrufudur. Enerji tasarrufu, mevcut enerji kayıplarının önlenmesi ve enerji atıklarının değerlendirilmesi yoluyla tüketilen enerji miktarının, kalite ve performansı düşürmeden en aza indirilmesi ile sağlanmakta ve verimli kullanım sonucu kullanılan enerji düşük maliyetli olmaktadır (Yildirim vd., 2017)

Enerji performansı, binaların enerji verimliliğinin değerlendirilmesine hizmet etmektedir. Binanın enerji performansı uygulaması için mevzuat ve yönergelerle uygulama koşullarının açıklanması, ilgili standartlarla tanımlanması gerekmektedir. Mevzuat ve standart, binalarda enerji korunumu potansiyelinin farkına varılmasına ve enerji etkin bina tasarlamaya teşvik etmek/yönlendirmek amacıyla bina tasarımı üzerinde belirli düzeyde bir kontrol mekanizması kurulmasına imkân sağlamaktadır. Ayrıca, bu yasal ve teknik düzenlemeler binalarda enerji bilinçli tasarımın gelişmesini sağlamak üzere, pek çok ülkede kullanılmakta ve geliştirilmektedir.

2.1. Yasal Düzenlemeler

1970’li yıllarda yaşanan enerji ve petrol krizi, neticesinde ortaya çıkan küresel problemler dünyada enerji verimliliği politikalarını tetiklemiştir. 1980’li yıllarda kaynakların tükenmesi tehlikesi ve çevrenin korunması gerekliliği neticesinde enerji verimliliği kavramı, doğal kaynakları yok etmeden, bugünün kaynaklarını gelecek kuşaklara aktarılabilme olanağı tanıyan ve sürdürülebilir kalkınmayı etkileyen parametrelerden biri olarak yerini almıştır.

Enerji sektörü ile paralel olarak büyüyen küresel iklim değişimi gibi kaygılar doğrultusunda enerji güvenliği ve iklimin korunması amacını kapsayan politikalar geliştirmek tıpkı tüm dünya ülkelerinde olduğu gibi Türkiye'nin de önemli ve öncelikli gündemini oluşturmaktadır. Türkiye'de enerji arz güvenliğinin sağlanmasına katkıda bulunmak, çevresel tahribatı en aza indirmek ve binaların enerji performansını artırmak için uygun yasal bağlayıcı düzenlemeleri yapma hususları Avrupa Enerji Şartı Konferansı Nihai Senedi, Enerji Şartı Anlaşması ve Ekini Teşkil Eden Kararlar ile Enerji Verimliliği ve İlgili Çevresel Hususlar Protokolünün Onaylanmasının Uygun Bulunduğu Hakkındaki 4519 Sayılı Kanun'un 23956 sayılı ve 06 Şubat 2000 tarihli Resmi Gazetede yayımlanarak yürürlüğe girmesi ile boyut kazanmıştır (Beyhan, 2017).

2007 yılında yürürlüğe giren Enerji Verimliliği Kanunu, Türkiye'de enerji verimliliğine verilen önemin en temel göstergesidir. Kanunun yürürlüğe girmesinden sonra, Türkiye'nin enerji verimliliği mevzuat çerçevesi farklı bakanlıklar aracılığıyla çok sayıda kanun, yönetmelik, genelge, tebliğ ve belge yayımlanmasıyla oluşmuştur (Çizelge 2.1). Kanunun amacı, "enerjinin etkin kullanılması, israfın önlenmesi, enerji maliyetlerinin ekonomi üzerindeki yükünün hafifletilmesi, çevrenin korunması için enerji kaynaklarının verimliliğin artırılmasıdır". Kanun, endüstriyel işletmeleri, binaları, elektrik enerjisi üretim tesislerini, iletim ve dağıtım şebekelerini kapsamaktadır (T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, 2016b).

Çizelge 2.1. Türkiye’de enerji verimliliği ile ilgili başlıca yasal düzenlemeler

<i>Tarih</i>	<i>Yasal Düzenlemeler</i>
Mayıs 2007	5627 Sayılı Enerji Verimliliği Kanunu
Şubat 2008	2008 Enerji Verimliliği Yılı ile İlgili Başbakanlık Genelgesi
Ekim 2008	Enerji Kaynaklarının ve Enerjinin Kullanımında Verimliliğin Artırılmasına İlişkin Yönetmelik
Aralık 2008	Binalarda Enerji Performansı Yönetmeliği
Nisan 2011	Binalarda Enerji Performansı Yönetmeliğinde Değişiklik Yapılmasına Dair Yönetmelik
Ekim 2011	Enerji Kaynaklarının ve Enerjinin Kullanımında Verimliliğin Artırılmasına İlişkin Yönetmelik Değişikliği
Şubat 2012	Enerji Verimliliği Strateji Belgesi
Temmuz 2012	Enerji Verimliliği Destekleri Hakkında Tebliğ
Temmuz 2012	Enerji Verimliliği Hizmetlerini Yürütecek Kurum ve Kuruluşlara Yetki Belgesi Verilmesi Hakkında Tebliğ
Eylül 2012	Enerji Verimliliği Eğitim ve Sertifikalandırma Faaliyetleri Hakkında Tebliğ
Ocak 2013	Enerji Verimliliği Hizmetlerini Yürütecek Kurum ve Kuruluşlara Yetki Belgesi Verilmesi Hakkında Tebliğ
Nisan 2014	Enerji Kaynaklarının ve Enerjinin Kullanımında Verimliliğin Artırılmasına Dair Yönetmelikte Değişiklik Yapılması Hakkında Yönetmelik
Kasım 2017	Ulusal Enerji Verimliliği Eylem Planı

Enerji Kaynaklarının ve Enerjinin Kullanımında Verimliliğin Artırılmasına Dair Yönetmelik, 25 Ekim 2008 tarihinde Enerji ve Tabii Kaynaklar Bakanlığı tarafından, enerjinin verimliliğinin ve enerji kaynaklarının artırılmasını temel alan ve Enerji Verimliliği Kanunu’nun uygulanması amacına yönelik yaklaşım ve prosedürleri belirlemek amacıyla yayımlanmıştır. 27 Ekim 2011 tarihinde Enerji Kaynaklarının ve Enerjinin Kullanımında Verimliliğin Artırılmasına Dair Yönetmelik yayımlanmış ve 2014 yılında revizyona uğramıştır. Eski yönetmeliği yürürlükten kaldıran bu yönetmeliğin amacı; “enerjinin etkin kullanılması, enerji israfının önlenmesi, enerji maliyetlerinin ekonomi üzerindeki yükünün hafifletilmesi ve çevrenin korunması için enerji kaynaklarının ve enerjinin kullanımında verimliliğin artırılmasına ilişkin usul ve esasları düzenlemek” tir (T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, 2016b). Yönetmelik, enerji verimliliğine yönelik hizmetlerin ve çalışmaların yönlendirilmesi ve yaygınlaştırılmasında üniversitelerin, meslek odalarının ve Enerji Verimliliği Değerlendirme şirketlerinin yetkilendirilmesi, enerji verimliliği ile ilgili eğitim ve sertifikalandırma faaliyetleri, enerji yönetimi uygulamaları, enerji yöneticileri ile enerji yönetim birimlerinin görev ve sorumlulukları, projeler hazırlanması ve projelerin

desteklenmesi gibi usul ve esasları kapsamaktadır (T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, 2016b).

Binalarda, tüketilen enerjiyi kontrol altına almak, enerjinin çevresel etkilerini azaltmak ve enerji performansını arttırmak amacıyla, Avrupa Birliği (AB) tarafından 2002 yılında *Bina Enerji Performansı Direktifi (EPBD)* yayımlanmıştır. Bu direktif, “dış iklim şartları, iç mekân konfor gereksinimleri ve yerel koşullar dikkate alınarak, binalarda enerji hizmetlerini iyileştirmek için ilgili ölçütlerin, yenilenebilir enerji kaynaklarının uygulanabilirliğinin değerlendirilmesini, sera gazı salımı sınırlandırılmasını, bununla birlikte enerjinin verimli ve etkin kullanılması ile çevrenin korunmasını amaçlamaktadır. Ayrıca, direktif, yeni ve mevcut binalarda, yasal mevzuat ile tanımlanmış olan asgari enerji performans gereksinimlerinin sağlanması, binaların enerji performansının hesaplanması için ulusal yöntemlerin geliştirilmesi ve tüm binaların sertifikalandırılması” nı zorunlu kılmıştır. (Akt. Atmaca, 2016)

Türkiye, son yıllarda, Avrupa Birliği’ne uyum süreci çerçevesinde enerji tasarrufu ve yenilenebilir enerji kaynaklarının kullanımına ilişkin, mevcut yasalarını revize etmekte, yeni standart ve yönetmelikler yayımlamaktadır. Binalarda Isı Yalıtımı Yönetmeliği’ni yürürlükten kaldıran 05 Aralık 2009 tarihinde yürürlüğe giren *Binalarda Enerji Performansı (BEP) Yönetmeliği*, bu yasal düzenlemelerin en önemlisidir. Yönetmelik, Avrupa Birliğinin 2002/91/EC sayılı çerçeve direktifi doğrultusunda hazırlanmıştır. BEP Yönetmeliği’nin amacı, “dış iklim şartlarını, iç mekân gereksinimlerini, mahalli şartları ve maliyet etkinliğini de dikkate alarak bir binanın bütün enerji kullanımlarının değerlendirilmesini sağlayacak hesaplama kurallarının belirlenmesini, birincil enerji ve karbondioksit emisyonu açısından sınıflandırılmasını, yeni ve önemli oranda tadilat yapılacak mevcut binalar için minimum enerji performans gereklerinin belirlenmesini, yenilenebilir enerji kaynaklarının uygulanabilirliğinin değerlendirilmesini, ısıtma ve soğutma sistemlerinin kontrolünü, sera gazı emisyonlarının sınırlandırılmasını, binalarda performans kriterlerinin ve uygulama esaslarının belirlenmesini ve çevrenin korunmasını düzenlemek” olarak belirlenmiştir (T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, 2008). Yönetmelikte geçen birincil enerji, binaların ısıtma enerjisi soğutma enerjisi tüketimi ve aydınlatma enerjisi tüketimi ve sıhhi sıcak su üretimi için harcanan enerjinin toplamıdır. Ayrıca her bina için beklenen enerji performans sonuçlarının gösterildiği “Enerji Kimlik Belgesi (EKB)” hazırlanması yönetmelikte yer alan unsurlardandır. EKB’nin hazırlanmasında, bina enerji performansı

hesaplama yöntemi kullanılır. Hesaplama yöntemi, binaların enerji sınıfını belirlemek ve enerji performansını değerlendirmek amacıyla, binada enerji tüketimine etki eden tüm parametrelerin, binanın enerji verimliliğine etkisini değerlendirmek için konutlar, eğitim binaları, ofisler, oteller, sağlık binaları ve alışveriş merkezleri gibi yönetmelik kapsamındaki tüm mevcut ve yeni bina tipleri için oluşturulmuştur. Bina enerji performansı hesaplama yöntemi, binaların ısıtma soğutma ihtiyacı için gerekli yüklerin hesabını, binaların havalandırılması amacıyla tüketilen enerji yükünü ve aydınlatma gerektiği durumlarda gerekli enerji yükü ile sıcak su gerekliliğine karşın tüketilen enerji miktarı hesabını kapsamaktadır. Enerji performansı belirlenmesinde, Türkiye şartları için uygun ulusal bir yazılım sistemi olan BEP-TR geliştirilmiş ve 2009 yılında kullanıma açılmıştır. Yönetmelik ile tanımlanan Bina Enerji Kimlik Belgesi BEP-TR yazılımıyla, yetkilendirilmiş uzmanlar tarafından verilmektedir. BEP-TR ulusal yazılımında, mekânların ısıtılması ve soğutulması için ihtiyaç duyulan enerjinin hesaplanmasında TS EN ISO 13790 standardı temel alınmaktadır (T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, 2016b). BEP-TR yazılımında uygulama yönelik ortaya çıkan eksikliklerin giderilmesi amacıyla geliştirilen ve 20 Ağustos 2017 yayımlanan BEP-TR 2 kullanıma açılmıştır.

AB, binalarda enerji verimliliğini geliştirmek amacıyla ilk olarak 2002/91/EC sayılı “Binaların Enerji Performansı Direktifi” yayımlamıştır. Binalarda enerji tasarruf potansiyelini harekete geçirmek ve AB ülkeleri arasında yapıli çevrelerdeki enerji verimliliği düzeylerinde meydana gelen farklılıkları en aza indirmek için direktif yeniden düzenlenerek “2010/31/EU sayılı Binalarda Enerji Performansı Direktifi (BEPD)” olarak yayımlanmıştır. EPBD Recast (2010) ile yapılan güncellemelerle sera gazı salımının 1990 yılındaki oranın %20 azaltılması, Avrupa Birliği ülkelerinde kullanılan enerjinin %20’sinin yenilenebilir enerji kaynaklarından sağlanması, üye ülkelerin enerji tüketiminin %20 oranında düşürülmesi ve tüm binaların neredeyse sıfır enerjili olması hedeflenmiştir (The European Parliament and The Council Of The European Union, 2010). Bu direktifte meydana gelen değişikliklerin, mevcut yönetmelikte anlaşılmayan noktaların açığa kavuşturulması ve çeşitli hataların düzeltilmesi gibi unsurların gözetilmesiyle Türkiye’de de 27539 sayılı ve 01.04.2010 tarihli Resmi Gazete ile “Binalarda Enerji Performansı Yönetmeliğinde Değişiklik Yapılmasına Dair Yönetmelik” yayımlanarak mevzuat, direktife uygun hale getirilmesi hedeflenmiştir.

Mevzuatın uygulanmasına destek vermek amacıyla binaların enerji performansını etkileyen bağlayıcı unsurlara sahip standartlar yayımlanmıştır. Zorunlu bir standart olan TS 825'in amacı, *“binalarda ısıtma amacıyla kullanılan enerji miktarlarını azaltmayı, enerji tasarrufunu artırmayı ve enerji ihtiyacının hesaplanması için kullanılacak standart hesap metodu ve değeri belirlemek”*tedir. Ayrıca *“binaların ısıtma enerjisi tüketimlerini, binayı yenilenmeden önce enerji tasarruf tedbirlerini ve tasarruf miktarı ile yeni yapılacak binalarda standartta açıklanan hesap metodu ve değerleri uygulanarak enerji performansı sağlayacak tasarım seçeneğini belirlemek”* olarak ifade edilmiştir (TS 825, 2013). TS 825 standardında, farklı amaçlara hizmet veren binaların enerji performansı/enerji talebini belirlemek için kullanılan yapı bileşenlerinin ısıl geçirgenlik katsayıları, binalar için ortalama iç sıcaklık değerleri, binaların güneşlenme süreleri ve yer aldıkları iklim dikkate alınarak derece gün bölgelerinin yer aldığı tablolar bulunmaktadır. TS 825 standardının 2013 yılında revize edilmesiyle bir önceki versiyonda 4 olan derece gün bölge sayısı 5'e çıkarılmıştır (Çizelge 2.2).

Çizelge 2.2. TS 825'te derece gün bölgeleri

BÖLGELER	YAPI ELEMANLARININ MAKSİMUM U DEĞERLERİ			
	Duvar- U_D W/m ² K	Çatı - U_T W/m ² K	Döşeme - U_t W/m ² K	Pencere - U_P W/m ² K
1.BÖLGE	0,66	0,43	0,66	1,8
2.BÖLGE	0,57	0,38	0,57	1,8
3.BÖLGE	0,48	0,28	0,43	1,8
4.BÖLGE	0,38	0,23	0,38	1,8
5.BÖLGE	0,36	0,21	0,36	1,8

Farklı bakanlıklar tarafından enerji verimliliği konusunda eylem planları hazırlanmıştır. Mülga Çevre ve Şehircilik Bakanlığı, 2012 yılında “İklim Değişikliği Uyum Stratejisi ve Eylem Planı 2011-2023”ını yayımlamıştır. Raporda, enerji etkin sistem uygulamaları ve ısı yalıtımı ile ilgili yönetmelik koşullarının sağlanması, tüm binaların enerji kimlik belgesi alması zorunluluğu, binalarda yıllık enerji tüketiminin belirli oranlarda azaltılması gibi enerji performansı ile ilgili birtakım uygulamalarının hayata geçirilmesi hedeflenmiştir (T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, 2012). Enerji ve Tabii Kaynaklar Bakanlığı tarafından ilgili kamu ve özel sektör kuruluşlarının yanı sıra dernek, birlik, üniversite ve sivil toplum örgütlerinin görüş ve önerilerinden de faydalanmak suretiyle “Ulusal Enerji Verimliliği Eylem Planı (2017-2023)” hazırlanmıştır. Eylem Planı ile enerji verimliliğinde

destek modellerinin daha etkin hale getirilmesi, sürdürülebilir finansman mekanizmalarının geliştirilmesi, sürdürülebilir satın alma, kamu ve özel sektörde enerji verimliliği kültürünün, farkındalığının ve bilincinin geliştirilmesi, yerinde üretim ve tüketimin özendirilmesi, akıllı şehirlerin ve akıllı şebekelerin inşa edilmesi, sanayi, ulaşım ve tarımda enerji verimliliğinin arttırılması, bölgesel ısıtma sistemlerinin yaygınlaştırılması, alternatif yakıt ve kaynakların enerji verimliliği çerçevesinde kullanımının teşvik edilmesi, sürdürülebilir çevre dostu yapıların yaygınlaştırılması ve mevcut yapıların daha verimli hale getirilmesi kapsamında tüm sektörlerde enerji verimliliği etkinliğinin arttırılması hedeflenmiştir (T.C. Enerji ve Tabii Kaynaklar Bakanlığı, 2016).

Yukarıda binaların enerji performansını etkileyen düzenlemeler bütünü oluşturarak temel mevzuat özetlenmiştir. Her binanın enerji performansı, bina özelliklerine göre farklılaşmaktadır. Bu aşamada ise binaların enerji performansını etkileyen temel parametreler incelenmiştir.

2.2. Bina Enerji Performansını Etkileyen Parametreler

Enerji verimli bina üretiminin en etkili yöntemi çevreyle uyumlu diğer bir deyişle iklim dengeli bina tasarımıdır. Böylelikle, kullanıcıların yaşamsal faaliyetlerini sürdürebileceği iç mekânlar oluşturulurken, ısı konfor koşulları da minimum enerji harcanarak sağlanacaktır. Avrupa’da, iklimsel veriler dikkate alınarak tasarlanan bir binanın ısıtılması için gerekli enerji miktarının diğer binalara göre 10 kat daha az olduğu hesaplanmıştır (Tıkansak, 2013). İklimsel verilerinin yanı sıra enerji verimliliği, binanın fiziksel özelliklerine, tasarım parametrelerine, kullanıcıya ilişkin parametrelere ve yapıda kullanılan aktif sistemlere göre de değişmektedir (Çizelge 2.3).

Çizelge 2.3. Bina enerji performansına etki eden parametreler

<i>Kullanıcıya İlişkin Parametreler</i>	<i>Çevreyle İlişkin Parametreler</i>	<i>Yapıya İlişkin Parametreler</i>	
		<i>Pasif Sistemler</i>	<i>Aktif Sistemler</i>
- Fizyolojik Değişkenler - Niteliğe ve Duruma İlişkin Değişkenler - Irk, Yaş, Cinsiyet - Aktivite Düzeyi - Giysi Türü - Mekandaki Konum ve Duruş Şekli	- İklim - Güneş Işınımı - Dış Hava Sıcaklığı - Dış Hava Nemliliği - Rüzgâr - Topografya ve Bitki Örtüsü - Yapılaşma Yoğunluğu	- Yapının Arazi İçindeki Konumu - Yapı Aralıkları ve Yükseklikleri - Yapı Formu - Mekân Organizasyonu - Yapı Kabuğu - Yapı Kabuğu Bileşenlerinin Optik ve Termofiziksel Özellikleri - Yapı Kabuğu Bileşenlerinde Malzeme Kullanımı	- Isıtma Sistemleri - Soğutma Sistemleri - Havalandırma Sistemleri - Sıcak Su Sistemleri

2.2.1. Çevreye ilişkin parametreler

Yapının bulunduğu çevredeki etmenlere uyum sağlayabilirliği, enerji tüketiminin belirleyici bir unsur olup, iklimsel veriler, topografya etmeni ve çevredeki yapılaşma bina için çevreye ilişkin parametreleri oluşturmaktadır.

İklimsel veriler


İklim oldukça geniş bir bölge içinde ve uzun yıllar değişmeyen ortalama hava koşullarıdır. İklim elemanları çeşitli oranlarda birleşerek bir yerin iklimini oluşturan atmosfer özellikleridir. Güneş ışıınımı, sıcaklık, rüzgâr, yağış gibi iklim elemanlarının farklılaşması farklı iklim tiplerini oluşturmaktadır (Meteoroloji Genel Müdürlüğü, 2023). Türkiye’de sıcak

nemli; sıcak kuru, ılıman nemli, ılıman kuru ve soğuk olarak, 5 ayrı iklim tipi belirlenmiştir (Şekil 2.1).



Şekil 2.1. Türkiye -derece gün bölgelerine göre iller (TSE, 2013)

Tasarımları doğrudan etkileyen iklimsel veriler hava sıcaklığı, güneş, nem, rüzgâr parametrelerinden oluşmaktadır. Bu veriler binanın şekillenmesini ve kullanıcı konforunu etkilemektedir (Şekil 2.2).



Şekil 2.2. Bina kabuğu ve iç mekân konforunu etkileyen iklimsel parametreler (T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, 2016b)

Hava sıcaklığı: Kuru termometre ile gölgede ölçülen değerdir. Dış hava sıcaklığı güneşin geliş açısına ve atmosfer koşullarına bağlı olarak değişmekte ve 24 saatlik zaman dilimleriyle tekrarlanmaktadır. Hava sıcaklığı değerleri ısıtma ve soğutma yüklerini etkileyen en önemli parametrelerdendir. Diğer iklimsel parametrelerden rüzgâr ve nem öğeleri de sıcaklık üzerinde etkilidir. Güneyden gelen rüzgâr sıcaklığı artırırken, kuzeyden gelen rüzgar azaltmaktadır. Nem ise bulunduğu yere göre günlük ve yıllık sıcaklık farkını azaltmaktadır. Sıcaklığın fazla olduğu yerlerde soğutma yükü, sıcaklığın düşük olduğu yerlerde ısıtma yükü ölçütlerinin dikkate alınması gerekmektedir.

Güneş ışıınımı: Yüzeyin birim alanına düşen güneş ısısını ifade eden güneş ışıınımı bütün cisimlerin ısınmalarına sebep olarak sıcaklık değişimlerine neden olmaktadır. Bina kabuğunun kazandığı ısı miktarı üzerinde doğrudan etkili olan ışıınım şiddeti, atmosfer koşullarına, güneşin geliş ve yükseliş açısına, bulunulan yerin deniz seviyesinden yüksekliğine bağlıdır. Enerji verimli tasarımda, konfor ve çalışma verimliliği için beklenen performansa uygun olarak mekânlara kontrollü gün ışığı alımı (pencerelerden, çatı ışııklıklarından vb.) önemlidir. Güneş ışıınımı yoluyla konfor koşullarının oluşmasını, mekân organizasyonu, kütle oluşumu, saydamlık oranı ve kabuk malzemesi seçimi etkileyen temel etmenlerdir (Özüer, 2012).

Nem: Nem, havadaki su buharı miktarıdır ve su buharı miktarı, sıcaklık, rüzgâr, basınç gibi etmenlerden etkilenmektedir. Nem ölçümlerinde, bağıl nem ve mutlak nem hesaplanmaktadır. Bağıl nem, havadaki nem miktarının o havanın alabileceği maksimum neme oranı; mutlak nem ise birim hacimdeki nem miktarıdır. Binalar için nem değerleri, bina iç konfor koşulları etkileyen doğal havalandırma ile alınan temiz havanın nem değeri bağlamında önemlidir (Atmaca, 2016). Sıcak-nemli iklim bölgelerinde yüksek nem oranını azaltacak, sıcak-kuru iklim bölgelerinde ise nem oranını arttıracak tasarım stratejilerine ihtiyaç vardır.

Rüzgâr: Atmosferik basınç farklılıklarından oluşan rüzgâr, yüksek basınç alanından alçak basınç alanına doğru hareket etmekte ve iki alan arasındaki basınç farkı attıkça rüzgârın şiddeti de artmaktadır. Bu hareketler hava kütleleri arasında yoğunluk farklarının oluşumuna ve dolayısıyla sıcaklık farklarına sebep olmaktadır. Rüzgârın bina üzerindeki etki seviyesi, rüzgâr yönüne ve karakterine, hızına, süresine, binanın zemin ile ilişkisine, bina biçimine, yüksekliğine, çevre yapıların, topoğrafyanın ve yeşil dokunun niteliğine bağlıdır. Soğuk

iklim bölgelerinde rüzgârdan korunum önceliği nedeniyle enerji kayıplarının azaltılması amaçlanırken, sıcak iklim bölgelerinde rüzgârın soğutma etkisinden yararlanarak soğutma yüklerinin azaltılması amaçlanmaktadır.

Topografya ve bitki örtüsü

Bir bölgenin mikrokliması (lokal iklimsel özellikleri), yapının konumlandığı arazinin topografyasına, çevredeki yapılaşma ve bitki örtüsüne bağlı olarak değişmektedir. İklimin yapılara etki düzeyi, yapının çevresindeki dağların denizle olan ilişkisi, rakım, eğim ve yön gibi topografik özellikleri ile ilişkilidir. Buna bağlı olarak yapının gün ışığını kullanma, doğal havalandırma ve güneş ısınımından faydalanma biçimleri değişmektedir. Aynı zamanda, yapının olduğu bölgede yer alan doğal bitki örtüsü ve yapı çevrede uygulanan peyzaj tasarımı, doğrudan ya da dolaylı olarak yapının enerji performansını etkilemektedir. Su ögeleri, ağaçlar, bitki toplulukları ve yüzey malzemeleri rüzgâr ve güneş kontrolünü, sıcaklığın ve nem oranının dengelenmesini, havadaki tozun filtrelenmesini ve gürültünün azaltılmasını etkilemektedir.

Yapılaşma yoğunluğu

Yapıların, yoğun yerleşim dokusunda ya da daha az yoğunlukta yer alması enerji kullanımında farklılaşmasına sebep olmaktadır. Doğal yeşil alanların yerini yapılaşmayla birlikte asfalt, taş, beton gibi güneş ışınlarını bünyesinde barındırma özelliği yüksek yüzeyler bıraktığı için yapılaşmanın fazla olduğu yerlerde hava sıcaklığı yükselmektedir. Ayrıca, azalan yeşil doku nedeniyle kentlerde havadaki nem oranı, kırsal alanlardan daha düşüktür. Yağışlarla gelen nem, kırsal alanlarda toprak zeminde tutulabilirken, kentlerdeki yüzey malzemeleri çoğunlukla geçirimsiz özelliktedir.

2.2.2. Kullanıcıya ilişkin parametreler

Bir ortamı kullanan kişilerin, yaşamsal aktivitelerini sağlıklı sürdürebilmesi için, ortamdaki ısı konfor koşullarının sağlanmış olması gerekmektedir. Kullanıcının vücut sıcaklığı, terleme miktarı gibi fizyolojik değişkenleri, aktivite düzeyi, giysi türü vb. kullanıcıya ilişkin parametreler olarak sıralanabilir. Aktivite düzeyi (metabolizma düzeyi), insan vücudunun

birim yüzey alanında birim zamanda üretilen enerji miktarıdır. Kişinin yaptığı eylem türü ile doğrudan ilişkilidir ve çoğu kez MET birimi ile ifade edilmektedir ($1 \text{ MET} = 58,2 \text{ W/m}^2$).

Giysi türü (termal düzey), giysilerin ısı yalıtım direncini ve dolayısıyla insanla çevresi arasındaki ısı geçiş miktarını etkilediğinden, iklimsel konfor koşullarının belirlenmesinde önemlidir. Giysilerin ısı yalıtım direnci genelde Clo birimi ile ifade edilmektedir ($1 \text{ Clo} = 0,155 \text{ m}^2 / \text{W}$).

2.2.3. Aktif sistemlere ilişkin parametreler

Aktif sistem parametreleri binada istenen konfor koşullarının mekanik ve elektrik sistemler ile karşılanması olarak, seçilen sistemlere göre iç konfor koşullarını sağlamak için harcanan enerji miktarı değişkenlik göstermektedir. Aktif sistemlerden harcanan enerjinin azaltılması için iklimsel verilerden yola çıkarak pasif sistemlerin bina tasarımına entegre edilmesi büyük önem taşımaktadır (Atmaca, 2016).

Isıtma sistemleri: İstenilen sıcaklık konforunun sağlanması için, iklimlendirilen mekânların mekanik yolla ısıtılmasını ve sıcaklığın talep edilen düzeyde ve zaman aralığında korunmasını sağlamaktadır.

Soğutma sistemleri: İç mekândaki talep edilen konfor şartlarının sağlanması için mekânların mekanik yolla soğutulmasını ve iç mekân sıcaklığının istenilen düzeye düşürülmesini sağlamaktadır.

Havalandırma sistemleri: İç mekân konfor koşullarının sağlanması için mekânın mekanik yolla havalandırılmasını ve iç mekândaki taze hava miktarının dengede tutulmasını sağlamaktadır.

Aydınlatma sistemleri: Mekândaki görsel konfor koşullarını talep edilen aydınlık düzeyini sağlamak için mekânın elektrik sistemler ile yapay olarak aydınlatmasını sağlamaktadır.

Sıcak su sistemleri: Kullanım sıcak suyunun ihtiyaçlar doğrultusundaki sıcaklık düzeyine getirilmesini sağlayan sistemdir.

2.2.4. Binaya ilişkin parametreler



Bina içerisindeki durumu anlatan iklimsel konfor koşullarını etkileyen iklimsel verilerden optimum ve en uygun yarar sağlayarak aktif sistemleri en az düzeyde kullanmak için mimari tasarım ilkelerinde pasif kriterlerin uygulanması gerekmektedir. Bu doğrultuda iklim verileri çerçevesinde iç iklimsel konforun sağlanması için gerekli pasif tasarım kriterleri:

- Binanın arazi içindeki yeri/konumu
- Bina aralıkları
- Binanın yönü/ Yönelim
- Binanın formu
- Mekân örgütlenmesi
- Binayı çevreleyen yapı kabuğu elemanlarının ısı geçişini etkileyen fiziksel özellikleri


olarak sınıflandırılmaktadır.

Binanın yeri: Binanın dünya düzlemindeki konumunu işaret eden yer, iklimsel verilerin tespiti ve gerekli önlemlerin alınması için önemli bir parametredir. Binanın bulunduğu yer, yeryüzü parçasının yönü, konumu ve eğimi gibi alt bileşenlerin bütününden oluşmaktadır (Yılmaz, 2005). Enerji etkinliğinin sağlanabilmesi için, bina arazide konumlandırılırken, arazinin kendi fiziksel şartları çerçevesinde iklim etmenlerinden optimum ölçüde yararlanmaya ya da korunmaya imkân sağlayan bölge seçilmelidir (Çizelge 2.4).

Çizelge 2.4. Farklı iklim bölgelerine göre bina formları (Ovalı, 2009)

İKLİM BÖLGESİ	BİNA YERİ
Sıcak-Nemli	Rüzgârdan maksimum derecede yararlanmak ve nemden kaçınmak için, rüzgâr etkisinin fazla olduğu tepe noktalar önerilir. Arazi Eğimi max. 0°-6° 
Sıcak-Kuru	Rüzgârdan korunmak ve güneş ışınlamalarının ısıtıcı etkisini azaltmak amacıyla, vadi tabanları önerilir. Arazi Eğimi max. 0°-6° 
Ilıman-Kuru ve Ilıman-Nemli	Ilıman nemli iklim bölgesinde, nemin uzaklaştırılabilmesi için, yazın serin rüzgâr alan yamacın üst kısımları, ılıman kuru iklim bölgelerinde ise, rüzgârın etkisinin daha az hissedildiği yamacın alt kısımları avantajlıdır. Arazi Eğimi max. 22° 
Soğuk	Güneş ışınlamından azami ölçüde yararlanmak ve rüzgârdan korunmak için, yamacın vadi tabanlarına yakın alt noktaları önerilir. Güneş ışınlamalarından daha çok yararlanan eğimli araziler avantajlı durumdadır. Arazi Eğimi max. 22° 

Bina aralıkları: Binalar aralarındaki mesafeye, yüksekliklere ve birbirlerine göre konumlandırılış biçimlerine bağlı olarak güneş ışınlamı, rüzgâr gibi iklimsel verilere karşı birbirlerine bariyer olarak işlevlendirilebilir. Bu doğrultuda binaların birbirlerine göre konumlarının belirlenmesinde iklimsel veriler çerçevesinde enerji performansını artıracak tasarımlar geliştirilmelidir. Örneğin güneş ışınlamından korunmanın öncelikli olduğu bir bölgede binalar birbirlerine gölge oluşturacak şekilde konumlandırılmalı veya rüzgâr hızından yararlanmak veya korunmak talebine göre binaların konum ve yükseklikleri belirlenmelidir (Şekil 2.3).



Şekil 2.3. Gölgenin istendiği (A) ve istenmediği (B) durumlara göre yapı aralıkları (Gazioğlu, 2012)


Yapılarının birbirlerine göre konumlarına, yapı aralıklarına, yüksekliklerine bağlı olarak güneşten ve rüzgârdan yararlanma ya da korunma durumları değiştiğinden, iklim bölgelerine göre farklı stratejiler uygulanmalıdır. Şekil 2.4.'te iklim bölgelerine bağlı olarak, rüzgâra ve güneşe göre yerleşim önerileri gösterilmiştir.

İKLİM BÖLGESİ	YAPI ARALIKLARI		YERLEŞİM ÖNERİSİ
	rüzgâra göre	güneşe göre	
SOĞUK			
ILIMLI NEMLİ ILIMLI KURU			
SICAK NEMLİ			
SICAK KURU			

Şekil 2.4. Farklı iklim bölgelerine göre yapı aralıkları ve yerleşim önerisi (Demir, 2017)

Yönelim: Bulunduğu iklim bölgesine göre, güneşten ve rüzgârdan yararlanabilecek veya korunacak şekilde binaların yönlendirilmesi, iç mekânlarda ısı kaybını önlemek, ışığı kontrol etmek ve doğal havalandırma sağlamak için önemli bir tasarım parametresidir. Binaların yönelimine göre, rüzgârın soğutma etkisi ve güneş ışıınının ısıtma etkisi değişir.





Kışın en yüksek güneş kazancı, yazın da en düşük kazanç sağlamak, bina yönelişinde temel ilkedir. Yaz güneşinin dik açısı ve kuzey yarımkürede kış güneşinin eğim açısı, güneye bakan cephelerin kışın daha fazla güneş ışıını almasını sağlarken yaz aylarında bu ışıınımdan, saçak veya güneş şemsiyeleri ile koruma sağlamak mümkün olabilir. Bu nedenle enerji etkin bina tasarımında güneye bakan cepheler önem kazanmaktadır (Kılıç Demircan ve Gültekin, 2017). Aynı zamanda, rüzgârın serinletici etkisinin daha önemli olduğu iklim bölgelerinde hâkim rüzgâr yönü önemlidir ve bina uzun cephesi genellikle bu yöne bakacak şekilde konumlandırılmalıdır (Şekil 2.5).



Şekil 2.5. Farklı iklim bölgelerine göre önerilen yapı yönlendirmeleri (Ovalı, 2009)

Bina formu: Binalarda planlama ve estetik açıdan değerlendirilen bina formu, binanın çevresel etkenlerden yararlanma veya korunma düzeyini, dolayısıyla enerji performansını doğrudan etkileyen bir parametredir. Bina formu bina planı uzunluğunun derinliğine oranı, bina yüksekliği, çatı türü ve eğimi, cephe türü ve eğimi gibi değişkenler ile tanımlanmakta ve binanın toplam dış yüzey alanı, farklı yönlerde bakan çatı ve cephe yüzey alanları, cephesel hareketler gibi faktörler bina formunun enerji performansını etkilemektedir (Mangan, 2015). Geleneksel mimari örnekler incelendiğinde, farklı iklim özelliklerine sahip bölgelerde farklı biçimlenmiş yapı örnekleri görülmektedir. Bu doğrultuda, ısıtma ihtiyacının yüksek olduğu iklim bölgelerinde enerji kaybeden yüzey alanlarını en az seviyeye indirmek için kompakt

form tercih edilmelidir. Soğutma ihtiyacının yüksek olduğu iklim bölgelerinde ise ısı kazançlarını en az seviyeye indirmek için kompakt ve avlulu form ile havalandırmaya en üst düzeyde olanak sağlayacak hâkim rüzgâr doğrultusunda uzun cepheleri yönlendirilmiş form tasarımları yapılmalıdır (Şekil 2.6). İklim bölgelerine göre yapı formundaki en boy oranının optimizasyonu değişirken, tüm iklim bölgelerinde, genellikle, doğu-batı yönünde konumlandırılan, kuzey cephesinde ısı kaybı minimize edilmiş; güney cephesinde ise kontrollü güneş kazancına sahip yapılar, enerji korunumu ve verimliliği yönünden oldukça avantajlıdır.

İKLİM BÖLGESİ	YAPI ORANLARI	ÖNERİLEN YAPI FORMU
SOĞUK	1x1 - 1x1,3 	 Isı kaybını en az indirmek için, yüzey alanı az olan kompakt formlar ile eğimli çatılar
ILIMLI NEMLİ	1x2,4 - 1x1,3 	 Rüzgara açık, geniş yüzeyli, dikdörtgen ya da serbest formlar ile eğimli çatılar
ILIMLI KURU	1x2,4 - 1x1,3 	 Rüzgara kapalı, kareye yakın kompakt formlar ile eğimli çatılar
SICAK NEMLİ	1x1,7 - 1x3 	 Rüzgar etkileşim alanını arttırmak için, dikdörtgene yakın formlar ile yükseltilmiş ya da eğimli çatılar
SICAK KURU	1x1,3 - 1x1,6 	 Gölgeli alan oluşturabilmek için avlulu kompakt formlar ile düz çatılar

Şekil 2.6. Farklı iklim bölgelerine göre yapı oran ve formları (Oral, 2010)

Mekân organizasyonu: İşlev organizasyonuna uygun olarak aynı tip aktiviteyi barındıran, gün içerisinde kullanım zamanları çakışan, kullanıcı yoğunlukları yakın olan mekânların beraber düşünülmesi binanın daha ısıl zonlara ayrılmasını verimli kılmaktadır.

Birincil(ana) mekânlar, kullanıcı sayısı ve kullanım sıklığı fazla olan ısıtma ihtiyacı yüksek mekânlardır. Kullanıcı sayısı ve kullanım süresi düşük, ısıtmaya ihtiyaç duyulmayan ya da az ısıtılan mekânlar ise ikincil mekânlardır. Bina tasarımında enerji etkinliği daha verimli hale getirmek, ikincil mekânları ana mekânların çevreyle ilişkisini kısıtlayarak tampon bölge oluşturacak şekilde konumlandırılmasıyla olabilir. Birincil ve ikincil mekânlar için enerji verimliliği stratejilerinden bazıları aşağıda özetlenmektedir:

- Sirkülasyon alanlarının ve ıslak hacimlerin ana mekânlar arasında tampon görevi görecektir şekilde konumlandırılması, ana mekânların kışın soğuma süresini uzatır.
- Rüzgârlı alanlarda yapı girişinde tasarlanan rüzgârlıklar, ısı kaybını azaltır.
- Toprak altında kalan bodrum katlar, toprağın ısıyı tutması sebebiyle dış hava sıcaklığına direk maruz kalmaz ve mekândaki ısı kaybı azalır.
- Şeffaf yapı malzemeleri kullanılarak genellikle ana mekânın önünde konumlandırılan güneş odası, ısı kazancı elde eden ve ısı depolayan alanlardır. Ancak yaz mevsiminde aşırı ısınma durumuna karşın farklı önlem de alınmalıdır.

Yapı kabuğu: Bir yaşam alanını dış ortamdan ayıran ve içerdiği yapı bileşenlerinin seçimiyle iklimsel konfor ve yüksek enerji performansı sağlamak için tasarımcıya fırsatlar sunan yapı bileşenlerinden biridir. Yapı kabuğunun enerji etkin tasarımı amacıyla; güneş ışığından azami ölçüde yararlanan, iç ortam hava kalitesini artıran, kullanıcının mahremiyet ve görsellikle ilgili gereksinimlerini karşılayan bir katman oluşturmak gerekmektedir (Gür ve Aygün, 2008). Yapı kabuğunu, fiziksel özellikleri ve ısı davranışları farklı olan opak ve saydam olmak üzere iki bileşen oluşturmaktadır. Bina kabuğunun opak ve saydam bileşenlerinin performansını etkileyen en önemli optik ve termofiziksel özellikleri:

- Opak ve saydam bileşenlerin ısı geçirme katsayısı (U),
- Opak bileşenin genlik küçültme faktörü (ϕ),
- Opak bileşenin zaman geciktirmesi (Φ , h),
- Saydam bileşenin güneş ışınlamına kadar geçirgenlik katsayısı (τ),
- Opak ve saydam bileşenlerin yutuculuk (a) ve yansıtıcılık (r) katsayıları
- Saydamlık oranı

olarak sıralanabilir.

Isı geçirme katsayısı; birim yüzey alanı, hava sıcaklığı değeri ve bina bileşeninin iki tarafı arasında 1°C sıcaklık farkı olduğunda birim alanından, bu alana dik doğrultuda birim zamanda iletimle, taşınım ve ışımayla geçen ısı enerjisi olarak tanımlanmaktadır. Genlik küçültme faktörü ve zaman geciktirmesi, kabuğun opak katmanlarının yalıtım kapasitesini belirleyen ve opak katman malzemelerinin ısı depolama kapasitelerine bağlı olan ve iki özelliştir.

Zaman geciktirmesi, bileşenin dış yüzeyindeki maksimum sıcaklığın oluştuğu saat ile iç yüzeyinde maksimum sıcaklığın oluştuğu saat arasındaki zaman farkını ifade ederken, genlik küçültme faktörü, bileşenin iç yüzeyindeki sıcaklık değişimi genliğinin, dış yüzeyindeki sıcaklık değişimi genliğine oranını ifade etmektedir (Mangan, 2015).


Yutuculuk, geçirgenlik ve yansıtıcılık katsayıları, sırasıyla bileşen tarafından yansıtılan, geçirilen ve yutulan güneş ışıını miktarlarının bileşen dış yüzeyine gelen güneş ışıınına oranlarıdır (Mangan, 2015). Opak ve saydam bileşenlerin güneş ışıınına karşı optik özellikleri olarak bilinen geçirgenlik, yutuculuk ve yansıtıcılık katsayıları saydam bileşenler için doğrudan ve yaygın güneş ışıınına karşı farklı değeri almaktadır. Doğrudan ışıına karşı saydam bileşenlerin optik özellikleri güneş ışıınının geliş açısına bağlı olarak değeri. Opak bileşenler için ise geçirgenlik söz konusu olmayıp, yutuculuk ve yansıtıcılığın doğrudan ve yaygın ışıını için farklı olmaksızın yüzeyin rengine bağlı olarak değeri. (Özüer, 2012).

Saydıamlık oranı, opak ve saydam yüzeylerden oluşan yapı kabuğunda, saydam yüzey alanının toplam bina kabuğu alanına oranıdır. Bu oran, doğal aydınlatma ve havalandırma ile kabuktaki toplam ısı geçiş miktarını etkilemektedir. Enerji performansını artırmak için, bölgenin iklimsel özellikleri dikkate alınarak, cephelerin güneşlenme durumuna göre saydıamlık oranı düzenlenmeli ve istenmeyen ısı kazançlarının önüne geçilmelidir. Mekânların saydıamlık oranlarının % 20-50 arasında olması, bina kullanıcılarının dış görüş gereksinimlerinin karşılanabilmesi, doğal aydınlatmanın iç mekânlarda yeterli oranda sağlanabilmesi açısından önerilmektedir (Enerji ve Tabii Kaynaklar Bakanlığı Yenilenebilir Enerji Genel Müdürlüğü, 2016).

İklim bölgelerinin konfor gereksinimlerini karşılamak amacıyla yapı kabuğu, iklim bölgesine uygun optik ve termo-fiziksel özelliklere sahip malzemelerle tasarlanmalıdır.

Sıcak-kuru iklim bölgelerinde yüksek gündüz-gece sıcaklık farkı için yüksek ısı depolama kapasitesine sahip yapı kabuğu tasarlanmalı, sıcak-nemli iklim bölgelerinde soğutma önceliği ve düşük gündüz-gece sıcaklık farkı için düşük ısı depolama kapasitesine sahip yapı kabuğu tercih edilmelidir (Ovalı, 2009). İklim bölgelerine göre değişen yapı kabuğu özellikleri Çizelge 2.5’ te verilmiştir.

Çizelge 2.5. İklim bölgelerine göre tercih edilebilecek yapı kabukları (Oral, 2010)

İKLİM BÖLGESİ	YAPI KABUĞUNUN ÖZELLİKLERİ	YAPI KABUĞU
Sıcak-Nemli	Gölgeleme elemanlarına sahip büyük pencereler ve doğal havalandırma sağlamak için yükseltilmiş veya eğimli çatılar tercih edilmelidir. Duvarlar düşük ısı depolama kapasitesine sahip açık renkli malzemeden seçilmelidir.	
Sıcak-Kuru	Güneşin ısı etkisinden korunmak için küçük boyutlu pencereler ve düz çatılar tercih edilmelidir. Öte yandan, büyük günlük hava sıcaklığı değişiklikleri nedeniyle yüksek ısı depolama kapasitesine sahip malzeme seçilmelidir.	
Ilıman-Kuru ve Ilıman-Nemli	Doğal havalandırma sağlamak için büyük pencereler ve yalıtımlı eğimli çatılar tercih edilmelidir. Duvarlar için, iç mekânda konfor koşullarını sağlayacak yalıtım değerlerine sahip malzemeler seçilmelidir.	
Soğuk	Isı kaybını azaltmak için küçük pencereler ve yalıtımlı eğimli çatılar tercih edilmelidir. Duvarlar için, yüksek ısı depolama kapasitesine sahip iyi yalıtılmış malzeme seçilmelidir.	

Yapı kabuğu tasarımında enerji etkinlik ve kullanıcı konforu için amaçlanan hedeflerin optimizasyonu sağlanmalı ve kullanılacak malzemeeler bu doğrultuda seçilmelidir.

Yapı kabuğu saydam bileşen özellikleri, yapı kabuğunda bulunan saydam yüzeylerin görevi, görsel ve fiziksel olarak dış ortamla etkileşim sağlamak ve güneş ışınımından faydalanmaktır. Saydam yüzeyde kullanılan malzemelerin termofiziksel özellikleri, toplam saydam yüzey alanı, saydam yüzey alanının iç mekân alanına oranı, saydam yüzeyin tasarlandığı cephe yönleri binaların enerji etkinliğini etkileyen parametrelerdendir. Binalarda saydamlık oranı iklim bölgesi, yönlenme, bina hacmi gibi fiziksel tasarım kriterlerine göre şekillenmektedir. Görsel açıdan bina cephelerinin oluşturulmasında binanın mimari biçimlenişinde saydamlık oranı etkilidir.

Sıcak kuru iklim bölgelerinde, saydam yüzeyler küçük tercih edilerek güneş ışığının istenmeyen ısı kazancının önüne geçilebilir. Nemli ve sıcak iklim bölgelerinde ise büyük boyutlu saydam yüzeyler tercih edilerek havalandırma sağlanabilir. Aynı zamanda bu bölgelerde istenmeyen güneş ışığının önüne geçmek için güneş kontrol elemanları kullanılmalıdır. Soğuk iklim bölgelerinde ısı kayıplarının minimize edilmesi amacıyla az sayıda ve küçük boyutlu saydam yüzeyler kullanılmalıdır. Bulunduğu konum itibarıyla Türkiye’de güney cepheden elde edilen ısı kazancı fazla olduğu için saydamlık oranı güney cephesinde diğer cephelere oranla fazla olmalıdır (Çizelge 2.6).

Çizelge 2.6. İklim bölgesine göre saydam yüzey tasarımında dikkat edilmesi gereken kriterler (ETK Bakanlığı Yenilenebilir Enerji Genel Müd., 2016)

İklim bölgeleri-pilot şehirler	Saydam yüzey tasarımında dikkat edilmesi gereken kriterler
Ilımlı-kuru (Ankara)	. Görsel, iklimsel ve işitsel konfor açılarından optimize edilmiş . Isıtmanın istendiği dönemdeki rüzgârı almayacak şekilde yönlendirilmiş . Gerekli yönlerde güneş kontrolüne sahip
Sıcak-nemli (Antalya)	. Görsel, iklimsel ve işitsel konfor açılarından optimize edilmiş . Hâkim rüzgâr doğrultusunda yönlendirilmiş, hava hareketlerine izin verecek şekilde tasarlanmış . Gerekli yönlerde gölgeleme amaçlı güneş kontrolüne sahip
Sıcak-kuru (Diyarbakır)	. Görsel, iklimsel ve işitsel konfor açılarından optimize edilmiş . Dış cephe için daha küçük, iç avlu yönünde daha büyük açıklıklara sahip . Gerekli yönlerde gölgeleme amaçlı güneş kontrol elemanlarına sahip
Soğuk (Erzurum)	. Görsel, iklimsel ve işitsel konfor açılarından optimize edilmiş . Rüzgâra az yüzey veren cephelere yönlendirilmiş . Dış cephe için küçük açıklıklara sahip . Gerekli yönlerde gölgeleme amaçlı güneş kontrol elemanlarına
Ilımlı-nemli (İstanbul)	. Görsel, iklimsel ve işitsel konfor açılarından optimize edilmiş . Isıtmanın istenmediği dönemdeki rüzgâra doğru yönlendirilmiş . Gerekli yönlerde güneş kontrolüne sahip saydam yüzey tasarımı

Yapı kabuğu ve fiziksel özellikleri iklimsel verilerden faydalanarak iç çevre konfor koşullarının iyileştirilmesinde en önemli rol oynayan parametre olup, bina yeri, yönü, formu ve binaların aralıkları parametrelerinden en üst düzeyde etkilenmektedir.

2.3. Enerji Performansı Belirleme/Tahminleme Yöntemleri

Enerji performansı, enerji kullanımı bağlamında bir binanın kalitesini göstermektedir. Bir binanın enerji performansı iklim, yapı kabuğu, bina enerji sistemleri, bina işletimi ve bakımı, kullanıcı aktiviteleri ve davranışları ve iç mekân çevre kalitesi tarafından belirlenmektedir (Institute for Building Environment and Energy Conservation, 2013). Bir binanın enerji performansını değerlendirmek için sayılabilir ölçütler olarak genellikle enerji performans göstergeleri kullanılır. Binaların birden fazla enerji taşıyıcısı kullanması muhtemel olduğundan dolayı farklı maliyetleri, birimleri, ekserji veya çevresel etkileri toplamak için ortak bir enerji taşıyıcısı ifadesi kullanmak gerekmektedir. Bu nedenle, bir binada tüketilen nihai enerji, birincil enerji derecelendirmesi, karbondioksit emisyon faktörleri ile ağırlıklandırılabilir (Borgstein vd., 2016). Birçok bina türü için en yaygın olarak kullanılan gösterge, enerji kullanım yoğunluğudur (EUI) (kWh/m²). Binaların brüt alanına göre normalize edilen yıllık enerji tüketimini veren enerji kullanım yoğunluğu (EUI), hesaplama kolaylığı nedeniyle yaygın olarak kullanılmaktadır. EUI tabanlı sınıflandırma, kullanıcıların binanın enerji performansını karşılaştırmasını sağlamaktadır (Park vd., 2019). Araştırmacılar bina performansı hakkında daha kapsamlı bilgileri son dönemde gelişen teknolojilerden yararlanarak öğrenebilmektedir (Gunay vd., 2018). Örneğin, 2016 yılına kadar ABD'de 70 milyon akıllı elektrik sayacı kurulmuştur (Park vd., 2019) . Akıllı sayaçların binalara entegrasyonu ile elde edilen enerji kullanım bilgileri sayesinde araştırmacılar bina performansı analizini yüksek doğruluk payı ile yapmaktadır.

Bina enerji performansı tahmin/belirleme yöntemleri ve araçları, çevresel faktörler, enerji gibi ilgili konular, belgelendirme, karar verme, performans teşhisi gibi amaçlar ve bina düzeyi, çok düzeyli gibi ayrıntılı yaklaşımlar açısından farklılık göstermektedir. Örneğin, Zhao ve Magoulès, 2012 bina enerji tahmin yöntemlerini beş tipte sınıflandırmıştır:

1. Mühendislik yöntemleri: Termal dinamikleri ve enerji davranışını hesaplamak için fiziksel ilkeleri kullanan bu yaklaşım “ayrıntılı kapsamlı yöntemler” ve “basitleştirilmiş yöntemler” olmak üzere iki sınıfa ayrılmıştır.
2. İstatistiksel yöntemler: Enerji tüketimini veya enerji endeksini etkileyen değişkenlerle ilişkilendirmek için istatistiksel teknikleri kullanır. Ayrıca tarihsel verilerden geliştirilen ampirik modeller olarak da anılır.
3. Sinir Ağları

4. Destek Vektör Makineleri
5. Gri modeller

Bir diğ er sınıflandırmada (Foucquier vd., 2013)

1. Fiziksel modeller ya da bina termal davranış modelleri
2. Makine  ğrenimini kullanan İstatiksel Y ntemler
3. Hibrid Modeller olarak tanımlanmıştır.

Fumo (2014) tarafından y r t len bařka bir  alıřmada ise, literat rde yer alan birtakım sınıflamalar sunulmuřtur. ASHRAE El Kitabı 2009 sınıflandırmasına g re binalarda enerji tahmin y ntemleri:

1. İleri (klasik) yaklařım: Sistemlerin fiziksel davranıřlarını ve girdilerini a ıklayan denklemler  ıktıyı tahmin etmek i in kullanılır (tanımlayıcı/fiziksel/m hendislik/beyaz kutu yaklařımı).
2. Veriye dayalı (ters) yaklařım: Sistemlerin performansını y neten girdi ve  ıktı deėiřkenleri  l  l r ve bu bilinen veriler sistemin matematiksel bir ifadesini tanımlamak i in kullanılır:
 - Ampirik veya “Kara Kutu” yaklařımı:  ıktılar ve girdi parametreleri arasındaki iliřkiyi bulmak i in basit veya  ok deėiřkenli bir regresyon ger ekleřtirilir.
 - Kalibre edilmiř sim lasyon yaklařımı: Daha iyi tahminler vermek i in ger ek  l  len verilerle kalibre edilmiř bir sim lasyon bilgisayar programı kullanır.
 - Gri Kutu yaklařımı: İlk olarak, binanın enerji t ketimini etkileyen fiziksel  zelliklerini tanımlamak i in bir matematiksel model geliřtirilir. İkinci olarak, parametreleri tanımlamak ve deėerlerini belirlemek i in istatistiksel y ntemler kullanılır.

Literat rde bu y ntemler yaygın olarak farklı isimlerle adlandırılmıř olmasına raėmen kara kutu, gri kutu ve beyaz kutu metodolojileri olarak    kategoride karřımıza  ıkmaktadır ( izelge 2.7).

Çizelge 2.7. Bina enerji tahminleme yöntemleri (Batish and Agrawal, 2019)

- Beyaz Kutu Modelleri - Tanımlayıcı/Mühendislik/Teorik/ Fiziksel/Klasik Yöntemler	- Kara Kutu Modelleri - Veriye Dayalı/ Ampirik Yöntemler	- Gri Kutu Modelleri - Hibrit Yöntemler
. Derece Gün Yöntemi . Sıcaklık Frekans Yöntemi. Hesaplamalı Akışkanlar Dinamiği (CFD) (3D) yaklaşımı [FLUENT, . COMSOL Multi-physics, MIT-CFD, PHOENICS-CFD vb.] . Bölgesel (2D) [SPARK] . Multizone veya Nodal (1D) yaklaşımı [TRNSYS, . EnergyPlus, ESP-r, eQUEST, IDA-ICE vb.] . İletim Transfer Fonksiyonu (CTF) yöntemi [BLAST, TRNSYS & Energyplus] . Termal tepki faktörü yöntemi [DOE-2] . Radyant zaman serisi yöntemi (RTF) . Toplu Parametre modelleri	Doğrusal Regresyon . Temel Bileşen Analizi (PCA) . Otomatik Regresif Hareketli Ortalama (ARMA) . Otomatik Gerilemeli Entegre Hareketli Ortalama (ARIMA) . Çoklu Doğrusal Regresyon(MLR)/Koşullu Talep Analizi(CDA) . Sıradan en küçük kare regresyon (OLSR), Polinom regresyon, Üstel regresyon, Çok değişkenli uyarlanabilir regresyon eğrisi (MARS), (CBR) vb. . Karar Ağaçları(DT) . Yapay Sinir Ağı(YSA/ANN) . Destek Vektör Makinesi (SVM) . Genetik Algoritma (GA) . Derin Sinir Ağları(DNN) . Parçacık Sürü Optimizasyonu (PSO) . Yapay zeka tekniklerinin bir kombinasyonunu kullanarak modelleri bir arada kullanılması	MAKİNE ÖĞRENİMİ kullanarak fiziksel ve veriye dayalı yöntemlerin kombinasyonu fiziksel parametre tahmincisi olarak öğrenme -Meta modelleme (Monte Carlo simülasyonları)

2.3.1. Beyaz kutu modelleri

Beyaz kutu modelleri binaların enerji davranışını tanımlamak için fiziksel denklem çözümlerine dayanan ve şeffaf bir süreç kullanan modellerdir (Zhai vd., 2019). Sistemin fiziksel davranışını ve çevre ile etkileşimlerini hesaba katmak için çeşitli denklemleri kullanarak bina bileşenlerinin veya tüm binanın enerji tüketimini tahmin eder ve iç mantık bilindiği için 'beyaz kutu' yöntemi olarak tanımlanır (Ahmad vd., 2018; Zhao vd., 2019; Li vd., 2014). Fizik temelli modelleme, “ileri klasik yaklaşım”, “kalibre edilmiş simülasyon yaklaşımı”, “enerji simülasyon programları” “mühendislik yöntemleri / yaklaşımı”, “fiziksel modellemeler” olarak farklı isimlerle adlandırılır. Bu modellerin alt sınıflandırmaları girdi

verilerinin kökenine, modellemede uygulanan ayrıntı düzeyine ve modelleme kalibrasyon yöntemlerine bağlı olarak oluşturulur (Foucquier vd., 2013; Swan and Ugursal, 2009).

Enerji sertifikasyon sistemleri ya da simülasyon modeline dayalı yaklaşımlar beyaz kutu modeline örnektir. Çeşitli Energy Performance of Buildings Directive (EPBD) katılımcıları tarafından birçok enerji performansı sertifikasyon yöntemi geliştirilmiştir. Bu durum, Avrupa'da zorunlu olarak bina enerji performans değerlendirmesini gerektiren EPBD' nin uygulanmasıyla önem düzeyi artmıştır. Örneğin, “Energy Management Scheme for Large Buildings (ELO)” ve “Energy Certification Scheme for Small Buildings (EM)”, Danimarka'daki yeni ve mevcut binaları ele alan iki zorunlu programdır (Wang vd., 2012). Hollanda'da mevcut konutlar için “Energy Performance Advice (EPA-W)”; konut dışı binalar için “EPA-U” ve yeni binalar için “Energy Performance Coefficient (EPC)” oluşturulmuştur. “Energy Performance Assessment for Residential Buildings (EPA-ED)” ve “Energy Performance Assessment for Non-Residential Buildings (EPA-NR)”, Avrupa Komisyonu tarafından ve Avrupa üye devletlerinin katılımıyla desteklenen iki projedir (Wang vd., 2012). Enerji ölçüm yöntemlerinin çoğu (hem yeni hem de mevcut binalar için) standart davranışa dayalı asset rating/aktif derecelendirmedir. “Asset rating”, mekanik sistemler, yapı kabuğu, yönlendirme ve gün ışığı gibi tasarım bileşenlerini hesaba katarak bina performansının modeline dayalı olarak değerlendirmektedir (Wang vd., 2012). Simülasyon modeline dayalı yaklaşımlar, idealleştirilmiş bina performansı modeline dayanarak enerji ölçütlerini hesaplayan, her mekân için ayrı hesaplamalar gerçekleştirebilen ve genellikle saatlik bazda binanın bütün olarak performansını analiz edebilen araçlardır (Ulukavak Harputlugil, 2014). EnergyPlus, TRNSYS, ESP-r ve DOE-2 gibi yaygın ayrıntılı enerji simülasyon araçları beyaz kutu modelidir (Serale vd., 2018).

2.3.2. Kara kutu modelleri

Binanın iç ilişkisi ve bölümleri hakkında herhangi bir bilgi olmadan ya da çok az bir bilgi ile enerji tüketimini tahmin eden veriye dayalı modellerdir. Yapay zeka tabanlı, tamamen istatistiksel bir yöntemdir (Ahmad vd., 2018; Zhao vd., 2019; Li vd., 2014) “Veriye dayalı teknikler” ve “istatistiksel teknikler” olarak da adlandırılmıştır (Ahmad vd., 2018; Amasyali and El-Gohary, 2018; Tardioli vd., 2015; Wei vd., 2018).

İstatistiksel (veya regresyon temelli) değerlendirme araçlarından olan Energy Star ve Cal-Arch, ABD'de sıklıkla kullanılan bina kıyaslama aracıdır. Energy Star, enerji verimliliği oranlarına dayalı bir sıralama puanı oluşturmak için kullanılan regresyon modelleri ve normalleştirme yöntemlerinin kullanılması yoluyla binalar arasındaki farkları ortaya koyar (Energy Star). Cal-Arch, Kaliforniya'daki benzer binalar için veritabanını sorgulamaya ve sorgu sonuçlarının dağıtımını için histogramlar ve istatistikler sağlamaya yarayan bir araçtır (Matson and Piette, 2006).

Hiyerarşik değerlendirme ve teşhis araçları da veriye dayalı teknik örneklerindendir. Hiyerarşik değerlendirme (çok seviyeli değerlendirme), bina seviyesinden sistem ve / veya bileşen seviyesine uzanan enerji performansının değerlendirilmesini ifade etmektedir (Wang vd., 2012). Hiyerarşik ve son kullanım ölçütleri, enerji kullanımını iklim ve işlevsel gereksinimlerle ilişkilendiren kıyaslamaların üretilmesine atıfta bulunur. Buradaki fikir, analize tüm bina seviyesinde başlamak ve performans verilerini bulmak için kademeli olarak temel sistem ve bileşenler seviyesine inmektir. Örneğin, en yüksek düzeydeki veriler brüt alan ve yıllık hizmet faturaları, ikinci en yüksek düzey kullanım türlerinin yüzdesi ısıtma, soğutma ve havalandırma (HVAC) sistemi ve ardından en düşük düzey bölge enerji kullanımları olabilir. Bu yöntem, mevcut binalarda ayrıntılı bir enerji denetimi ile sorunlu alanları belirlemek ve daha spesifik geliştirme önerileri sağlamak için faydalı olabilir (Wang, 2015; Wang vd., 2012). Ancak, gereken veri türü genellikle hemen bulunmaz.

2.3.3. Gri kutu modelleri

Sınırlı bina fiziği bilgisini istatistiksel metodolojilerle karıştırarak yöntemlerle ilişkili sınırlamaları ortadan kaldırmayı amaçlayan bu yöntem, beyaz kutu ve kara kutu yöntemlerini birleşiminden meydana gelmektedir (Ahmad vd., 2018; Zhao vd., 2019; Li vd., 2014). Optimizasyon yöntemleriyle tek veri odaklı tekniklerin iyileştirilmesi ya da birkaç makine öğrenimi algoritmasının kombinasyonu olarak literatürde yerini almıştır. “Gri kutu yaklaşımı”, “hibrit modeller”, “geliştirilmiş modeller”, “veriye dayalı teknikler” olarak da adlandırılmıştır (Batish and Agrawal, 2019; Zhao vd., 2019; Fouquier vd., 2013; Tardioli vd., 2015)

Özellikle, Design Builder veya Ecotect gibi bina performans simülasyonları (Building Performance Simulation/BPS) yazılımlarından elde edilen verileri istatistiksel veya yapay

zekâ/ makine öğrenimi algoritmaları ile birlikte kullanan modellerdir (Batish and Agrawal, 2019).

Bina enerji performansı değerlendirme alanının, aynı analiz türlerini tanımlayan birkaç farklı terminoloji veya sınıflandırmayı benimsediği görülmektedir. Enerji performansı belirleme uygulamaları, enerji sınıflandırması ve enerji performansı tanısı için oluşturulmuş olup, bu tanımlar aşağıda özetlenmektedir:

Enerji performans tanısı, herhangi bir nicel enerji performansı değerlendirme yönteminin temelidir. Belirli bir binanın enerji kullanım miktarını veya enerji performansı göstergelerini, toplanan ilgili bilgilere dayanarak belirleme sürecidir. Kamu hizmetleri faturaları, bina denetim verileri, son kullanım alt ölçüm sistemi veya bina yönetimi sistemi (BMS) izleme ve bilgisayar simülasyonları, bina enerji kullanımlarını ölçmek için yaygın kaynaklardır (Wang vd., 2012).

Enerji sınıflandırması, bina sahiplerine veya kamuoyuna değerlendirilen binaların enerji performansına ilişkin bilgi sağlayan bir araçtır. Bu tür bilgiler genellikle çok pratik ve anlaşılır biçimlerde ifade edilir (1-100 veya A-M veya zayıf-mükemmel), daha iyi performansa ve bina sahiplerini enerji performansını iyileştirmeye sevkeder (Wang vd., 2012).

Beyaz kutu, kara kutu modelleri ve gir kutu modelleri olmak üzere 3 farklı özellikteki bina enerji tahmin modelleri yukarıda tanımlanmış olup, modellere ait karşılaştırmalar Çizelge 2.8’de verilmektedir.

Çizelge 2.8. Bina enerji tahmin model tekniklerinin karşılaştırılması (Batish and Agrawal, 2019; Zhao and Magoulès, 2012; Fouquier vd., 2013)

ÖZELLİKLER	BEYAZ KUTU MODELLERİ	KARA KUTU MODELLERİ	GRİ KUTU MODELLERİ
Tahmin yöntemi ve yaklaşımı	Enerji davranışını hesaplamak için termodinamik denklemleri ya da basitleştirilmiş yöntemleri kullanır.	Enerjiyi değişkenlerin bir fonksiyonu olarak ifade etmek için Enerji ile ilgili çıktıyı/bağımlı değişkenleri girdi/bağımsız değişkenlerle ilişkilendirir.	Veriye dayalı yöntemlerle birlikte Mühendislik/fiziksel yöntemleri kullanır.
Bina geometrisi bilgisi	Ayrıntılı tanımlama gereklidir.	Ayrıntılı tanımlama gerekli değildir	Kabataslak bir tanımlama yeterlidir.
Eğitim verileri (Gerçek veya simüle edilmiş veri)	Eğitim verisi gerekmez	Kapsamlı bir süre boyunca toplanan büyük miktarda eğitim verisi gereklidir.	Kısa bir süre içinde toplanan az miktarda eğitim verisi yeterli olur.

3. MAKİNE ÖĞRENİMİ İLE ENERJİ PERFORMANSI TAHMİNLEMESİ

Binalar, kullanıcılarının sağlığını ve refahını en üst düzeye çıkarırken mümkün olan en az enerji ve malzemeyi tüketecek şekilde tasarlanmalıdır. Bu gereklilik bina tasarımı ya da mevcut binalar üzerinde yapılan iyileştirme süreçlerinde, binalarda tüketilecek enerjinin fizik tabanlı bir simülasyon programı kullanılarak tahmin edildiği bina performans odaklı bir yaklaşım ile çözüm bulabilir. Mühendislik yöntemleri veya beyaz kutu modelleri olarak da adlandırılan bu yöntem, ayrıntılı enerji modellemesi ve analizi için termodinamik kurallarına dayanır. Bu yazılımlara örnek olarak EnergyPlus, eQuest ve Ecotect verilebilir. Bu tür yazılımlar bina enerji tüketimi, mimari proje girdileri, HVAC bilgileri, iklim, güneş/gölgeleme bilgileri gibi unsurları detaylı bina ve çevresel parametrelere dayalı olarak hesaplamaktadır (Zhao and Magoulès, 2012). Detaylı parametrelerin bazıları simülasyon sırasında kullanıcılar için mevcut olmayabilir bu da tahmin performansının düşük olmasına neden olabilir. Bu yöntem bir tasarımcının, yapım süreçlerinden önce form, malzeme ve sistemlerin bir binanın beklenen enerji performansı üzerindeki etkisini incelemesine de imkân sağlar. Ancak gerçekçi bina modellerinden çok sayıda performans simülasyonu ve önemli miktarda zaman ve hesaplama kaynağı neticesinde sonuç alınabilir. Bu sorunun üstesinden gelmek için veriye dayalı modellerin kullanılması önerilmiştir (Zhao and Magoulès, 2012).

3.1. Makine Öğrenimi İçin Tahminleme Süreci

Makine öğrenmesi modelleri, fiziksel sorunu temsil eden, ölçülen veya simüle edilmiş verilerden öğrenilen, girdiler ve çıktılar arasındaki matematiksel ilişkilerin kurulduğu veriye dayalı sistemlerdir. Mevcut verilerden öğrenen bir bilgisayar algoritmasını tanımlamak için kullanılan makine öğrenmesinde önemli miktarda veri ve nispeten az sayıda girdi özelliği kullanılmaktadır. Son yıllarda yapı sektöründe ısıtma ve soğutma yüklerinin, enerji tüketiminin ve çeşitli koşullardaki performansın tahmin edilmesi için çok sayıda makine öğrenimi tekniği önerilmiştir. Dolayısıyla, yeterince hassas modeller, hesaplama açısından yoğun bir tasarım süreci sırasında hızlı ve doğru alternatifler sağlamaktadır (Rastogi vd., 2017).

Veriye dayalı bina enerji tüketimi tahmin modellemesi, tahmin için geçmiş / mevcut verilerden öğrenir. Veri odaklı bir model geliştirmek genel olarak dört temel adımla özetlenebilir (Amasyalı and El-Gohary, 2018):


Veri toplama, bina enerji tüketimi tahmini alanında, veri toplama, hava durumu ve elektrik tüketimi verileri gibi model eğitimi için geçmiş / mevcut verilerin toplanmasını içerir.

Veri ön işleme, veri temizleme, veri entegrasyonu, veri dönüşümü, özellik seçimi ve/veya veri azaltmayı içeren, tahmin doğruluğunu artırmak için verileri modele dahil etmeden önce yürütülen işlemler bütünüdür.

Model eğitimi, bir eğitim veri kümesi kullanılarak modelin eğitilmesidir.

Model testi, standart değerlendirme ölçütlerini kullanarak modelin tahmin performansını değerlendirmeyi amaçlar.

Bina sistemleri hakkında hiçbir bilgiye ihtiyaç duymayan makine öğrenimi modelleri bir kara kutu gibi çalışır. Veri setinde yer alan çeşitli girdi özellikleri ile çıktı hedefleri arasındaki ilişkiyi keşfeder. Veri seti, ilk olarak verilen problemlerin tahmini için bir grup algoritmaya karar vermek amacıyla, eğitim ve test olmak üzere ikiye ayrılır. Makine öğreniminde tahmin modeli sürecinde, eğitim veri seti üzerinden model oluşturulur ve tahmin veri seti ile oluşturulan model test edilir, bu süreç modelin öğrenme süreci olarak tariflenebilir (Şekil 3.1).



Şekil 3.1. Makine öğrenimi ile bina enerji performansı tahmininin şematik gösterimi

Eğitim ve test olarak ayrılan veri setinin özelliklerine göre problem olmasının önüne geçilebilmesi amacıyla cross-validation/çapraz doğrulama yöntemi kullanılabilir. Bu yöntem, makine öğrenmesi modelinin görmediği veriler üzerindeki performansını mümkün olduğunca objektif ve doğru bir şekilde değerlendirmek için kullanılan istatistiksel bir yeniden örnekleme (resampling) yöntemidir. Yöntem, algoritmanın çalışma zamanı ve sonuçlarını optimize etmeye katkı sağlar (Namlı vd., 2019). Bu aşamada eğitim verisi test edilmeden önce validasyon yöntemiyle ön test sürecinden geçerek model üretilir. Eğitim veri seti rastgele k adet farklı parçaya bölünerek her bir grup test verisi olarak kullanılmak üzere ayrılır. Geri kalan verilerin tamamı modeli eğitmek için kullanılır (Şekil 3.2). Başka bir deyişle algoritma k kez veriyi eğitir ve sonuçlarını test eder. Uygulanan metodun doğruluğu ise her bir test verisinin sonuçlarının ortalamasıdır (Namlı vd., 2019).



Şekil 3.2. Çapraz doğrulama modeli

Modeller, yeterli miktarda veri ile eğitildiğinde, özellikler ile hedefler arasındaki ilişki tanımlanmamış olsa da, yeni performansları tahmin etmek için kullanılabilir. Gelişen ve gelecek vaat eden bir teknoloji olarak, makine öğrenimi, çok miktarda veriye gömülü değerli bilgileri otomatik olarak çıkarmak için güçlü ve çok yönlü bir araçtır.

3.1.1. Makine öğrenimi modeli için girdi verilerinin ön işleme süreci

Tahmin modellerinde girdi verilerini oluşturacak parametrelerin doğru belirlenmesi oldukça önemlidir. Doğru parametrelerin oluşturduğu girdi verilerinin temizliği, doğruluğu, kalitesi, niteliği tahmin sonuçlarını doğrudan etkilemektedir. Bu nedenle girdi verilerinin ön işlemden geçirilmesi gerekmektedir. Literatür taraması sürecinde incelenen birçok çalışma da girdi verilerinin birtakım yöntemlerle ön işleme sürecine tabii tutulduğu gözlemlenmiştir. Genel olarak, veri ön işleme, tahmin için yaygın bir uygulamadır. Veri ön işleme farklı şekillerde yürütülebilir (Kuster vd., 2017; Fan vd. 2014):

- Veri temizleme/ eksik değerlerin düzeltilmesi ve doldurulması,
- Kategorik verilerin dönüştürülmesi,
- Aykırı değer tespiti/anormallik tespiti
- Değişkenlerin bağımlılığının ve anlamlılığının ölçülmesi,
- Veri seçimi/ verilerin ayrıştırılması, sınıflandırılması ve özellik seçimi
- Veri normalizasyonu

Veri temizleme, eksik veriler, tekrar eden veriler ya da sıra dışı enerji davranışlarını gösteren aykırı değerler gibi tüm düşük kaliteli bilgileri kaldırmak için manuel veya otomatik olarak

yapılan bir adımdır. Kategorik veriler numeric-sayısal veri olmadıkları için makine öğrenimi algoritmalarında doğrudan kullanılamazlar. Bu nedenle veri setinde yer alan kategorik verileri numerik verilere dönüştürmek gereklidir. Aykırı değer tespiti, verilerin çoğunluğundan önemli ölçüde sapma nedeniyle şüphe uyandıran nadir öğelerin, olayların veya gözlemlerin tanımlanmasıdır (Zhang vd., 2021). Aykırı değer tespiti genellikle bina verilerinin akıllı sayaçlarla ve sensörlerle elde edildiği durumlarda kullanılmaktadır (Seem, 2007; Fan vd., 2014).

Değişkenlerin bağımlılığı ve anlamlılığı, regresyon analiziyle ölçülür. Regresyon analizi, değişkenler arasındaki ilişkinin varlığı ve gücü hakkında bilgi edinmeyi sağlar. Girdi verisi seçimi, tahmin performanslarını artırmak ve hesaplama karmaşıklığını azaltmak amacıyla en etkili parametreleri elde etmek için belirli girdi kombinasyonlarını seçmeyi amaçlamaktadır. Literatürde farklı birçok parametre girdi verisi olarak kullanılmıştır. Girdi verileri çeşitli özellik seçimi algoritmalarının kullanılmasının yanı sıra manuel olarak da belirlenebilmektedir (Ertosun Yıldız vd., 2021; Fan vd., 2017). Girdi verilerinin veri normalizasyonu bir çeşit dönüştürme işlemidir ve verileri normalleştirilmiş forma dönüştürür. Normalleştirme sürecinde, her giriş veri noktası 0 ve 1 aralığına dönüştürülür. Literatürde, normalleştirme sürecinin modelin öğrenme sürecini geliştirdiği özellikle YSA tabanlı tahmin modellerinin daha iyi performans göstermesine neden olduğu belirtilmiştir (Raza and Khosravi, 2015).

Veri ön işleme sürecinde çeşitli matematiksel ve istatistiksel araçlar kullanılmaktadır. Yaygın olarak, bir dizi muhtemelen ilişkili değişkeni daha az sayıda değişkene dönüştürmek için kullanılan temel bileşen analizi (PCA), iki değişken arasındaki ilişkinin olup olmadığını belirleyen ki kare testi (Chi-Square Test), iki değişken arasındaki ilişkinin derecesini, yönünü gücünü ve birbirleriyle olan ilişkilerinin ölçümünü gösteren korelasyon analizleri (PCC-SCC), girdi veri setinde verilerin geneline uymayan gözlemlerin belirlenmesi amacıyla kullanılan Cook's Distance ve Centered Leverage Value analizi, veriler arasındaki ilişkiyi değerlendirmeye yönelik doğrusal bir modelleme yöntemi olan varyans analizi/ p değeri (ANOVA) , birden fazla bağımlı değişkenin bağımsız bir değişkenin grupları arasında herhangi bir farklılık oluşturup oluşturmadığını belirlemek için kullanılan MANOVA, bir girdi verisinin çıktı verilerini ne derece etkilediğinin ölçülmesini hedefleyen hassasiyet analizi de literatürde karşılaşılan veri ön işleme yöntemlerindendir. Bu yöntemlerin ortak amacı, çıktı verilerini girdi verileri ile ilişkilendirip etkisini gözlemleyerek tahmin modelinin

doğruluğunu artırmak, gereksiz ya da niteliksiz girdi verisi kullanımını önlemektir (Kristensen and Petersen, 2016; Li vd., 2018; Nilashi vd., 2017, Bourdeau vd., 2019).

3.2. Makine öğrenimi ile bina enerji performansı tahminine yönelik literatür araştırmaları

Bu bölümde makine öğrenimi ile enerji tüketimi tahmini alanındaki çalışmalara genel bir bakış sunulmuştur. Bir dizi modelin kapsamı, bina türleri (konut ve konut dışı), tahmin edilen enerji tüketimi türleri (ısıtma, soğutma, aydınlatma ve genel) açısından gözden geçirilmiştir. Bu modelleri eğitmek ve test etmek için kullanılan verilerin özellikleri, veri türleri (gerçek, simülasyon), özellik türleri (dış hava koşulları, iç ortam koşulları, bina özellikleri, geçmiş enerji tüketim verileri ile ilgili özellikler) ve verilerin boyutları (veri toplama süresi, veri örneği sayısı) dahil olmak üzere irdelenmiştir.

Makine öğrenimi algoritmaları ile enerji tüketimi tahmini son yıllarda büyük ilgi görmüştür. Zhao ve Magoulès (2012), bina enerji tüketimi tahmin yöntemlerini ayrıntılı mühendislik yöntemleri, basitleştirilmiş mühendislik yöntemleri, istatistiksel yöntemler, YSA tabanlı yöntemler, DVM tabanlı yöntemler ve gri modeller olarak sınıflandırmış ve model karmaşıklığı, kullanım kolaylığı, çalışma hızı, ihtiyaç duyulan girdiler ve doğruluk açısından bazı karşılaştırmalı analizler yapmıştır. Ahmad ve diğerleri (2018) YSA tabanlı, SVM tabanlı ve hibrit yöntemlerin incelenmesine odaklanmış ve bu yöntemlerin prensiplerini, avantajlarını ve dezavantajlarını tartışmıştır. Bourdeau ve diğerleri (2019), çeşitli çalışmalar tarafından önerilen bina enerji tüketimi tahmin yöntemlerinin sınıflandırmasını özetlemiş ve modelleme için kullanılan verilerinin incelenmesine özel bir vurgu yapmıştır. Li ve diğerleri (2018), ofis binaları üzerinde kapsayıcı bir inceleme gerçekleştirmiş; yalnızca bina enerji modellemesi ve tahmini üzerine değil, bina enerji kıyaslaması için son çalışmaları gözden geçirmiştir. Li ve diğerleri (2014), bina enerji kıyaslama yöntemlerini gözden geçirmiş ve kullanıcılara uygun tahmin yöntemini seçmelerinde yardımcı olmayı amaçlayan bir akış şeması önermiştir. Wang ve diğerleri (2018), tekli yapay zeka tabanlı yöntemlerin (örneğin YSA ve SVM) ve topluluk yöntemlerinin ilkelerini, uygulamalarını, avantajlarını ve dezavantajlarını incelemiş ve karşılaştırmıştır.

Karar ağacı yöntemine dayanarak bir binanın enerji talebi tahmin modelinin geliştirilmesini anlatmaktadır. Yöntem ile Japonya'daki konut binalarına bina enerji kullanım yoğunluğu

düzeylerini tahmin etmek amaçlanmıştır. Bu noktada yıllık ortalama hava sıcaklığı, bina yapım tipi, zemin ısı kaybı katsayısı, eşdeğer sızıntı alanı, kullanıcı sayısı, ısıtma ve sıcak su kullanımları veri seti olarak kullanılmıştır. Sonuçlar, karar ağacı yönteminin kullanılmasının, bina enerji talebi seviyelerini doğru şekilde sınıflandırabileceğini ve tahmin edebileceğini (eğitim verileri için % 93 ve test verileri için % 92) göstermiştir (Yu vd., 2010).

Yapılan bir çalışmada kıyaslama yöntemi regresyon modelinin dağılımına dayandırılmıştır. Araştırmada, çoklu regresyon analizi kullanılarak bir kıyaslama tablosu elde edilmiştir. Bu, enerji kullanım yoğunluğuna dayanan önemli faktörlerin yeniden tanımlanması olarak kabul edilmektedir (Chung vd., 2006). Çevre Koruma Ajansı (EPA) tarafından geliştirilen Energy Star bina kıyaslama programı adım adım doğrusal regresyon yöntemini kullanan başka bir örnektir (Energy Star, 2011).

Kumar, Aggarwal ve Sharma'nın (2013) çalışmalarında yapay zeka analizini uygulamaları için taban oluşturmuştur. Çeşitli YSA yöntemlerini uygulayarak yaz ve kış aylarında bir binanın enerji ihtiyacının bulunması, binanın enerji tüketiminin tahmini, iç hava sıcaklığının tahmin edilmesi ve ısıtma, havalandırma ve iklimlendirme sistemleri analizini yapmışlardır. YSA'nın büyük bir veri setinin tahmini için uygun olduğu sonucuna varılmıştır (Kumar vd., 2013).

Soğutma ve ısıtma yükü talebini tahmin etmek için yapılan bir çalışmada binaların enerji performansı, destek vektör uygulaması (SVM), yapay sinir ağı (YSA), sınıflandırma ve regresyon ağacı gibi çeşitli makine öğrenim yöntemleri uygulanmıştır. Tahmin modelleri için, aynı hacme sahip, aynı malzemelerin kullanıldığı ancak farklı yüzey alanlarına ve boyutlarına sahip 12 bina Ecotect'te simüle edilmiştir. Simülasyon verilerini yüzey alanı, duvar alanı, çatı alanı, toplam yükseklik, cam alanı, cam dağılımı ve soğutma yükü / ısıtma yükü oluşturmaktadır. Karşılaştırma sonuçları, veri madenciliğinin ısıtma ve soğutma yükünü tahmin etmek için en iyi model olduğunu, ortalama % 4'ün altında hataların olabileceğini göstermiştir (Chou and Bui, 2014).

Kullanıcı davranışına bağlı tahmin modelleri oluşturmak amacıyla ofis binalarını kapsayan bir çalışma yapılmıştır. Kullanıcı davranışının bina HVAC enerji tüketimi üzerindeki etkisi karar ağacı algoritması kullanılarak incelenmiş ve farklı iklim koşullarındaki binalarda tahmin sonuçlarında büyük farklılıklar olduğu görülmüştür (Zhao vd., 2014).

Hong Kong' da 490 m yükseklikte ticari bir gökdelenin günlük enerji tüketimi ile maksimum enerji talebini tahmin etmek için bir veri madenciliği temelli yöntem önerilmiştir. Sekiz temel makine öğrenimi modelinin birleştirilmesi ve genetik algoritma yardımıyla yeni bir ölçüm modeli geliştirilmiştir. Yapılan çalışmada binadan 15 dakikalık aralıklarla güç tüketim verileri ve yıllık olarak meteoroloji verileri toplanmıştır. Sonuçlar, birleştirilmeyle oluşan yeni modellerin bireysel modellere göre daha yüksek tahmin doğruluğu elde ettiğini göstermiştir (Fan vd., 2014)

Bir doktora tez çalışmasında, enerji ve azami elektrik tüketimini azaltacak sıfır enerjili bina tasarımında kullanılabilecek uyarlanabilir ve gerçek zamanlı kontrol ve karar verme stratejisi geliştiren sıfır enerjili bina kümeleme simülasyonu oluşturularak, enerji tahmin modelleri geliştirme hedeflenmiştir. Araştırma kapsamında ilk olarak mevcut işletme stratejileri ve tüketimleri ortaya koyan bir bina kümelemesi geliştirilmiştir. Daha sonra aktif sistemleri tanımlama ve verileri birleştirme teknikleri kullanılarak, bina sistemi karakteristik değerlendirmesi, sistem uyarma ve model adaptasyonu içeren bir bina enerji tahmin metodolojisi geliştirilmiştir. Fotovoltaik panelleri, bataryaları, termal depolama sistemleri için enerji tahminlerini içeren ve çevrimiçi olarak erişim sağlanabilen bina kümeleme enerji tahmin sistemi metodolojisinin doğrulanması için küçük ölçekli gerçek bina validasyon çalışması yapılmıştır. Sonuç olarak kümelenmenin enerji tahmin modelinin geliştirilmesinde ve model bazlı kontrol ve operasyon optimizasyonunda kullanılabileceği ortaya çıkarılmıştır (Li, 2015).

Kullanıcı davranışının bina teknolojileri ve işletimi üzerindeki etkilerini araştırmayı ve buna ilişkin bir model geliştirmeyi amaçlayan bir çalışmada literatür araştırması yapılarak veri odaklı davranış modelleri geliştirilmiş ve binalarda enerji ile ilgili bina kullanıcılarının davranışını temsil eden bir ontoloji sunulmuştur. Zaman, insan-makine etkileşimlerini temsil etmek için ihtiyaç-eylem-olay bilişsel teorik çerçeveleri kullanılmıştır. Bu makalenin 1. Bölümünde, yayınlanmış 130' dan fazla davranış araştırmasının incelemesi yapılmıştır. İnsan-bina-sistem etkileşiminin saha izlemesine dayalı olarak çok çeşitli veri odaklı davranış modelleri geliştirilmiştir. Coğrafi olarak dünya çapında standardizasyon ve tutarlılıktan yoksun çalışmalar olduğu için çalışmalar birbirleriyle karşılaştırılırken zorluklarla karşılaşmıştır. Bu sorunu çözmek için, binalarda enerji ile ilgili bina kullanıcılarının davranışını temsil eden bir ontoloji sunulmuştur. Buna göre, teknik DNA çerçevesi dört temel bileşene dayalı olarak geliştirilir: i) Davranış sürücüleri, ii) Bina sakinlerinin

ihtiyaçları, iii) Bina sakinleri tarafından gerçekleştirilen eylemler ve iv) Bina sakinleri tarafından kullanılan bina sistemleri. Bu DNA çerçevesi, uluslararası araştırma topluluğunu binalarda enerji ile ilgili kullanıcı davranışının sistematik bir temsilini standartlaştırmak için tasarlanmıştır (Hong vd., 2015).

Yapılan farklı bir çalışmada, özel ofis binası için sınırlı bilgi içeren dinamik enerji kıyaslamaları geliştirmenin sistematik bir yöntemi sunulmaktadır. Eş zamanlı olarak, ofis binası için saatlik olarak enerji değerlendirmesi sağlamak üzere bir enerji tüketim derecelendirme (ECR) sistemi kurulmuştur. EnergyPlus ortamında gerçekleştirilen ofis binası modeli tarafından üretilen verilere dayanarak, bu çalışma üç adımda gerçekleştirilmiştir:

Adım 1: Veri hazırlama;

Adım 2: Dinamik enerji kriterlerinin geliştirilmesi ve

Adım 3: Dinamik enerji kriterleri ve ECR sisteminin değerlendirilmesi.

Karar ağacı analizine dayanarak, sistem enerji tüketimi, erişilebilir hava ve zaman değişkenleri, yani dış mekân kuru termometre sıcaklığı, bağıl nem, gün tipi ve saat tipi ile sekiz paternde sınıflandırılmıştır. Ardından, hafta içi dört enerji tüketim modeline göre dört enerji testi geliştirilmiştir. Yapılan yöntem önerilen dinamik enerji kriterlerinin etkinliğini doğrulamak için, sırasıyla, Eylül, Ekim ve Kasım aylarında bina enerji performansını değerlendirmek için kullanılmış ve onaylanmıştır. Karar analizi sonucunun güvenilirliği, ANOVA analizi ve Post-hoc testi kullanılarak doğrulanmıştır. Son olarak, ECR sistemi, enerji tüketim oranını yedi dereceye, yani A – G'ye göre sınıflandırarak bina enerji performansına ilişkin nicel bir değerlendirme sağlamak için kurulmuştur. (Liu vd., 2017).

Diğer bir çalışmada, kullanıcı davranışını göz önünde bulundurarak yeni bir bina kıyaslama metodolojisi geliştirilmiştir. Tanımlanan kıyaslama değerinin kullanıcı davranışıyla ilişkili bina enerji tasarrufu potansiyellerinin daha fazla değerlendirilmesini kolaylaştırmak için kullanılabileceği gösterilmiştir. Yöntem, binalarda gerçek kullanıcı davranışını taklit edebilen agent-based modelleme yöntemine dayanmaktadır. Agent based (vekil tabanlı) modelleme yöntemi, araçların yerleşik ortamda nasıl harekete geçtiklerini ve diğer araçlarla nasıl etkileşimde bulunduklarını açıklayabilen gelişmiş bir hesaplama yöntemidir. Bu yöntemin en büyük avantajı, kullanıcıların gerçek taleplerini hesaba katmak ve yapısına bağlı olarak

farklı seviyelere (örneğin, bina sakinleri, sistem ve bina) göre etkisini analiz etmektir. Kıyaslama değerlerinin hesaplanmasında ana unsuru kullanıcı davranış profilleri olan standart profil kullanılmıştır. Uygulanabilirliği, Japon konut binaları veri tabanından seçilen tipik bir konuta uygulanarak gösterilmiştir. İklimlendirme ve aydınlatmaya yönelik standart davranış profilleri oluşturulmuş ve kullanıcı davranışı ile ilgili enerji tasarrufu potansiyeli belirlenmiştir. Mevcut yöntemlerle karşılaştırıldığında, önerilen yöntemin daha pratik ve güvenilir bir bina enerji kıyaslama değeri sağlayabileceği ve belirlenen enerji tasarrufu potansiyelinin doğruluğu gösterilmiştir. Bu çalışma gelecekteki kıyaslama araştırmasının, sosyo ekonomik gibi farklı faktörler göz önünde bulundurularak daha sistematik bir yöntem geliştirmek için daha fazla çaba harcaması gerektiğini ileri sürmüştür (Huang vd., 2017).

Bir otelin saatlik HVAC enerji tüketimini (ısıtma soğutma yükü) tahmin etmek amacıyla bir makine öğrenim tekniği geliştirilmiştir. Bu amaçla, yapay sinir ağı modeli (YSA) performansı, topluluk tabanlı bir yöntem olan “random forest” modeli (RF) ile karşılaştırılarak değerlendirilmiştir. Sonucunda, YSA, RF'den olarak daha iyi performans göstermiştir. Bununla birlikte, kategorik değişkenlerle ayarlama ve modelleme kolaylığı, topluluk tabanlı algoritmalara binalarda tipik olan çok boyutlu karmaşık verilerle başa çıkmak için bir avantaj sunar. Her iki model de benzer tahmin gücüne sahiptir ve bina enerji uygulamalarında neredeyse eşit derecede uygulanabilir olduğunu göstermiştir (Ahmad vd., 2017).

Üniversite binalarının günlük elektrik kullanımını tahmin etmek için çoklu regresyon (MR) algoritması kullanılarak matematiksel bir denklemin geliştirildiği çalışmada altı açıklayıcı değişkenden üç değişkenin; çevredeki sıcaklık, hafta içi endeksi ve bina türü binaların enerji tüketimi üzerinde önemli etkiye sahip olduğu tespit edilmiştir. Bu modelin sonuçları, idari bina için % 12 ve akademik bina için % 13'lük Normalleştirilmiş Kök Ortalama Kare Hatası (NRMSE) ile ilişkilendirilmiştir (Amber vd., 2017).

Londra’ da bulunan bir yönetim binasının elektrik tüketimini tahmin ederek çoklu regresyon (MR), genetik programlama (GP), yapay sinir ağı (YSA), derin sinir ağı (DNN) ve destek vektör makinesi (SVM) olmak üzere beş farklı akıllı sistem tekniğinin tahmin yeteneklerinin karşılaştırıldığı bir çalışmada; dört yıllık elektrik tüketimi verileri modellerin eğitilmesi ve beşinci yıl için tahmin verilerinin elde edilmesi için kullanılmıştır. Son olarak, tüm modellerin tahmini elektrik tüketimi, beşinci yılın gerçek tüketimi ile karşılaştırılmıştır.

Sonuçlar, YSA'nın % 6 ortalama mutlak yüzde hatası (MAPE) ile diğer dört teknikten daha iyi performans gösterdiğini, MR, GP, SVM ve DNN'nin sırasıyla % 8.5,% 8.7,% 9 ve% 11 MAPE'ye sahip olduğunu göstermiştir. Bu çalışmanın uygulanabilirliği diğer bina kategorilerine yayılabilir ve enerji yönetimi ekiplerinin çeşitli binaların enerji tüketimini tahmin etmesine yardımcı olabileceği görülmüştür (Amber, vd., 2018).

Bir çalışma, çeşitli etkinlikler ve disiplinler için alanlar sağlayarak karmaşık işlevlere hizmet eden yükseköğretim kampüslerinde farklı bina türlerinin enerji kullanım özelliklerini anlama ve bir enerji kıyaslama sistemi kurmayı amaçlamıştır. Veriler, Avustralya'da 80 üniversite kampüs binalarından toplanmıştır. Öğretim, araştırma, yönetim, akademik ofis işleri ve kendi kendine öğrenme gibi çeşitli akademik etkinliklerde kullanılan farklı binalarda enerji kullanım özellikleri belirlenmiştir. Araştırma binalarında enerji kullanımı yoğunluğu, öğretim binaları, akademik ofisler, idari ofisler ve kütüphaneler gibi diğer bina tipleriyle karşılaştırıldığında önemli bir fark gözlenmiştir. Disiplinler arasında enerji yoğunluğunda daha ince bir fark bulunurken, enerji tüketim değerleri bina büyüklüğüne, enerji yoğunluğu ise bina tipinde ve özellikle laboratuvar kullanılan alanlarda gerilemiştir. Enerji tüketimi (EC) ve enerji kullanım yoğunluğunun (EUI) yanı sıra ilgili alan türleri ve doluluk koşulları analiz edilmiştir. Bazı istatistiksel yöntemlerin karşılaştırmalı çalışmasına dayanarak, stokastik analiz (SFA) yöntemi, bu araştırma için en uygun kıyaslama tekniği olarak seçilmiştir. SFA istatistik tekniği kullanılarak çeşitli etkinlikler ve disiplinler için referans değerler belirlenmiştir. Her bina tipi için geliştirilen enerji kriterleri, üniversite yetkililerini, enerji kullanımını değerlendirerek, uygulanabilir enerji tasarrufu tekniklerini belirleyerek ve gelecekteki planlama gelişimini öngörerek enerji verimliliğini arttırmaya yönlendirebilecek bir çalışma sunulmuştur. Diğer iklim bölgelerinde ve çeşitli üniversitelerden vaka çalışmaları ile benzer çalışmalar, bu çalışmayı doğrulamak ve farklı iklimdeki kampüs binaları için güvenilir enerji kıyaslama sistemleri sağlamak amacıyla gelecekteki araştırmalar için önerilmiştir (Khoshbakht vd, 2018)

Bir bina enerji kıyaslaması, makul düzeyde enerji talebini göstererek planlama aşamasında belirsiz bilgilerle karşılaşıldığında gerekli adımları kolaylaştırır. Fiziksel veya istatistiksel modelleme yoluyla yapılan geleneksel girişimlerin yanı sıra, özellikle ayrıntılı bilgi olmadan planlama aşaması için bir çalışmada sınırlı veri setlerine dayalı yeni bir araştırma yapılmıştır. Lorenz eğrisi binalar arasında enerji tüketimi eşitsizliğini tanımlamak için kullanılmıştır. Pekin'deki üç bina tipindeki (ofis, otel, alışveriş merkezi) 195 binadan elde edilen veri

örnekleri, yüzdelik kotalara ve Lorenz eğrisine dayanarak bölgesel veri odaklı bir kıyaslama metodolojisi belirlenmiştir. Bu veri güdümlü yaklaşım sınırlı bilgiye dayanarak geliştirilmiş ve enerji politika belirleme planlamacılarına enerji kıyaslama hedefleri oluşturmada ve enerji verimliliğini artırmada yardım etmeyi hedeflemiştir. Bu yöntemi geliştirmek için bina sınıflandırmasına sahip diğer şehirlerde daha fazla tartışma yapılması çalışmanın bir sonraki odak noktası olarak vurgulanmıştır (Chen vd., 2018)

Villa tipi konutların ortalama günlük enerji tüketimini tahmin etmek amacıyla çeşitli regresyon yöntemlerini içeren bir çalışma, diğer modellerde mevcut olan bazı kararsız tahmin problemlerini çözmenin yanı sıra genelleme becerisinde önemli bir gelişme göstermiştir. Sonuçlar aynı zamanda önerilen topluluk modelinin sınırlı verilerle gelişmiş tahmin performansı üretme yeteneği hakkında içgörüler sağlayarak önerilen modelin geçerliliğini göstermiştir. İyileştirilmiş tahmin için veri kullanılabilirliği gerekliliğinin yaygın olan yanlış anlaşılmasından ziyade, alt topluluklara verilen veri kümeleri içindeki çeşitliliğin gerekliliğine vurgu yaparak, toplu öğrenmenin faydası gösterilmiştir (Alobaidi vd., 2018).

Bir çalışmada konut binalarında ısıtma ve soğutma yüküne etkiyen tasarım parametrelerini belirlemek için on altı makine öğrenme yöntemi denenmiştir. Tahmin modellerinden, random forest (RD) ve rules decision table (RDT) tahmin modellerinin daha iyi performans gösterdiği görülmüştür (Gao, 2019). Literatürde konuyu kapsamlı ele alan gözden geçirme makaleleri ile de sıklıkla karşılaşılmaktadır. Tüm çalışmalar, makine öğrenimi ile binaların enerji talebini belirlemenin oldukça hızlı ve güvenilir olduğunu göstermiştir (Bourdeau, 2019; Seyedzadeh, 2018; Ahmad, 2018; Amasyali, 2018)

Literatür araştırmasıyla ortaya koyulan çalışmalarla kullanılan makine öğrenimi yöntemlerine/algoritmalarına odaklanarak enerji tüketimi tahmini araştırma çabaları hakkında kapsamlı bir inceleme sağlanmıştır. İncelenen çalışmalar bina enerji tüketimi tahmini araştırmalarını, tahmin kapsamı, kullanılan veri türleri, tahmin için kullanılan özellik veri boyutları (veri toplama süresi, veri örneği sayısı) açısından ele almıştır (Çizelge 3.1).

Çizelge 3.1. Literatür araştırmaları analizi

ÇALIŞMA	YÖNTEM	BİNA TİPİ	TAHMİN EDİLEN	VERİ TİPİ	VERİ ÖZELLİKLERİ	VERİ BOYUTU
Xuemei vd., 2010	SVM, PCA	Konut dışı	Soğutma Yüğü	Gerçek Veri	Gün, günlük ortalama, en yüksek, en düşük sıcaklık,	620 örnek
Chae vd., 2016	ANN	Konut dışı	Toplam enerji talebi	Gerçek Veri	Günlük bağıl nem, günlük ort. Kuru term sıcaklığı	1 aylık veri
Wong vd., 2010	ANN	Konut dışı	Isıtma-Soğutma	Simulasyon	Günlük ort. Kuru term. sıcaklığı, günlük güneş ışıması	8760 örnek
Naji vd., 2016	ANN	Konut	Isıtma-Soğutma	Simüasyon	Yalıtım kalınlığı	180
Catalina vd., 2013	MR	Konut	Isıtma	Gerçek veri	İç mekan sıcaklığı, hava sıcaklığı	17 örnek
Jain vd., 2014	SVM	Konut	Toplam enerji talebi	Ashrae dataset	Sıcaklık,güneş ışıması	6 aylık
Massana vd., 2015	MLR-ANN-SVM	Konut dışı	Toplam enerji talebi	Gerçek	Rüzgar yönü, nem, hava sıcaklığı	-
Chou and Bui, 2014	ANN SVM DT LR	Konut	Isıtma Soğutma	Simülasyon	Yüzey alanı, çatı alanı, duvar alanı, yönlenme	-
Candanedo vd., 2017	SR DT SVM	Konut	Toplam enerji talebi	Gerçek veri	Dış Hava Koşulları sıcaklık bağıl nem rüzgar hızı, İç Mekan Koşulları sıcaklık bağıl nem aydınlatma düzeyi	1 yıl
Ahmad vd., 2017	ANN RF/DT	Konut dışı	Isıtma-Soğutma	Gerçek veri	Kullanıcı Sayısı/ Davranışı, dış hava koşulları, sıcaklık bağıl nem rüzgar hızı,	-
Alobaidi vd. 2018	LR ANN	Konut	Toplam enerji talebi	Gerçek veri	Geçmiş enerji yükü, dış hava koşulları sıcaklık bağıl nem rüzgar hızı, sıcaklık bağıl nem rüzgar hızı,	1 yıl

Çizelge 3.1 (devam) Literatür araştırmaları analizi

ÇALIŞMA	YÖNTEM	BİNA TİPİ	TAHMİN EDİLEN	VERİ TİPİ	VERİ ÖZELLİKLERİ	VERİ BOYUTU
Bagnasco 2015	ANN	Konut dışı	Toplam enerji talebi	Gerçek veri	Geçmiş enerji yükü, dış hava koşulları, sıcaklık bağıl nem rüzgar hızı, sıcaklık bağıl nem rüzgar hızı	6 ay
Amber vd., 2017	LR	Konut	Toplam enerji talebi	Gerçek veri	Geçmiş enerji yükü, dış hava koşulları İç-dış ortam sıcaklığı ve bağıl nem rüzgar hızı,	-
Amber vd., 2018	SVM DNN	Konut	Toplam enerji talebi	Gerçek veri	Geçmiş enerji yükü, dış hava koşulları, sıcaklık bağıl nem	-
Shi vd., 2016	ANN	Konut dışı	Toplam enerji talebi	Gerçek veri	Hava sıcaklığı ve kullanıcı	4 yıl
Gao vd., 2014	KNN	Konut dışı	Isıtma-soğutma yükü	Gerçek veri	Geçmiş enerji yükü, dış-ıç hava koşulları, sıcaklık bağıl nem rüzgar hızı,	1 yıl
D'Oca vd., 2015	KNN DT	Konut dışı	Isıtma-soğutma yükü	Gerçek Veri	Sıcaklık bağıl nem rüzgar hızı,	

Literatür araştırmaları, veriye dayalı bina enerji tüketim tahmininin önemli bir araştırma konusu olduğunu göstermektedir. Farklı modeller farklı amaçlara hizmet etmekte, farklı kapsamlara sahip olmakta, farklı veri kümeleri üzerinde eğitilmekte ve tahmin için farklı özellikler kullanılmaktadır. Modellerin kendi içerisinde güçlü ve zayıf yönleri vardır ve farklı koşullar altında farklı performans gösterirler. Tüm koşullar altında kullanılabilecek, her tasarıma uyan tek bir model yoktur. Bu nedenle, uygulamaya özel model geliştirmek esastır.

3.3. Makine Öğrenimi ile Enerji Performans Tahmini için Kullanılan Modeller

Enerji tüketimi tahmin modelini eğitmek için bir makine öğrenme algoritmasına ihtiyaç vardır. Veriye dayalı bina enerji tüketimi tahmini yapan çalışmalarda SVM, ANN, karar ağaçları ve/veya diğer istatistiksel algoritmalar kullanılmıştır. Genel olarak çalışmalarda modellerini eğitmek için YSA, SVM, DT ve regresyon modelleri kullanılmaktadır.

3.3.1. İstatistiksel regresyonlar

İstatistiksel regresyonlar, çıktı değerini ifade eden bir bağımlı değişken ve bu çıktı değerini etkileyen bir veya daha fazla girdi değişkeni (bağımsız değişkenler/açıklayıcı değişkenler) arasındaki ilişkiyi bir denklem biçiminde modellemeyi amaçlamaktadır. Bağımlı değişken “y” harfi ile gösterilirken bağımsız değişkenler ise “x” harfi ile gösterilir. Enerji tüketimi model ve tahmini için literatürde, “multiple linear regression” çoklu doğrusal regresyonları (MLR), “linear regressions” doğrusal regresyonlar, “Bayesian regressions” Bayesian regresyonları ve “Gaussian process regressions” Gauss süreci regresyonları yöntemleri kullanılmıştır (Bourdeau vd., 2019; Dagnely vd., 2015; Chou and Bui, 2014). Diğer istatistiksel algoritmalar arasında genel doğrusal regresyon (GLR), sıradan en küçük kareler regresyonu (OLS), otoregresif (AR), Bayes regresyonu bulunmaktadır (Amasyalı vd., 2018).

Multilinear regresyon modelleri, basitlikleri ve iyi tahmin performansları nedeniyle yaygın olarak kullanılmaktadır. Ancak model, doğrusal verilerden etkilendiğinden doğru sonuç verme oranı düşmektedir. LR modelleriyle ilgili yayınlanmış bina enerji tahmini çalışmaları Çizelge 3.2 'de özetlenmiştir.

Çizelge 3.2. LR modeli ile yapılan tahminleme çalışmaları

ÇALIŞMA	BİNA TİPİ	TAHMİN EDİLEN	VERİ TİPİ	VERİ ÖZELLİKLERİ
Amiri vd., 2015	Konut dışı	Toplam enerji	Simülasyon	Dış duvar özellikleri, yönelme, kullanıcı davranışı (17 parametre)
Wang vd., 2017	Konut	Isıtma yükü	-	Kullanıcı davranışı, bina özellikleri, yapı kabuğu özellikleri (181 parametre)
Tronchin vd., 2018	Konut	Toplam enerji	Simülasyon	Bina özellikleri, HVAC sistem (17 parametre)
Atalay vd., 2019	Konut+ konut dışı	Isıtma ve soğutma yükü	Gerçek veri	Soğutma derece günü, pencere boyutu pencere u değerleri (10 aylık veri)
Thiangchanta vd., 2020	Konut dışı	Isıtma yükü	Gerçek veri	Opak-saydam yüzey termal parametreleri, hava durumu
Fumo vd., 2021	Konut	Toplam enerji	Simülasyon/ Model	Tavan ve duvarlar için R değerleri, ısıtma mevsimsel performans faktörü
Mohammed vd., 2021	Konut dışı	Toplam enerji	Gerçek veri	Konum, bina özellikleri
Perez-Montalvo vd., 2022	Konut dışı	Elektrik kullanımı	Gerçek veri	Sıcaklık, nem, rüzgar yönü, zemin alanı
Lee vd., 2022	Konut	Toplam enerji	Simülasyon	Kullanıcı özellikleri

3.3.2. Karar ağaçları (Decision Tree)

Karar ağaçları, tahmin uygulamaları için uygulanan yaygın bir makine öğrenme algoritmasıdır. Hem erken tasarım hem de yenileme aşamasında enerji performans tahmini için uygulanan tekniklerdendir. Köklerden yapraklara büyüyen bir ağacın fikrini takip eder. Bir DT' nin temel yapısı düğümler, dallar ve yapraklar olarak adlandırılan üç temel bölümden oluşur. Ağaç yapısında her öznitelik bir düğüm ile temsil edilir. Dallar ve yapraklar DT yapısının diğer elemanlarıdır. DT' nin son kısmı yaprak, en üst kısmı ise kök olarak adlandırılır. Kökler ve yapraklar arasındaki kısımlar dallar olarak ifade edilir. Başka bir deyişle, bir ağaç yapısı veri içeren bir kök düğüm, iç düğümler (dallar) ve uç düğümlerden (yapraklar) oluşur. Eğitim verilerinin öznitelik bilgileri kullanılarak bir DT yapısının kurulmasındaki temel prensip, veriler hakkında bir dizi soru sorulması ve elde

edilen cevaplar üzerinden hareket edilerek en kısa sürede sonuca gidilmesi olarak tanımlanabilir. DT, sorulara verilen cevapları toplar ve karar kuralları oluşturur. Ağacın ilk düğümü olan kök düğüme, ağaç yapısının oluşturulması için sorular sorulmaya başlanır. Her düğümde, bir girdi değişkeni üzerindeki belirli bir koşul dikkate alınır ve dallar, tahmin edilen çıktının olası bir değerini tahminlemek için yaprak düğümlere ya da dalsız düğümlere ulaşılan kadar bölünmeye devam eder. Test verileri, oluşturulan ağacın yeni bir veri seti için genelleme yeteneğini belirlemek için kullanılır. Eğitim verileriyle oluşturulan ağaç yapısına yeni bir test verisi ağacın köküne girer. Kökte bulunan bu yeni veri, test sonucuna göre bir alt düğüme gönderilir. Bu işlem ağacın belirli bir yaprağına ulaşana kadar devam eder. Kökten her yaprağa sadece tek bir yol veya tek bir karar kuralı vardır. (Bourdeau vd., 2019; Akıncı ve Noğay, 2019).

Tek bir karar ağacı kullanmaya alternatif olarak daha iyi tahmin performansı üretmek için birkaç karar ağacını birleştiren topluluk yöntemleri (Ensemble decision trees) geliştirilmiştir. Topluluk modelinin temel prensibi bir grup zayıf modelin bir araya gelerek güçlü bir model oluşturmasıdır. Bu ağaçları uygulamak için iki teknik kullanılmaktadır:

Bagging/Torbalama: Amaç rastgele seçilen eğitim veri setinden birkaç veri alt kümesi oluşturmaktır. Her bir alt küme veri koleksiyonu kendi karar ağaçlarını eğitmek için kullanılır. Sonuç olarak, farklı modellerden oluşan bir topluluk elde edilir. Tek bir karar ağacından daha güvenilir olması amacıyla farklı ağaçlardan gelen tüm tahminlerin ortalaması kullanılır. Random Forest /Rastgele Orman literatürde sıkça karşılaşılan bir torbalama yöntemidir.

Boosting/ Güçlendirme: Boosting, bir tahminci koleksiyonu oluşturmak için kullanılan başka bir topluluk tekniğidir. Bu teknikte, her bir model, kendinden önceki modelin performansını iyileştirmeye çalışan birkaç modelin sırayla eğitilmesinden oluşur. AdaBoost, Gradient Boosting ve XGBoost, yaygın olarak kullanılan güçlendirme algoritmalarından bazılarıdır. DT modelleriyle ilgili bina enerji tahmini çalışmaları Çizelge 3.3' te özetlenmiştir.

Çizelge 3.3. Karar ağaçları modeli ile yapılan tahminleme çalışmaları

ÇALIŞMA	BİNA TİPİ	TAHMİN EDİLEN	VERİ TİPİ	VERİ ÖZELLİKLERİ
Ma and Cheng, 2016	Konut	Toplam enerji kullan	Gerçek veri-veri tabanları	171 özellik-bina özellikleri, eğitim,-ekonomik boyut, çevre boyutu
Smarra vd., 2018	Konut	Toplam enerji	Gerçek veri+simülasyon verileri	Geçmiş bina verileri
Ahmad vd., 2017	Konut dışı	Toplam enerji tüketimi	Gerçek veriler	İklim verileri, kullanıcı sayısı, oda kullanımı
Wang vd., 2018	Konut dışı	Saatlik elektrik kullanımı	Gerçek veriler	11 parametre, kullanıcı sayısı, iklim verileri(sıcaklık, nem, rüzgâr hızı)
Zekic-Susac vd., 2021	Konut dışı	Toplam enerji tüketimi	Gerçek veri-veri tabanları	31 parametre- fiziksel özelliği, kullanıcı sayısı, makine özellikleri gibi
Liu vd., 2017	Konut dışı	Isıtma-Soğutma	Gerçek veri	Dış hava koşulları Sıcaklık bağıl nem rüzgar hızı,

3.3.3. Destek vektör makinesi (Support Vector Makinesi)

Destek Vektör Makinesi, hem model eğitimi için hem de regresyon ve sınıflandırma için kullanılabilen çekirdek tabanlı bir makine öğrenimi algoritmasıdır (Amasyalı and El-Gohary, 2018). Destek vektör makineleri, nispeten sınırlı miktarda mevcut veri ile doğru sonuçlar veren bir teknik olduğundan, kayıtlı geçmiş verileri olmadan çalışma vakalarını modellemek için doğru çözümler olabilmektedir (Zhao and Mogules, 2012). Tahmin uygulamaları için süreç, bir regresyon probleminin çözümüne benzerdir. Tüm regresyon problemlerinde olduğu gibi amaç, belirli bir veri kümesini iki alt veri kümesine bölerek SVM modellemesinde bir karar düzleminin araştırılmasına dayalı olarak geliştirilen en uygun işlevi bulmaktır (Seyedzadeh, 2018). İlk olarak, doğrusal olmayan problemi yüksek boyutlu bir uzaya yansıtır ve yüksek boyutlu uzaya en iyi uyan $f(x)$ fonksiyonunu belirler. İkinci olarak, karmaşık nonliner haritayı doğrusal bir problem haline getirmek için bir çekirdek fonksiyonu uygular (Amasyalı and El-Gohary, 2018). SVM en sağlam ve doğru algoritmalarından olup, IEEE Uluslararası Veri Madenciliği Konferansı tarafından araştırma topluluğundaki en etkili ilk on veri madenciliği algoritması arasında listelenmiştir (Kumar vd., 2018). Yaygın fonksiyonları doğrusal, radyal tabanlı ve Gauss'tur. SVM modelleri,

doğrusal olmayan problemleri çözmedeki üstünlükleri nedeniyle binalarda enerji kullanımının tahmini için uygundur. Çizelge 3.4' te SVM modelleriyle ilgili bina enerji tahmini çalışmaları sunulmuştur.


Çizelge 3.4. SVM modeli ile yapılan tahminleme çalışmaları

ÇALIŞMA	BİNA TİPİ	TAHMİN EDİLEN	VERİ TİPİ	VERİ ÖZELLİKLERİ
Jain vd., 2014	Konut	Enerji tüketimi	Gerçek veri	Saatlik/günlük hava durumu
Paudel vd., 2017	Konut	Enerji tüketimi	Gerçek veri	Geçmiş günlük iklim verileri, bina özellikleri, kullanıcı profili
Zhong vd., 2019	Konut dışı	Soğutma yükü	-	İklim verileri(rüzgâr yönü, nem, kuru termometre sıcaklığı, gibi)
Shao, vd. 2020	Konut dışı	Enerji tüketimi	Gerçek veri	Hava durumu parametreleri ve otel klima sisteminin çalışma parametreleri
Liu, vd., 2020	Konut dışı	Eneji tüketimi(klima)	Gerçek veri	Geçmiş enerji tüketimi verileri, iklim faktörleri

3.3.4. Yapay sinir ağları (Artificial Neural Network)

Yapay sinir ağları, bina enerji performansı için bu alandaki başlıca veriye dayalı tahmin algoritmalarından biridir ve çoğu problemi çözmeyi sağlayan uyarlanabilir esnek modellerdendir. Doğrusal olmayan problemlerin ve karmaşık sistemlerin modellenmesinde başarıyla kullanılmaktadır (Seyedzadeh vd., 2018). Her YSA çok katmanlı (en az iki katman) nöronlardan ve nöronlar arasındaki bağlantıları oluşturan aktivasyon fonksiyonlarından oluşur (Şekil 3.3). Her model regresyon için ileri beslemeli, tam bağlı bir sinir ağıdır. Sinir ağının ilk tam bağlı katmanı ağ girişinden (tahmin edici veriler) bir bağlantıya sahiptir ve sonraki her katman bir önceki katmandan bir bağlantıya sahiptir. (Mathworks, 2023). Bazı sık kullanılan fonksiyonlar doğrusal, sigmoid ve sert limit fonksiyonlarıdır (Park and Lek, 2016). İnsan beynindeki sinir ağlarından etkilenilerek üretilen bu teknikte ilk olarak, bir işlem elemanından (nöron) gelen bilgi, bir bağlantı (akson) aracılığıyla ağırlık (sinaps) ile aşağıdaki işlem elemanlarına gönderilir. Bunlar, bir birleştirme işlevi (dendrit) kullanarak diğer nöronlardan gelen bilgilerle alınan bilgileri birleştirir. Son olarak, ağırlıklı bilgilerin

kombinasyonu, bir aktivasyon işlevine bağlı olarak diğer alıcılara gönderilir. İşlem, ağdaki katman sayısına bağlı olarak model verilere tam olarak uyana kadar veya maksimum yineleme sayısına ulaşana kadar tekrarlanır (Bourdeau vd., 2019).



Şekil 3.3. Girdi, çıktı katmanı ve gizli katmandan oluşan yapay sinir ağı modeli

YSA'nın temel formu üç katmandan oluşur (Magoulès and Zhao, 2016):

- Modeli eğitmek veya test aşamasında giriş verilerinden tahmin almak için kullanılan bir girdi katmanı,
- Nihai sonuçları veren bir çıktı katmanı ve
- Girdiler ve çıktılar arasında köprü oluşturan gizli bir katman (sayısı ve yapısı YSA'nın türüne ve modellenmenin ihtiyaçlarına bağlı olarak değişir).

Yapay sinir ağları modelleriyle ilgili bina enerji tahmini çalışmaları Çizelge 3.5'te özetlenmiştir.

Çizelge 3.5. Yapay sinir ağları modeli ile yapılan tahminleme çalışmaları

ÇALIŞMA	BİNA TİPİ	TAHMİN EDİLEN	VERİ TİPİ	VERİ ÖZELLİKLERİ
Li vd., 2018	Konut dışı	Saatlik elektrik enerjisi tüketimi	Gerçek veri	İklim verileri
Deb vd., 2018	Konut dışı	HVAC enerji tüketimi	Gerçek veri	56 bina -14 parametre/bina özellikleri, enerji tüketim geçmiş verileri
D'Amico vd., 2019	Konut dışı- ofis	Isıtma yükü	Simülasyon verileri	13 enerji verisi 16 çevresel veri
Chegari vd., 2021	Konut	Toplam enerji tüketimi	Gerçek veri	Konum, hava durumu, iklimlendirme koşulları ve bina kabuğu parametreleri
Bui vd., 2020	Konut	Isıtma ve soğutma	Simülasyon verileri	Yüzey alanı, duvar alanı, çatı alanı, toplam yükseklik,
Elbeltagi vd., 2021	Konut	Toplam enerji tüketimi	Simülasyon verileri	Bina boyutları, bina yönelimi, dış cephe konstrüksiyonları, cam tipi gibi

Enerji tüketimi tahmin modelleri geliştirmek için kullanılan algoritmalarından YSA ve SVM birçok girdi parametresi gerektirdiğinden ötürü gerçek ölçümler zerinden çalışıldığında pahalı olabilir, ancak tahmin doğrulukları çoğu durumda karar ağaçları ve istatistiksel algoritmalarından daha iyidir. Öte yandan, karar ağaçları ve diğer istatistiksel algoritmaların kullanımı genellikle kolaydır, hesaplama açısından ucuzdur, ancak performansları genellikle ortalama seviyededir (Amasyalı and El-Gohary, 2018; Zhao and Magoulès, 2012).

3.4. Makine Öğrenimi Tahmin Performansı Değerlendirme Metrikleri

Girdi değişkenleri üzerinden çıktı değişkenlerini tahmin etmeye çalışan veri odaklı makine öğrenimi modellerinde, tahmin sonuçlarının performansını ya da doğruluğunu ölçmek amacıyla gerçek ve tahmin edilen sonuçlara dayalı çeşitli performans değerlendirme metrikleri kullanılmaktadır. Tahmin modellerinin performansı, Ortalama Mutlak Yüzde Hata (MAPE), Ortalama Karekök Hata (Root Mean Square Error-RMSE), Ortalama Mutlak

Hata (Mean Absolute Error-MAE), Korelasyon Katsayısı (R), Mutlak Değişim Yüzdesi/Açıklayıcılık Katsayısı (R^2) ve Ortalama Karesel Hata (Mean Square Error-MSE) gibi çoklu değerlendirme metrikleri kullanılarak karşılaştırılır (Eş. 1-5) (Kaboli vd., 2017; Amber, 2018; Seyedzadeh vd., 2018; Amasyali and El-Gohary, 2018; Zheng, 2015).

$$R^2 = 1 - \left[\frac{\sum_t (y_t - \bar{y}_t)^2}{\sum_t (\bar{y}_t)^2} \right] \quad (1)$$

$$MAPE = \frac{1}{T} \sum \left| \frac{y_t - \bar{y}_t}{y_t} \right| \times 100 \quad (2)$$

$$MSE = \frac{1}{T} \sum_{t=1}^T (y_t - \bar{y}_t)^2 \quad (3)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^T (Z_{y_t,i} - Z_{\bar{y}_t,i})^2}{T}} \quad (4)$$

$$MAE = \frac{1}{T} \sum_{i=1}^T |Z_{y_t,i} - Z_{\bar{y}_t,i}| \quad (5)$$

(y_t = Gerçek değerler $\bar{y}_t$ = Tahmin değerleri T= Tahmin sayısı)


Elde edilen sonuçlar, tahmin modelinin mümkün olan en az girdi verileriyle geliştirilmesine yön vermektedir. R değeri, tahmin değeri ve gerçek değer arasındaki uzaklığın ifadesi; R^2 , tahmin modelinin doğruluk oranı katsayısıdır. R ve R^2 değerlerinin 1'e yakın olması beklenir. Bu katsayı değerlerinin yüksek olması tahmin sonucunun iyi olduğunu gösterirken hata ölçüleri olan MSE, RMSE ve MAE metriklerinde ise düşük değerler, tahmin performansının yüksek olduğunu göstermektedir.

4. MATERİYAL VE YÖNTEM

Bu bölümde, Türkiye 3. iklim bölgesinde yer alan konut binalarının ısıtma ve soğutma yüküne karşı enerji performansını tahmin etmek amacıyla tez kapsamında geliştirilen makine öğrenim yöntemi ve aşamaları açıklanmaktadır. Çalışmada; literatür çalışmaları detaylıca incelenmiş olup literatürde yer alan performans göstergeleri, kriterler ve değerlendirmeler dikkate alınarak pasif tasarım kriterleri doğrultusunda 6 ana girdi verisi ile 2 çıktı verisinin makine öğrenimi tahmin süreci için ele alınmasına karar verilmiştir. Design Builder v6 ve JEPlus v2.1.0 simülasyon programları aracılığı ile 12960 veri oluşturulmuştur.

Çalışmanın bu bölümünde, ısıtma ve soğutma yükleri için talep tahmini yapılırken kullanılan materyaller, belirlenen senaryolar üzerinden Design Builder v6 ve JEPlus v2.1.0. yazılımları aracılığıyla hazırlanan verilerdir. Verileri düzenlemek ve toplamak amacıyla Microsoft Office Excel 2016 sürümü; veri ön işleme sürecinde SPSS 28.0.1 sürümü kullanılmıştır. Tahminleme çalışması ısıtma ve soğutma yük tahmini olmak üzere iki aşamada yapılmıştır. Tahmin yöntemine ilişkin eğitim ve test verileri MATLAB R2023a yazılım ortamına aktarılmıştır. Araştırmaya dair ana strüktürü, verilere ulaşma yöntemini, işleyiş adımlarını ve yöntemlerini gösteren çalışmanın kavramsal modeli Şekil 4.1’de gösterilmiştir.

Isıtma ve soğutma yüklerine yönelik talep tahmini yapılırken makine öğrenimi algoritmalarından Doğrusal Regresyon (Linear Regression), Karar Ağaçları (Fine Tree, Medium Tree, Boosted Tree, Bagged Tree), Destek Vektör Makinesi/Support Decision Tree (Linear SVM), Yapay Sinir Ağları (Narrow-Wide Neural Network) modelleri uygulanmıştır. Model tahmininde incelenen algoritmalar daha yüksek doğruluk sağlaması nedeniyle çalışmaya dâhil edilmiştir. Tahmin sonuçları, performans değerlendirme metrikleri üzerinden değerlendirilerek ısıtma ve soğutma yükü için en iyi sonucu veren model bulunmuş ve son tahmin modeli olarak sunulmuştur.



Şekil 4.1. Yöntem akış diyagramı

4.1. Çalışmanın Veri Toplama Yöntemi

Bu bölümün amacı, senaryolar üzerinden konut binaları için ısıtma ve soğutma için tüketim miktarını tanımlama yöntemini açıklamaktır. Bir binanın enerji performansı (EP) yerinde ölçüm, manuel hesaplama ve simülasyona dayalı hesaplamalar ile belirlenebilmektedir. Enerji performansı hesaplanacak bina kullanılan bir bina olduğunda, yerinde ölçüm kullanmak mümkündür. Yerinde ölçüm ve manuel hesaplama zaman alıcı yöntemlerdir. Sonraki adımlarda olası senaryoların sayısı göz önünde bulundurulduğunda, bu tür belirleme yöntemlerini kullanmak güvenilir olmayabilir. Yerinde ölçüm ve manuel hesaplama ile bir binanın enerji performansı belirlendikten sonra yapılacak farklı analizler için simülasyona dayalı hesaplamalar kullanılırsa bu iki sonucun kalibrasyonu zorlayıcı ve güvenilmez olur. Bu nedenle, makine öğrenimine girecek girdi verilerini oluşturmak için ön adımı oluşturan veri setinin hazırlanması aşamasında, çoklu senaryolar geliştirebilmesi hususu değerlendirilerek simülasyona dayalı hesaplamalar yönteminin kullanılması tercih edilmiştir.

EN 13790'da tanımlanan (CEN, 2008) detaylı dinamik hesaplama yöntemi dikkate alınarak, ABD Enerji Bakanlığı (Department of Energy-DoE) lisansı altında yaygın olarak kullanılan EnergyPlus, binaların enerji performansını tanımlamak için kullanılan simülasyon yazılımıdır. Bu detaylı dinamik simülasyon aracı, binanın EP'sini farklı zaman dilimlerinde hesaplayabilmektedir. Simülasyon sonuçlarının doğruluğu için kritik olan iklim veri dosyası DOE web sitesinden alınmalı veya ortalama çok yıllık iklim verilerinden oluşturulmalıdır. EP hesaplamasında çok yararlı olan bir başka simülasyon aracı da "DesignBuilder" programıdır. Design Builder, performans verilerinin üretiminde yazılım hesaplama algoritması olarak EnergyPlus dinamik simülasyon motorunu kullanır. Sanal bina modelleri oluşturarak enerji tüketimi, karbon salımı, konfor koşulları, maksimum yaz dönemi sıcaklıkları, HVAC bileşen boyutları gibi pek çok parametre performansına cevap verebilmektedir. Detaylı dinamik hesaplama yöntemini temsilen DesignBuilder simülasyon programı araç olarak seçilmiştir. Ancak oluşturulması istenen veri sayısının fazlalığı, zaman yönetimi açısından destek bir program gerektirmiş ve Design Builder'a ek olarak JEPlus yazılımı kullanılmıştır. JEPlus, kullanıcıların parametreleri ve değerlerini grafiksel bir kullanıcı arayüzünde tanımlamasına olanak tanıyan 2009 yılında geliştirilmiş ve birçok araştırmada kullanılan EnergyPlus tabanlı bir parametrik simülasyon programıdır. JEPlus

kullanarak parametrik simülasyonları çalıştırmak için binayı tanımlayan girdi veri dosyasının (IDF) düzenlenmesi gerekir. JEPlus yazılımının girdileri aşağıda listelenmiştir:

- Dikkate alınan modelin idf uzantılı dosyaları,
- Çalışma alanı (Ankara) için hava durumu dosyası,
- Değiştirilecek parametrelerin dağılımları,
- Gerekli iterasyon sayısı gibi simülasyon parametreleri
- Enerji modellerinden gerekli çıktılar (ısıtma-soğutma yükü) ve
- Çıktı sonuçlarının nasıl özetleneceğine dair düzenleme (Excel dosyası).

Idf, anlaşılması biraz çaba gerektiren bir metin dosyasıdır. Parametreler için arama dizileri girilirken oldukça dikkatli davranmak gerekir. Program “simüle et” komutuyla çalıştırılana kadar kontrolü yapılamadığından dolayı hata riski yüksektir. Ancak Design Builder’da her bir senaryo üzerinden model geliştirip simülasyonunu yapmak oldukça zaman alıcı olduğundan, Design Builder+ JEPlus programları birlikte kullanılmıştır. Design Builder, planlanan senaryolar için bir grafik arayüz sağlamak amacıyla kullanılmıştır. JEPlus ise seçili parametrelere ait değerlerin belli aralıklarla değiştirildiği çok sayıda parametrik simülasyonları yönetmek için kullanılmıştır.

4.2. Veri setinin oluşturulması


Makine öğrenmesinde veri sayısı, doğruluğu sonraki süreçte alınacak sonuçlar için oldukça önemlidir. Makine ne kadar çok ve doğru veri ile eğitilirse tahmin doğruluğu da o kadar artmaktadır. Bu amaçla konut tipi üzerinden duvar katmanları, plan tipi, yönlenme durumu, pencere tipi değiştirilerek 12960 tane senaryo oluşturulmuş ve çalışmanın ilk aşamasını oluşturan kısım tamamlanmıştır.

4.3. Bina tasarım senaryolarının oluşturulması

Türkiye’de konut stokunun yıllık toplam enerji tüketiminin yaklaşık % 25’inden sorumlu olduğu düşünüldüğünde konut tasarımlarının enerji performansı odaklı olması gerektiği açıktır. Ayrıca, konut sektöründe iç mekân konfor koşullarının sağlanması amacıyla özellikle de ısıtma yükü olmak üzere önemli ölçüde enerji tasarruf potansiyellerinin olması

yapılan bu çalışmanın konutlar üzerinden yürütülmesi gerekliliğini göstermiştir. Bu doğrultuda ilk olarak, konutlar üzerinden senaryolar oluşturulmuş ve simülasyon yoluyla ısıtma soğutma yükleri belirlenmiştir.

Senaryolar oluşturulurken, tasarım sürecinin karmaşık bir süreç olduğu düşünülerek bir binanın enerji performansını en çok etkileyen parametrelerin baz alınması ile çok sayıda tasarım alternatiflerinin geliştirilmesine karar verilmiştir. Bu amaçla, öncelikle genel konut tipolojisi incelenerek plan tipi geometrilerinin sistematik bir şekilde basitleştirilmesi ile dikdörtgen, kare ve L plan olmak üzere 3 adet plan tipine karar verilmiştir. Bu planlar, birbirine eş 12 modülün ($4 \times 3 \text{ m}^2$) bir araya getirilmesiyle oluşturulmuştur (Şekil 4.2).

		
Dikdörtgen Plan (12 modül)	Kare Plan (12 modül)	L plan 12 (modül)
Her bir modül $4 \times 3 = 12 \text{ m}^2$		

Şekil 4.2. Senaryolar için belirlenen plan tipi geometrileri

Daha sonraki aşamada, dış mekânla etkileşimi nedeniyle binaların enerji performansı hususunda en önemli tasarım kararlarının uygulanabildiği yapı kabuğunda en çok yüzey alanına sahip olan cephe yüzeyleri üzerinden çalışılmıştır. Cepheler, opak ve saydam yüzeylerin bir arada bulunduğu yapı elemanlarıdır. Opak ve saydam yüzeylerde kullanılan malzemeler, yüzeylerin oluşum biçimi ve yüzey oranları enerji performansını büyük ölçüde etkilemektedir. Bu doğrultuda, konut cepheleri oluşturulurken kullanılan malzemeler ve yüzey oranlarına bağlı olarak 60 adet duvar tipi; 3 adet pencere tipi geliştirilmiştir.

Konut yapım sisteminde cepheyi oluşturan dış duvarlarda alçı esaslı sıva; gaz beton, delikli tuğla, normal agregalı beton ve bims olmak üzere 4 ana duvar malzemesi; alçı esaslı dış kaplama paneli, çimento esaslı kaplama paneli, doğal taş kaplama, ahşap esaslı kaplama paneli, olmak üzere 4 dış kaplama malzemesi, dış duvar elemanlarının ısı geçirgenlik direncini artırmak için taş yünü, XPS ve EPS olmak üzere 3 yalıtım malzemesi kullanılmıştır (Çizelge 4.1). Yapı kabuğu alternatifleri, 3. derece gün bölgesinde bulunan Ankara ili için










TS825 Isı Yalıtım Kurallarında belirtilen toplam ısıl geçirgenlik katsayısına (U değeri) sınır katsayıları dikkate alınarak oluşturulmuştur (U_d : 0.48 W/m²K).

Çizelge 4.1. Senaryolar için belirlenen duvar katmanları







Duvar Katmanı	Malzeme	Isı İletkenlik Katsayısı λ - W/mK	Renk
İç Sıva	Alçı esaslı sıva	0,400	
Ana Duvar Malzemeleri	Delikli tuğla	0,72	
	Gazbeton	0,24	
	Bims	0,12	
	Beton	0,1900	
Yalıtım Malzemeleri	Taş Yünü	0,033	
	EPS	0,04	
	XPS	0,03	
Dış Sıva/ Dış Kaplama Malzemeleri	Çimento esaslı sıva	0,7200	
	Alçı esaslı kaplama	0,21	
	Çimento esaslı kaplama	0,23	
	Doğal taş kaplama	3,49	
	Ahşap esaslı kaplama	R=Isı İletkenlik Direnci: 0.18 m ² K/W	
Ara Boşluk Katmanı	Hava Boşluğu	R=Isı İletkenlik Direnci: 0.18 m ² K/W	-

Dış duvar alternatifleri 1,5 cm iç sıva; gazbeton, betonblok, bims kullanılan alternatiflerde 20 cm, delikli tuğla kullanılan alternatiflerde ise 19 cm ana duvar malzemesi; 2 cm dış kaplama malzemeleri olarak belirlenmiştir. Her dış duvar konstrüksiyonu alternatifinde farklı malzeme kullanıldığı için yalıtım malzemeleri her konstrüksiyon alternatifinde farklı kalınlıklarda kullanılmıştır. Toplam 60 adet tasarlanan alternatif dış duvar tipleri ve U değerleri, Çizelge 4.2, Çizelge 4.3, Çizelge 4.4'te ve Çizelge 4.5'te gösterilmiştir.










Çizelge 4.2. Ana duvar malzemesi tuğla olan alternatif dış duvar konstrüksiyonları ve U değerleri

Kod	U değeri	Katmanlar	Kalınlık(cm)	Görsel
DT1	0,432	Alçı sıva	1,5	
		Delikli tuğla	19	
		Taş yünü	6	
		Çimento sıva	2	
DT2	0,431	Alçı sıva	1,5	
		Delikli tuğla	19	
		Taş yünü	5	
		Hava boşluğu	5	
		Alçı esaslı kaplama	2	
DT3	0,432	Alçı sıva	1.5	
		Delikli tuğla	19	
		Taş yünü	5	
		Hava boşluğu	5	
		Çimento esaslı kaplama	2	
DT4	0,428	Alçı sıva	1.5	
		Delikli tuğla	19	
		Taş yünü	5	
		Hava boşluğu	5	
		Ahşap esaslı kaplama	2	
DT5	0,448	Alçı sıva	1.5	
		Delikli tuğla	19	
		Taş yünü	5	
		Hava boşluğu	5	
		Doğal Taş Kaplama	2	
DT6	0,445	Alçı sıva	1,5	
		Delikli tuğla	19	
		EPS(standart)	7	
		Çimento sıva	2	
DT7	0,434	Alçı sıva	1,5	
		Delikli tuğla	19	
		EPS	6	
		Hava boşluğu	5	
		Alçı esaslı kaplama	2	
DT8	0,435	Alçı sıva	1,5	
		Delikli tuğla	19	
		EPS	6	
		Hava boşluğu	5	
		Çimento esaslı kaplama	2	
DT9	0,431	Alçı sıva	1,5	
		Delikli tuğla	19	
		EPS	6	
		Hava boşluğu	5	
		Ahşap esaslı kaplama	2	




Çizelge 4.2 (devam) Ana duvar malzemesi tuğla olan alternatif dış duvar konstrüksiyonları ve U değerleri

Kod	U değeri	Katmanlar	Kalınlık(cm)	Görsel
DT10	0,451	Alçı sıva	1,5	
		Delikli tuğla	19	
		EPS	6	
		Hava boşluğu	5	
		Doğal Taş Kaplama	2	
DT11	0,462	Alçı sıva	1,5	
		Delikli tuğla	19	
		XPS	5	
		Çimento sıva	2	
DT12	0,467	Alçı sıva	1,5	
		Delikli tuğla	19	
		XPS	4	
		Hava boşluğu	5	
		Alçı esaslı kaplama	2	
DT13	0,469	Alçı sıva	1,5	
		Delikli tuğla	19	
		XPS	4	
		Hava boşluğu	5	
		Çimento esaslı kaplama	2	
DT14	0,464	Alçı sıva	1,5	
		Delikli tuğla	19	
		XPS	4	
		Hava boşluğu	5	
		Ahşap esaslı kaplama	2	
DT15	0,420	Alçı sıva	1,5	
		Delikli tuğla	19	
		XPS	5	
		Hava boşluğu	5	
		Doğal Taş Kaplama	2	








Çizelge 4.3. Ana duvar malzemesi gazbeton olan alternatif dış duvar konstrüksiyonları ve U değerleri

Kod	U değeri	Katmanlar	Kalınlık(cm)	Görsel
DG1	0,438	Alçı sıva	1,5	
		Gaz beton	20	
		Taş yünü	4	
		Çimento sıva	2	
DG2	0,438	Alçı sıva	1,5	
		Gaz beton	20	
		Taş yünü	3	
		Hava boşluğu	5	
		Alçı esaslı kaplama	2	
DG3	0,439	Alçı sıva	1,5	
		Gaz beton	20	
		Taş yünü	3	
		Hava boşluğu	5	
		Çimento esaslı kaplama	2	
DG4	0,422	Alçı sıva	1,5	
		Gaz beton	20	
		Taş yünü	3	
		Hava boşluğu	5	
		Ahşap esaslı kaplama	2	
DG5	0,455	Alçı sıva	1,5	
		Gaz beton	20	
		Taş yünü	3	
		Hava boşluğu	5	
		Doğal Taş Kaplama	2	
DG6	0,447	Alçı sıva	1,5	
		Gaz beton	20	
		EPS	3	
		Çimento sıva	2	
DG7	0,470	Alçı sıva	1,5	
		Gaz beton	20	
		EPS	3	
		Hava boşluğu	5	
		Alçı esaslı kaplama	2	
DG8	0,472	Alçı sıva	1,5	
		Gaz beton	20	
		EPS	3	
		Hava boşluğu	5	
		Çimento esaslı kaplama	2	
DG9	0,467	Alçı sıva	1,5	
		Gaz beton	20	
		EPS	3	
		Hava boşluğu	5	
		Ahşap esaslı kaplama	2	







Çizelge 4.3 (devam) Ana duvar malzemesi gazbeton olan alternatif dış duvar konstrüksiyonları ve U değerleri

Kod	U değeri	Katmanlar	Kalınlık(cm)	Görsel
DG10	0,437	Alçı sıva	1,5	
		Gaz beton	20	
		EPS	4	
		Hava boşluğu	5	
		Doğal Taş Kaplama	2	
DG11	0,465	Alçı sıva	1,5	
		Gaz beton	20	
		XPS	2	
		Çimento sıva	2	
DG12	0,421	Alçı sıva	1,5	
		Gaz beton	20	
		XPS	3	
		Hava boşluğu	5	
		Alçı esaslı kaplama	2	
DG13	0,422	Alçı sıva	1,5	
		Gaz beton	20	
		XPS	3	
		Hava boşluğu	5	
		Çimento esaslı kaplama	2	
DG14	0,418	Alçı sıva	1,5	
		Gaz beton	20	
		XPS	3	
		Hava boşluğu	5	
		Ahşap esaslı kaplama	2	
DG15	0,437	Alçı sıva	1,5	
		Gaz beton	20	
		XPS	3	
		Hava boşluğu	5	
		Doğal Taş Kaplama	2	









Çizelge 4.4. Ana duvar malzemesi bims olan alternatif dış duvar konstrüksiyonları ve U değerleri

Kod	U değeri	Katmanlar	Kalınlık	Görsel
DBIMS1	0,454	Alçı sıva	1,5	
		Bims	20	
		Taş yünü	1	
		Çimento sıva	2	
DBIMS2	0,398	Alçı sıva	1,5	
		Bims	20	
		Taş yünü	1	
		Hava boşluğu	5	
		Alçı esaslı kaplama	2	
DBIMS3	0,399	Alçı sıva	1,5	
		Bims	20	
		Taş yünü	1	
		Hava boşluğu	5	
		Çimento esaslı kaplama	2	
DBIMS4	0,396	Alçı sıva	1,5	
		Bims	20	
		Taş yünü	1	
		Hava boşluğu	5	
		Ahşap esaslı kaplama	2	
DBIMS5	0,413	Alçı sıva	1,5	
		Bims	20	
		Taş yünü	1	
		Hava boşluğu	5	
		Doğal Taş Kaplama	2	
DBIMS6	0,465	Alçı sıva	1,5	
		Bims	20	
		EPS	1	
		Çimento sıva	2	
DBIMS7	0,407	Alçı sıva	1,5	
		Bims	20	
		EPS	3	
		Hava boşluğu	5	
		Alçı esaslı kaplama	2	
DBIMS8	0,408	Alçı sıva	1,5	
		Bims	20	
		EPS	1	
		Hava boşluğu	5	
		Çimento esaslı kaplama	2	
DBIMS9	0,404	Alçı sıva	1,5	
		Bims	20	
		EPS	1	
		Hava boşluğu	5	
		Ahşap esaslı kaplama	2	







Çizelge 4.4 (devam) Ana duvar malzemesi Bims olan alternatif dış duvar konstrüksiyonları ve U değerleri

Kod	U değeri	Katmanlar	Kalınlık	Görsel
DBIMS10	0,422	Alçı sıva	1,5	
		Bims	20	
		EPS	1	
		Hava boşluğu	5	
		Doğal Taş Kaplama	2	
DBIMS11	0,447	Alçı sıva	1,5	
		Bims	20	
		XPS	1	
		Çimento sıva	2	
DBIMS12	0,393	Alçı sıva	1,5	
		Bims	20	
		XPS	1	
		Hava boşluğu	5	
		Alçı esaslı kaplama	2	
DBIMS13	0,395	Alçı sıva	1,5	
		Bims	20	
		XPS	1	
		Hava boşluğu	5	
		Çimento esaslı kaplama	2	
DBIMS14	0,391	Alçı sıva	1,5	
		Bims	20	
		XPS	1	
		Hava boşluğu	5	
		Ahşap esaslı kaplama	2	
DBIMS15	0,408	Alçı sıva	1,5	
		Bims	20	
		XPS	1	
		Hava boşluğu	5	
		Doğal Taş Kaplama	2	

Çizelge 4.5. Ana duvar malzemesi beton blok olan alternatif dış duvar konstrüksiyonları ve U değerleri

Kod	U değeri	Katmanlar	Kalınlık	Görsel
DBB1	0,451	Alçı sıva	1,5	
		Beton blok	20	
		Taş yünü	3	
		Çimento sıva	2	
DBB2	0,454	Alçı sıva	1,5	
		Beton blok	20	
		Taş yünü	2	
		Hava boşluğu	5	
		Alçı esaslı kaplama	2	
DBB3	0,456	Alçı sıva	1,5	
		Beton blok	20	
		Taş yünü	2	
		Hava boşluğu	5	
		Çimento esaslı kaplama	2	
DBB4	0,437	Alçı sıva	1,5	
		Beton blok	20	
		Taş yünü	2	
		Hava boşluğu	5	
		Ahşap esaslı kaplama	2	
DBB5	0,474	Alçı sıva	1,5	
		Beton blok	20	
		Taş yünü	2	
		Hava boşluğu	5	
		Doğal Taş Kaplama	2	
DBB6	0,433	Alçı sıva	1,5	
		Beton blok	20	
		EPS	4	
		Çimento sıva	2	
DBB7	0,477	Alçı sıva	1,5	
		Beton blok	20	
		EPS	2	
		Hava boşluğu	5	
		Alçı esaslı kaplama	2	
DBB8	0,479	Alçı sıva	1,5	
		Beton blok	20	
		EPS	2	
		Hava boşluğu	5	
		Çimento esaslı kaplama	2	
DBB9	0,474	Alçı sıva	1,5	
		Beton blok	20	
		EPS	2	
		Hava boşluğu	5	
		Ahşap esaslı kaplama	2	






Çizelge 4.5 (devam) Ana duvar malzemesi beton blok olan alternatif dış duvar konstrüksiyonları ve U değerleri

Kod	U değeri	Katmanlar	Kalınlık	Görsel
DBB10	0,443	Alçı sıva	1,5	
		Beton Blok	20	
		EPS	3	
		Hava boşluğu	5	
		Doğal Taş Kaplama	2	
DBB11	0,433	Alçı sıva	1,5	
		Betonarme	20	
		XPS	3	
		Çimento sıva	2	
DBB12	0,442	Alçı sıva	1,5	
		Beton blok	20	
		XPS	2	
		Hava boşluğu	5	
		Alçı esaslı kaplama	2	
DBB13	0,444	Alçı sıva	1,5	
		Beton blok	20	
		XPS	2	
		Hava boşluğu	5	
		Çimento esaslı kaplama	2	
DBB14	0.439	Alçı sıva	1,5	
		Beton blok	20	
		XPS	2	
		Hava boşluğu	5	
		Ahşap esaslı kaplama	2	
DBB15	0,460	Alçı sıva	1,5	
		Beton blok	20	
		XPS	2	
		Hava boşluğu	5	
		Doğal Taş Kaplama	2	

Cepheden beklenen enerji performansı için opak yüzey kadar saydam yüzey alanı tasarımı da etkilidir. Sıydam yüzey gün ışığının ve güneş enerjisinin doğrudan içeri alınmasını sağlarken yüzeye gelen güneş ışınımını yüksek oranda iç mekâna taşımaktadır. Ancak saydam yüzey yüksek ısı iletkenlik katsayıları nedeniyle ısı konfor açısından yapı kabuğunun zayıf noktalarından birini oluşturmaktadır. Sıydam yüzey alanı, opak- sıydam yüzey oranı, kullanılan malzemeler ve pencere detayları gibi tasarım kriterleri enerji performansını doğrudan etkilemektedir. Bu nedenle, duvar alternatiflerinin belirlenmesinden sonra yapı kabuğunun saydam yüzeylerine yönelik kararlar alınmıştır. Sıydamlık oranı değeri; pencere alanı/pencere duvar alanı olarak tanımlanmıştır. Literatürde

minimum sınır %20 psikolojik konfor-dış görüş (Akt. Tekin vd., 2018) olarak belirtildiğinden dolayı alt sınır değer %20 olmak üzere, %60 ve %100 olarak üç oran belirlenmiştir (Çizelge 4.6).

Çizelge 4.6. Senaryolar için belirlenen saydamlık oranları

Saydamlık Oranı	Dikdörtgen Plan	Kare Plan	L Plan
% 20			
% 60			
% 100			

Dış duvarlarda saydam alanları oluşturan pencere tipi konut mimarisinde yaygın kullanılan PVC doğramalı hava tabakalı çift camlı pencere olarak belirlenmiştir. Farklı cam özelliklerinin kullanılmasıyla, ısı kontrollü low-e çift camlı pencere (P1), reflekte çift camlı pencere (P2) ve ısı+güneş kontrollü solar çift camlı pencere (P3) olarak 3 pencere tipi tasarlanmıştır (Çizelge 4.7).

Çizelge 4.7.Senaryolar için belirlenen pencere tipleri

Kod	U Değeri	Katmanlar	Kalınlık	Cam Özelliği	Görsel
P1	1,365	Dış Cam	6 mm	Low-e cam	iç  dış
		Ara Boşluk	16 mm	Hava	
		İç Cam	6 mm	Low-e cam	
P2	2,310	Dış Cam	6 mm	Reflektif Cam	iç  dış
		Ara Boşluk	16 mm	Hava	
		İç Cam	6 mm	Reflektif Cam	
P3	2,101	Dış Cam	6 mm	Solar cam	iç  dış
		Ara Boşluk	16 mm	Hava	
		İç Cam	6 mm	Solar cam	

Binanın yönlenme biçimi iklimsel konforu ve enerji performansını etkileyen diğer pasif tasarım parametrelerdendir. Yönlenme ile iklim bölgesine göre güneş ışıınının ısıtıcı,


rüzgârın serinleten etkisinden faydalanmak ya da kaçınmak mümkün olabilir. Yapılan tez çalışmasında senaryolar oluşturulurken yönelme bir ölçüt olarak alınmış ve belirlenen kütleler sırasıyla 0-315 derece arasında 45 derecelik açıyla döndürülerek denenmiştir.

Çizelge 4.8. Senaryolar için belirlenen yönelme durumları

Derece	Kare	Dikdörtgen	L Plan
0			
45			
90			
135			
180			
225			
270			
315			

4.3.1. Senaryolara yönelik verilerin oluşturulması

Belirlenen parametreler, oluşturulan senaryolar doğrultusunda uygulanarak her bir alternatif için konut başına düşen yıllık nihai enerji tüketim miktarı öncelikle Design Builder sonra alternatifleri daha hızlı simüle edebilmek amacıyla JEPlus aracılığı ile hesaplanmıştır. Enerji tüketimi kapsamında konutun yıllık ısıtma ve soğutma yükleri (kWh/yıl) esas alınmıştır. Senaryolara ait enerji performans değerlerine ulaşma aşamaları Şekil 4.3'te verilmektedir.



Şekil 4.3. Senaryolara ait enerji performans değerlerine ulaşma adımları

Öncelikle Türkiye’de 3. iklim bölgesinde yer alan Ankara ili için tasarlanan 3 ayrı plan tipine sahip prototip konutların bulunduğu bölge programdan seçilmiştir. Daha sonra model oluşturmuş, yönüne göre konumlandırılmış ve bulunduğu topografya eğimsiz olarak kabul edilmiştir. Ayrıca, etrafında çevresel etkileri engelleyecek herhangi bir bina olmadığı varsayılmıştır. Dış duvar elemanlarının performansını konu alan bu çalışmada taban ve tavan

döşemeleri geçirimsiz olarak ele alınmış, tasarlanan alternatif duvar konstrüksiyonları sırasıyla model üzerine işlenmiştir. Binanın iç iklimi için ısıtma ve soğutma sistemi 7/24 çalışacak şekilde ayarlanmış olup, ısıtma döneminde iç mekân sıcaklığı 22 °C, ısıtma sisteminin iç mekân sıcaklığını sağladığı üst sınır değer ise 18 °C olarak belirlenmiştir. Soğutma dönemi için iç mekân sıcaklığı 25 °C, soğutma sisteminin iç mekân sıcaklığını sağladığı üst değer ise 28 °C olarak belirlenmiştir. Bina enerji simülasyon modelinde mekanik havalandırma sistemi kullanılmamıştır. Binada her dairede aktivite düzeyi normal dinlenme olarak tanımlanan 4 kişinin yaşadığı varsayılmıştır. Mekânda bulunan kullanıcıların giysi düzeyleri normal mevsimlik giysi değeri olan 1 clo değerinde tanımlanmıştır. Bina içerisinde iç mekân sıcaklığını etkileyebilecek iç kazanım faktörlerinin olmadığı varsayılmıştır.


Çizelge 4.9. Simülasyonu yapılacak olan alternatif senaryolar

Değişken Çeşidi		Değişken Sayısı	Değişkenler									
Plan Tipi		3 adet	Kare Plan			Dikdörtgen Plan				L Plan		
Opak Yüzey	Duvar malz.	4 adet	Tuğla		Bims		Gazbeton			Beton		
	Yalıtım malz.	3 adet	XPS			EPS			Taş Yünü			
	Kaplam a malz.	5 adet	Alçı Esaslı K.	Çimento Esaslı K.	Ahşap Esaslı K.		Doğal Taş K.		Çiment o sıva			
	Sıva(iç)	1 adet	Alçı sıva									
Saydam Yüzey		3adet	Isı korunumlu			Güneş Korunumlu				Isı ve Güneş K		
Saydamlık Oranı		3 adet	% 20			% 60				% 100		
Yönlenme		8 adet	K	KD	D	GD	G	GB	B	KB		
Simülasyonu Yapılan Alternatif Sayısı		12960										

DesignBuilder üzerinden denenecek senaryoların toplam sayısı 12960 olarak belirlenmiştir (Çizelge 4.9). Sayıca fazla olan bu alternatif senaryolar için aynı anda birçok parametre ile çoklu simülasyon yapabilecek bir programa ihtiyaç duyulmuş ve bu süreçte JEPlus yazılımından destek alınmıştır. JEPlus yazılımı, EnergyPlus simülasyon motoru kullanarak parametrik varyasyonların aynı anda analiz edilmesine izin veren çoklu simülasyon


motorudur. JEPlus yazılımı çalışma konsepti Şekil 4.4' te verilekte olup, yazılımının çalışması için gerekli girdiler aşağıda listelenmiştir:

- Dikkate alınan her bir plan tipine ait modelin EnergyPlus (idf uzantılı) dosyaları (Tez sürecinde farklı plan tiplerine ve farklı saydamlık oranlarına göre 9 adet idf dosyası üzerinden yürütülmüştür. Her bir idf dosyasında JEPlus aracılığıyla 1440 adet simülasyon eş zamanlı yapılmıştır. Toplamda kare plan tipi için 4320; dikdörtgen plan tipi için 4320 ve L plan tipi için 4320 adet simülasyon gerçekleştirilmiştir.)
- Ankara için hava durumu dosyası (Climate One Building, 2023)
- Değiştirilecek parametrelerin dağılımları,
- Simülasyonun parametreleri,
- Enerji modellerinden ihtiyaç duyulan çıktılar (ısıtma-soğutma yükleri)
- Çıktı sonuçlarının nasıl özetleneceği (Excel dosyası).




Şekil 4.4. JEPlus yazılımı çalışma konsepti

İlk olarak DesignBuilder programında dikdörtgen plan tipinde, sırasıyla %20, % 60 ve %100 saydamlık oranına sahip farklı dosyalarda bina geometrileri oluşturulmuştur. Oluşturulan modele yukarıda belirtilen kabuller girildikten sonra belirlenen parametrelerden birer tane seçilerek malzemeler atanmış, konut modellenerek ısıtma soğutma yükü hesaplanmıştır (Şekil 4.5).



Şekil 4.5. Dikdörtgen plan tipi için Design Builder ara yüzü

Elde edilen dosya JEPlus'ta çalıştırılmak üzere IDF uzantılı olarak kaydedilmiştir. Şekil 4.5.'te belirtilen alanlar doldurulduktan sonra idf dosyası düzenlenerek JEPlus çalışma ekranında kodlamaya başlanmıştır (Şekil 4.6).



Şekil 4.6. JEPlus çalışma ekranı

Düzenleme yapılırken ilk iş parametreleri oluşturan tüm malzemelerin/materyallerin dosyada tanımlandığından emin olmaktır. Örneğin duvarı ya da pencereyi oluşturan her bir katmanın termofiziksel özellikleri tanımlanmalı daha sonra da parametrede yer verilen duvar/pencere tipi tanımlanmalıdır. Aşağıda DG2 kodlu duvar için tanımlama kodları yer almaktadır:

“ ! DG2

Construction, Wall DG2,

2010 NCM Plasterboard (wallboard)_002,	!- .02m
5_RVAL_2,	!- R-value
Rock wool - at 10C degrees_003,	!- .03m
Aerated Concrete Block_02,	!- .2m
Gypsum Plastering_0015;	!- .015m

! 2010 NCM Plasterboard (wallboard)- thickness 0,02

Material, 2010 NCM Plasterboard (wallboard)_002,

Rough,	!- Roughness
.02,	!- Thickness {m}
0.21,	!- Conductivity {w/m-K}
700,	!- Density {kg/m3}
1000,	!- Specific Heat {J/kg-K}

! Special material to represent an R-value 81ort he next constructions

Material:NoMass, 5_RVAL_2, !- Material name - Air
layer, 50mm, wall

Rough,	!- Roughness
.2399,	!- Resistance {m2-K/w}
0.9,	!- Thermal Emittance
0.7,	!- Solar Absorptance
0.7;	!- Visible Absorptance

! Rock wool - at 10C degrees- thickness 0,03

Material, Rock wool - at 10C degrees_003,

Rough,	!- Roughness
.03,	!- Thickness {m}
0.033,	!- Conductivity {w/m-K}
100,	!- Density {kg/m3}
710,	!- Specific Heat {J/kg-K}
0.9,	!- Thermal Emittance
0.6,	!- Solar Absorptance
0.6;	!- Visible Absorptance

! Aerated Concrete Block- thickness 0,2

Material, Aerated Concrete Block_02,

Rough,

!- Roughness

.2,

!- Thickness {m}

0.24,

!- Conductivity {w/m-K}

750,

!- Density {kg/m3}

1000,

!- Specific Heat {J/kg-K}

0.9,

!- Thermal Emittance

0.6,

!- Solar Absorptance

0.6;

!- Visible Absorptance

! Gypsum Plastering- thickness 0,015

Material, Gypsum Plastering_0015,

Rough,

!- Roughness

.015,

!- Thickness {m}

0.4,

!- Conductivity {w/m-K}

1000,

!- Density {kg/m3}

1000,

!- Specific Heat {J/kg-K}

0.9,

!- Thermal Emittance


0.5,

!- Solar Absorptance

0.5;

!- Visible Absorptance ”

JEPlus yazılımında, proje sisteme tanıtılırken girilen parametrelerin numaralarına göre (P0_0,P0_2, P1_1, P1_1, vb.) çaprazlanmasıyla elde edilen senaryolar job_ID olarak tanımlanmaktadır. Tüm simülasyonlar tamamlandığında program sonuçları “output” adlı dosya içinde sunulmaktadır. Bu dosya içinde her bir senaryoya ait alt dosyalar bulunmaktadır (Şekil 4.7).



Şekil 4.7. JEPlus output dosya ve içerikleri

Dosya içinde eplustbl dosyası simülasyon sonuçlarının web portalında oluşturulduğu rapor dosyasıdır. Simülasyon rapor metni içinde yer alan “End Uses” tablosu üzerinden ısıtma ve soğuma yükleri her bir simülasyon için Çizelge 4.10’daki gibi girilerek 12960 veri simülasyon sonuçlarını kapsayan ilk veri tablosu oluşturulmuştur.

Çizelge 4.10. Microsoft Excel üzerinde hazırlanan parametre-sonuç tablo örneği

Job_ID	duvar	yönl.	pencere	plan	s.o.	Isıtma (kWh)	Soğutma (kWh)
EP_G-T_0-W_0-P0_0-P1_0-P2_0	DG1	0	1001P1	dikdörtgen	%60	7692,46	2153,26
EP_G-T_0-W_0-P0_0-P1_1-P2_0	DG1	45	1001P1	dikdörtgen	%60	7632,74	2755,8
EP_G-T_0-W_0-P0_0-P1_3-P2_0	DG1	135	1001P1	dikdörtgen	%60	6412,94	3716,27
EP_G-T_0-W_0-P0_1-P1_7-P2_1	DG2	315	1001P2	dikdörtgen	%60	9368,37	1271,18
EP_G-T_0-W_0-P0_2-P1_0-P2_1	DG3	0	1001P2	dikdörtgen	%60	9436,88	967,99
EP_G-T_0-W_0-P0_2-P1_1-P2_1	DG3	45	1001P2	dikdörtgen	%60	9398,34	1161,66
EP_G-T_0-W_0-P0_16-P1_7-P2_1	DBB2	315	1001P2	kare	%20	8168,15	815,05
EP_G-T_0-W_0-P0_17-P1_0-P2_1	DBB3	0	1001P2	kare	%20	8192,95	736,64
EP_G-T_0-W_0-P0_17-P1_1-P2_1	DBB3	45	1001P2	kare	%20	8185,89	787,88
EP_G-T_0-W_0-P0_17-P1_2-P2_0	DBB3	90	1001P1	kare	%20	7447,55	1227,61
EP_G-T_0-W_0-P0_35-P1_6-P2_0	DBIMS6	270	1001P1	kare	%20	7702,09	1412,91
EP_G-T_0-W_0-P0_35-P1_7-P2_0	DBIMS6	315	1001P1	kare	%20	7919,32	1225,89
EP_G-T_0-W_0-P0_36-P1_0-P2_0	DBIMS7	0	1001P1	kare	%20	7632,26	1024,72
EP_G-T_0-W_0-P0_55-P1_1-P2_0	DT11	45	1001P1	L Plan	%100	7457,31	3951,50
EP_G-T_0-W_0-P0_55-P1_2-P2_1	DT11	90	1001P2	L Plan	%100	10183,26	1705,45
EP_G-T_0-W_0-P0_55-P1_0-P2_1	DT11	0	1001P2	L Plan	%100	10617,06	1082,73

Daha sonraki aşama elde edilen veriler üzerinden makine öğreniminde gerekli olan girdi-çıkı verilerinin oluşturulması için gerekli ön işlemlerin yapılması sürecidir.

4.4. Tahmin Modelinde Girdi Verileri ve Ön İşleme Süreci

Çalışma için girdi verileri bir önceki adımda anlatılan simülasyon ile veri sağlama sürecini kapsamaktadır. Simülasyonla elde edilen sonuç ürünleri ve senaryo kararları ile belirlenen parametreler doğrultusunda makine öğrenimine girecek veriler Çizelge 4.11’ de tanımlanmıştır. İlk olarak, 7 adet girdi parametresi ve 2 adet çıktı parametresi belirlenmiştir. Girdi verilerini oluşturan duvar alanı dairenin toplam duvar alanını olan opak ve saydam yüzey alanının toplamını ifade etmektedir. Çizelge 4.11’ de sunulan veri örnekleme, veri setini oluşturan parametreleri ve özellikleri içermektedir. Ancak makine öğrenimi algoritmasına girdi verisi oluşturacak verilerin numerik veri olması gerekmektedir. Bu nedenle öncelikle aşağıda belirtilen parametreler sayısal verilere dönüştürülecektir:

Duvar parametresinde yer alan duvar çeşitleri U değerlerine,

Pencere parametresinde yer alan pencere çeşitleri u değerlerine,

Plan tipleri sırasıyla kare 1; L plan tipi 2; ve dikdörtgen 3 değerlerine dönüştürülmüş ve 12960 satırdan oluşturulan veri seti oluşturulmuştur.

Çizelge 4.11. Belirlenen girdi verileri

Veri Sınıflaması	Kod	Girdi parametreleri
Girdi	X1	Plan Tipi
	X2	Yönlenme
	X3	Duvar Tipi U değeri
	X4	Pencere Tipi U değeri
	X5	Duvar Alanı
	X6	Opak Yüzey Alanı
	X7	Saydam Yüzey Alanı
Çıktı	Y1	Isıtma
	Y2	Soğutma
n(ısıtma-soğutma yükü)= 12960		
<i>x= girdi parametresi; y= çıktı parametresi; n= örneklem sayısı</i>		

Tahmin algoritmalarının uygulanmasından önce veri setine uygulanacak işlemler bütünü olan ön işleme sürecinde korelasyon ilişkisi incelenen girdi verilerinden opak yüzey alanı ve

saydam yüzey alanı toplamının duvar alanını vermesi sebebiyle aralarında ilişki düzeyi yüksek çıkan parametrelerden opak yüzey alanı girdi verilerinden çıkartılmıştır. Plan tipi, yönlenme, duvar tipi u değeri, pencere tipi u değeri, duvar alanı, saydam yüzey alanı girdi verilerinden belirlenen değer aralıkları ile oluşan 12960 adet senaryodan ısıtma ve soğutma çıktı verilerine tahminleme algoritmaları uygulanmadan önce modelin karmaşıklığını gidermek ve modele katkı vermeyen veri setlerini tespit etmek amacıyla SSPS v.28.0 programı aracılığı ile aykırı değerlerin tespiti yapılmıştır. Aykırı değerlerin tespiti için yaygın olarak Cook distance, Centered Leverage Value, Mahalanobis' Distance yaklaşımları kullanılmaktadır. Bu yaklaşımlar bağımlı değişken olan ısıtma ve soğutma yükleri için ayrı ayrı test edilerek aykırı senaryolar bulunmuş ve modelden çıkarılmıştır.

Cook distance: Aykırı değerlerin belirlenmesi amacıyla Cook tarafından ortaya atılmıştır ve en küçük kareler regresyonunda bir veri noktasının modele etkisine ilişkin en yaygın kullanılan tahmin haline gelmiştir. Belirli bir gözlem verisinin veri setinden çıkarılmasının modele etkisini ölçmekte ve hem aykırı değerleri hem de yüksek kaldıraç noktalarını tanımlamaktadır. Cook distance yaklaşımında bir gözlemi aykırı değer olarak tanımlamak için aşağıdaki denklem kullanılmaktadır (Sorokina vd., 2021):

$$D_i = 4 / (n - k - 1) \quad (6)$$

D_i : Cook Distance

n : Gözlem sayısı

k : Bağımsız girdi verileri sayısı

Centered Leverage Value: İstatistiki çalışmalarda ve özellikle regresyon analizinde leverage, bir gözlemin bağımsız değişken değerlerinin diğer gözlemlerin değerlerinden ne kadar uzakta olduğunun ölçüsünü göstermektedir. Leverage değerleri 0 ile 1 arasında olup, 1'e yaklaştıkça verinin aykırı değere sahip olma olasılığı artarken, 0' a yaklaştıkça verinin aykırılığı yok olarak ifade edilmektedir. Centered Leverage Value yaklaşımında bir gözlemi aykırı değer olarak tanımlamak için aşağıdaki denklem kullanılmaktadır (Zelterman, 2015):

$$V_i = (2k+2) / n$$

(7)

V_i : Centered Leverage Value

n : Gözlem sayısı

k : Bağımsız girdi verileri sayısı

Mahalanobis' Distance: Çok değişkenli veri setleri içerisindeki aykırı değerlerin tespitinde veri tahmini için kullanılan Mahalanobis' Distance yaklaşımı veri setlerinin modelin merkezine olan uzaklıklarının ölçülmesi esasına dayanmaktadır. Cook distance, Centered Leverage Value yaklaşımlarından farklı olarak bu yaklaşımda, veri setleri ki-kare olasılık yoğunluk fonksiyonu kullanılarak olasılıklara çevrilip uzaklık değerleri hesaplanıp, bulunan uzaklık değerleri ki-kare tablosundaki değerlerle karşılaştırılmaktadır. Ki-kare tablosunda serbestlik derecesi bağımsız veri sayısını ifade ederken, anlamlılık düzeyindeki 0.001 sütünü aykırı değerler için üst değerleri vermektedir (Şekil 4.8) (Hodge and Austin, 2004; Zeltermann, 2015).

Serbestlik derecesi		Anlamlılık düzeyi													
df	0.995	0.990	0.975	0.95	0.9	0.75	0.5	0.25	0.1	0.05	0.025	0.01	0.005	0.001	
1	0.000039	0.000157	0.000982	0.00393	0.0158	0.102	0.455	1.323	2.706	3.841	5.024	6.635	7.879	10.828	
2	0.010	0.020	0.051	0.103	0.211	0.575	1.386	2.773	4.605	5.991	7.378	9.210	10.597	13.816	
3	0.072	0.115	0.216	0.352	0.584	1.213	2.366	4.108	6.251	7.815	9.348	11.345	12.838	16.266	
4	0.207	0.297	0.484	0.711	1.064	1.923	3.357	5.385	7.779	9.488	11.143	13.277	14.860	18.467	
5	0.412	0.554	0.831	1.145	1.610	2.675	4.351	6.626	9.236	11.070	12.833	15.086	16.750	20.515	
6	0.676	0.872	1.237	1.635	2.204	3.455	5.348	7.841	10.645	12.592	14.449	16.812	18.548	22.458	
7	0.989	1.239	1.690	2.167	2.833	4.255	6.346	9.037	12.017	14.067	16.013	18.475	20.278	24.322	
8	1.344	1.646	2.180	2.733	3.490	5.071	7.344	10.219	13.362	15.507	17.535	20.090	21.955	26.124	
9	1.735	2.088	2.700	3.325	4.168	5.899	8.343	11.389	14.684	16.919	19.023	21.666	23.589	27.877	
10	2.156	2.558	3.247	3.940	4.865	6.737	9.342	12.549	15.987	18.307	20.483	23.209	25.188	29.588	
11	2.603	3.053	3.816	4.575	5.578	7.584	10.341	13.701	17.275	19.675	21.920	24.725	26.757	31.264	
12	3.074	3.571	4.404	5.226	6.304	8.438	11.340	14.845	18.549	21.026	23.337	26.217	28.300	32.909	
13	3.565	4.107	5.009	5.892	7.042	9.299	12.340	15.984	19.812	22.362	24.736	27.688	29.819	34.528	
14	4.075	4.660	5.629	6.571	7.790	10.165	13.339	17.117	21.064	23.685	26.119	29.141	31.319	36.123	
15	4.601	5.229	6.262	7.261	8.547	11.037	14.339	18.245	22.307	24.996	27.488	30.578	32.801	37.697	
16	5.142	5.812	6.908	7.962	9.312	11.912	15.338	19.369	23.542	26.296	28.845	32.000	34.267	39.252	
17	5.697	6.408	7.564	8.672	10.085	12.792	16.338	20.489	24.769	27.587	30.191	33.409	35.718	40.790	
18	6.265	7.015	8.231	9.390	10.865	13.675	17.338	21.605	25.989	28.869	31.526	34.805	37.156	42.312	
19	6.844	7.633	8.907	10.117	11.651	14.562	18.338	22.718	27.204	30.144	32.852	36.191	38.582	43.820	
20	7.434	8.260	9.591	10.851	12.443	15.452	19.337	23.828	28.412	31.410	34.170	37.566	39.997	45.315	
21	8.034	8.897	10.283	11.591	13.240	16.344	20.337	24.935	29.615	32.671	35.479	38.932	41.401	46.797	
22	8.643	9.542	10.982	12.338	14.041	17.240	21.337	26.039	30.813	33.924	36.781	40.289	42.796	48.268	
23	9.260	10.196	11.689	13.091	14.848	18.137	22.337	27.141	32.007	35.172	38.076	41.638	44.181	49.728	
24	9.886	10.856	12.401	13.848	15.659	19.037	23.337	28.241	33.196	36.415	39.364	42.980	45.559	51.179	
25	10.520	11.524	13.120	14.611	16.473	19.939	24.337	29.339	34.382	37.652	40.646	44.314	46.928	52.620	
26	11.160	12.198	13.844	15.379	17.292	20.843	25.336	30.435	35.563	38.885	41.923	45.642	48.290	54.052	
27	11.808	12.879	14.573	16.151	18.114	21.749	26.336	31.528	36.741	40.113	43.195	46.963	49.645	55.476	
28	12.461	13.565	15.308	16.928	18.939	22.657	27.336	32.620	37.916	41.337	44.461	48.278	50.993	56.892	
29	13.121	14.256	16.047	17.708	19.768	23.567	28.336	33.711	39.087	42.557	45.722	49.588	52.336	58.301	
30	13.787	14.953	16.791	18.493	20.599	24.478	29.336	34.800	40.256	43.773	46.979	50.892	53.672	59.703	
40	20.707	22.164	24.433	26.509	29.051	33.660	39.335	45.616	51.805	55.758	59.342	63.691	66.766	73.402	
50	27.991	29.707	32.357	34.764	37.689	42.942	49.335	56.334	63.167	67.505	71.420	76.154	79.490	86.661	
60	35.534	37.485	40.482	43.188	46.459	52.294	59.335	66.981	74.397	79.082	83.298	88.379	91.952	99.607	
70	43.275	45.442	48.758	51.739	55.329	61.698	69.334	77.577	85.527	90.531	95.023	100.425	104.215	112.317	
80	51.172	53.540	57.153	60.391	64.278	71.145	79.334	88.130	96.578	101.879	106.629	112.329	116.321	124.839	
90	59.196	61.754	65.647	69.126	73.291	80.625	89.334	98.650	107.565	113.145	118.136	124.116	128.299	137.208	
100	67.328	70.675	74.222	77.929	82.358	90.133	99.334	109.141	118.498	124.342	129.561	135.807	140.169	149.444	

Şekil 4.8. Ki kare tablosu

Aykırı/uç değerlerin tespiti modeldeki senaryoların aşırı uç değerlerini inceleyen bir hassasiyet analizi alt çalışması olup, uç değerlerin tespiti ile aykırı gözlemler modelden

çıkarılarak modelin gücü ve anlamlılığı artırılmaktadır. Mahalanobis' Distance, Cook's Distance, Centered Leverage Value yaklaşımları için 12960 adet senaryodan SPSS 28.0.1 programından elde edilen değerler ısıtma bağımlı girdi değişkeni için Çizelge 4.12.'de verilmiştir.

Çizelge 4.12. Isıtma yükü için yaklaşımlara ait aykırılık hesabında kullanılan eşik değerler

<i>Yaklaşımlar</i>	Minimum	Maximum	Ortalama	Standart sapma	Gözlem sayısı
<i>Cook's Distance</i>	0,000	0,003	0,000	0,000	12960
<i>Centered Leverage Value</i>	0,000	0,001	0,001	0,000	12960
<i>Mahal. Distance</i>	1,537	12,589	5,999	1,773	12960

Soğutma bağımlı girdi değişkeni için uç değerlerin tespit edilmesi amacıyla elde edilen değerler Çizelge 4.13' te verilmekte olup, uç değerler için maksimum değerlerin olduğu sütuna bakılmaktadır.

Çizelge 4.13. Soğutma için yaklaşımlara ait aykırılık hesabında kullanılan eşik değerler

<i>Yaklaşımlar</i>	Minimum	Maximum	Ortalama	Standart sapma	Gözlem sayısı
<i>Cook's Distance</i>	0,000	0,006	0,000	0,000	12960
<i>Centered Leverage Value</i>	0,000	0,001	0,001	0,000	12960
<i>Mahal. Distance</i>	1,537	12,589	5,999	1,773	12960

Cook's Distance' a göre aykırı değerlerin hesabı için Eş. (1) kullanılmış olup değer 0,000309 olarak hesaplanmıştır. Centered Leverage Value için aykırı değerlerin hesabında Eş. (2) kullanılmış olup, değer 0,001235 olarak hesaplanmıştır. Eşitliklerden elden edilen sonuçlar Çizelge 4.12. ve Çizelge 4.13.' te Cook's Distance ile Centered Leverage Value için maksimum değerlerin üzerinde olması hazırlanan veri setinde aykırı gözlemlerin olduğunu göstermiştir. Bu durumda SPSS programından her gözlem için maksimum değerlerin üzerindeki değerler tespit edilerek ısıtma yükü için 4358 adet gözlem çıkarılmıştır. 12960 adet gözlemden 4358 adet modele katkı sağlamayan aykırı gözlemin çıkarılması neticesinde 8602 adet gözlem ısıtma yükü tahmin modelinin geliştirilmesi için kullanılmıştır. Soğutma yükü için ise 3343 adet gözlem eşitliklerden elde edilen değerlerin üzerindeki değeri içererek

modele katkı vermemesi sebebiyle soğutma yükü modelinden çıkarılmıştır. Son durumda soğutma yükü için 12960 adet gözlemden 3343 adet modele katkı sağlamayan aykırı gözlemin çıkarılması neticesinde 9617 adet gözlem kalmıştır.

Mahalanobis' Distance' a göre aykırı değerleri hesaplamak için dağılımın kritik değerlerini gösteren Ki-Kare tablosundan bağımsız değişken sayısına göre serbestlik derecesinde 7, anlamlılık düzeyi 0,001 olan satıra karşılık gelen 22,322 kritik değeri aykırı değeri göstermektedir. Çizelge 4.12. ve 4.13.' e göre Mahalanobis' Distance için maximum değerler 22,322 kritik değerinin altında olduğundan bu yaklaşım için aykırı gözlemler bulunmamıştır. Sonuç olarak 12960 adet senaryo içerisinde modele katkı vermeyen gözlemlerin tespit edilerek çıkarılması neticesinde ısıtma yük tahmini için 8602 adet örnekten oluşan veri seti; soğutma yük tahmini için ise 9617 adet örnekten oluşan veri seti oluşturulmuş, modelin karmaşıklığı azaltılarak gücü ve anlamlılığı artırılmıştır (Çizelge 4.14).

Çizelge 4.14. Makine öğrenimi için hazırlanan veri seti

Veri Sınıflaması	Kod	Parametreler	Veri Sınıflaması	Kod	Parametreler
Girdi Verisi	X1	Plan Tipi	Girdi Verisi	X1	Plan Tipi
	X2	Yönlenme		X2	Yönlenme
	X3	Duvar Tipi U değeri		X3	Duvar Tipi U değeri
	X4	Pencere Tipi U değeri		X4	Pencere Tipi U değeri
	X5	Duvar Alanı		X5	Duvar Alanı
	X6	Saydam Yüzey Alanı		X6	Saydam Yüzey Alanı
Çıktı Verisi	Y1	Isıtma Yükü	Çıktı Verisi	Y2	Soğutma Yükü
n(ısıtma yükü)= 8602			n(soğutma yükü)= 9617		
x= girdi parametresi; y= çıktı parametresi; n= örneklem sayısı					

4.5. Isıtma ve Soğutma Yükleri için Tahmin Modelinin Geliştirilmesi

Bu çalışmada, önceki bölümde bina verileri, makine öğrenmesi yöntemiyle tahmin modelleri geliştirmek için kullanılmıştır. İlk olarak, Türkiye’de 3. İklim bölgesindeki konut stoğu için enerji performans ihtiyacı bu çalışmadaki ana problem olarak ele alınmıştır. Bu noktada, bir konutun ısıtma ve soğutma talebine ilişkin performans tahmini amacıyla ilk olarak çeşitli senaryolar üzerinden performanslar belirlenmiştir. Sonra belirlenen


parametreler doğrultusunda girdi ve çıktı verileri oluşturulmuştur. Daha sonra ısıtma ve soğutma yükleri tahmini için sırasıyla çeşitli makine öğrenimi algoritmalarına sokulmuş ve bu algoritma sonuçları kıyaslanarak en doğru tahmini veren yöntem belirlenmiştir. Tahmin modeli geliştirme süreci bu bölümde detaylıca ele alınacaktır.

4.5.1. Yazılım programı seçimi

MATLAB yüksek performans gösteren bir programlama dilidir. Programa gösterilen tüm girdiler ve çıktılar ile diğer programların belirteçlerine gerek duymadan bir matris tanımlar. MATLAB programı üniversitelerde kullanıldığı gibi iş sahalarında mühendislik ve araştırma alanlarında karşılaşılan problemlere hızlı ve pratik çözümler sunmaktadır. Ayrıca, MATLAB programında “Toolbox-Araç kutusu” olarak nitelendirilen özellikler bulunmaktadır. Bu özellik sayesinde, kullanıcıların herhangi bir kod yazmasına gerek kalmadan hazır fonksiyon dosyaları ile veri tabanı oluşturma, dosya işleme ve derleme, dijital sinyal işleme, iletişim kurma ve işleme, Excel bağlantısı kurma, tahmin modellemeleri gibi birçok ihtiyaca cevap vermektedir (Uzunoğlu vd., 2003). Çalışmada makine öğrenimi tahmin modellerinin oluşturulup uygulanmasında MATLAB R2023a programı kullanılmıştır.


4.5.2. Soğutma yükü tahmin modeli geliştirilmesi

Çalışmanın bu bölümünde, soğutma yükü için talep tahmin modeli oluşturulmuştur. Tahmin modeli oluştururken kullanılan materyaller, belirlenen senaryolar üzerinden Design Builder ve JEPlus yazılımları aracılığıyla hazırlanan verilerdir. Verileri düzenlemek ve toplamak amacıyla Microsoft Office Excel 2016 sürümü kullanılmıştır. Veriler Excel ortamında hazırlandıktan sonra, modellerin oluşturulması ve eğitilmesi için veri tabanında bulunan girdi ve çıktı değerlerinin MATLAB’e aktarılması gerekmektedir. “Import data” sekmesi aracılığı ile programa değerlerin girişleri yapılır (Şekil 4.9).



Şekil 4.9. MATLAB import sekmesi ile verilerin aktarımı

Soğutma yükü için tüm veriler öncelikle 9617x7 boyutunda matris olarak MATLAB'e aktarılır. Daha sonra model eğitimi için giriş ve çıkış matrislerinin ayrılması gerekmektedir. Giriş matrisi 9617x6 boyutunda, çıkış matrisi ise 9617x1 boyutunda matrise atanır. Arayüzde yer alan "Regression Learner" eklentisi desteği ile tahminleme algoritmaları çalıştırılmıştır (Şekil 4.10).



Şekil 4.10. MATLAB eklentisi arayüzü

Makine öğreniminde tahmin modeli sürecinde, eğitim veri seti üzerinden model oluşturulur ve tahmin veri seti ile de oluşturulan model test edilir. MATLAB a yüklenen veriler, regression learner eklentisi üzerinden ilk olarak verilen problemlerin tahmini için bir grup algoritmaya karar vermek amacıyla, % 80 i eğitim; % 20'si de test olmak üzere ikiye bölünmüştür. Eğitim verileri de çapraz doğrulama yöntemi için rastgele olarak 5 parçaya ayrılmıştır (Şekil 4.11). Daha sonra model, performansını test etmek amacıyla her seferinde verilerin farklı bir 5'te 1'lik bölümü "gizlenerek" beş kez eğitilmiştir. Eğitim metrikleri çapraz doğrulama sırasında oluşturulmuş ve hesaplanan değerlerin ortalaması olarak sunulmuştur. Eğitimden sonra model, test verilerine uygulanmıştır. Test verileri, eğitim sırasında model tarafından görülmediğinden modelin eğitim performansını doğrulamak için uygun olmaktadır.

n (toplam veri)= 9617					
n(eğitim)= 7694					n(test)=1923
n(böl1)=1539	n(val)=308	n(eğit)=308	n(eğit)=308	n(eğit)=308	n(eğit)=307
n(böl2)=1539	n(eğit)=308	n(val)=308	n(eğit)=307	n(eğit)=308	n(eğit)=308
n(böl3)=1539	n(eğit)=308	Eğitim	n(val)=308	n(eğit)=308	n(eğit)=308
n(böl4)=1539	n(eğit)=308	n(eğit)=307	n(eğit)=308	n(val)=308	n(eğit)=308
n(böl5)=1538	n(eğit)=307	n(eğit)=308	n(eğit)=308	n(eğit)=307	n(val)=308

Performans Değerlendirme Metrikleri Ort.
 $R^2(val)$, RMSE(val), MAE(val)

Şekil 4.11. Soğutma tahmini için verilerin bölünmesi

Veriler eğitim ve test olarak ayrıldıktan sonra, nihai modelin oluşturulması için çeşitli makine öğrenimi algoritmaları uygulanmıştır. Bir önceki bölümde tariflenen makine öğrenim modellerinin, sırasıyla soğutma yükü için tahmin performans grafikleri ve karşılaştırma tablosu sunulmuştur.


Doğrusal Regresyon-DR (Linear Regression -LR)

Doğrusal regresyon modeli ile soğutma yükü için tahminleme sonuçları Çizelge 4.15'te görülmektedir. Çizelgede, uygulanan modelin performans değerlendirme metriklerine göre sonuçları yer almaktadır. Performans metriklerinde sıklıkla karşılaşılan ölçüt olan mutlak değişim yüzdesi(R^2) değerine göre eğitim veri setinde uygulanan validasyonun doğruluk oranı % 67; test veri setinde ise % 68 oranında bir doğruluk gözlemlenmiştir.

Çizelge 4.15. Doğrusal regresyon modelinin tahmin sonuçları


Model 1	Doğrusal Regresyon	Eğitim /validasyon sonuçları			Test sonuçları		
		R ²	RMSE	MAE	R ²	RMSE	MAE
		0,67	1016,1	779,76	0,68	980,12	762,24

Şekil 4.12, gerçek değerler ve tahmin değerlerinin karşılaştırmasını sunmaktadır. Görselde ifade edildiği üzere regresyon yöntemi denenen tahmin modelinde gerçek değerler ve tahmin değerlerinin farklı noktalarda olduğu görülmektedir.



Şekil 4.12. Doğrusal regresyon modelinde gerçek değer ve tahmin sonuçlarının karşılaştırılması

Şekil 4.13' te yer alan grafik olması gereken çıktı değeri ve tahmin edilen çıktı değerinin ilişkisini gösteren doğruyu sunmaktadır. Etrafa yayılan noktalar ise modelden elde edilen tahmin değerleridir. Tahmin doğruluğu yüksek olduğunda bu noktaların doğruya çok yakın şekilde üzerinde ya da etrafında yer alması beklenir. Elde edilen doğrusal regresyona dayalı model grafiğine göre hem validasyon sürecinde hem de test sürecinde elde edilen tahmin değerlerinin gerçek sonuçlara pek yaklaşamamıştır.



Şekil 4.13. DR’da en iyi tahmin çizgisi ve gerçek değerlerin yayılımı (a. Validasyon b. Test)

Karar Ağaçları-KA (Decision Tree- DT)


Uygulamanın yapıldığı ortamda karar ağaçları üç ayrı yapı olarak verilmiştir. İlk yapı üçü arasında en karmaşık olan “Fine” karar ağaçlarıdır. İkincisi “Medium” ve üçüncüsü de “Coarse” karar ağacı yapısıdır. Tahminleme aşamasında karar ağaçlarında, esnek bir model oluşturmak için, minimum yaprak boyutu basit ağaç (fine tree) için 36, orta ölçekli ağaç (medium tree) için 12, kompleks ağaç (coarse tree) için 4 olarak belirlenmiştir. Aynı zamanda tahmin modellerinin oluşturulduğu uygulamada, birkaç karar ağacının bir arada çalıştırılmasıyla elde edilen gruplandırılmış ağaçlar(ensemble trees) olarak sunulan “Bagged Trees” ve “Boosted Trees” modelleri de yer almaktadır. “Boosted Trees” için grup metodu AdaBoost, öğrenme tipi karar ağacı, öğrenen sayısı 30, öğrenme oranı 0.1, minimum yaprak boyutu 8 seçilmiştir. “Bagged Trees” için grup metodu Bag, öğrenme tipi karar ağacı, öğrenen sayısı 30 ve minimum yaprak boyutu 8 seçilmiştir. Diğer üç karar ağacı (DT) yapısına ek olarak iki geliştirilmiş karar ağacı yapılarının her biri soğutma yükünü tahmin etmek için denenmiştir. Çizelge 4.16 modellerin sonuçlarını sunmaktadır.

Çizelge 4.16. Karar ağaçları modelinin tahmin sonuçları

	Karar Ağaçları	Eğitim /validasyon sonuçları			Test sonuçları		
		R ²	RMSE	MAE	R ²	RMSE	MAE
Model 2	Coarse Tree	0,95	322,78	129,87	0,96	249,83	110,38
	Medium Tree	0,95	314,34	113,25	0,96	248,57	105,01
	Fine Tree	0,94	329,49	114,76	0,96	257,93	103,99
	Boosted Tree	0,94	369,76	177,88	0,95	314,66	169,98
	Bagged Tree	0,95	306,28	104,27	0,96	236,71	96,688


Performans metriklerine göre karar ağacı modelleri genel olarak tahmin performansında yüksek doğruluklu sonuç vermiştir. Karar ağacı alt modellerinin denendiği çalışmada, “Coarse Tree” karar ağacı validasyon sürecinde % 95 doğruluk, test sürecinde % 96 doğruluk vermiştir. “Medium Tree” karar ağacı modeli tıpkı ilk model gibi validasyon sürecinde % 95, test sürecinde % 96 doğrulukla sonuçlanmıştır. Diğer hata oranı metrikleri üzerinden kıyaslandığında ise “Medium Tree” çok az oranla ilk modelden daha iyi çalışmıştır. “Fine Tree” modeli validasyon sürecinde % 94, test sürecinde % 96 doğruluk sunmuştur. Birkaç karar ağacı modelinin bir araya gelmesiyle oluşturulan birleştirilmiş karar ağaçları modelinden “Boosted Tree” karar ağacı validasyon sürecinde % 95, test sürecinde % 96; “Bagged Tree” modeli de validasyon sürecinde % 95 ve test sürecinde ise % 96 doğruluk oranı ile tamamlanmıştır.

Denenen tüm modellerin tahmin doğruluğu yüksek çıkmıştır. En iyi sonuç veren modeller arasından, “Coarse Tree” karar ağacı modeli üzerinden şekil ve grafikler sunulmuştur. Şekil 4.14.’te gerçek değerler ve tahmin değerlerinin birbiri ile çakışma görseli sunulmaktadır.



Şekil 4.14. Karar Ağacı modelinde gerçek değer ve tahmin sonuçlarının karşılaştırılması

Gerçek değer ve tahmin değerinin ilişkisi Şekil 4.15’ te sunulmaktadır. Tahmin değerlerinin sunulduğu noktaların doğrunun üzerinde ve etrafında olması başarılı bir model olduğunu göstermektedir. Test süreci grafiğinde, validasyon sürecine göre daha az tahmin verisi etrafa yayılmıştır.



Şekil 4.15. KA’nda en iyi tahmin çizgisi ve gerçek değerlerin yayılımı (a.Validasyon b.Test)


Destek Vektör Makinesi-DVM (Support Vector Machine-SVM)

Uygulamanın yapıldığı ortamda Destek Vektör Makinesi (SVM) modeli, üç ayrı yapı üzerinden çalışılmıştır. Destek vektör makinelerinde çekirdek ölçek modu doğrusal SVM (Linear SVM), kuadratik SVM (Quadratic SVM), kübik SVM (Cubic SVM) için otomatik olarak; Kernel fonksiyonu Linear SVM’de doğrusal, Quadratic SVM’de kuadratik, Cubic SVM’de kübik olarak belirlenmiştir. SVM’de kutu kısıtlama düzeyi otomatik olarak oluşturulmuştur. Çizelge 4.17 modellerin sonuçlarını sunmaktadır.

Çizelge 4.17. Destek vektör makineleri modellerinin tahmin sonuçları


	Destek Vektör Makinesi	Eğitim /validasyon sonuçları			Test sonuçları		
		R ²	RMSE	MAE	R ²	RMSE	MAE
Model 3	Doğrusal SVM	0.64	1053.9	755.44	0.66	1003.3	734.99
	Kuadratik SVM	0.87	632.77	379.71	0.89	585.86	360.61
	Kübik SVM	0.94	429.54	240.87	0.95	379.29	232.05

Destek vektör makineleri uygulamaları incelendiğinde, “doğrusal destek vektör makinesi” modeli validasyon sürecinin % 64, test sürecinin doğruluğu % 66, “kuadratik destek vektör makinesi” validasyon sürecinin doğruluğu % 87, test sürecinin % 89 ve “kübik destek vektör makinesi” için validasyon sürecinin doğruluğu % 94, test sürecinin doğruluğu da % 95 olarak sonuçlanmıştır. En iyi performansı gösteren kübik destek vektör makinesine ait gerçek değerler ile tahmin edilen değerlerin çakışma durumu Şekil 4.16’ da sunulmuştur.



Şekil 4.16. Destek Vektör Makinesi modelinde gerçek değer ve tahmin sonuçlarının karşılaştırılması

Tahmin edilen değerler ile gerçek değerler arasındaki yayılımı gösteren grafik Şekil 4.17’de ifade edilmiştir. Validasyon ve test sürecinde tahmin değerlerinin en mükemmel tahmin doğrusunun etrafında yerleştiği görülmüştür.



Şekil 4.17. SVM’de en iyi tahmin çizgisi ve gerçek değerlerin yayılımı (a.Validasyon b.Test)

Yapay Sinir Ağları-YSA (Artificial Neural Network-ANN)


Uygulama ortamında yapay sinir ağları modeli üç alt model üzerinden çalışılmıştır. Sinir ağındaki tam bağlı katmanların boyutu ve sayısına göre esnekliği değişen bu modellerden “Narrow Neural Network”ta 1 girdi katmanı, 1 çıktı katmanı ve 1 tam bağlı katman, 10 nöron, “Medium Neural Network”ta 1 girdi katmanı, 1 çıktı katmanı 1 tam bağlı katman, 25 nöron ve “Wide Neural Network”ta 1 girdi katmanı, 1 çıktı katmanı 1 tam bağlı katman, 100 nöron ve üç modelde de iterasyon sayısı 1000 olarak sunulmuştur. Tahmin model sonuçları Çizelge 4.18’de yer almaktadır.

Çizelge 4.18. Yapay sinir ağı modellerinin tahmin sonuçları

	Yapay Sinir Ağları	Eğitim /validasyon sonuçları			Test sonuçları		
		R ²	RMSE	MAE	R ²	RMSE	MAE
Model 4	Narrow ANN	0.77	844.19	530.99	0.78	820.33	511.87
	Medium ANN	0.90	564.98	307.76	0.97	320.05	185.72
	Wide ANN	0.97	311.84	118.02	0.98	252.92	117.13


Performans metriklerinde yapay sinir ağları modellerinin nöron sayıları farklılaştığında sonuç performansının da etkin bir şekilde değiştiği görülmektedir. 10 nöronlu yapay sinir ağı modelinde validasyon süreci % 77, test sürecinin doğruluğu ise % 78 olmuş, nöron sayısı 25 e çıktığında ise doğruluk oranında ciddi bir artış gözlemlenmiştir. Medium ANN de doğruluk oranı validasyon sürecinde % 90, test sürecinde % 97’ye ulaşmıştır. Son olarak nöron sayısının 100’e çıktığı modelde validasyon süreci doğruluk oranı % 97, test sürecinin doğruluk oranı ise % 98’ le yapılan modeller arasındaki en iyi sonuç görülmüştür.

En iyi performans gösteren “Wide ANN” ile yapılan model üzerinden gerçek değerler ve tahmin değerlerinin kesişimini gösteren görsel Şekil 4.18’de verilmiştir.



Şekil 4.18. YSA modelinde gerçek değer ve tahmin sonuçlarının karşılaştırılması

Validasyon ve test süreçlerinden elde edilen tahmin sonuçlarının gerçek değerlerle olan ilişkilerinin gözlemlendiği görselde, iki süreçte de tahmin değerlerinin mükemmel tahmin doğrusu üzerinde konumlandığı görülmüştür (Şekil 4.19).



Şekil 4.19. YSA’da en iyi tahmin çizgisi ve gerçek değerlerin yayılımı (a.Validasyon b.Test)

Soğutma yükü için toplam 12 makine öğrenmesi modeli denenmiştir. Tüm modellerin performans özetlerinin yer aldığı çizelge, Çizelge 4.19 da sunulmuştur.


Çizelge 4.19. Soğutma yükü tahmin modellerinin tahmin sonuçları

Tahmin modeli	Eğitim /validasyon sonuçları				Test sonuçları			
	R ²	RMSE	MAE	MSE	R ²	RMSE	MAE	MSE
Bagged Trees KA	0.95	306	104	93805	0.96	237	97	56033
Yapay Sinir Ağı	0.97	311	118	97242	0.98	253	117	63970
Karar Ağaçları	0.94	329	115	108590	0.95	258	104	66526
Doğrusal Regresyon.	0.67	1016	780	103270	0.68	980	762	960660
Destek Vektör Mak.	0.94	429	241	184771	0.95	379	232	143880

Çizelge 4.19’ da yer alan modeller incelendiğinde, birkaç karar ağacı modelinin rastgele birleştirilmesiyle elde edilen “Bagged Trees” olarak sınıflandırılan modelin doğruluk performansı % 96; yapay sinir ağları ile elde edilen modelin doğruluk performansı % 98; tek karar ağacı modelinin tahmin doğruluk performansı % 95; destek vektör makineleri için doğruluk performansı % 95 ve doğrusal regresyon tahmin performansı ise % 67 olarak gözlemlenmiştir. Soğutma yükleri için modeller genel olarak yüksek doğrulukla sonuçlanmıştır. Tahmin ve gerçek değerler arasında regresyon ilişkisi en kuvvetli sonucu veren ve düşük hata oranı sahip olan model Yapay Sinir Ağları modelidir.


Yapay Sinir Ağı modelinin basit yapısı, uygulama kolaylığı, gömülü sistemlere entegrasyonu gibi ek nedenler soğutma yükü için nihai modelin yapay sinir ağları üzerinden türetilmesini sağlamıştır. YSA yöntemine ilişkin eğitim ve test verileri MATLAB R2023a yazılım ortamına aktarılmıştır. Yapay sinir ağı yapısında gizli katman sayılarını, bu katmanlardaki nöron sayısını, katmanların aktivasyon fonksiyonunu, α öğrenme hızı ve momentum katsayılarını belirlemek için deneme yanılma yöntemi kullanılarak çeşitli kombinasyonlar denenmiş ve en düşük hataya sahip parametreler elde edilmiştir. Model türetilirken MATLAB R2023 kullanılmıştır. “nftool” komutu ile YSA tahminleme aracı çalıştırılmıştır. “Import data” tıklanarak gözden geçirilen değerlerin girişleri yapılmıştır. YSA’nın oluşturulması ve eğitilmesi için veri tabanında bulunan girdi ve çıktı değerlerinin MATLAB’e aktarılması gerekmektedir. Tüm veriler öncelikle 9617x7 boyutunda matris olarak MATLAB’e aktarılır. Daha sonra YSA eğitimi için giriş ve çıkış matrislerinin ayrılması gerekmektedir. Giriş matrisi 9617x6 boyutunda, çıktı matrisi ise 9617x1

boyutunda matrise atanmıştır. YSA'lar sütunlar ile işlem yaptığından, bu matrislerin YSA'ya uygun olması için transpozese alınmıştır. Model oluşturulurken veriler % 15'i test % 5'i validasyon ve % 80'i eğitim olmak üzere rastgele bölünmüştür. (nveri=9617, neğitim=7693 nvalidasyon=481, ntest=1443) (Şekil 4.20).




Şekil 4.20. MATLAB' de soğutma yükü YSA model ağı yapısı

En başarılı deneyde, model, bir girdi katmanı, bir gizli katman ve bir çıktı katmanından oluşan ileri beslemeli çok katmanlı bir ağ olarak ele alınmaktadır. 6 değişkenli giriş katmanı 20 nöronlu bir gizli katman ve tek değişkenli 1 çıkış katmanından oluşmaktadır (Şekil 4.21).




Şekil 4.21. Önerilen YSA soğutma modeli

Deneyler sonucunda başarılı regresyon oranına ve düşük hata oranına sahip YSA modeli, eğitim sürecinde % 98, test sürecinde % 98 ve validasyon sürecinde % 99 tahmin doğruluğu ile sonuçlanmıştır. Soğutma yükü için karar verilen YSA modelinin eğitim ve test regresyon sonuçları ve tahmin değerlerinin grafik üzerindeki yerleşimi Şekil 4.22’de verilmektedir.



Şekil 4.22. Eğitim, validasyon ve test regresyonu

Şekil 4.23' te eğitim, doğrulama ve test sürecindeki hata oranı gösterilmektedir. Validasyon süreci, modelin eğitim verileri üzerinden yürütülen doğrulama aşamasıdır. Burada bulunan en düşük hata oranı, modelin en iyi performansın elde edilmesiyle tahmin modelinin eğitim aşamasının tamamlandığının göstergesidir. Soutma yükü tahmin modelinde en düşük hata oranı 251. yinelemede bulunmuştur.



Şekil 4.23. Soğutma yükü en iyi tahmin performans dağılımı

4.5.3. Isıtma yükü tahmin modeli geliştirilmesi

Çalışmanın bu bölümünde, ısıtma yükü için tahmin modeli oluşturulmuştur. Belirlenen senaryolar üzerinden Design Builder ve JEPlus yazılımları aracılığıyla hazırlanan veriler, tahmin modeli oluşturulurken kullanılan materyallerdir. Veriler, Microsoft Office Excel 2016 aracılığıyla düzenlenmiş ve toplanmıştır. Excel ortamında veriler hazırlandıktan sonra, modellerin oluşturulması ve eğitilmesi için veri tabanında bulunan girdi ve çıktı değerlerinin MATLAB'e "import" sekmesi ile girişleri yapılmıştır (Şekil 4.24).

IMPORTVIEW

Range: A2:G8603

Variable Names Row: 1

Output Type: Numeric Matrix

Text Options

Replaceunimportable cells withNaN

Import SelectionIMPORT


SELECTIONIMPORTED DATAUNIMPORTABLE CELLS

ısıtma_yeni_azaltılmış5_matlab.xlsx

	A	B	C	D	E	F	G
	stmayenazaltılmış5matlab						
1	X1-PlanTipi	X2-Yönlendirme...	X3-Uduvar	X4-Upenc	X5-Toplam...	X7-Saydam...	Y1-Isıtma
2	2	0	0.4380	1.3650	144	6.8200	8.7815e+03
3	2	0	0.4380	2.3100	144	6.8200	8.2219e+03
4	2	45	0.4380	1.3650	144	6.8200	8.7784e+03
5	2	45	0.4380	2.3100	144	6.8200	8.0427e+03
6	2	90	0.4380	1.3650	144	6.8200	8.6987e+03
7	2	90	0.4380	2.3100	144	6.8200	7.8355e+03
8	2	135	0.4380	1.3650	144	6.8200	8.6252e+03
9	2	135	0.4380	2.3100	144	6.8200	7.6704e+03
10	2	180	0.4380	1.3650	144	6.8200	8.5533e+03
11	2	180	0.4380	2.3100	144	6.8200	7.7711e+03
12	2	225	0.4380	1.3650	144	6.8200	8.6005e+03
13	2	225	0.4380	2.3100	144	6.8200	7.9930e+03
14	2	270	0.4380	1.3650	144	6.8200	8.6795e+03
15	2	270	0.4380	2.3100	144	6.8200	8.2114e+03
16	2	315	0.4380	1.3650	144	6.8200	8.7752e+03
17	2	315	0.4380	2.3100	144	6.8200	7.8670e+03
18	2	0	0.4380	1.3650	144	6.8200	8.4061e+03
19	2	0	0.4380	2.3100	144	6.8200	7.8446e+03
20	2	45	0.4380	1.3650	144	6.8200	8.4004e+03
21	2	45	0.4380	2.3100	144	6.8200	7.6649e+03
22	2	90	0.4380	1.3650	144	6.8200	8.3201e+03
23	2	90	0.4380	2.3100	144	6.8200	7.4547e+03
24	2	135	0.4380	1.3650	144	6.8200	8.2433e+03
25	2	135	0.4380	2.3100	144	6.8200	7.2900e+03
26	2	180	0.4380	1.3650	144	6.8200	8.1715e+03
27	2	180	0.4380	2.3100	144	6.8200	7.3889e+03
28	2	225	0.4380	1.3650	144	6.8200	8.2175e+03
29	2	225	0.4380	2.3100	144	6.8200	

Şekil 4.24. MATLAB import sekmesi ile ısıtma yükü için verilerin aktarımı

Isıtma yükü için tüm veriler öncelikle 8602x7 boyutunda matris olarak MATLAB'e aktarılır. Makine öğrenim modellerinin oluşturulabilmesi için verilerin girdi ve çıktı verileri olarak ayrılması ve matrislere atanması gerekmektedir. Girdi verisi, 8602 örneklemin 6 değişkeninin sayısal değerlerinden oluşurken çıktı verisi ise 8602 örneklemin soğutma yükü değerlerini içermektedir. Girdi verileri 8602x6 boyutunda, çıktı verisi ise 8602x1 boyutunda matrise atanmıştır. Regression Learner eklentisi desteği ile tahminleme algoritmaları çalıştırılmıştır (Şekil 4.25).



Şekil 4.25. MATLAB eklentisi arayüzü

Makine öğrenimi, eğitim ve test olmak üzere iki süreci kapsamaktadır. Modele girecek veri seti eğitim ve test olmak üzere ikiye bölünür. Eğitim sürecinde, eğitim veri seti üzerinden model oluşturulur ve test sürecinde de test veri seti ile oluşturulan model test edilir. MATLAB a yüklenen veriler, ilk olarak verilen problemlerin tahmini için bir algoritmaya karar vermek amacıyla, % 80 i eğitim; % 20'si de test olmak üzere ikiye bölünmüştür. Eğitim verileri de validasyon süreci için çapraz doğrulama yöntemiyle rastgele olarak 5 parçaya ayrılmıştır. Validasyon süreci, model performansının test edilmesi amacıyla her seferinde verilerin farklı bir 5'te 1'lik bölümünün "gizlenerek" beş kez eğitime işlemidir (Şekil 4.26).

n (toplam veri)= 8602					
n(eğitim)= 6882					n(test)=1720
n(böl1)=1376	n(val)=275	n(eğit)=275	n(eğit)=275	n(eğit)=275	n(eğit)=276
n(böl2)=1376	n(eğit)=275	n(val)=275	n(eğit)=275	n(eğit)=276	n(eğit)=275
n(böl3)=1376	n(eğit)=275	n(eğit)=275	n(val)=275	n(eğit)=275	n(eğit)=275
n(böl4)=1377	n(eğit)=275	n(eğit)=276	n(eğit)=276	n(val)=275	n(eğit)=275
n(böl5)=1377	n(eğit)=275	n(eğit)=275	n(eğit)=276	n(eğit)=276	n(val)=275

Performans Değerlendirme Metrikleri Ort.
R²(val), RMSE(val), MAE(val)

Şekil 4.26. Isıtma tahmini için verilerin bölünmesi

Eğitim sürecinden elde edilen performans metrikleri, çapraz doğrulama sırasında oluşturulan ve hesaplanan değerlerin ortalaması olarak sunulan değerlerdir. Eğiti süreci tamamlandıktan

sonra model, test verilerine uygulanmıştır. Test verileri, model tarafından daha önce hiç görülmediğinden, oluşturulan modelin eğitim performansını test etmek için uygun olmaktadır. Veriler makine öğrenim modellerine girmek için hazır hale getirildikten sonra, soğutma yükü tahmin modelinin oluşturulması için uygulanan algoritmalar, ısıtma yükü tahmin modelinin geliştirilmesi için de sırasıyla uygulanmıştır. Aşağıda, nihai ısıtma yükü tahmin modelinin geliştirilmesi için denenen modeller ve performans metrikleri sunulmuştur.


Doğrusal Regresyon-DR (Linear Regression-LR)

Doğrusal regresyon modeli ile ısıtma yükü için tahminleme sonuçları Çizelge 4.20’de görülmektedir. Performans metriklerinde sıklıkla karşılaşılan ölçüt olan mutlak değişim yüzdesi(R^2) değerine göre validasyon sürecinde tahmin doğruluğu % 57, test sürecinde ise % 56 olarak sonuçlanmıştır.

Çizelge 4.20. Doğrusal regresyon modelinin ısıtma yükü tahmin sonuçları


Model 1	Doğrusal Regresyon	Eğitim /validasyon sonuçları			Test sonuçları		
		R^2	RMSE	MAE	R^2	RMSE	MAE
		0,57	842,22	686,23	0,56	841,8	692,87

Doğrusal regresyon performans göstergeleri gerçek değerler ve tahmin değerlerinin karşılaştırmasını sunmaktadır. Şekil 4.27’de tahmin değerleri ile gerçek değerlerin birbiri ile çakışma durumunu sunmaktadır ancak tahmin modelinden elde edilen sonuç değerleri gerçek değerlerle örtüşmemektedir.



Şekil 4.27. DR modelinde gerçek değer ve tahmin sonuçlarının karşılaştırılması

Gerçek değer ve tahmin değeri ile ilişkiyi ifade eden grafikte yer alan mükemmel tahmin doğrusunun etrafında, her iki süreçte de tahmin değerleri oldukça yayılmıştır. Grafiklerdeki yoğunluk farkı iki süreç arasındaki örneklem sayısından kaynaklanmaktadır (Şekil 4.28).



Şekil 4.28. DR’da en iyi tahmin çizgisi ve gerçek değerlerin yayılımı (a. Validasyon b. Test)

Karar Ağaçları-KA (Decision Tree-DT)


Uygulamanın yapıldığı ortamda karar ağaçları “Fine”, “Medium” ve “Coarse” karar ağaçları olmak üzere üç ayrı yapı olarak verilmiştir. Tahminleme aşamasında karar ağaçları (decision trees)nda, esnek bir model oluşturmak için azaltılan yaprak boyutu, minimum yaprak boyutu, kompleks karar ağacı modeli olan “Coarse Tree” için 4, orta ölçekli karar ağacı modeli olan “Medium Tree” için 12 ve basit karar ağacı modeli olan “Fine Tree” için 36 olarak belirlenmiştir. “Bagged Trees” and “Boosted Trees” olarak adlandırılan grupplandırılmış karar ağaçları modelleri de uygulama ortamında yer almaktadır. Bagged Trees için grup metodu Bag, öğrenme tipi karar ağacı, öğrenen sayısı 30 ve minimum yaprak boyutu 8 seçilmiştir. Boosted Trees için grup metodu AdaBoost, öğrenme tipi karar ağacı, öğrenen sayısı 30, öğrenme oranı 0.1, minimum yaprak boyutu 8 seçilmiştir. Yukarıda bahsedilen beş karar ağacı modelinin her biri ısıtma yükünü tahmin etmek için denenmiştir. Çizelge 4.21, tüm modellerin performans metrikleri üzerinden sonuçlarını sunmaktadır.

Çizelge 4.21. Karar ağaçları modelinin ısıtma yükü tahmin sonuçları

	Karar Ağaçları	Eğitim /validasyon sonuçları			Test sonuçları		
		R ²	RMSE	MAE	R ²	RMSE	MAE
Model 2	Coarse Tree	0,82	552,96	421,28	0,81	545,04	416,35
	Medium Tree	0,84	515,37	383,18	0,83	516,26	379,42
	Fine Tree	0,84	514,57	367,36	0,83	519,02	362,47
	Boosted Tree	0,75	650,45	497,79	0,73	656,44	503,43
	Bagged Tree	0,87	471,52	344,33	0,86	481,7	348,12


Isıtma yükü tahmini için uygulanan karar ağaçları modellerinin performans metriklerine göre “Coarse tree” karar ağacı validasyon sonucunda % 82, test sürecis onucunda % 81 doğruluk, “Medium Tree” karar ağacı validasyon sürecinde % 84, test sonucunda % 83, “Fine Tree” karar ağacı validasyon süreci sonunda % 84, test süreci sonunda % 83 doğruluk vermiştir. Birleştirilmiş karar ağaçları modellerinden “Boosted Tree” karar ağacı validasyon süreci sonunda % 75, test süreci sonunda % 73, “Bagged Tree” karar ağacı modeli validasyon sonunda % 87, test sonucunda ise % 86 doğruluk oranı vermiştir (Çizelge 4.21).

Isıtma yükü tahmini için uygulanan beş karar ağaçları modellerinden en yüksek doğruluk “Bagged Tree” modeli ile elde edilmiştir. Şekil 4.29’da gerçek ve tahmin değerlerinin karşılaştırılmalı sonucu ifade edilmiştir.



Şekil 4.29. Karar Ağacı modelinde gerçek değer ve tahmin sonuçlarının karşılaştırılması

Modelin validasyon ve test sürecinde elde edilen tahmin değerlerinin en iyi tahmin doğrusu etrafında yayılımları Şekil 4.30’ da görülmektedir. Grafîğe göre, tahmin değerleri doğrudan uzak alanlara da yayılım göstermiştir.



Şekil 4.30. KA’nda en iyi tahmin çizgisi ve gerçek değerlerin yayılımı (a.Validasyon b.Test)


Destek Vektör Makinesi-DVM (Support Vector Machine-SVM)

Destek Vektör Makinesi(SVM) modeli, doğrusal SVM (Linear SVM), kuadratik SVM (Quadratic SVM) ve kübik SVM (Cubic SVM) olarak üç ayrı yapı üzerinden çalışılmıştır. Modellerde çekirdek ölçek modu doğrusal SVM (Linear SVM), kuadratik SVM (Quadratic SVM), kübik SVM (Cubic SVM) için otomatik olarak; Kernel fonksiyonu Linear SVM’de doğrusal, Quadratic SVM’de kuadratik, Cubic SVM’de kübik olarak belirlenmiştir. SVM’de kutu kısıtlama düzeyi otomatik olarak oluşturulmuştur. Çizelge 4.22 üç SVM modelinin sonuçlarını sunmaktadır.

Çizelge 4.22. Destek vektör makineleri modellerinin tahmin sonuçları


	Destek Vektör Makinesi	Eğitim /validasyon sonuçları			Test sonuçları		
		R ²	RMSE	MAE	R ²	RMSE	MAE
Model 3	Doğrusal SVM	0,57	844,8	685,18	0,56	841,77	689,82
	Kuadratik SVM	0,74	661,22	502,8	0,73	662,83	504,15
	Kübik SVM	0,77	624,66	453,62	0,76	626,36	456,29

Isıtma yükü tahmini için denenen SVM uygulamalarından doğrusal SVM modeli validasyon sonucunda % 57, test sonucunda % 56 doğruluk, kuadratik SVM validasyon sürecinde % 74 doğruluk, test sonucunda % 76 doğruluk, kübik SVM modeli validasyon sonucunda % 77 doğruluk, test sonucunda ise % 76 doğruluk oranı ile sonuçlandırılmıştır. Aralarında en iyi performansı gösteren kübik SVM modeline ait tahmin ve gerçek değerlere ilişkin grafik, tahmin değerlerinin gerçek değerlerle örtüşmediğini göstermektedir (Şekil 4.31).



Şekil 4.31. SVM ısıtma tahmin modelinde gerçek değer ve tahmin sonuçlarının karşılaştırılması

Validasyon ve test süreci sonundaki tahmin değerlerinin mükemmel tahmin sonuçlarının oluşturduğu doğru etrafında oldukça yayıldığı görülmüştür (Şekil 4.32).



Şekil 4.32. SVM’de en iyi tahmin çizgisi ve gerçek değerlerin yayılımı (a.Validasyon b.Test)


Yapay Sinir Ağları-YSA (Artificial Neural Network-ANN)

Uygulama ortamında iyi tahmin doğruluğuna sahip yapay sinir ağları modeli üç alt model üzerinden çalışılmıştır. Sinir ağındaki tam bağlı katmanların boyutu ve sayısına göre esnekliği değişen bu modellerden Narrow Neural Network’ ta 1 girdi katmanı,1 çıktı katmanı ve 1 tam bağlı katman, 10 nöron, Medium Neural Network’ ta 1 girdi katmanı,1 çıktı katmanı 1 tam bağlı katman, 25 nöron ve Wide Neural Network’ ta 1 girdi katmanı,1 çıktı katmanı 1 tam bağlı katman, 100 nöron ve üç modelde de iterasyon sayısı 1000 olarak sunulmuştur. Tahmin model sonuçları Çizelge 4.23.’de yer almaktadır.

Çizelge 4.3. Yapay sinir ağı modellerinin tahmin sonuçları


	Yapay Sinir Ağları	Eğitim /validasyon sonuçları			Test sonuçları		
		R ²	RMSE	MAE	R ²	RMSE	MAE
Model 4	Narrow ANN	0,76	636	485,26	0,75	633,65	486,99
	Medium ANN	0,77	625,54	474,28	0,76	623,58	475,37
	Wide ANN	0,88	475,98	340,38	242	0,86	480,75

Performans metriklerine göre “Narrow ANN modelinin validasyon doğruluğu %76, test doğruluğu % 75, Medium ANN için validasyon doğruluğu % 77, test doğruluğu %76 ve son olarak “wide ANN modelinin validasyon sonucu %88 ve test tahmin doğruluğu % 86 olarak elde edilmiştir. ANN modelleri arasında en iyi tahmin sonucu gözle görülür farkla wide ANN modelidir. Bu modelin tahmin değerleri ve gerçek değerler ilişkisi Şekil 4.33’te sunulmuştur.



Şekil 4.33. Yapay sinir ağları modelinde gerçek değer ve tahmin sonuçlarının karşılaştırılması

Modelde üretilen tahmin değerleri gerçek değerlerin sunulduğu mükemmel tahmin doğrusu etrafında yayılmaktadır. Yine de, özellikle test sürecinde değerlerin farklı bölgelere kaydığı da gözlemlenmiştir (Şekil 4.34).




Şekil 4.34. YSA'da en iyi tahmin çizgisi ve gerçek değerlerin yayılımı (a.Validasyon b.Test)

Isıtma yükü için toplamda 12 makine öğrenmesi modeli denenmiştir. Tüm modellerin performans özetlerinin yer aldığı çizelge, Çizelge 4.24'te sunulmuştur.

Çizelge 4.24. Soğutma yükü tahmin modellerinin tahmin sonuçları


Tahmin modeli	Eğitim /validasyon sonuçları				Test sonuçları			
	R ²	RMSE	MAE	MSE	R ²	RMSE	MAE	MSE
Bagged Tree	0,87	471,52	344,33	222	0,86	481,7	348,12	232
Fine Tree	0,84	514,57	367,36	264	0,83	519,02	362,47	269
Wide ANN	0,88	475,98	340,38	242	0,86	480,75	350,33	248
Kübik SVM	0,74	661,22	502,8	364	0,73	662,83	504,15	389
Doğrusal Regresyon	0,57	842,22	686,23	709	0,56	841,8	692,87	708

Elde edilen modellerin tahmin doğruluklarının performansları incelendiğinde Karar ağaçları-“Random forest” model doğruluğu % 86; karar ağacı model doğruluğu % 83; Yapay sinir ağı modeli doğruluğu % 86, destek vektör makinesi modeli tahmin doğruluğu % 73 ve doğrusal regresyon model tahmin doğruluğu % 57 ile sonuçlandığı görülmüştür. En yüksek sonuçları çoklu karar ağacı modelleri ve yapay sinir ağıları modelleri sunmuştur. Daha farklı deneylerle daha yüksek performans elde edilebilir düşüncesi ile karar ağaçları ve yapay sinir ağıları modelleri üzerinden alternatif deneyler yapılarak modeller türetilmiş ve nihai tahmin modeli, soğutmayükü tahmini gibi yapay sinir ağıları algoritması üzerinden çalışılmıştır. Model seçilirken tahmin performansının yanı sıra modelin eğitim süresi ve tahmin hızı da etkili olmuştur. YSA yöntemine ilişkin eğitim ve test verileri MATLAB R2023a yazılım ortamına aktarılmıştır. Model türetilirken MATLAB R2023 kullanılmıştır. “nftool” komutu ile YSA tahminleme aracı çalıştırılmıştır. “Import data” tıklanarak gözden geçirilen değerlerin girişleri yapılmıştır. YSA’nın oluşturulması ve eğitilmesi için veri tabanında bulunan girdi ve çıktı değerlerinin MATLAB’e aktarılması gerekmektedir. Tüm veriler öncelikle 8602x7 boyutunda matris olarak MATLAB’e aktarılmıştır. Daha sonra YSA eğitimi için giriş ve çıkış matrisleri ayrılmıştır. Giriş matrisi 8602x6 boyutunda, çıktı matrisi ise 8602x1 boyutunda matrise atanmıştır. YSA’lar sütunlar ile işlem yaptığından, bu matrislerin YSA’ya uygun olması için transpozesi alınmıştır. Model oluşturulurken veriler % 15 si test % 5 i validasyon ve % 80 i eğitim olmak üzere rastgele bölünmüştür. ($n_{veri}=8602$, $n_{eğitim}=6452$ $n_{validasyon}=430$, $n_{test}=1720$) (Şekil 4.32).



Şekil 4.35. MATLAB ısıtma yükü YSA modeli


Isıtma yükü tahmini için oluşturulan nihai model, 6 değişkenli 1 girdi katmanı; 20 nöronlu bir gizli katman ve tek değişkenli 1 çıktı katmanından oluşan ileri beslemeli çok katmanlı bir ağ yapısına sahiptir (Şekil 4.36).



Şekil 4.36. Önerilen yapay sinir ağı ısıtma yükü tahmin modeli


Deneyler sonucunda başarılı regresyon oranına ve düşük hata oranına sahip YSA modelinin, eğitim sürecinin doğruluk oranı % 90, test sürecinin doğruluğu % 92 ve validasyon sonucu

% 91 olarak sonuçlanmıştır. Soğutma yükü için karar verilen YSA modelinin eğitim ve test regresyon sonuçları ve hata oranı Şekil 4.37’de verilmektedir.



Şekil 4.37. Isıtma yükü YSA modeli eğitim, validasyon ve test regresyonu

En düşük hata oranı 41. yinelemede bulunmuştur. Şekil 4.38’de eğitim, doğrulama ve test hata oranı gösterilmektedir. Tahmin edilen değerler gerçek değerlere yakın olup, hata değerleri de kabul edilebilir düzeydedir.



Şekil 4.38. Isıtma yükü en iyi tahmin performans dağılımı

4.6. Nihai Tahmin Modelinin Sınanması ve Değerlendirme

Bu bölümde, makine öğrenimi ile ısıtma ve soğutma yükleri için enerji talep tahmini yapan nihai modeller üzerinden yeni girdi verileri ile 40 adet örneklem/senaryo üzerinden tahminleme çalışılmıştır. Girdi verileri, hazırlanan senaryolar üzerinden Design Builder v6+ JEPlus v2.1.0. yazılımları aracılığıyla üretilen verilerdir. Veriler, Microsoft Office Excel 2016 sürümünden yararlanılarak düzenlenmiş ve tahminleme için kullanılan MATLAB yazılım programına hazır hale getirilmiştir.

Sınama senaryoları için, kare, dikdörtgen ve L plan tiplerinden oluşan kuzey yönünü sıfır derece olarak almak üzere 0-315 dereceye kadar 45 derece de bir değişen çeşitli yönlenme açılarına sahip, farklı duvar katmanlarından oluşan farklı duvar değerleri, farklı pencere değerlerinden ve farklı opak-saydam yüzey boyutlarıyla oluşan saydamlık oranlarına sahip daire tipleri senaryoları oluşturulmuş ve modellenmiştir. Saydam yüzeyler, ısı kontrollü low-e çift camlı pencere(P1), reflekte çift camlı pencere(P2) ve ısı+güneş kontrollü solar çift

camlı pencere(P3) olmak üzere üç çeşittir. Opak yüzeyler 4.2.1. başlıkta detaylandırıldığı üzere gaz beton, delikli tuğla, normal agregalı beton ve bims olmak üzere 4 ana duvar malzemesinden ve alçı esaslı dış kaplama paneli, çimento esaslı kaplama paneli, doğal taş kaplama paneli, ahşap esaslı kaplama paneli olmak üzere 4 dış kaplama malzemesi ile taş yünü, XPS ve EPS olmak üzere 3 yalıtım malzemesi kullanılarak oluşturulmuş duvar yüzeylerinden oluşan duvar tiplerinin arasından seçilmiştir. Senaryolara dair veriler Çizelge 4.25'te işlenmiştir.

Çizelge 4.25. Nihai modellerin sınanması için belirlenen senaryolar

Senaryo	Plan Tipi	Yönlenme	Duvar Tipi	Pencere Tipi	Saydamlık Oranı
1.	L Plan	KB	DBB8	P1	100
2.	L Plan	KB	DT6	P1	20
3.	Dikdörtgen	KB	DT6	P1	20
4.	L Plan	Kuzey	DT6	P1	20
5.	L Plan	Kuzey	DBIMS2	P1	60
6.	Dikdörtgen	Kuzey	DT6	P1	20
7.	L Plan	Batı	DT6	P1	20
8.	L Plan	Kuzeydoğu	DT6	P1	20
9.	Kare	Kuzeybatı	DT6	P1	20
10.	L plan	Kuzeybatı	DT6	P2	100
11.	Dikdörtgen	Batı	DT6	P1	20
12.	L plan	Güneybatı	DT11	P2	60
13.	Dikdörtgen	Kuzeydoğu	DT6	P1	20
14.	L plan	Doğu	DT6	P1	20
15.	L plan	Doğu	DB11	P2	60
16.	L plan	Kuzey	DT6	P2	60
17.	Kare	Kuzey	DT6	P1	20
18.	L plan	Batı	DT2 -9	P1	60
19.	Dikdörtgen	Kuzeybatı	DT6	P2	60
20.	L plan	Güneybatı	DT6	P1	20
21.	L plan	Batı	DBB12	P1	100
22.	L plan	Kuzeybatı	DT6	P2	20
23.	Dikdörtgen	Doğu	DT6	P1	20
24.	Kare	Batı	DT6	P1	20
25.	L Plan	Kuzeybatı	DG7	P2	100
26.	L Plan	Kuzeybatı	DG8	P2	100
27.	Dikdörtgen	Batı	DBB1	P3	20
28.	Dikdörtgen	Güneybatı	DG12	P3	100
29.	Dikdörtgen	Güneybatı	DG4	P3	100
30.	Dikdörtgen	Güneybatı	DBB6	P3	100
31.	Dikdörtgen	Güneydoğu	DBB13	P3	100
32.	Dikdörtgen	Güneydoğu	DG3	P3	100
33.	Dikdörtgen	Güneydoğu	DBIMS2	P3	100
34.	Dikdörtgen	Güneydoğu	DBIMS3	P3	100
35.	Dikdörtgen	Güneydoğu	DG11	P3	100
36.	Dikdörtgen	Güneybatı	DBIMS14	P3	60
37.	Dikdörtgen	Kuzeydoğu	DT6	P3	60
38.	Kare	Kuzey	DT7	P2	60
39.	Kare	Güneybatı	DBB1	P2	100
40.	Dikdörtgen	Güney	DT10	P2	20

Hazırlanan senaryolara göre yıllık ısıtma soğutma yükleri simülasyon programı aracılığı ile elde edilmiştir. Elde edilen sonuçlar sınama sürecinde gerçek değer olarak kabul edilmiştir (Çizelge 4.26.).

Çizelge 4.26. Design Builder ile elde edilen çıktı verileri

Senaryo	Isıtma Yüğü(kWh)	Soğutma Yüğü(kWh)
1.	7232,74	4702,99
2.	13305,44	1420,22
3.	12388,27	1431,5
4.	13314,55	1147,63
5.	2159,35	2278,18
6.	12384,36	1137,47
7.	13048,2	1618,19
8.	13336,05	1287,52
9.	12259,26	1277,19
10.	13966,55	1759,08
11.	12145,43	1675,14
12.	3861,29	1418,53
13.	12419,34	1322,51
14.	13136,76	1422,28
15.	3355,41	1392,92
16.	14005,33	1321,33
17.	12268,47	1098,64
18.	2044,7	6499,73
19.	13073,53	1798,22
20.	12793,5	1584,72
21.	2227,85	7153,35
22.	13982,77	1061,34
23.	12221,77	1472,65
24.	12041,88	1398,17
25.	11112,86	1692,43
26.	11138,57	1677,4
27.	10843,29	1581,65
28.	4848,32	7877,37
29.	4852,17	7864,64
30.	4880,76	7939,41
31.	5037,29	6895,93
32.	4965,74	7010,89
33.	5073,42	6965,22
34.	5078,34	6950,62
35.	5609,73	6741,92
36.	5108,29	4812,78
37.	11362,82	2566,61
38.	11278,14	972,54
39.	11094,4	1798,02
40.	11484,94	864,81

Gerçek kabul edilen veriler hazırlandıktan sonraki aşama verilerin Microsoft Office Excel aracılığıyla düzenlenerek sınanması için MATLAB a atılmasıdır. Isıtma ve soğutma yüklerinin tahmin modeli aracılığı ile belirlenebilmesi için girdi parametrelerine ait değerlerin bilinmesi gerekmektedir. Girdi verilerini oluşturan parametreler, tahmin modeli oluşturulurken belirlenen verilerdir. Modelin girdi parametreleri plan tipi, yönlenme, duvar tipi u değeri, pencere tipi u değeri, duvar alanı ve saydam yüzey alanı olmak üzere altı parametreden oluşmaktadır. Çıktı verisi ise soğutma yükü tahmin modelinde soğutma yükünden; ısıtma modeli tahmin modelinde ise ısıtma yükünden oluşmaktadır (Çizelge 4.27).

Çizelge 4.27. Girdi ve çıktı verilerini oluşturan parametreler

Girdi Verileri						Çıktı Verileri	
X1	X2	X3	X4	X5	X6	Y1	Y2
Plan tipi	Yönlenme	U_{duvar}	U_{pencere}	Toplam duvar alanı	Saydam yüzey alanı	Isıtma yükü	Soğutma yükü

Tahmin modeli oluşturulurken model hem girdi hem de çıktı verilerinden oluşan veri seti ile eğitilmiş ve test edilmişti. Bu aşamada yapılacak sınama sürecinde ise modele sadece girdi verileri sunularak oluşturulan nihai modellerin çıktı değerlerini tahmin etmesi beklenmiştir. Tahmin edilen değerler, simülasyon programı aracılığı ile elde edilen ve gerçek değer olarak kabul edilen sonuçlarla karşılaştırılmış ve YSA algoritması ile elde edilen nihai tahmin modelleri değerlendirilmiştir. Bu doğrultuda oluşturulan sınama senaryolarına ait parametrelerden oluşan girdi verileri Çizelge 4.28’de sunulmuştur.

Çizelge 4.28. Sınama modeli için hazırlanan girdi verileri

Senaryo	X1	X2	X3	X4	X5	X6
1.	3	315	0,479	1,365	168	44,36
2.	3	315	0,445	1,365	168	9,03
3.	1	315	0,445	1,365	150	9,22
4.	3	0	0,445	1,365	168	9,03
5.	3	0	0,398	1,365	168	27,1
6.	1	0	0,445	1,365	150	9,22
7.	3	270	0,445	1,365	168	9,03
8.	3	45	0,445	1,365	168	9,03
9.	2	315	0,445	1,365	144	6,82
10.	3	315	0,445	2,31	168	44,36
11.	1	270	0,445	1,365	150	9,22
12.	3	225	0,462	2,31	168	27,1
13.	1	45	0,445	1,365	150	9,22
14.	3	90	0,445	1,365	168	9,03
15.	3	90	0,433	2,31	168	27,1
16.	3	0	0,445	2,31	168	44,36
17.	2	0	0,445	1,365	144	6,82
18.	3	270	0,431	1,365	168	44,36
19.	1	315	0,445	2,31	150	45,02
20.	3	225	0,445	1,365	168	9,03
21.	3	270	0,442	1,365	168	44,36
22.	3	315	0,445	2,31	168	9,03
23.	1	90	0,445	1,365	150	9,22
24.	2	270	0,445	1,365	144	6,82
25.	3	315	0,470	2,31	168	44,36
26.	3	315	0,472	2,31	168	44,36
27.	1	270	0,451	2,101	150	9,22
28.	1	225	0,421	2,101	150	45,02
29.	1	225	0,422	2,101	150	45,02
30.	1	225	0,433	2,101	150	45,02
31.	1	135	0,444	2,101	150	45,02
32.	1	135	0,439	2,101	150	45,02
33.	1	135	0,398	2,101	150	45,02
34.	1	135	0,399	2,101	150	45,02
35.	1	135	0,465	2,101	150	45,02
36.	1	225	0,391	2,101	150	27,67
37.	1	45	0,445	2,101	150	27,67
38.	2	0	0,434	2,31	144	20,47
39.	2	225	0,451	2,31	144	33,37
40.	1	180	0,451	2,31	150	9,22

4.6.1. Soğutma yükü YSA modelinin sınanması

Soğutma yükü için elde edilen nihai model 6 girdi verisi, 20 nöronlu 1 gizli katman ve 1 çıktı verisinden oluşan bir YSA algoritmasıdır. Çizelge 4.23'te hazırlanan girdi verileri Microsoft Excel'de düzenlendikten sonra MATLAB R2023a/R2018b yazılımına "import" sekmesi yardımıyla aktarılmıştır (Şekil 4.39).

	A	B	C	D	E	F
	yenitahmin					
1	X1-PlanTipi	X2-Yönlendirme	X3-Uduvar	X4-Upenc	X5-Toplama	X6-Saydam
2	3	315	0.4790	1.3650	168	44.3600
3	3	315	0.4450	1.3650	168	9.0300
4	1	315	0.4450	1.3650	150	9.2200
5	3	0	0.4450	1.3650	168	9.0300
6	3	0	0.3980	1.3650	168	27.1000
7	1	0	0.4450	1.3650	150	9.2200
8	3	270	0.4450	1.3650	168	9.0300
9	3	45	0.4450	1.3650	168	9.0300
10	2	315	0.4450	1.3650	144	6.8200
11	3	315	0.4450	2.3100	168	44.3600
12	1	270	0.4450	1.3650	150	9.2200
13	3	225	0.4620	2.3100	168	27.1000
14	1	45	0.4450	1.3650	150	9.2200
15	3	90	0.4450	1.3650	168	9.0300
16	3	90	0.4330	2.3100	168	27.1000
17	3	0	0.4450	2.3100	168	44.3600
18	2	0	0.4450	1.3650	144	6.8200
19	3	270	0.4310	1.3650	168	44.3600
20	1	315	0.4450	2.3100	150	45.0200
21	3	225	0.4450	1.3650	168	9.0300
22	3	270	0.4420	1.3650	168	44.3600
23	3	315	0.4450	2.3100	168	9.0300
24	1	90	0.4450	1.3650	150	9.2200
25	2	270	0.4450	1.3650	144	6.8200
26	3	315	0.4700	2.3100	168	44.3600
27	3	315	0.4720	2.3100	168	44.3600
28	1	270	0.4510	2.1010	150	9.2200
29	1	225	0.4210	2.1010	150	45.0200

Şekil 4.39. Sınama verilerinin MATLAB a aktarılması


Matlaba veriler aktarıldıktan sonra, YSA algoritmaları sütunlar ile işlem yaptığından, bu giriş matrislerinin YSA'ya uygun olması için transpozu alınmıştır. Daha sonra, Eş. (8) de belirtilen fonksiyon uygulanarak sınama verisine ait soğutma yükü tahmin edilmiştir.

$$y = \text{sim}(\text{net}, \text{simple}) \quad (8)$$

net: Geliştirilen model

simple: Girdi verileri dosyası

Fonksiyon denkleminde “net” YSA soğutma modelini; “simple” ise girdi verilerinin olduğu dosyayı ifade etmektedir (Şekil 4.40).




Şekil 4.40. Fonksiyonun MATLAB üzerinde uygulanması

Fonksiyon çalıştırıldıktan sonra sıralanan değerler, YSA modelinin sınaama senaryolarının soğutma yükünü tahmin ettiği değerlerdir. Değerlerin gerçek ve tahmin değerleri Çizelge 4.29.’ da verilmiştir.

Çizelge 4.29. Soğutma yüküne ilişkin tahmin sonuçları ve gerçek değerler

Senaryo	Gerçek veriler(kWh)	Tahmin Verileri(kWh)
1.	4702,99	4921,59
2.	1420,22	1274,63
3.	1431,5	1327,33
4.	1147,63	1208,29
5.	2278,18	2168,82
6.	1137,47	1110,06
7.	1618,19	1546,64
8.	1287,52	913,79
9.	1277,19	1021,89
10.	1759,08	1605,53
11.	1675,14	1641,91
12.	1418,53	1579,78
13.	1322,51	1226,53
14.	1422,28	1421,44
15.	1392,92	1385,68
16.	1321,33	1169,74
17.	1098,64	978,75
18.	6499,73	6946,24
19.	1798,22	1570,60
20.	1584,72	1419,78
21.	7153,35	6881,09
22.	1061,34	848,26
23.	1472,65	1550,45
24.	1398,17	1439,57
25.	1692,43	1666,41
26.	1677,4	1685,03
27.	1581,65	1559,28
28.	7877,37	7605,10
29.	7864,64	7591,53
30.	7939,41	7447,97
31.	6895,93	6304,28
32.	7010,89	6316,84
33.	6965,22	6720,13
34.	6950,62	6712,50
35.	6741,92	6332,69
36.	4812,78	4599,66
37.	2566,61	2819,74
38.	972,54	880,11
39.	1798,02	1801,62
40.	864,81	811,29

Soğutma modelinin ilişki grafiği incelendiğinde tahmin edilen değerlerin gerçek değerlerle neredeyse birebir örtüştüğü görülmektedir. YSA modeli oluşturulurken sürecin bir parçası olan test aşamasında elde edilen doğruluk oranı ($R= 0,98$) ile modelin daha önce hiç görmediği veriler üzerinden yeniden sınanması sonucu elde edilen grafikte aynı sonucu vermektedir (Şekil 4.41).



Şekil 4.41. Soğutma yükü tahmin değeri ve gerçek değerin karşılaştırılması

4.6.2. Isıtma yükü YSA modelinin sınanması


Isıtma yükünün tahmini için geliştirilen model YSA algoritmasına sahip bir modeldir. Nihai model 6 girdi parametresinden oluşan 1 girdi katmanı, 15 nöronlu 1 gizli katman ve 1 çıktı katmanından oluşmaktadır. Bu YSA modeli üzerinden, Çizelge 4.23.'te hazırlanan girdi verileri ile bir yük tahmini yapılmıştır. Isıtma modeli tahmini için yazılıma aktarılan veriler kullanılmıştır (Şekil 4.36). Transpozu alınmış sınama verileri daha önceki bölümlerde geliştirilen YSA ısıtma yükü tahmin modeli üzerinden Eş. (8) da belirtilen fonksiyon aracılığıyla çalıştırılmıştır. Nihai YSA modeli üzerinden alınan soğutma yüküne ait tahmin ve gerçek değerler Çizelge 4. 30'da verilmiştir.

Çizelge 4.30. Isıtma yüküne ilişkin tahmin sonuçları ve gerçek değerler

Senaryo	Gerçek veriler(kWh)	Tahmin Verileri(kWh)
1.	7232,74	7368,60
2.	13305,44	7880,41
3.	12388,27	7551,41
4.	13314,55	7875,03
5.	2159,35	6940,73
6.	12384,36	7534,46
7.	13048,2	7581,48
8.	13336,05	7958,93
9.	12259,26	7659,42
10.	13966,55	10019,06
11.	12145,43	7199,60
12.	3861,29	9053,32
13.	12419,34	7553,85
14.	13136,76	7750,59
15.	3355,41	10134,72
16.	14005,33	10218,99
17.	12268,47	7546,27
18.	2044,7	7138,87
19.	13073,53	9742,11
20.	12793,5	7416,81
21.	2227,85	6458,16
22.	13982,77	8793,65
23.	12221,77	7349,80
24.	12041,88	7378,88
25.	11112,86	10273,35
26.	11138,57	10291,09
27.	10843,29	7533,43
28.	4848,32	5885,50
29.	4852,17	5915,85
30.	4880,76	6826,81
31.	5037,29	6221,25
32.	4965,74	6239,48
33.	5073,42	5671,40
34.	5078,34	5681,32
35.	5609,73	6487,18
36.	5108,29	5738,03
37.	11362,82	7462,75
38.	11278,14	9426,38
39.	11094,4	8662,97
40.	11484,94	8352,81

Değerlerin birbiri ile tutarlılık seviyeleri Şekil 4.41’de görülmektedir. Isıtma modeli için oluşturulan farklı mimariye sahip YSA modelinde test verilerinin doğruluğu ($R = \% 92$),

modelin doğruluğu ($R=0,90$) olarak sonuçlandırılmıştır. Sınama verileri ile elde edilen sonuç, modelin daha önce görmediği veriler üzerinde etkisinin model sonucunda çıkan oranla kesiştiğini göstermektedir.



Şekil 4.41. Isıtma yükü tahmin değeri ve gerçek değer karşılaştırılması

Aynı girdi parametreleri üzerinden yürütülen ısıtma ve soğutma yükleri tahminleme çalışmasında ısıtma yükünün tahmin doğruluğu % 90 seviyelerinde sonuçlanmışken, soğutma yükünün tahmin sonuç doğruluğu ise % 98 seviyelerindedir. Bu farklılık, veri ön işleme sürecinde gerçekleştirilen uygulamalar sonucu her iki yükün tahmin modelleri için farklı sayıda örneklem ($n_{\text{soğutma}}=9617$; $n_{\text{ısıtma}}=8602$) üzerinde çalışması nedeniyle olabilir.

5. SONUÇ VE ÖNERİLER

Binalarda enerji tüketimini ve bina enerji performansını etkileyen ana faktörler; ısıtma, soğutma, sıcak su, aydınlatma ve havalandırma sistemleridir. Bu parametrelerin bina enerji performansını ne oranda etkilediği iklime, binanın fiziksel özelliklerine ve kullanıcı davranışlarına bağlıdır. Binaların enerji tüketim parametrelerinin karışık olduğu, birbirleriyle ilişkili ve doğrusal olmadığı görülmektedir. Bu sebepten binaların enerji tüketimini tahmin etmek için basit analizler yeterli olmamakta ve yeni potansiyeller barındıran yöntemlere ihtiyaç duyulmaktadır.

Sanayinin dijital dönüşümü olarak nitelendirilen günümüzde büyük veri, artırılmış gerçeklik, yapay zekâ, makine öğrenimi gibi teknolojik gelişmelerden ortaya çıkan kavramlar türemiştir. Bu kavramlardan makine öğrenimi terimi mevcut verilerden öğrenen bir bilgisayar algoritmasını tanımlamak için kullanılmaktadır. Bu algoritmalar tipik olarak öğrenme süreci için önemli miktarda veri ve nispeten az sayıda girdi özelliği kullanmaktadır. Makine öğrenimi modelleri yeterli miktarda veriyle eğitildiğinde, özellikler ve hedefler arasındaki ilişki tanımlanmamış olsa dahi bilinmeyen özellikteki hedefleri tahmin etmek için kullanılabilirler. Makine öğrenimi uzmanlığı, enerji performans belirleme alanında güncel olarak karşılaşılan bir yaklaşımdır. Değişkenleri barındıran bir veritabanı mevcut ve girdi verileriyle oluşturulan model yeterince eğitildiyse birtakım bina tasarım parametreleri değiştirilerek enerji performansı kolaylıkla elde edilebilir.

Bu tez, 3. iklim bölgesinde yer alan konutların enerji tüketimini tahmin etmede yüksek doğruluk oranıyla ısıtma ve soğutma yükleri için gerekli enerji miktarını tahmin edebilen, etkili ve hızlı bir sonuç alınabilen ve bu sayede enerji tasarrufu için erken bina tasarımını kolaylaştıran makine öğrenimi yöntemini geliştirmiştir. Yeni tasarlanacak konutlar için binanın enerji yükünün çok kısa sürede tahmini ile erken tasarım aşamasında alınan kararların bu yöntem üzerinde denenerek enerji verimliliği açısından optimum performans gösteren konutların üretilmesi ve sürdürülebilir çevrelerin sağlanmasına hizmet edilebilmesi bu çalışmanın temel gayesidir. Bu araştırma makine öğrenimi aracılığı ile enerji performansına yönelik tahminlerin, -yeterli veri sağlandığında- yüksek doğrulukla sonuçlanabileceğini göstermektedir.

Bu amaçla, Türkiye’de yıllık toplam enerji tüketiminin büyük bir kısmını konutlar oluşturmaları sebebiyle çalışma odağını konut sektörüne çevirmiştir. Ayrıca, bu sektör önemli ölçüde tasarruf potansiyeli de barındırmaktadır. Bu doğrultuda çalışma alanı olarak 3. İklim bölgesi seçilmiştir. Konutların ısıtma- soğutma yüklerini tahmin etmek için üç aşamalı bir çalışma planlanmıştır:

- Bölgede yer alan konutların simülasyon yoluyla yıllık ısıtma soğutma yüklerinin belirlenmesi
- Makine öğrenimi yoluyla konutların ısıtma-soğutma yük tahminlemesinin yapılması amacıyla her bir yük tahmini için nihai model oluşturulması
- Simülasyon programı ile elde edilen ve gerçek veri olarak nitelendirilen veri ile makine öğrenimi sonucu elde edilen nihai modelden elde edilen tahmin sonuçlarının kıyaslanması

İlk olarak, 3.iklim bölgesinde yer alan konut biçimlemeleri ile çeşitli senaryolar üretilmiştir. Senaryolar, binaların dış alanla en çok temas ettiği yüzeyler olan cephe yüzeyleri odağında pasif tasarım parametrelerine dayandırılarak kurgulanmıştır. Plan tipi, duvar tipi, pencere tipi, saydamlık oranı, yönlenme parametreleri senaryolar için değişkenler olarak kabul edilmiştir:

- Plan tipi geometrilerinin sistematik bir şekilde basitleştirilmesi kare plan tipi, dikdörtgen plan tipi ve L plan tipi olmak üzere 3 adet plan tipine karar verilmiştir. Farklı plan tipolojileri 4x3 birimden oluşan 12 modülün bir araya getirilmesiyle oluşturulmuştur.
- Duvar yapı kabuğunda gaz beton, delikli tuğla, normal agregalı beton ve bims olmak üzere 4 ana duvar malzemesi; alçı esaslı dış kaplama paneli, çimento esaslı kaplama paneli, doğal taş kaplama, ahşap esaslı kaplama paneli, olmak üzere 4 dış kaplama malzemesi, yapı kabuğunun ısı geçirime direncini artırmak için taş yünü, XPS ve EPS olmak üzere 3 yalıtım malzemesi kullanılarak toplam 60 adet duvar tipi geliştirilmiştir.
- Pencere tipi konutlarda yaygın kullanılan pencere tipi olan PVC doğramalı hava tabakalı çift camlı pencere olarak (6-16-6 mm) belirlenmiştir. Farklı cam özelliklerinin kullanılarak, ısı kontrollü low-e çift camlı pencere, reflekte çift camlı pencere ve ısı+güneş kontrollü solar çift camlı pencere olarak 3 pencere tipi belirlenmiştir.

- Saydamlık oranı, yönlenmenin kurgulandığı cephedeki pencere alanının pencere+ duvar alanına oranı olarak tanımlanmıştır. Alt sınır değer % 20 olmak üzere, %60 ve %100 olarak 3 çeşit oran olarak uygulanmıştır.
- Yönlenme parametresi plan düzleminde kuzeye bakan cephe 0 derece olarak başlamış ve 45 derecelik açıyla döndürülerek denenmiştir. Böylelikle, ara ve ana yönler olmak üzere toplam 8 alternatif oluşturulmuştur.

Tüm parametrelerin bir araya getirilmesiyle toplam 12960 adet senaryo Design Builder+ JEPlus yazılımları aracılığı ile simüle edilerek ısıtma soğutma yükleri hesaplanmıştır. Sonraki aşama makine öğrenim sürecidir.

- İlk olarak makine öğrenimi için veri seti hazırlanmış ve kullanılacak parametrelere karar verilmiştir. Plan tipi, yönlenme, duvar tipi U değeri, pencere tipi U değeri, toplam duvar alanı, opak yüzey alanı ve saydam yüzey alanı olmak üzere 7 adet girdi parametresi ile ısıtma ve soğutma yükü olmak üzere çıktı parametreleri belirlenerek toplam 12960 satırdan oluşan veri seti oluşturulmuştur.
- Parametrelerin oluşturduğu girdi verilerinin, temizliği, doğruluğu, kalitesi, niteliği tahmin sonuçlarını doğrudan etkilemektedir. Bu nedenle girdi verileri ön işlemden geçirilmiştir. Opak yüzey alanı ve saydam yüzey alanı aralarında ilişki düzeyi yüksek çıkan parametrelerden opak yüzey alanı girdi verilerinden çıkartılmıştır.
- 12960 adet senaryodan ısıtma ve soğutma çıktı verilerine modelin karmaşıklığını gidermek ve modele katkı vermeyen veri setlerini tespit etmek amacıyla programı aracılığı ile aykırı değerlerin tespiti yapılarak ısıtma için hazırlanan veri seti 8602 örnekleme; soğutma yükü için hesaplanan veri seti ise 9617 örnekleme/gözleme düşürülmüştür.
- Daha sonra, ısıtma ve soğutma yükleri için makine öğrenim modelleri denenmiştir. Önce modeller eğitim test ve validasyon olmak üzere ayrılmıştır. Test % 20; validasyon ve eğitim % 80 olmak üzere rastgele bölünmüştür. Linear regresyon modeli, karar ağaçları, destek rektör makineleri ve yapay sinir ağları üzerinden model denerek en iyi tahmin performansını veren algoritma üzerinde çalışılmıştır.
- Isıtma modeli oluşturulurken modellerin tahmin performansları incelendiğinde karar ağaçları-random forest modeli 0.86; karar ağacı modeli 0.83; yapay sinir ağı modeli 0.86; destek vektör makinesi 0.73 ve doğrusal regresyon 0.57 doğruluk oranı ile sonuçlandırılmıştır.

görülmektedir. En yüksek doğruluk oranı YSA ve random forest modelinde görülmüştür. YSA modelinin basit yapısı ve kolay uygulanabilirliği düşünülmüş ve nihai ısıtma modeli YSA ile çalışılmıştır.

- Isıtma yük tahmini için %90 doğruluk oranı ile 1 girdi katmanı 15 nöronlu 1 gizli katman ve 1 çıktı katmanından oluşan YSA modeli geliştirilmiştir.
- Soğutma yükü tahmin modeli geliştirmek için kullanılan algoritmaların sonuçlarına bakıldığında, tahmin performansları rastgele orman (birleştirilmiş karar ağacı) modeli için 0.96; yapay sinir ağları için 0.98; karar ağaçları için 0.95; destek vektör makineleri için 0.95 ve doğrusal regresyon için 0.67 oranla genel olarak yüksek doğrulukla sonuçlandırılmıştır. Tahmin ve gerçek değerler arasında regresyon ilişkisi en kuvvetli sonucu veren ve düşük hata oranı sahip olan model Yapay Sinir Ağları modelidir. Soğutma yükü için nihai model yapay sinir ağları üzerinden türetilmiştir.
- Soğutma yük tahmini için % 98 doğruluk oranı ile 6 değişkenli girdi katmanı 20 nöronlu 1 gizli katman ve tek değişkenli 1 çıktı katmanından oluşan YSA modeli geliştirilmiştir.
- Nihai modeller oluşturulduktan sonra modeller, daha önce hiç görmedikleri veriler üzerinden sınanmıştır. Soğutma modeli, sınama çalışması sonucunda tıpkı makine öğreniminin ikinci ayağı olan test aşamasında olduğu gibi yüksek sonuç vermiştir. Isıtma yükü için oluşturulan tahmin modeli, soğutma modeli kadar yüksek başarı göstermemiş olmasına rağmen doğruluğu hem test hem de sınama çalışmasında birbirleri ile örtüşmektedir.

Tüm bu araştırmaların sonucunda makine öğrenmesi aracılığı ile enerji tüketimi tahmini, çalışma içeriğine ve niteliğine göre iki temel sınırlama barındırabilir:

- Makine öğrenimi tahmin modelleri eğitim aralıklarının dışında iyi performans sunmayabilir. Öğrenme algoritmasıyla eğitilen modeller, modelin eğitim verileri dışındaki yeni veriler üzerinde performansını göstermeyebilir. Bu nedenle eğitim için kullanılan veri kümesi, uygulama aralığını temsil etmeli ve yeterli çeşitlilik içermesi gerekmektedir. Bu tür temsili ve geniş kapsamlı verilerin toplanması zor, maliyetli ve zaman alıcı olmaktadır. Bu nedenle, bir uygulamada veriye dayalı bir model kullanmanın uygunluğu belirlenirken aynı zamanda modelin eğitimi için kullanılacak verileri belirlemek ve yelpazeyi geniş tutmak oldukça önemlidir. Bu araştırma, tahmin

sonuçlarını daha etkin kılmak amacıyla veri setinde örneklem/gözlem sayısını oldukça yüksek tutmuştur.

- Makine öğrenimi tahmin modelleri kara kutu modeller olması sebebiyle yeterli tahmin doğruluğu sağlamasına rağmen farklı parametrelerin enerji tüketimi açısından davranışının analizinde sınırlı olabilir. Bu nedenle girdi parametrelerinin doğru seçimi, tasarım aşamasına hizmet edebilmesi sebebiyle önem kazanmaktadır. Araştırma sürecinde özellikle enerji performansına etkisinin yüksek olduğu bilinen pasif tasarım parametrelerine yönelik veriler, girdi verileri olarak belirlenmiştir.

Bu bağlamda gelecek çalışmalarda,

- Oluşturulan modeller bir arayüze dönüştürülerek program kullanıcılarının yanı sıra herkes için erişilebilir hale getirilebilir.
- Programları aracılığı ile veri üretimi yerine, veri seti hazırlamak amacıyla -daha uzun süreler harcanarak- yerinde ölçüm ile gerçek verilere dayandırılan çalışmalar yürütülebilir.
- Simülasyon programında elde edilen veriler farklı pencere tiplerinin eklenmesiyle geliştirilebilir ve çeşitlendirilebilir.
- Araştırmanın ilk aşamasını oluşturan veri üretme sürecinde elde edilen senaryolar, farklı girdi verileri ile yeniden makine öğrenimi algoritmaları ile çalışılabilir.
- Bir binanın enerji performansı, bina tipine, iklimsel koşullara, kullanıcı ihtiyaçlarına, yapma çevreye ilişkin tasarım parametrelerine ve yönetmeliklere bağlı olarak farklılık göstermesinden ötürü gerçekleştirilen araştırma yöntemi farklı iklim bölgeleri, bina tipolojileri ve fonksiyonlarına uygun olarak çeşitlendirilebilir.

KAYNAKLAR

- Aghay-Kaboli, S., Fallahpour, A., Selvaraj, J., and Rahim, N.A. (2017). Long-term electrical energy consumption formulating and forecasting via optimized gene expression programming. *Energy*, 126, 144-164.
- Ahmad, M. W., Mourshed, M., and Rezgui, Y. (2017). Trees vs Neurons: Comparison between random forest and ANN for high-resolution prediction of building energy consumption. *Energy and buildings*, 147, 77-89.
- Ahmad, T., Chen, H., Guo, Y., and Wang, J. (2018). A comprehensive overview on the data driven and large scale based approaches for forecasting of building energy demand: A review. *Energy and Buildings*, 165, 301-320.
- Akıncı, T. Ç. and Noğay, H. S. (2019). Application of decision tree methods for wind speed estimation. *European Journal of Technique*, 9 (1), 74-83.
- Akova, S. ve Beyhan, F. (2015). Yapılı çevrelerin enerji politikasına etkisi: AB Türkiye karşılaştırması. *Enerji Diplomasisi*, 13, 623-644.
- Alobaidi, M. H., Chebana, F., and Meguid, M. A. (2018). Robust ensemble learning framework for day-ahead forecasting of household based energy consumption. *Applied Energy*, 212, 997-1012.
- Alobaidi, W., Sandgren, E., and Alkuam, E. (2017). Decision support through intelligent agent based simulation and multiple goal based evolutionary optimization. *Intelligent Information Management*, 9, 97-113.
- Amasyali, K. and El-Gohary, N. M. (2018). A review of data-driven building energy consumption prediction studies. *Renewable and Sustainable Energy Reviews*, 81, 1192-1205.
- Amber, K. P., Aslam, M. W., Mahmood, A., Kousar, A., Younis, M. Y., Akbar, B., and Hussain, S. K. (2017). Energy consumption forecasting for university sector buildings. *Energies*, 10(10), 1579.
- Amber, K. P., Ahmad, R., Aslam, M. W., Kousar, A., Usman, M., and Khan, M. S. (2018). Intelligent techniques for forecasting electricity consumption of buildings. *Energy*, 157, 886-893.
- Amiri, S.S., Mottahedi, M., and Asadi, S. (2015). Using multiple regression analysis to develop energy consumption indicators for commercial buildings in the U.S. *Energy and Buildings*, 109, 209-216.
- Arslan, H. (2008). *Sakarya Üniversitesi Web Sitesi Erişim Kayıtlarının Web Madenciliği ile Analizi*. Yüksek Lisans Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Sakarya.

- Atalay, S.D., Calis, G., Kus, G., and Kuru, M. (2019). Performance analyses of statistical approaches for modeling electricity consumption of a commercial building in France. *Energy and Buildings*, 195, 82–92.
- Atmaca, M. (2016). *Avrupa Birliği Bina Enerji Performansı Direktifi' nin Türkiye' deki Mevcut Otel Binaları İçin Uyarlanmasına Yönelik Bir Yaklaşım*, Doktora Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 36, 37, 41, 44.
- Agrawal, A. and Batish, A. (2019, 3-7 September). *Building energy prediction for early-design-stage decision support: a review of data-driven techniques*. Paper presented Building Simulation 2019, Rome.
- Bagnasco, A., Fresi, F., Saviozzi, M., Silvestro, F., and Vinci, A. (2015). Electrical consumption forecasting in hospital facilities: An application case. *Energy and Buildings*, 103, 261-270.
- Borgstein, E. H., Lamberts, R., and Hensen, J. L. M. (2016). Evaluating energy performance in non-domestic buildings: A review. *Energy and Buildings*, 128, 734-755.
- Bourdeau, M., Zhai, X., Nefzaoui, E., Guo, X., and Chatellier, P. (2019). Modeling and forecasting building energy consumption: A review of data-driven techniques. *Sustainable Cities and Society*, 48, 101533.
- Bui, D. K., Nguyen, T. N., Ngo, T. D., and Nguyen-Xuan, H. (2020). An artificial neural network (ANN) expert system enhanced with the electromagnetism-based firefly algorithm (EFA) for predicting the energy consumption in buildings. *Energy*, 190, 116370.
- Chae, Y. T., Horesh, R., Hwang, Y., and Lee, Y. M. (2016). Artificial neural network model for forecasting sub-hourly electricity usage in commercial buildings. *Energy and Buildings*, 111, 184-194.
- Candanedo, L. M., Feldheim, V., and Deramaix, D. (2017). Data driven prediction models of energy use of appliances in a low-energy house. *Energy and buildings*, 140, 81-97.
- Catalina, T., Iordache, V., and Caracaleanu, B. (2013). Multiple regression model for fast prediction of the heating energy demand. *Energy and Buildings*, 57, 302–312.
- Chae, Y.T., Horesh, R., Hwang, Y., and Lee, Y.M. (2016). Artificial neural network model for forecasting sub-hourly electricity usage in commercial buildings. *Energy and Buildings*, 111, 184–94.
- Chegari, B., Tabaa, M., Simeu, E., Moutaouakkil, F., and Medromi, H. (2021). Multi-objective optimization of building energy performance and indoor thermal comfort by combining artificial neural networks and metaheuristic algorithms. *Energy and Buildings*, 239, 110839.
- Chen, Y., Tan, H., and Berardi, U. (2018). A data-driven approach for building energy benchmarking using the Lorenz curve. *Energy and Buildings*, 169, 319-331.

- Chou, J. S. and Bui, D. K. (2014). Modeling heating and cooling loads by artificial intelligence for energy-efficient building design. *Energy and Buildings*, 82, 437-446.
- Chung, W. (2012). Using the fuzzy linear regression method to benchmark the energy efficiency of commercial buildings. *Applied Energy*, 95, 45-49.
- Chung, W., Hui, Y. V., and Lam, Y. M. (2006). Benchmarking the energy efficiency of commercial buildings. *Applied Energy*, 83(1), 1-14.
- Dagnely, P., Ruelle, T., Tourwé, T., Tsiporkova, E., and Verhelst, C. (2015). *Predicting hourly energy consumption. can regression modeling improve on an autoregressive baseline?* Paper presented Data Analytics for Renewable Energy Integration, Porto.
- De Wilde, P. (2014). The gap between predicted and measured energy performance of buildings: A framework for investigation. *Automation in Construction*, 41, 40-49.
- Deb, C., Lee, S. E., and Santamouris, M. (2018). Using artificial neural networks to assess HVAC related energy saving in retrofitted office buildings. *Solar Energy*, 163, 32-44.
- D'Amico, A., Ciulla, G., Traverso, M., Brano, V. L., and Palumbo, E. (2019). Artificial Neural Networks to assess energy and environmental performance of buildings: An Italian case study. *Journal of Cleaner Production*, 239, 117993.
- D'Oca, S., and Hong, T. (2014). A data-mining approach to discover patterns of window opening and closing behavior in offices. *Building and Environment*, 82, 726-739.
- D'Oca, S., and Hong, T. (2015). Occupancy schedules learning process through a data mining framework. *Energy and Buildings*, 88, 395-408.
- Elbeltagi, E. and Wefki, H. (2021). Predicting energy consumption for residential buildings using ANN through parametric modeling. *Energy Reports*, 7, 2534-2545.
- Fan, C., Xiao, F., and Wang, S. (2014). Development of prediction models for next-day building energy consumption and peak power demand using data mining techniques. *Applied Energy*, 127, 1-10.
- Elbeltagi, E. and Wefki, H. (2021). Predicting energy consumption for residential buildings using ANN through parametric modeling. *Energy Reports*, 7, 2534-2545.
- Enerji ve Tabii Kaynaklar Bakanlığı Yenilenebilir Enerji Genel Müdürlüğü. (2016). *Bütünleşik Bina Tasarım Yaklaşımı - Bina Performansına Yönelik Öncelik ve Hedefler*. Ankara: Enerji ve Tabii Kaynaklar Bakanlığı Yenilenebilir Enerji Genel Müdürlüğü.
- Enerji ve Tabii Kaynaklar Bakanlığı Yenilenebilir Enerji Genel Müdürlüğü. (2016). *Bütünleşik Bina Tasarım Yaklaşımı ile Proje Geliştirme Süreci Uygulama Kılavuzu*. Ankara: Enerji ve Tabii Kaynaklar Bakanlığı Yenilenebilir Enerji Genel Müdürlüğü.

- Ertosun Yıldız, M., Beyhan, F., and Uçar, M.K. (2021). *Prediction of heating-cooling load by artificial neural networks for energy efficient building design*. Paper presented at the 9th International Symposium on Innovative Technologies in Engineering and Science - Academic Perspective, Sakarya.
- Fan, C., Xiao, F., and Wang, S. (2014). Development of prediction models for next-day building energy consumption and peak power demand using data mining techniques. *Applied Energy*, 127, 1-10.
- Fan, C., Xiao, F., and Zhao, Y. (2017). A short-term building cooling load prediction method using deep learning algorithms. *Applied Energy*, 195, 222-233.
- Fouquier, A., Robert, S., Suard, F., Stéphan, L., and Jay, A. (2013). State of the art in building modelling and energy performances prediction: A review. *Renewable and Sustainable Energy Reviews*, 23, 272-288.
- Fumo, N., Torres, M.J., and Broomfield, K. (2021). A multiple regression approach for calibration of residential building energy models. *Journal of Building Engineering*, 43, 102874.
- Gao, X. (2013). A new methodology for building energy benchmarking: An approach based on clustering concept and statistical models (Doctoral dissertation, University of Pennsylvania)
- Gao, X. and Malkawi, A. (2014). A new methodology for building energy performance benchmarking: An approach based on intelligent clustering algorithm. *Energy and Buildings*, 84, 607-616.
- Gao, J., Yan, T., Xu, T., Ling, Z., Wei, G., and Xu, X. (2019). Development and experiment validation of variable-resistance-variable-capacitance dynamic simplified thermal models for shape-stabilized phase change material slab. *Applied Thermal Engineering*, 146, 364–375.
- Gazioğlu, A. (2012). *Enerji Etkin Bina Tasarımında Isıtma Enerjisi Harcamalarını Azaltmaya Yönelik Bir İyileştirme Çalışması*, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 11.
- Gray, F. M. and Schmidt, M. (2018). A hybrid approach to thermal building modelling using a combination of Gaussian processes and grey-box models. *Energy and Buildings*, 165, 56-63.
- Gunay, B., Shen, W., Huchuk, B., Yang, C., Bucking, S., and O'Brien, W. (2018). Energy and comfort performance benefits of early detection of building sensor and actuator faults. *Building Services Engineering Research and Technology*, 39(6), 652-666.
- Gültekin A.B. ve Farahbakshe, B. (2016). Energy performance of glass building materials. *TÜBAVBilimDergisi*, 9(3), 52-65.

- Gültekin, A. B. and Karaca, N. K. (2017 12-16 Jun). *Business management in sustainable buildings: Ankara-Turkey case*. Paper presented World Multidisciplinary Civil Engineering-Architecture-Urban Planning Symposium On Business Management İn Sustainable Buildings. Prague, Czech Republic.
- Gültekin, A. B. and Yavaşbatmaz, S. (2013). Sustainable design of tall buildings. *Journal of the Croatian Association of Civil Engineers Gradevinar*, 65 (5); 449-461.
- Gür, V. N. ve Aygün, M. (2008). Mimaride sürdürülebilirlik kapsamında değişken yapı kabukları için bir tasarım destek sistemi. *İstanbul Teknik Üniversitesi Dergisi*, 7(1), 74-82.
- Hamilton, I., Summerfield, A., Oreszczyn, T., and Ruyssevelt, P. (2017). Using epidemiological methods in energy and buildings research to achieve carbon emission targets. *Energy and Buildings*, 154, 188-197.
- Hodge, V J. and Austin, J. (2004). A survey of outlier detection methodologies. *Artificial Intelligence Review*, 22(2), 85-126.
- Harputlugil, G. (2016). *Türkiye’de Konut Kalitesinin İyileştirilmesine Yönelik Kullanıcı Davranışının Enerji Ve Konfor Üzerindeki Etkisine Dayalı Bir Yöntem Geliştirilmesi* (Proje No: 113K799). TUBİTAK, Ankara.
- Huang, Y., Yu, Z. J., Li, J., Zhou, Y., Zhou, J., and Zhang, G. (2017). A Novel Energy benchmarking methodology based on an agent-based modeling method. *Procedia Engineering*, 205, 1725-1732.
- Hong, T., D'Oca, S., Turner, W. J., 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.
- International Energy Agency (2021). World Energy Outlook 2018, *IEA*, Paris, 206-208.
- İnternet: Climate One Building (2023). Ankara İklim Verileri. URL: https://climate.onebuilding.org/WMO_Region_6_Europe/TUR_Turkey/index.html#I_DAN_Ankara- Son Erişim Tarihi: 10.10.2023.
- İnternet: Energy Star (2011) About Energy Star URL: <https://www.energystar.gov/about?s=mega> Son Erişim Tarihi: 10.10.2023.
- İnternet: Mathworks (2023). MATLAB for Artificial Intelligence. URL: <https://www.mathworks.com/> Son Erişim Tarihi: 10.10.2023.
- İnternet: Meteoroloji Genel Müdürlüğü (2023). Türkiye İklim Sınıflandırması URL: <https://www.mgm.gov.tr/FILES/genel/sss/iklimsiniflandirmalariturkiye.pdf> Son Erişim Tarihi: 10.10.2023.
- İnternet: T.C. Enerji ve Tabii Kaynaklar Bakanlığı (2016). Ulusal Enerji Verimliliği Eylem Planı URL: <https://enerji.gov.tr/bilgi-merkezi-enerji-verimliliği-ulusal-enerji-verimliliği-eylem-planı> . Son Erişim Tarihi: 10.10.2023.

- İnternet: T.C. Enerji ve Tabii Kaynaklar Bakanlığı (2021). Güneş Enerjisi. URL: <https://enerji.gov.tr/eigm-yenilenebilir-enerji-kaynaklar-gunes>. Son Erişim Tarihi: 10.10.2023.
- İnternet: T.C. Enerji ve Tabii Kaynaklar Bakanlığı (2022). Türkiye Ulusal Enerji Planı. URL: https://enerji.gov.tr/Media/Dizin/EIGM/tr/Raporlar/TUEP/T%C3%BCrkiye_Ulusal_Enerji_Plan%C4%B1.pdf. Son Erişim Tarihi: 10.10.2023.
- İnternet: T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı (2008). Binalarda Enerji Performansı Yönetmeliği. URL: <http://www.mevzuat.gov.tr/Metin.Aspx?MevzuatKod=7.5.13594&MevzuatIliski=0&sourceXmlSearch>. Son Erişim Tarihi: 10.10.2023.
- İnternet: T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı (2012). İklim Değişikliği Uyum Stratejisi ve Eylem Planı 2011-2023. URL: https://webdosya.csb.gov.tr/db/iklim/editordosya/uyum_stratejisi_eylem_plani_TR.pdf. Son Erişim Tarihi: 10.10.2023.
- İnternet: T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı (2016a). Binalarda Enerji Verimliliğinin Artırılması İçin Teknik Yardım Projesi, Binalarda Enerji Verimliliği, AB ve Türk Mevzuatı. URL: <http://webdosya.csb.gov.tr/csb/dokumanlar/mhgm0002.pdf>. Son Erişim Tarihi: 10.10.2023.
- İnternet: T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı (2016b). Binalarda Enerji Verimliliğinin Artırılması İçin Teknik Yardım Projesi, Enerji Verimli Bina Tasarım Stratejileri. URL: <http://webdosya.csb.gov.tr/csb/dokumanlar/mhgm0005.pdf>. Son Erişim Tarihi: 10.10.2023.
- Jain, R. K., Smith, K. M., Culligan, P. J., and Taylor, J. E. (2014). Forecasting energy consumption of multi-family residential buildings using support vector regression: Investigating the impact of temporal and spatial monitoring granularity on performance accuracy. *Applied Energy*, 123, 168-178.
- Karataşlı, M., Özer, T. and Varinlioğlu, A. (2016). Enerji ve çevre. *İstanbul Aydın Üniversitesi Dergisi*, 8(30), 103-124.
- Khoshbakht, M., Gou, Z., and Dupre, K. (2018). Energy use characteristics and benchmarking for higher education buildings. *Energy and Buildings*, 164, 61-76.
- Kılıç, R. ve Gültekin A. B. (2017). Binalarda pasif ve aktif güneş sistemlerinin incelenmesi *TÜBAVBilimDergisi*, 10(1), 36-51.
- Jinhu, L., Xuemei, L., Lixing, D., and Liangzhong, J. (2010). Applying principal component analysis and weighted support vector machine in building cooling load forecasting. *Computer and Communication Technologies in Agriculture Engineering*, 1, 434-437.

- Kolokotsa, D., Diakaki, C., Grigoroudis, E., Stavrakakis, G., and Kalaitzakis, K. (2009). Decision support methodologies on the energy efficiency and energy management in buildings. *Advances in Building Energy Research*, 3(1), 121-146
- Kristensen, M. H. and Petersen, S. (2016). Choosing the appropriate sensitivity analysis method for building energy model-based investigations. *Energy and Buildings*, 130, 166-176.
- Kumar, R., Aggarwal, R. K., and Sharma, J. D. (2013). Energy analysis of a building using artificial neural network: A review. *Energy and Buildings*, 65, 352-358.
- Kuster, C., Rezgui, Y., and Mourshed, M. (2017). Electrical load forecasting models: A critical systematic review. *Sustainable Cities and Society*, 35, 257-270.
- Lee, S. J. and Song, S. Y. (2022). Determinants of residential end-use energy: Effects of buildings, sociodemographics, and household appliances. *Energy and Buildings*, 257, 111782.
- Li, K., Xie, X., Xue, W., Dai, X., Chen, X., and Yang, X. (2018). A hybrid teaching-learning artificial neural network for building electrical energy consumption prediction. *Energy and Buildings*, 174, 323-334.
- Li, Z., Han, Y., and Xu, P. (2014). Methods for benchmarking building energy consumption against its past or intended performance: An overview. *Applied Energy*, 124, 325-334.
- Li, X. (2015). *Net-Zero Building Cluster Simulations and On-line Energy Forecasting for Adaptive and Real-Time Control and Decisions*. Doctor of Philosophy, Drexel University, ABD.
- Liu, J., Chen, H., Liu, J., Li, Z., Huang, R., Xing, L., and Li, G. (2017). An energy performance evaluation methodology for individual office building with dynamic energy benchmarks using limited information. *Applied Energy*, 206, 193-205
- Liu, Y., Chen, H., Zhang, L., Wu, X., & Wang, X. J. (2020). Energy consumption prediction and diagnosis of public buildings based on support vector machine learning: A case study in China. *Journal of Cleaner Production*, 272, 122542.
- Magoulès, F. and Zhao, H. X. (2016). *Data mining and machine learning in building energy analysis*. New York, John Wiley & Sons, Inc, 149-162.
- Ma, J., and Cheng, J. C. (2016). Identifying the influential features on the regional energy use intensity of residential buildings based on Random Forests. *Applied Energy*, 183, 193-201.
- Mangan, D, S. (2015). *Yaşam Döngüsü Enerji Ve Maliyet Etkinliği Açısından Konut Binalarının Performanslarının Değerlendirilmesinde Kullanılabilecek Bir Yaklaşım*. Doktora Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 40.

- Massana, J., Pous, C., Burgas, L., Melendez, J., and Colomer, J. (2015). Short-term load forecasting in a non-residential building contrasting models and attributes. *Energy and Buildings*, 92, 322–30.
- Matson, N. and Piette, M.A. (2006). *Review of expanded california k-12 schools benchmarking database* (draft report). Berkeley, California. Lawrence Berkeley National Laboratory, 14.
- Mohammed, A., Alshibani, A., Alshamrani, O., and Hassanain, M. (2021). A regression-based model for estimating the energy consumption of school facilities in Saudi Arabia. *Energy and Buildings*, 237, 110809.
- Naji, S., Keivani, A., Shamsirband, S., Alengaram, U.J., Jumaat, M.Z., and Mansor, Z. (2016). Estimating building energy consumption using extreme learning machine method. *Energy*, 97, 506–16.
- Namlı, E., Ünlü, R., and Gül, E. (2019). Fiyat tahminlemede makine öğrenmesi teknikleri ve doğrusal regresyon yöntemlerinin kıyaslanması; türkiye’de satılan ikinci el araç fiyatlarının tahminlenmesine yönelik bir vaka çalışması. *Konya Journal of Engineering Sciences*, 7(4), 806-821.
- Nilashi, M., Dalvi-Esfahani, M., Ibrahim, O., Bagherifard, K., Mardani, A., and Zakuan, N. (2017). A soft computing method for the prediction of energy performance of residential buildings. *Measurement*, 109, 268-280.
- Oral, G. (2010). Güneş enerjisi ve yapı. diyARCH bülten. TMMOB Mimarlar Odası Diyarbakır Şubesi. 8-20.
- Ovalı, P. K. (2009). *Türkiye İklim Bölgeleri Bağlamında Ekoloji Tasarım Ölçütleri Sistematığının Oluşturulması. Kayaköy Yerleşmesinde Örneklenmesi*. Doktora Tezi, Trakya Üniversitesi, Fen Bilimleri Enstitüsü, Edirne.
- Özüer, O. M. (2012). Binalarda enerji korunumunu sağlayan fiziksel çevre ölçütleri, *Beykent University Journal Of Science And Engineering*, 5(2), 95-107.
- Park, Y. S. and Lek, S. (2016). Artificial neural networks: multilayer perceptron for ecological modeling. *Developments in Environmental Modelling*, 28, 123–140.
- Paudel, S., Elmitri, M., Couturier, S., Nguyen, P. H., Kamphuis, R., Lacarrière, B., and Le Corre, O. (2017). A relevant data selection method for energy consumption prediction of low energy building based on support vector machine. *Energy and Buildings*, 138, 240-256.
- Pérez-Montalvo, E., Zapata-Velásquez, M. E., Benítez-Vázquez, L. M., Cermeño-González, J.M., Alejandro-Miranda, J., Martínez Cabero, M.Á., and Puente-Gil, Á. (2022). Model of monthly electricity consumption of healthcare buildings based on climatological variables using PCA and linear regression. *Energy Reports*, 8, 250–258.

- Pham, A. D., Ngo, N. T., Truong, T. T. H., Huynh, N. T., and Truong, N.S. (2020). Predicting energy consumption in multiple buildings using machine learning for improving energy efficiency and sustainability. *Journal of Cleaner Production*, 260, 121082.
- Rastogi, P., Polytechnique, E., and Lausanne, F.D. (2017). *Gaussian-process-based emulators for building performance simulation*, in *building simulation 2017*. Paper presented The 15th International Conference of IBPSA, San Francisco.
- Raza, M.Q. and Khosravi, A. (2015). A review on artificial intelligence based load demand forecasting techniques for smart grid and buildings. *Renewable and Sustainable Energy Reviews*, 50, 1352-1372.
- Sarıman, G. (2011). Veri madenciliğinde kümeleme teknikleri üzerine bir çalışma: k-means ve k-medoids kümeleme algoritmalarının karşılaştırılması. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 15(3), 192-202.
- Sorokina, N., Booth, D. E., and Thornton, J. H. (2021). Robust methods in event studies: empirical evidence and theoretical implications. *Journal of Data Science*, 11(3), 575–606.
- Sayan, S. (2014). *Performans Tabanlı Bina Tasarımı İçin Bir Model Önerisi*. Doktora Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya.
- Seem, J. E. (2007). Using intelligent data analysis to detect abnormal energy consumption in buildings. *Energy and Buildings*, 39(1), 52-58.
- Serale, G., Fiorentini, M., Capozzoli, A., Bernardini, D., and Bemporad, A. (2018). Model predictive control (MPC) for enhancing building and HVAC system energy efficiency: Problem formulation, applications and opportunities. *Energies*, 11(3), 631.
- Seyedzadeh, S., Rahimian, F. P., Glesk, I., and Roper, M. (2018). Machine learning for estimation of building energy consumption and performance: a review. *Visualization in Engineering*, 6(1), 5-25.
- Shi, G., Liu, D., and Wei, Q. (2016). Energy consumption prediction of office buildings based on echo state networks. *Neurocomputing*, 216, 478–88.
- Shao, M., Wang, X., Bu, Z., Chen, X., & Wang, Y. (2020). Prediction of energy consumption in hotel buildings via support vector machines. *Sustainable Cities and Society*, 57, 102128.
- Smarra, F., Jain, A., De Rubeis, T., Ambrosini, D., D’Innocenzo, A., and Mangharam, R. (2018). Data-driven model predictive control using random forests for building energy optimization and climate control. *Applied Energy*, 226, 1252-1272.
- Swan, L. G., and Ugursal, V. I. (2009). Modeling of end-use energy consumption in the residential sector: A review of modeling techniques. *Renewable and Sustainable Energy Reviews*, 13(8), 1819-1835.

- Tardioli, G., Kerrigan, R., Oates, M., James, O. D., and Finn, D. (2015). Data driven approaches for prediction of building energy consumption at urban level. *Energy Procedia*, 78, 3378-3383.
- Tekin, Ç., Özgünler, M., ve Beyaztaş, H. (2018). Yapı Kabuğu Saydamlık Oranlarının Simülasyon Programı Aracılığıyla Belirlenmesi. *Journal of Science and Technology Of Dumlupınar University*, (41), 49-68.
- The European Parliament and The Council of The European Union (2010). Energy Performance of Buildings Directive (EPBD) - 2010/31/EU. *European Union*, 1-23.
- Thiangchanta, S., and Chaichana, C. (2020). The multiple linear regression models of heat load for air-conditioned room. *Energy Reports*, 6(9), 972-977.
- Tıkansak, T. (2013). Energy efficiency in housing. *Iconarp International Journal of Architecture and Planning*, 1 (2), 189-200.
- Tronchin, L., Manfren, M., and James, P.A.B. (2018). Linking design and operation performance analysis through model calibration: Parametric assessment on a Passive House building. *Energy*, 165, 26-40.
- Tsanas, A. and Xifara, A. (2012). Accurate quantitative estimation of energy performance of residential buildings using statistical machine learning tools. *Energy and Buildings*, 49, 560-567.
- TSE (2013). Binalarda Isı Yalıtım Kuralları Standardı (TS 825). Türk Standartları Enstitüsü, Ankara.
- Ulukavak Harputlugil, G. (2014). *Bina enerji performansı değerlendirme araçları-enerji simülasyonu*. *Tesisat Mühendisliği*, 144, 23-32.
- Ulukavak Harputlugil G. and Harputlugil, T. (2016). Çevresel konfor ve enerji tasarrufu bağlamında konut kullanıcıları davranış profilleri üzerine bir araştırma. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 31(3), 695-708.
- Wang, E. (2015). Benchmarking whole-building energy performance with multi-criteria technique for order preference by similarity to ideal solution using a selective objective-weighting approach. *Applied Energy*, 146, 92-103.
- Wang, S., Yan, C., and Xiao, F. (2012). Quantitative energy performance assessment methods for existing buildings. *Energy and Buildings*, 55, 873-888.
- Wang, Y., Wang, F., and Wang, H. (2017). Influencing factors regression analysis of heating energy consumption of rural buildings in China. *Procedia Engineering*, 205, 3585-3592.
- Wang, Z., Wang, Y., Zeng, R., Srinivasan, R. S., and Ahrentzen, S. (2018). Random Forest based hourly building energy prediction. *Energy and Buildings*, 171, 11-25.

- Wang, Z., Wang, Y., and Srinivasan, R. S. (2018). A novel ensemble learning approach to support building energy use prediction. *Energy and Buildings*, 159, 109-122.
- Wei, Y., Zhang, X., Shi, Y., Xia, L., Pan, S., Wu, J., and Zhao, X. (2018). A review of data-driven approaches for prediction and classification of building energy consumption. *Renewable and Sustainable Energy Reviews*, 82, 1027-1047.
- Wong, S. L., Wan, K. W., and Lam, T. N. T. (2010). Artificial neural networks for energy analysis of office buildings with daylighting. *Applied Energy*, 87(2), 551-557.
- Xuemei, L., Lixing, D., Jinhu, L., Gang, X., and Jibin L. A. (2010, 9-10 January). *Novel hybrid approach of kpca and svm for building cooling load prediction*. Paper presented 2010 Third International Conference on Knowledge Discovery and Data Mining, Phuket.
- Yılmaz, Z. (2005). *Akıllı binalar ve yenilenebilir enerji*. VII. Ulusal Tesisat Mühendisliği Kongresinde Sunuldu, İzmir.
- Yılmaz, Z., Oral, G.K., ve Manioğlu, G. (2000). *Isıtma Enerjisi Tasarrufu Açısından Bina Kabuğu Isı Yalıtım Değerinin Bina Formuna Bağlı Olarak Belirlenmesi* (Proje No:985). İstanbul Teknik Üniversitesi, İstanbul.
- Yi, Y. K., and Malkawi, A. M. (2009). Optimizing building form for energy performance based on hierarchical geometry relation. *Automation in Construction*, 18(6), 825-833.
- Yu, Z., Haghighat, F., Fung, B. C., and Yoshino, H. (2010). A decision tree method for building energy demand modeling. *Energy and Buildings*, 42(10), 1637-1646.
- Yu, Z. J., Haghighat, F., and Fung, B. C. (2016). Advances and challenges in building engineering and data mining applications for energy-efficient communities. *Sustainable Cities and Society*, 25, 33-38.
- Yıldırım, H. H., Gültekin, A. B., and Tanrıvermiş, H. (2016). *Evaluation of energy efficient urban planning approach*. In SBE16 International Conference On Sustainable Built Environment, İstanbul, 228-229.
- Zekić-Sušac, M., Has, A., and Knežević, M. (2021). Predicting energy cost of public buildings by artificial neural networks, CART, and random forest. *Neurocomputing*, 439, 223-233.
- Zelterman, D. (2015). *Applied multivariate statistics R*. New York: Springer, 195, 201, 203.
- Zhao, H. X. and Magoulès, F. (2012). A review on the prediction of building energy consumption. *Renewable and Sustainable Energy Reviews*, 16(6), 3586-3592.
- Zhao, J., Lasternas, B., Lam, K. P., Yun, R., and Loftness, V. (2014). Occupant behavior and schedule modeling for building energy simulation through office appliance power consumption data mining. *Energy and Buildings*, 82, 341-355.

- Zhao, X., Zuo, J., Wu, G., and Huang, C. (2019). A bibliometric review of green building research 2000–2016. *Architectural Science Review*, 62(1), 74-88.
- Zhong, H., Wang, J., Jia, H., Mu, Y., and Lv, S. (2019). Vector field-based support vector regression for building energy consumption prediction. *Applied Energy*, 242, 403-414.



Gazili olmak ayrıcalıktır