



Machine learning based evaluation of window parameters on building energy performance and occupant thermal comfort under climate change

Gizem Akköse¹, Ayça Duran¹, İpek Gürsel Dino¹, Çağla Meral Akgül^{2*}

¹Department of Architecture, Middle East Technical University, 06800, Çankaya, Ankara, Türkiye

²Department of Civil Engineering, Middle East Technical University, 06800, Çankaya, Ankara, Türkiye

Highlights:

- Climate change has a critical impact on building performance.
- Machine learning methods and statistical analyzes enable the optimization of building parameters.
- Machine learning methods are gaining importance in building energy consumption estimation and analysis

Keywords:

- Machine learning
- Climate Change
- Building energy efficiency
- Thermal comfort
- Retrofit

Article Info:

Research Article

Received: 12.08.2021

Accepted: 25.09.2022

DOI:

10.17341/gazimmfd.1069164

Acknowledgement:

The authors thank Tolga Tamer for her contribution to the cost calculations and Naz Dino for proofreading. This research was funded by Middle East Technical University BAP Grant No: GAP-30321-10674.

Correspondence:

Author: Çağla Meral Akgül
e-mail: cmeral@metu.edu.tr
phone: +90 312 210 2462

Graphical/Tabular Abstract

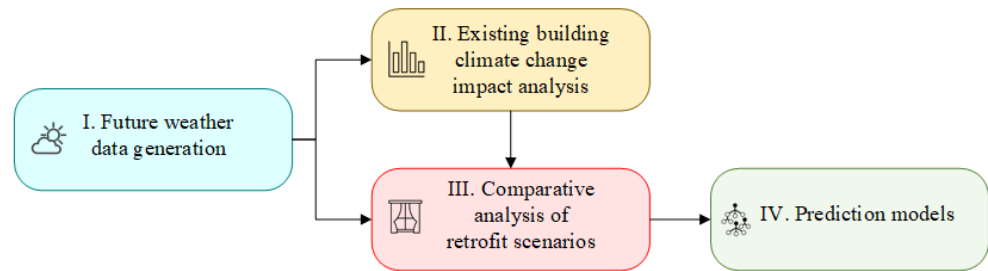


Figure A. The proposed framework

Purpose:

This study aims to evaluate the effect of climate change on energy consumption and thermal comfort of an existing educational building and to use machine learning techniques for building performance improvement through passive retrofit scenarios based on window parameters.

Theory and Methods:

The research proposes a four-step method based on performance analysis through building simulations: (i) the generation and analyses of climate change modified future weather files, (ii) climate change impact analysis on an existing building, (iii) comparative analysis of retrofit scenarios, and (iv) the analyses prediction models. The proposed method is implemented in a secondary school building in Ankara, Turkey.

Results:




Simulation results show that by 2050, the annual heating (Q_H) will decline by 33%, whereas the annual cooling (Q_S) will rise by 100%. The June indoor overheating degree ($\dot{I}AD_H$) values will increase from 0.74°C to 2.32°C, showing a drastic change of 213%, implying a significant increase in thermal discomfort. Correlation analysis indicates that both $\dot{I}AD_H$ and Q_S have a strong positive linear relationship with SHGC, whereas the Q_H has a strong positive linear relationship with $U_{pencere}$. Furthermore, the Q_H -SHGC relationship is moderate negative. Developed prediction models for energy consumption and thermal comfort have a high predictive capacity with a minimum R^2 of 0.927 and, on average, 2% deviation from their actual values based on RMSE. Random forest feature importances for the prediction models trained to predict Q_S and $\dot{I}AD_H$ agree on the importance of the SHGC. For Q_H , $U_{pencere}$ has a slightly higher significance than the SHGC.

Conclusion:

Building energy consumption and occupant thermal comfort are significantly affected by climate change. The fact that the majority of the school building occupants are composed of young children not only distinguishes school buildings from other building types but also makes these buildings more vulnerable to heat stress. The results of this study emphasize the necessity of retrofit measurements against climate change. The random forest feature importances indicate that the window SHGC value is the most critical window parameter of the performance-based improvement scenarios among the tested variables. The steps suggested and followed in this study can be applied to the other building typologies with different retrofit scenarios. The scope of this research can be expanded with varying building parameters and technologies.



Makina öğrenmesi ile pencere parametrelerinin bina performansına etkisinin iklim değişikliği gözetilerek incelenmesi

Gizem Akköse¹ , Ayça Duran¹ , İpek Gürsel Dino¹ , Çağla Meral Akgül^{2*} 

¹Orta Doğu Teknik Üniversitesi, Mimarlık Bölümü, 06800 Çankaya, Ankara, Türkiye

²Orta Doğu Teknik Üniversitesi, İnşaat Mühendisliği Bölümü, 06800, Çankaya, Ankara, Türkiye

ÖNEÇIKANLAR

- İklim değişikliği bina performansı üzerinde kritik bir etkiye sahiptir
- Makine öğrenmesi yöntemleri ve istatistiksel analizler bina parametrelerinin optimizasyonunu mümkün kılmaktadır
- Yapı enerji tüketimi tahmini ve analizinde makine öğrenmesi yöntemleri giderek önem kazanmaktadır

Makale Bilgileri

Araştırma Makalesi

Geliş: 12.08.2021

Kabul: 25.09.2022

DOI:

10.17341/gazimmfd.1069164

Anahtar Kelimeler:

Makine öğrenmesi,
iklim değişikliği,
bina enerji verimliliği,
retrofit,
ısı konfor

ÖZ

Bu çalışmada, iklim değişikliğinin eğitim binası enerji tüketimi ve ısı konforu üzerindeki etkileri incelenmiş ve pencere parametrelerine dayalı pasif iyileştirme senaryolarının etkinliği makine öğrenmesi ve istatistiksel analizler ile değerlendirilmiştir. Araştırma bina simülasyonlarına dayalı, dört aşamalı bir yaklaşıma dayanmıştır: (i) iklim değişikliği senaryosu ile modifiye edilmiş iklim veri setlerinin oluşturulması ve analizi, (ii) mevcut bina üzerinde iklim değişikliği etki analizi, (iii) iyileştirme senaryolarının karşılaştırmalı analizi, (iv) makine öğrenmesine dayalı tahmin modelleri analizi. Örnek vaka olarak Ankara'da mevcut bir ortaokul binası olarak seçilmiştir. Farklı pencere parametreleriyle, olası 2025 iyileştirme senaryosu parametrik olarak modellenmiştir. Simülasyonlarla üretilen veri betimsel istatistik yöntemleriyle incelenmiş, verinin bir alt kümesi ile Rastgele Orman (RO) tahmin modelleri eğitilmiştir. Parametrelerin öznelik önemleri RO modelleri 10-kat çapraz doğrulama yöntemiyle hesaplanmış ve test edilenler arasında pencere SHGC değerinin en kritik parametre olduğu görülmüştür. RO modelleriyle yapılan performans tahminleri gerçek değerlerinden ortalama %2 sapmış ve yüksek tahmin kapasitesi göstermiştir. İyileştirme senaryoları ile toplam enerji tüketiminde %50'ye varan azalmalara ve iç mekan ısı konforunda önemli iyileşmelere ulaşılmıştır. Sonuçlar mevcut eğitim binalarda pencere parametrelerinin seçimin bina enerji performansına etkisinin büyük olduğunu doğru vurgulamakta, binaların iklim değişikliğine adaptasyonu süreçlerinde makine öğrenmesinin etkin bir şekilde kullanılabilmesini göstermektedir. Kullanılan yöntem farklı bina parametrelerini ve teknolojilerini kapsayacak şekilde genişletilebilir.

Machine learning based evaluation of window parameters on building energy performance and occupant thermal comfort under climate change

HIGHLIGHTS

- Climate change has a critical impact on building performance
- Machine learning methods and statistical analyzes enable the optimization of building parameters
- Machine learning methods are gaining importance in building energy consumption estimation and analysis

Article Info

Research Article

Received: 12.08.2021

Accepted: 25.09.2022

DOI:

10.17341/gazimmfd.1069164

Keywords:

Machine learning,
climate change,
building energy efficiency,
retrofit,
thermal comfort

ABSTRACT

In this study, the effects of climate change on the energy consumption and thermal comfort of the education building were examined and the effectiveness of passive improvement scenarios based on window parameters was evaluated by machine learning and statistical analysis. The research was based on a four-stage approach based on building simulations: (i) creation and analysis of climate change scenario-modified climate datasets, (ii) climate change impact analysis on existing building, (iii) comparative analysis of improvement scenarios, and (iv) analysis of predictive models based on machine learning. An existing secondary school building in Ankara was chosen as a case study for the evaluation of the selected performance indicators. 2025 scenarios were parametrically modeled with varying window parameters. After analyzing the complete dataset generated from performance simulations with descriptive statistics, Random Forest (RF) prediction models are trained with a subset of the data for each performance indicator. For each performance indicator, the feature importance of fine-tuned RF models was calculated with 10-fold cross-validation method, and it was seen that the window SHGC value was the most critical parameter among the tested variables. Performance predictions with RF models deviate 2% on average from their actual values and imply high predictive capacity. Moreover, with the retrofit scenarios, total energy consumption showed a reduction of up to 50%, whereas a significant improvement in indoor thermal comfort was observed. The results emphasize that the right selection of window parameters in existing educational buildings has a great effect on building energy performance. The results show that machine learning can be used effectively in the adaptation processes of buildings to climate change. The method used can be extended to cover different building parameters and technologies.

*Sorumlu Yazar/Yazarlar / Corresponding Author/Authors : gizemakkose@gmail.com, aycaad@metu.edu.tr, ipekg@metu.edu.tr,

*cmeral@metu.edu.tr / Tel: +90 312 210 2462

1. Giriş (Introduction)

İklim değişikliği, 21. yüzyılda insanlığın karşı karşıya kaldığı en temel zorluklardan biridir. Küresel sıcaklık artışı, eriyen buz tabakaları, okyanusların ısınması ve asitlenmesi, deniz seviyesinin yükselmesi, aşırı hava olayları ve kontrol edilemeyen yangınların sıklaşması gibi çeşitli olumsuz çevresel etkilere yol açar [1]. 2021 yılı verilerine göre son yedi yıl tarihin kaydedilen en sıcak yılları olmuştur [1]. 1880 yılına kıyasla ortalama yüzey sıcaklığı artışı 2021 yılında 0,85°C mertebesinde [1]. İklim değişikliği ile antropogenic (insan kaynaklı) sera gazı emisyonları ve enerji tüketimi arasında güçlü bir ilişki vardır. Bu kapsamda, yaşam döngüleri boyunca (tasarım, inşaa, onarım, bakım, yenileme, işletme ve yıkım süreçleri dahil olmak üzere) yüksek oranda doğal kaynak ve enerji tüketen büyük miktarda sera gazı, katı atık ve su kirleticileri açığa çıkaran bina sektörü mercek altındadır [2-4]. Günümüzde bina sektörü, toplam nihai enerji tüketiminin yaklaşık üçte birini ve nihai kullanım sektörünün CO₂ emisyonlarının %15'ini oluşturmaktadır ve binalarda kullanılan elektrik ve ısıtma ihtiyacından kaynaklanan dolaylı emisyonlar dahil edildiğinde, emisyonların payı %30'lara çıkmaktadır [5]. Binaların iklim değişikliği üzerindeki etkisinin yanı sıra iklim değişikliğinin de bina sistemlerinin kapasitesinde uyumsuzluk, aşırı yüklenme, arızalanma ve bina performansında verimsizlik gibi binalar üzerinde önemli etkileri olması beklenmektedir [6, 7]. Ayrıca, birçok binanın uygunsuz yapı fiziği sebebiyle artan sıcaklıklar genel olarak ısıtma talebinde azalmaya ve soğutma talebinde artışa, dolayısıyla iklimlendirme sistemleri (klima) ihtiyacında ciddi bir artışa neden olmaktadır [8-10]. İklim değişikliğinin bina sakinleri üzerinde de ısı rahatsızlık, iç mekan aşırı ısınmasına bağlı hastalıklar, yüksek ölüm riski, üretkenlik ve performans kaybı gibi sonuçları gözlemlenmektedir. Tüm bu problemler, bina emisyonlarında artışa dolayısıyla iklim değişikliğinin daha fazla tetiklenmesine sebep olmaktadır ve sonuç olarak sürekli birbirini besleyen bir döngü halini almaktadır [6]. Bina kabuğu yoluyla enerji kaybını azaltmak ve iç mekânlarda ısı konfor şartlarını sağlamak için etkili eylemlerden biri cephedeki şeffaf bileşenlerin yani pencerelerin ısı performansını, alanını ve konumunu optimize etmektir [11, 12]. Cephe ile ısı alışverişinin yani enerji kayıplarının önemli bir kısmı pencere camları aracılığı ile gerçekleşmesi cam elemanlarının önemini artırmaktadır. Cam elemanlarının performans göz önüne alındığında, yalnızca ısı iletimin neden olduğu ısı kaybı veya kazançları değil, aynı zamanda gelen güneş ışınımının etkileri yani ısıtma, yapay aydınlatma talebinin azalması ve doğal havalandırma etkisi ile soğutma talebinin azalması da dikkate alınmalıdır. Binalarda ısıtma ve soğutma talebinin azaltılmasına yönelik çalışmalar [11], pencere yönü, boyutu ve camların ısı performans kriterlerinin etkisini dikkate almışlardır [13-16]. Bu kriterler iklim bölgelerine bağlı olarak çeşitli kombinasyonlar ile pencerelerin ısı performanslarının artırılması olanaklıdır. Farklı teknik özelliklere sahip cam seçeneklerinin yıllık soğutma enerjisi üzerine olan etkisi araştırılan çalışmalarda, camların ısı performansları iyileştirildiğinde iklimle ilgili olarak %0,5-2,7 aralığında bir azalma gözlemlenmiştir [17, 18]. Pencere açıklıklarının boyutu veya pencere-duvar-oranının (PDO) değiştirilmesi enerji tüketimi açısından her cephede farklı sonuçları beraberinde getirmektedir [19, 20]. PDO'nun azaltılması güney cephedeki mekânların ısıtma enerji talebi üzerinde olumlu sonuçlanırken kuzey cephe için aynı değişim olumsuz sonuçlanabilmektedir. Daha önce bahsedildiği üzere cam performansının iç mekân ısı konforu üzerinde de etkileri vardır. İklim bölgelerinin özelliklerine uygun olarak yapılan cam seçimleri ile en uygun konfor koşullarına ulaşılabilmektedir. Hindistan'da yapılan bir çalışmada 15 farklı cam tipinin ısı konforu üzerine etkileri araştırılmıştır ve karma iklim koşullarında ısı ve güneş kontrol camlarının iç konfor koşullarını sağlamakta en iyi performansı gösterdiği sonucuna varılmıştır [21]. Toplam enerji tüketiminin büyük bir kısmından sorumlu olan eğitim

binaları iklim değişikliği açısından önemli yapılarıdır [22, 23]. Örneğin ABD ve İngiltere'de okul binalarının enerji kullanımı toplam bina enerji kullanımının sırasıyla %13 ve %10'unu oluşturmaktadır [24]. Enerji tüketimi seviyesinin yanı sıra, diğer bina tipolojileri ile karşılaştırıldığında farklı ısı konfor gereksinimleri eğitim binalarını özel ve önemli kılmaktadır. İç ortam/mekân koşulları, hem öğrencilerin hem de öğretmenlerin performansı, üretkenliği, katılımı ve sağlığı üzerinde belirleyici bir rol oynamaktadır [25]. Ayrıca, yetişkinlere kıyasla çocuklar, yaşları, vücutları ve metabolizmalarındaki farklılıklar nedeniyle zayıf ısı konfor koşullarına karşı daha savunmasızdırlar [26]. Eğitim binalarının özellikle sınıfların genel olarak günün en sıcak saatleri olan öğlen saatlerinde tam kapasiteyle kullanılması yüksek seviyelerde ısı kazanımlarına ve iç mekânların aşırı ısınmasına sebep olmaktadır. Tüm bu sebeplerle son yıllarda eğitim binalarının performansı ve iyileştirme eylemleri dikkat edilmesi gereken önemli bir mesele haline gelmiştir.

Eğitim binası kullanıcılarının, özellikle öğrencilerin, iklim değişikliği ile beraber gerek artan olumsuz iç ortam koşulları problemi için acil önlemler alınmasını gerekmektedir. Var olan bina sistemlerini iyileştirmek, enerji kullanımını azaltmak ve bina kullanıcılarının konforunu sağlamak açısından uygun bir strateji olarak görülmektedir. Bu acil ihtiyaçlar, farklı iklimler, kullanıcı profilleri ve bina yapım teknikleri açısından eğitim binalarının performansını iyileştirmeyi amaçlayan birçok çabayı beraberinde getirmiştir [27-30]. İklim değişikliği etki değerlendirme çalışmaları [31-34], aktif ve pasif tekniklerin analizi [35-38] literatürde geniş çapta sunulmuştur. Bu çalışmalar çoğunlukla konut ve ofis binalarına odaklanırken, daha önce bahsedildiği gibi eğitim binaları son yıllarda dikkat çeken bir mesele haline gelmiştir. Bu nedenle, eğitim binalarının sera gazı emisyonlarını azaltmak için nasıl iyileştirilebileceği ve aynı zamanda iklim koşullarındaki değişikliklere nasıl uyarlatabileceği hala araştırılması gereken ve bilgi boşluğu bulunan bir konudur.

Farklı iyileştirme senaryolarının analizi, bina enerji performansı ile iyileştirilen parametreleri arasındaki ilişkiyi görmek açısından önem taşımaktadır. Veriye dayalı analiz yöntemleri genellikle istatistiksel veya makine öğrenmesi metotları olmak üzere ikiye ayrılır [39]. Birçok çalışmada, bu metotlar kullanılarak binaların enerji tüketiminde iyileştirme senaryolarının etkinliği iyileştirme uygulaması öncesi ve sonrası bina performansı kıyaslanarak hesaplanmıştır [40-42]. Örneğin, 857 bina üzerinde yapılan bir çalışmada, farklı iyileştirme çalışmaları kıyaslanmış, istatistiksel yöntemler ile %30-50 arasında enerji tasarrufu yapılabileceği saptanmıştır [42]. New York'ta yapılan başka bir çalışmada binalara uygulanacak farklı kategorilerdeki iyileştirme senaryolarının etkisi makine öğrenmesi yöntemleri ile tahmin edilmiştir [43]. Benzer bir çalışmada, makine öğrenmesi yöntemlerinden yapay sinir ağları kullanılarak ideal iyileştirme senaryosunun saptanması amaçlanmıştır. Olası iyileştirme senaryolarının etki tahminleri R²=0,941 doğruluk değeriyle hesaplanmıştır [44].

Bina performansı üzerinde baskın etkisi olan faktörlerin tespit edilmesi, daha iyi performans tahminlerinin yapılması, bina performansının bağlı olduğu parametrelerin anlaşılması ve buna uygun iyileştirme politikalarının geliştirilmesi için gereklidir [39]. Bu amaçla birçok çalışmada istatistiksel bir yöntem olan korelasyon katsayısı hesaplaması ve makine öğrenmesi yöntemlerinden regresyon analizi yapılması sıkça tercih edilen yöntemler arasında olmuştur [45-48]. Başta olmak üzere, makine öğrenmesi modelleri içerisine gömülü öznitelik seçimi (feature selection) modülleriyle tahmin performansını etkileyen önemli parametrelerin tespitinde yöntemler arasındadır [49]. Örneğin, Tsanas ve Xifara (2012), 8 farklı değişken ile modelledikleri binaların, ısıtma ve soğutma yüklerini

Rastgele Orman (RO) makine öğrenmesi modelleriyle tahmin etmiş, değişkenlerin korelasyon ve önemlilik önem (feature importance) sıralamalarını hesaplamıştır. Yaptıkları analizler sonucunda cam alanının, incelendikleri 8 değişken arasında ısıtma ve soğutma yükünü etkileyen en önemli değişken olduğunu saptamıştır. Çalışmada, şeffaf yapı elemanlarına odaklanarak, farklı değişkenlerin etkisi RO önemlilik seçimi yöntemiyle detaylıca analiz edilmiştir. Cam alanının, ısıtma ve soğutma modelleri için sırasıyla yaklaşık %93 ve %87 öneme sahip olduğu bulunmuştur; diğer değişkenlerin önemlilik önemleri toplandığında tüm tahmin kapasitesi %100'e ulaşmaktadır.

Mevcut çalışma, iklim değişikliği altında eğitim binalarının performansını ve pencere özelliklerinin performans üzerindeki etkisini incelemeyi amaçlamaktadır. Çalışmada simülasyona dayalı sistematik bir yöntem izlenmiştir. İklim değişikliği etkisi gözetilerek analiz edilen bir vaka çalışması binası için pencere parametrelerine dayalı 2025 iyileştirme senaryosu hazırlanmıştır. Senaryoların günümüz ve 2050 performansları ısı yükü, enerji tüketimi, küresel ısınma potansiyeli ve maliyet olarak sunulmuştur. Simülasyona dayalı yöntemler ile üretilen bu veriler literatürde bulunan çalışmalardan farklı olarak hem bina ısı yükü hem de kullanıcı ısı konforu için bütünsel bir şekilde, makina öğrenmesi ile önemlilik önem yöntemleri ile analiz ederek pencere parametrelerinin bina performansına etkilerinin belirgin olarak anlaşılmasına ve en etkin iyileştirme senaryosunun belirlenmesine imkan sağlamaktadır. Performans göstergelerinin simülasyon tabanlı değerlendirmeleri için Ankara, Türkiye'deki mevcut bir ortaokul binası vaka çalışması olarak seçilmiştir.

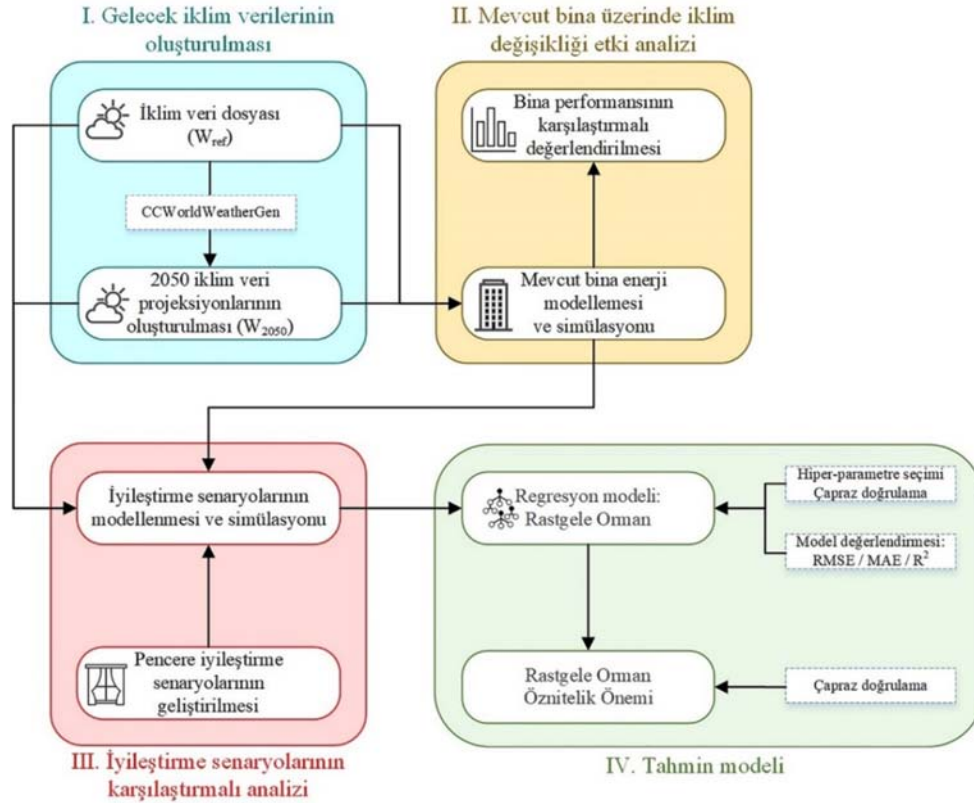
2. Metodoloji (Methodology)

Bu çalışma, iklim değişikliği etkisi altındaki eğitim binalarının iyileştirilmesi için sistematik, enerji simülasyon sonuçlarının

istatistiksel ve makine öğrenmesi yöntemleriyle analizine dayalı dört aşamalı bir değerlendirme yaklaşımı izlenmektedir (Şekil 1). İlk olarak, gelecek iklim verileri oluşturularak iklim verileri karşılaştırmalı olarak analiz edilmiştir. Daha sonra, Ankara'da mevcut bir eğitim binası üzerinde EnergyPlus motoru ve Ladybug Tools yardımıyla enerji modeli oluşturulmuştur [51] ve iklim değişikliği analizi yapılmıştır. Bu analizler sonucunda farklı pencere parametreleri belirlenmiştir ve bu parametreler ile 2025 farklı enerji modeli oluşturulmuştur. Ardından, bu modellerin referans ve 2050 yılı için hesaplanmış iklim verileri ile enerji simülasyonları gerçekleştirilmiş ve performans değerlendirme kriterleri (enerji tüketimi ve ısı konfor) hesaplanmıştır. Değerlendirme parametreleri göz önünde bulundurularak, seçilen pencere parametrelerinin duyarlılığı, simülasyon verisinin istatistiksel analizi ve RO regresyon algoritması ile değerlendirilmiştir. Günümüz ve 2050 yılı için üretilen veriler, veri ön işleme ve keşfinden sonra, iki ayrı rastgele orman modeli eğitilerek tahmin edilmiştir. Tahmin modellerinin performansı değerlendirilmiş ve günümüz ile 2050 yılı için seçilen performans göstergeleri için girdi değişkenlerinin önemi hesaplanmıştır. Makine öğrenimi modeli Python programlama dili ile sci-kit learn kütüphanesi [52] ile oluşturulmuştur. Tanımlanan metodoloji, pencere parametrelerinin performans göstergeleri üzerindeki göreceli önemini de değerlendirmektedir.

2.1. Gelecek iklim verilerinin oluşturulması (Generation of future weather files)

EnergyPlus, simülasyonlarda mevcut iklim koşullarını temsil eden EPW formatlı, 8760-saatlik veri dosyalarını kullanır. Bu çalışmada, Ankara ili 2050 yılı iklim veri dosyalarını oluşturmak için CCWorldWeatherGen kullanılmıştır. CCWorldWeatherGen, Hükümetler Arası İklim Değişikliği Paneli (IPCC) Üçüncü Değerlendirme Raporu küresel dolaşım modellerinin özet verilerini



Şekil 1. Önerilen analiz yaklaşımı (Proposed analysis approach)

kullanılarak, tipik bir meteorolojik yılı temsil eden istatistiksel 8760 saatlik iklim veri dosyalarını (.epw formatında) gelecek yıllar için modifiye eder (Jentsch, James ve Bahaj, 2012). Bu çalışmada, Hadley Center Birleştirilmiş Modeli, versiyon 3 ile A2 emisyon senaryosu (HadCM3 A2) kullanılmıştır. HadCM3 A2, orta CO₂ emisyon senaryolarından biridir ve gelecekteki iklim değişikliğini dengeli bir şekilde öngören genel bir sirkülasyon modelidir. Fakat, genel sirkülasyon model çıktılarını aylık bir çözünürlükle ifade edilir ve bu değerler bina performans simülasyonu amaçlarına uygun değildir. Bu sebeple, bir ölçek küçültme yöntemi olan dönüştürme (morphing) yöntemlerinden faydalanılır. CCWorldWeatherGen, Belcher vd. tarafından geliştirilen dönüştürme yöntemini kullanmaktadır [53]. Dönüştürme yöntemi, referans iklim verisi dizinlerini korurken, düşük ayrıntı düzeyine sahip iklim tahminlerini yüksek ayrıntı düzeyine sahip saatlik zaman serilerine çevirir. Dönüştürme yöntemi üç kapsamlı işlem içerir; i) kaydırma (shift), ii) doğrusal germe (linear stretch) ve iii) kaydırma ve doğrusal germe kombinasyonu [53]. Kaydırma işlemi iklim değişikliği senaryosu ortalamada mutlak bir değişiklik listelediğinde kullanılır. Mutlak bir artış yerine yüzde veya kesirli değişiklik olarak belirtilen ortalama veya varyansta bir değişiklik olduğunda veya olduğu gibi değişken tamamen kapatılabildiğinde doğrusal germe işlemi kullanılır. Hem ortalamanın hem de varyansın değiştirilmesi gerektiğinde kaydırma ve doğrusal germe kombinasyonu kullanılır [53]. CCWorldWeatherGen de bu işlemleri kullanarak referans EPW dosyasını kullanarak gelecek için ortalama sıcaklık, bağıl nem, güneş ışınımı, rüzgar hızı, atmosferik basınç ve yağış iklim değişkenlerini hesaplar ve bu değişkenlerinin saatlik değerlerini içeren EPW formatlı yeni bir iklim dosyası üretir.

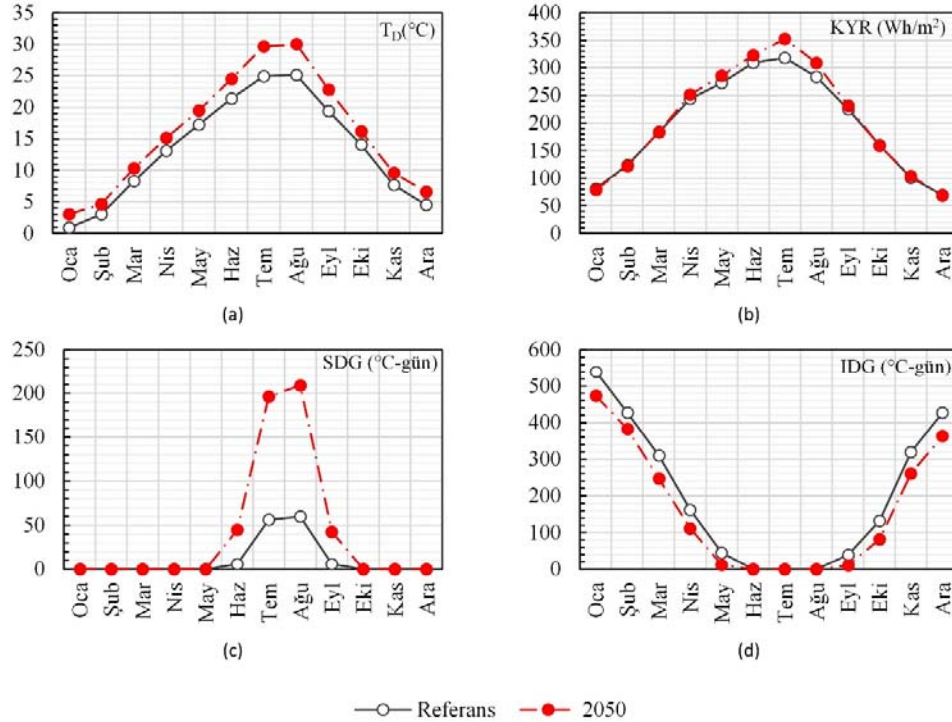
Hem referans (W_{ref}) hem de 2050 (W_{2050}) EPW dosyaları kullanılarak, ısıtma ve soğutma derece-gün (IDG ve SDG) değerleri, ortalama dış ortam kuru termometre sıcaklığı (T_D) ve küresel yatay radyasyon (KYR) metriklerini hesaplamak için kullanılmaktadır. W_{ref} ve W_{2050} hava verilerine göre hesaplanan aylık ortalama değerleri Şekil 2'de

sunulmuştur. Yıllık ortalama T_D 'da 2,83°C artış gözlemlenirken, yaz aylarında saatlik fark 5°C'ye kadar çıkmaktadır. Özellikle bu çalışmada, binanın kullanıldığı en sıcak olan Haziran ayı, kullanıcı ısı konforu açısından önem kazanmaktadır. Haziran ayı ortalama T_D değerleri referans yıl ve 2050 için sırasıyla 25,6°C ve 28,9°C'dir. KYR bina enerji kullanımı ve ısı konforu etkileyen önemli bir metriklerden biridir. Hesaplanan aylık ortalama KYR değerleri Şekil 2b'de sunulmuştur. Yıllık ortalama KYR 198,3 Wh/m²'den 205,5 Wh/m²'ye artmıştır.

Isıtma ve soğutma derece-gün değerleri (IDG ve SDG) binada konfor sıcaklığını korumak için gerekli olan ısıtma ve soğutma şiddetini göstermektedir. Bu çalışmada IDG ve SDG değerlerinin hesaplanması için baz sıcaklık, soğutma ve ısıtma için sırasıyla 18,3°C ve 23,3°C olarak alınmıştır. Aylık ortalama IDG ve SDG değerleri Şekil 2, Şekil 2c ve Şekil 2d'de sunulmuştur. İklim değişikliği ile yıllık IDG değerlerinin 460°C-gün azalması, yıllık SDG değerlerinin ise 365°C-gün artması beklenmektedir.

2.2. Bina performans değerlendirilmesi (Evaluation of building performance)

Bina performans değerlendirmesinde, bina enerji kullanımı ve sınıfların ısı konforunun simülasyona dayalı karşılaştırmalı bir analizini yapılması amaçlanmaktadır. Bir enerji modeli sadece binanın mevcut durumunun performans kriterlerini ölçmekle kalmaz, aynı zamanda performansını iyileştirmek için alternatif eylem yollarının üretilmesine ve araştırılmasına izin veren bir "deney kutusu" görevi görür [54]. İlk olarak, vaka çalışması olarak incelenen okul binasının bina enerji modeli geliştirilmiştir. Bu binanın verileri (malzemeler, ısıtma/soğutma dereceleri, kullanım gün/saatleri, iç ısı yükleri) bina etütleri ve bina belgelerinden elde edilmiştir. Simülasyonlarda ısıtmanın tüm bina için yapıldığı dikkate alınmış ve hesaplanan ısıtma yükleri kWh/m²-kullanım alanı olarak sunulmuştur. Soğutma ise



Şekil 2. Aylık ortalama a) T_D (°C), b) KYR (Wh/m²), c) SDG (°C-gün), ve d) IDG (°C-gün) değerleri (Monthly average a) T_D (°C), b) KYR (Wh/m²), c) SDG (°C-day), and d) IDG (°C-day) values)

sadece ofis ve öğretmen odalarında yapılmaktadır. Bu sebeple, soğutma yükleri kWh/m²-soğutulan alan olarak sunulmuştur. Ayrıca, elde edilen ısıtma yükleri üzerinden KIP ve maliyet hesapları yapılmış, bu hesaplamalarda kazan verimi ve klima sisteminin performans katsayısı da dikkate alınmıştır. Maliyet hesaplarında [10]'de tanımlanan yöntem ve değerler kullanılmıştır.

Binada klima ile soğutulmayan odalarda aşırı ısınma problemleri, çeşitli sağlık sorunlarına, verim düşüklüğüne ve dikkat bozukluklarına neden olabilir. Eğitim binalarının kullanıcıları, bahar ve yaz aylarında özellikle dersliklerde uzun süreler ısıya maruz kalmaktadır ve bu durum iklim değişikliği ile daha da zorlaşacaktır. Bu nedenle, ısı konforu, temel bir performans kriteri olarak değerlendirilmelidir. Bu çalışmada, sınıfların ısı konforu, iç ortam aşırı ısınma derecesi (İAD) dikkate alınarak değerlendirilmiştir. İAD, aşırı ısınmanın yoğunluğunu ve sıklığını göz önünde bulundurarak iç ortam ısı stresinin derecesini belirleyen bir metriktir [55]. İAD modeline göre, iç ortam operatif sıcaklığı (OT), ısı konfor sıcaklık limiti (TL_{konf})'un üzerine çıktığında bina kullanıcıları aşırı ısınma yaşar. TL_{konf} değerinin belirlenmesinde farklı ısı konfor modelleri benimsenebilmektedir. Bu çalışmada, TL_{konf} belirlenirken adaptif konfor modeline dayanan adaptif sıcaklık limiti ve ASHRAE 55-2010 tarafından belirtilen %80 kabul edilebilirlik sınırı kullanılmıştır [56]. Adaptif model genelde özellikle doğal havalandırılmalı binalarda uygulanır ve kullanıcıların kıyafetlerini ve aktivite seviyelerini değiştirerek ısı ortama uyum sağlamaları prensibine dayanır. Bu modelde kullanıcı ısı konfor algısı, iç hava sıcaklığı ve dış hava sıcaklığı arasında tanımlanan lineer matematiksel eşitlikler üstünden kurgulanır. Önce nötr konfor sıcaklıkları (T_{n,ay}) ile aylık ortalama dış hava sıcaklıklarını (T_{ort,ay}) ilişkilendirilir (Eş. 1); ardından, T_{n,ay} değerleri kullanılarak belirli bir z zonu için ısı konfor üst sınırı (TL_{konf,i,z}) hesaplanır (Eş. 2) [56]. Bir binanın aylık ortalama İAD'si Eş. 3 ile ifade edilir. Eşitlikte i dolu saatleri, N_{dolu(z)} hesaplama periyodunda z zonu dolu olduğu toplam saati ve OT_{i,z} z zonu için saatteki operatif sıcaklığı temsil eder. t ise zaman adıdır ve 1 saat olarak alınmıştır.

$$T_{n,ay} = 0.31T_{ort,ay} + 17,8 \quad (1)$$

$$TL_{konf,i,z} = T_{n,ay} + 2,5 \quad (2)$$

$$\dot{I}AD_{ay} = \frac{\sum_{i=1}^{N_{dolu(z)}} [\max\{OT_{i,z} - TL_{konf,i,z}, 0\} \times t_{i,z}]}{\sum_{i=1}^{N_{dolu(z)}} t_{i,z}} \quad (3)$$

Bu çalışmada, öncelikle vaka binasının aylık İAD değerleri incelenmiş, ardından binanın kullanıldığı en sıcak ay olan Haziran ayına odaklanılmıştır. Isıl konfor analizi sadece sınıflarda yapılmıştır ve yukarıdaki eşitliklerdeki z, sadece sınıfları ifade etmektedir.

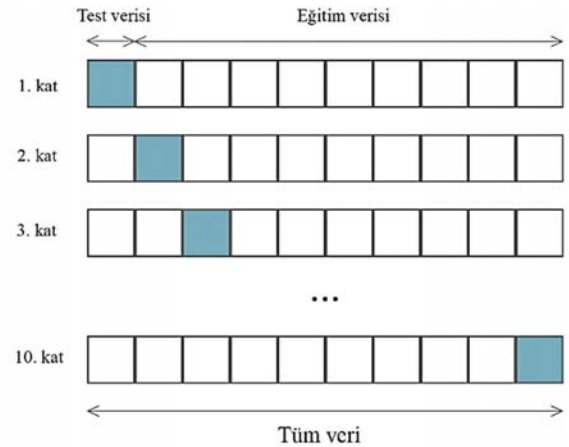
2.3. Veri Analizi: İstatistiksel Analiz ve Tahmin Modelleri (Data Analysis: Statistical Model and Prediction Models)

Simülasyonlar sonucunda elde edilen çıktı verilerinin dağılımını kontrol etmek için Shapiro-Wilk normallik testi yapılmıştır ($\alpha = 0,05$). Veri dağılımı Gauss olmayan (Non-gaussian) olduğundan, değişkenler arasındaki monotonik ilişkiyi değerlendirmek için Spearman korelasyon katsayısı (ρ) hesaplanmıştır ve değişken bağımlılığını yakalamak için bir korelasyon matrisi oluşturulmuştur. Bu ilişkilerin istatistiksel olarak anlamlılığı p değeri 0,05 anlamlılık düzeyi ile hesaplanmıştır. p değeri $< 0,05$ olduğunda değişkenlerin korelasyonu istatistiksel olarak anlamlıdır.

Çoklu doğrusal regresyon, yapay sinir ağları, karar ağaçları (KA) ve destek vektör makineleri dahil olmak üzere bina performansını tahmin etmek için çeşitli makine öğrenme teknikleri kullanılmaktadır [57].

KA, performans tahmini oluşturmak için kullanılan, denetimli (supervised) makine öğrenme tekniklerinin önemli yöntemlerinden biridir. KA, veri kümesinde aykırı değerler veya hatalı veri noktaları olduğunda, k-en yakın komşu veya diğer parametrik olmayan yöntemler gibi diğer yöntemlerden daha iyi performans gösterir [58]. Ayrıca, KA uygulaması, sinir ağları gibi "kara kutu" modellerine göre anlaşılabilirlik açısından daha avantajlıdır [59]. Bu nedenle, bu çalışma için KA metodlarından Rastgele Orman (RO) algoritması seçilmiş ve kullanılmıştır.

Temel olarak KA metodlarında, girdi özellik uzayı, çıktıları artıran homojenlik seviyeleri ile öz-yinelemeli olarak daha küçük gruplara bölünür. Regresyon ağacı, bölünmeyi kontrol eden kriter karşılana dek, diğer bir deyişle daha fazla bölünmeye gerek kalmayınca kadar büyür. Bu aşamada, ağaç karmaşıklığını kontrol etmek için kriterlerin seçimi çok önemlidir. Bölünme işlemi, kök düğümde gözlem uzayında başlar ve bölme işlemine gerek kalmayana, yani yapraklara ulaşana kadar bölünme devam eder. RO [60], birden çok KA'nın tahminlerini birleştiren bir topluluk (ensemble) modelidir. Regresyon ağacında olduğu gibi tek bir ağacın tahminlerine güvenmek yerine, RO'da tahminler bir dizi ağaç üzerine kuruludur. Sonuç olarak, tek bir regresyon ağacına kıyasla daha sağlam ve güvenilir sonuçlar verir. Birden fazla ağaç yetiştirmek için tahminde yeniden örnekleme (bootstrap samples) ve rastgelelik kullanılır. Bütün veri setinden, eğitim için ayrılan veri setiyle aynı büyüklükte rastgele seçilen bir değişken alt kümesi, KA benzeri bir algoritma ile aktarılır. Farklı KA'ların oluşan bir orman, diğer bir deyişle ağaçlar topluluğu oluşur. RO regresyon tahmini için, her bir ağaç tahmininin ortalaması alınır.



Şekil 3. 10-kat çapraz doğrulama yöntemi diyagramı (10-fold cross validation method diagram)

Daha iyi bir tahmin performansı için RO modeli hiper-parametrelerinin ayarlanması (hyperparameter tuning) gerekir. Öğrenme oranı (learning rate), alt örnek boyutu (subsample size) veya gama gibi model parametreleri tahmin performansında belirleyici etkiye sahiptir. Bu nedenle, optimize edilmiş hiper-parametrelerle en iyi tahmin modellerini oluşturmak için çapraz geçerlilik (cross validation) eşliğinde hiper-parametre uzayı grid-tarama (grid-search) yöntemiyle test edilir. Ardından, performansı güçlü bir şekilde tahmin etmek için yaygın olarak kullanılan bir 10-kat çapraz doğrulama (10-fold cross validation) yöntemi kullanılmıştır [61] ve tahmin modeli değerlendirme sonuçları çapraz doğrulama sonuçlarına dayandırılmıştır (Şekil 3). Tahmin modeli değerlendirmesi için ortalama karekök hata (Root Mean Square Error-RMSE), ortalama mutlak hata (Mean Absolute Error-MAE) ve R-kare (R²) hesaplanır Eş. 4-Eş. 6. Eşitliklerde p_i , tahmini değeri, a_i , gerçek değer ve n, veri kümesindeki veri noktalarının sayısıdır.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (p_i - a_i)^2}{n}} \quad (4)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |p_i - a_i| \quad (5)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (p_i - a_i)^2}{\sum_{i=1}^n (p_i - \bar{a}_i)^2} \quad (6)$$

Değişken önemi, tahmin doğruluğu sunan değişkenlerin etkileşiminin anlaşılmasını sağlar. Regresyon modelinin öznitelik önem sıralaması analizi, hedef değişken ile girdi değişkenlerinin ilişkisini anlamada birçok çalışmada kullanılmıştır [50]. Bu çalışmada, değişkenlerin önemini hesaplamak için literatürde mevcut bir yöntem kullanılmıştır [60]. Bu yöntemin hesaplama ilkesi, karar ağacının oluşma sürecine dayanmaktadır. Bir değişkenin önemi, ağaç düğümü ayrımı için toplam seçilme sayısı aracılığıyla değerlendirilebilir. Öznitelik önem sıralaması, girdi değişkenin etkileşimine bağlı olarak model performansı hakkında fikir verebilmektedir. Önem sıralamalarının geçerliliğini arttırmak amacıyla 10-kat çapraz doğrulama yöntemi kullanılarak farklı eğitim veri setleri ile önem değerleri hesaplanmıştır. Bu hesaplamaların ortalaması alınarak sonuçlar yorumlanmıştır.

3. Vaka Çalışması (Case study)

İklim değişikliğinin eğitim binalarının iyileştirme senaryolarının performansı üzerindeki etkisi, temsili bir vaka çalışması olarak bir ortaokul binası aracılığıyla araştırılmıştır.

3.1. Enerji simülasyonları için bina enerji modellemesi (Building energy modeling for energy simulations)

Vaka çalışması olarak seçilen eğitim binası, yapım yılı, doluluk düzeni, ısıtma ve soğutma sistemleri açısından eğitim binalarını büyük oranda temsil eden tipik bir ortaokuldur ve Ankara'da yer almaktadır. Ankara iklimi, Köppen iklim sınıflandırmasına göre Csb (İç Akdeniz) kategorisinde ve yazları sıcak ve kurak, kışlar soğuk ve karlı geçmektedir. Binanın güney ve doğusunda Orta Doğu Teknik Üniversitesi (ODTÜ) kampüsü ve ormanı bulunmaktadır. Kampüs içerisinde ODTÜ koleji ve ODTÜ'ye ait az katlı eğitim binaları, ofis ve depo binaları bulunmaktadır. Kampüs alanının kuzey ve batı sınırında Ankara'nın iki ana bulvarı olan Dumlupınar ve Bilkent bulvarları ve kentsel olarak yüksek yoğunluğa sahip bir muhit yer almaktadır. Bina alanına komşu kentsel alanda, yüksek ofis binaları, kamusal binalar ve çok büyük bir hastane kompleksi yer almaktadır.


Bina 1996 yılında inşa edilmiştir ve 8.303,78 m² olup 76 sınıf veya derslik, idari personele ayrılmış 18 ofis, 6 öğretmen odası, bir

kütüphane, bir yemekhane, 3 depo ve 12 WC'den oluşmaktadır (Şekil 4). Binada 10-14 yaş arası 987 öğrenci, 94 öğretmen ve 21 idari personel olmak üzere toplam 1.102 kişi hizmet vermektedir. Kafeterya 3,9 m tavan yüksekliğine sahiptir. Kalan bölgelerin tavan yüksekliği 3,2 m'dir. Temel bina özellikleri, mahal parametreleri ve binada kullanılan opak malzemeleri sırasıyla Tablo 1'de listelenmiştir. Ekipman ve aydınlatma yükleri, infiltrasyon oranı ve havalandırma yükü ASHRAE Standartlarına dayandırılmıştır [62]. Cephe malzemeleri saha çalışması ile belirlenmiştir. Binada alüminyum çerçeveli çift cam (U-değeri=2,7 W/m²K, SHGC=0,75, VT=0.80) kullanılmıştır. PDO 0,30'dur.

Kullanım açısından en kritik mekanlar olarak sınıflar, ofisler ve öğretmen odaları belirlenmiştir. Sınıflar, Eylül ayının başından haziran ayının sonuna kadar hafta içi 08:00-17:00 saatleri arasında 24 öğrenci tarafından kullanılmaktadır. Ofisler ve öğretmen odaları tüm yıl boyunca kullanımda olmakla birlikte, bu alanlar Temmuz ve Ağustos aylarında %80 kapasite ile kullanımda olacak bir şekilde tanımlanmıştır. Bina doğalgazlı merkezi ısıtma sistemine sahiptir. Toplam ısıtılan zemin alanı 8.303,78 m²'dir. Isıtma termostat dereceleri tüm mekanlar için 19:00-06:00 saatleri arası 18°C, kalan zamanlar için 21°C olarak ayarlanmıştır. Mekânsal ısıtmanın %80 verimle çalışan, KIP değeri 0,181 kg-CO₂eş/kWh olan bir doğal gaz kazanı ile karşılandığı varsayılmıştır [63-65]. Tüm bina için temel soğutma yöntemi, iç hava sıcaklığı 23,5°C'nin üzerinde olduğunda aktif olduğu varsayılan doğal havalandırmadır. Ayrıca soğutma döneminde (Mayıs-Ekim) sadece ofis ve öğretmen odalarında iç ortam sıcaklığı 25°C üstüne çıktığında aktive olan, 3,8 performans katsayılı (COP), şebeke elektriğine bağlı split tip klimalar kullanılmaktadır. Bu şekilde soğutulan zemin alanı 910,63 m²'dir. Mevcut, şebeke elektriği doğal gaz, kömür ve hidroelektriğe dayanmaktadır ve 0,557 kg-CO₂eş/kWh karbon yoğunluğuna sahiptir [9,66]. Kampüs binalarına doğal gaz veya elektrik sayaçları takılmaması sebebiyle, enerji modelinin kalibrasyonunu sağlayabilecek bilgilere erişmek mümkün olmamıştır. Ancak, ayrıntılı rölöve çalışmaları ve okul idari amirinden edilen detaylı bilgiler, binanın detaylı ve güvenilir bir enerji modeli geliştirilmesine olanak tanımıştır. Ayrıca, bu çalışmada kötümser bir yaklaşım benimsenerek 2020 ve 2050 yılları arasında Türkiye elektrik üretim teknolojilerindeki değişimin sınırlı kalacağı ve ısıtma/soğutma sistemi teknolojilerinin ve verimliliğinin değişmeyeceği varsayılmıştır.

3.2. İyileştirme senaryoları (Retrofit scenarios)

İyileştirme senaryoları, ısıtma ve soğutma yükünü azaltmayı, CO₂ emisyonlarını azaltmayı ve aşırı ısınmayı azaltmayı amaçlayan bina kabuğu üzerindeki şeffaf yapı elemanları aracılığı ile pasif önlemleri dikkate alır. Enerji iyileştirme ile ilgili önceki çalışmalar, opak ve şeffaf yapı elemanları yoluyla iletken ısı kazancını/kaybını



Şekil 4. Çalışma binasının güneydoğu (sol) ve kuzeybatı (sağ) görünüşleri (Turuncu: derslik, Mavi: ofis, Kahverengi: öğretmenler odası, Beyaz: Kafeterya, Sarı: koridorlar, Açık gri: tuvaletler, Koyu gri: depo) (Southeast (left) and northwest (right) views of the case building (Orange: classroom, Blue: office, Brown: teachers' room, White: cafeteria, Yellow: corridors, Light grey: toilets, Dark grey: storage))

azaltmanın, farklı gölgeleme elemanları veya cam özellikleriyle doğrudan güneş kazancını azaltmanın, düşük güneş absorpsiyonlu ve yüksek termal emisyonlu kaplamaların, etkin havalandırma kullanımının ve ısıtma/soğutma ayar noktalarındaki değişikliklerin önemini vurgulamaktadır [44,67-70]. Bu çalışmada, vaka çalışması olarak ele alınan eğitim binasının, pencere U-değeri ($U_{pencere}$), güneş ısı kazanc faktörü ve dört cephesindeki PDO değerleri değiştirilerek, iyileştirme senaryoları incelenmiştir. İncelenen girdi parametreleri bağımsız değişkenlerdir. Girdi parametreleri ile toplamda 2025 ($5 \times 5 \times 3 \times 3 \times 3 \times 3$) farklı senaryo modellenmiş ve enerji simülasyonları seçilen performans göstergeleri ile değerlendirilmiştir (Tablo 3). Günümüz ve 2050 yılı kıyaslaması için aynı iyileştirme senaryoları kullanılmıştır.

4. Bulgular (Results)

4.1. İklim değişikliğinin mevcut bina performansına etkisi (Impact of climate change on the performance of the existing building)

Bu bölüm, iklim değişikliğinin eğitim binası enerji tüketimine ve kullanıcı konforuna etkisini tartışmaktadır. Referans (W_{ref}) ve 2050 (W_{2050}) yıllarının karşılaştırmalı bir analiz için hem W_R hem de W_{2050} iklim verileri kullanılarak saatlik enerji tüketim ve operatif sıcaklık değerleri EnergyPlus simülasyon aracı ile hesaplanmıştır. Parantez

içerisinde sunulan değerler referans yılı ve 2050 yılı değerlerini yansıtmaktadır.

4.1.1. Enerji kullanımı (Energy consumption)

Mevcut eğitim binasının W_{ref} ve W_{2050} için hesaplanan yıllık ısı yükler Şekil 5'te özetlenmiştir. Bu çalışmada, referans yılı ile 2050 arasında iç yükler (kullanıcılar, ekipman ve aydınlatma) kaynaklı ısı kazanımlarının değişmeyeceği varsayılmıştır. Referans yılından 2050 yılına KYR'daki hafif yükseliş, güneş enerjisi kazanımlarında sınırlı bir artışa ($63,23 \rightarrow 64,43 \text{ kWh/m}^2$) neden olacaktır. Dış yükler büyük ölçüde iç ortam ile dış ortam arasındaki sıcaklık farkına bağlıdır. Artan T_D ile bu fark düşecektir. Opak yüzeylerden ($-46,78 \rightarrow -23,41 \text{ kWh/m}^2$) ve camlardan kondüksiyon ($-19,20 \rightarrow -14,41 \text{ kWh/m}^2$) ile ısı taşınımına, mekanik havalandırmaya ($-61,29 \rightarrow -53,56 \text{ kWh/m}^2$) ve infiltrasyona ($-12,39 \rightarrow -10,87 \text{ kWh/m}^2$) bağlı kayıplar azalacaktır. Neticede, bina yıllık ısıtma yükü (Q_1) ($59,17 \rightarrow 39,50 \text{ kWh/m}^2$) düşecektir. Ayrıca, ısıtma süresi (günlük ısıtma yükünün $0,01 \text{ kWh/m}^2$ 'i aştığı süre $203 \rightarrow 183$ gün) kısıllanacaktır (Şekil 6a). Daha düşük ısı geçirgenliğe sahip malzemelerin kullanımı ile opak ve cam yüzeylerden iletken ısı kayıpları azaltılarak ısıtma yükü etkin bir şekilde azaltılabilir. Vaka binasında soğutma için tüm binada birincil olarak doğal havalandırma kullanılmaktadır. Ek olarak ofisler ve öğretmen odaları klimalıdır. Gelecekte, artan sıcaklıklar soğutma

Tablo 1. Temel bina özellikleri (Main building properties)

Toplam taban alanı	8.303,78 m ²
İnşaat yılı	1996
Yapısal Sistem	Betonarme
Odalar	76 derslik, 18 idari personele ayrılmış ofis, 6 öğretmen odası, 1 kütüphane, 1 yemekhane, 3 depo ve 12 WC
Kullanıcı sayısı	1102 kullanıcı - 987 öğrenci, 94 öğretmen ve 21 idari personel
Tavan yüksekliği	Kafeterya 3,9 m; kalan alanlarda 3,2 m
Isıtma sistemi (tüm bina)	%80 verimli doğal gaz yakıtlı kazan Isıtma termostat dereceleri, 06:00-19:00 arası = 21°C, 19:00-06:00 arası = 18°C Isıtma dönemi: Kasım-Nisan
Soğutma sistemi (sadece ofislerde ve öğretmen odalarında)	Split klimalar, COP = 3.80 Soğutma ayar noktası = 25,5°C Soğutma dönemi = Mayıs-Ekim
Cephe yapı malzemeleri	Dış duvar: yalıtımsız tuğla duvarlar: U-değeri = 1,23 W/m ² K Çatı: yalıtımsız düz çatı, U-değeri = 2,96 W/m ² K Pencere: Çift camlı pencereler, U-değeri = 2,7 W/m ² K, SHGC = 0,75, VT = 0,80

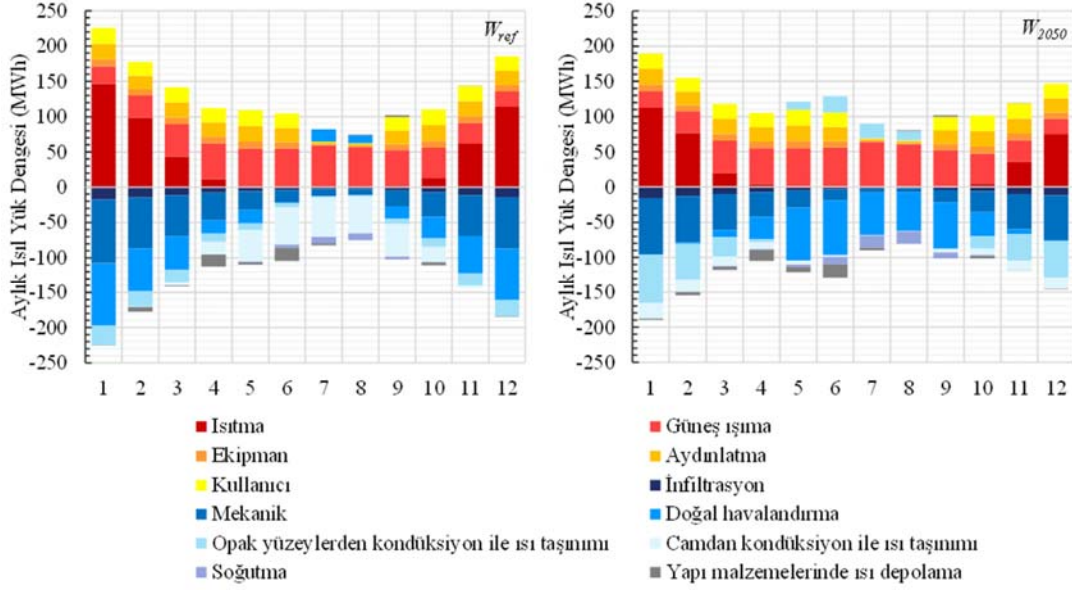
Tablo 2. Zon parametreleri (*) (Zone parameters *)

Parametre	Birim	Sınıf	Ofis	Öğretmenler Odası	Kütüphane	Kafeterya	Depo	WC	Koridor
Ekipman	W/m ²	7,31	7,85	5,00	7,31	14,00	7,85	2,90	2,90
Aydınlatma	W/m ²	15,06	11,85	11,85	12,91	9,68	5,50	9,68	5,38
Kullanıcı	kişi/m ²	0,04	0,01	0,07	0,22	0,68	0,05	0,09	1,10
İnfiltrasyon	m ³ /s-m ²	0,0002	0,0002	0,0002	0,0002	0,0002	0,0002	0,0002	0,0002
Havalandırma	m ³ /s-kişi	0,0047	0,0023	0,0023	0,0047	0,0035	0,0023	0	0

(*) Kullanıcı sayısı saha çalışması ile belirlenmiştir. Kalan diğer zon parametreleri [65]'den alınmıştır.

Tablo 3. Girdi parametreleri (Input Parameters)

Parametre	Birim	Dağılım	Alt limit	Üst limit	Artış
$U_{pencere}$	W/m ² K	Ayrık tekdüze	0,5	3,5	0,5
SHGC	-	Ayrık tekdüze	0,25	0,8	0,01
PDO (her yön için)	%	Ayrık tekdüze	0,1	0,5	0,2



Şekil 5. Aylık ısı yük dengesi (sol) W_{ref} ve (sağ) W_{2050} (Monthly thermal loads (left) W_{ref} and (right) W_{2050})

ihtiyacı da arttıracaktır. İlkbahar ve sonbahar mevsimlerinde en üst seviyeye ulaşan doğal havalandırma (-36,15→-50,54 kWh/m²) kaynaklı ısı kayıpları yükselecektir. Doğal havalandırma sadece iç ortam hava sıcaklığı dış ortam sıcaklığından daha düşük olduğunda etkili olmakta, etkinliği yaz aylarında azalmaktadır. Bu sebeple, yüksek yaz sıcaklıklarında doğal havalandırma aşırı ısınmaya karşı etkili bir çözüm olmaktan çıkar. İklim değişikliği ile beraber klima kullanımı artacak (yıllık soğutma yükü (Q_s) soğutulan birim alan başına 32,49→65,02 kWh/m²) ve yıllık soğutma süresi (günlük soğutma yükünün 0,01 kWh/m²'i aştığı süre 105→140 gün) uzayacaktır (Şekil 6a). Yılın en sıcak aylarında (Temmuz-Ağustos) öğrencilerin ve bazı çalışanların tatilde olması iç yükleri düşürür. Bu nedenlerle, vaka çalışmasında hesaplanan yıllık soğutma yükü, yıl boyunca dolu olan ve tamamen klimalı binalara nispeten daha düşüktür.

Elde edilen ısıtma ve soğutma yükleri kullanılarak ısıtılan veya soğutulan alan başına hesaplanan günlük KIP ve maliyet değerleri Şekil 6b, Şekil 6c'de sunulmuş ve yıllık değerler Tablo 4'de özetlenmiştir. Isıtma kaynaklı enerji tüketimindeki 33%'lik düşüşe (73,96 → 49,38 kWh/m²) paralel olarak KIP (13,39 → 8,94 kg-CO₂eq/m²) ve maliyet (1,6683 → 0,8158 \$/m²) değerlerinde önemli azalmalar beklenmektedir. Bununla beraber, soğutma kaynaklı enerji tüketimindeki 100%'lik artışa (8,55 → 17,11 kWh/m²) paralel olarak KIP (4,76 → 9,53 kg-CO₂eq/m²) ve maliyet (1,0859 → 1,5917 \$/m²) değerleri yükselecektir.

4.1.2. Kullanıcı ısı konforu (Occupant thermal comfort)

Bu çalışmada, kullanıcıyı ısı konforu İAD ile değerlendirilmektedir. İAD, OT ve TL_{konf} arasındaki sıcaklık farkı (ΔT) kullanılarak ölçülür. Bu çalışmada, ısı konfor sadece sınıflar için tartışılmıştır. Zira, ofisler ve öğretmen odaları ise klimalıdır ve bu alanlarda İAD ihmal edilebilir. Sınıflar ise kullanıcı sayısı ve kullanım süresi açısından en yoğun kullanılan alanlar olmasına rağmen sadece doğal havalandırma ile soğutulmaktadır. Şekil 7a'da referans yıl ve 2050 için adaptif konfor sıcaklığına göre tanımlanmış TL_{konf} değerleri ile sınıfların dolu oldukları saatlerdeki ortalama OT değerleri sunulmaktadır. Sınıfların aylık ortalama İAD değerleri Şekil 7b'de gösterilmektedir. Gelecekte, İAD değerleri tüm aylar için neredeyse iki katına çıkmaktadır. En

yüksek İAD değerleri, yapının kullanıldığı en sıcak ay olan Haziran için hesaplanmıştır. Bu ayı sırasıyla Mayıs ve Eylül ayları takip etmektedir. Sınıflar için Haziran ayı ortalama İAD değerleri (\dot{IAD}_H) referans yılından 2050 yılına 0,74°C 'den 2,32°C'ye yükselmiştir. Ankara'nın en sıcak ayları olan Temmuz ve Ağustos aylarında sınıflar yaz tatili sebebi ile boştur; bu sebeple, bu aylar için İAD değerleri sıfırdır.

4.2. İyileştirme senaryoları etki analizi (Retrofit scenarios impact analysis)

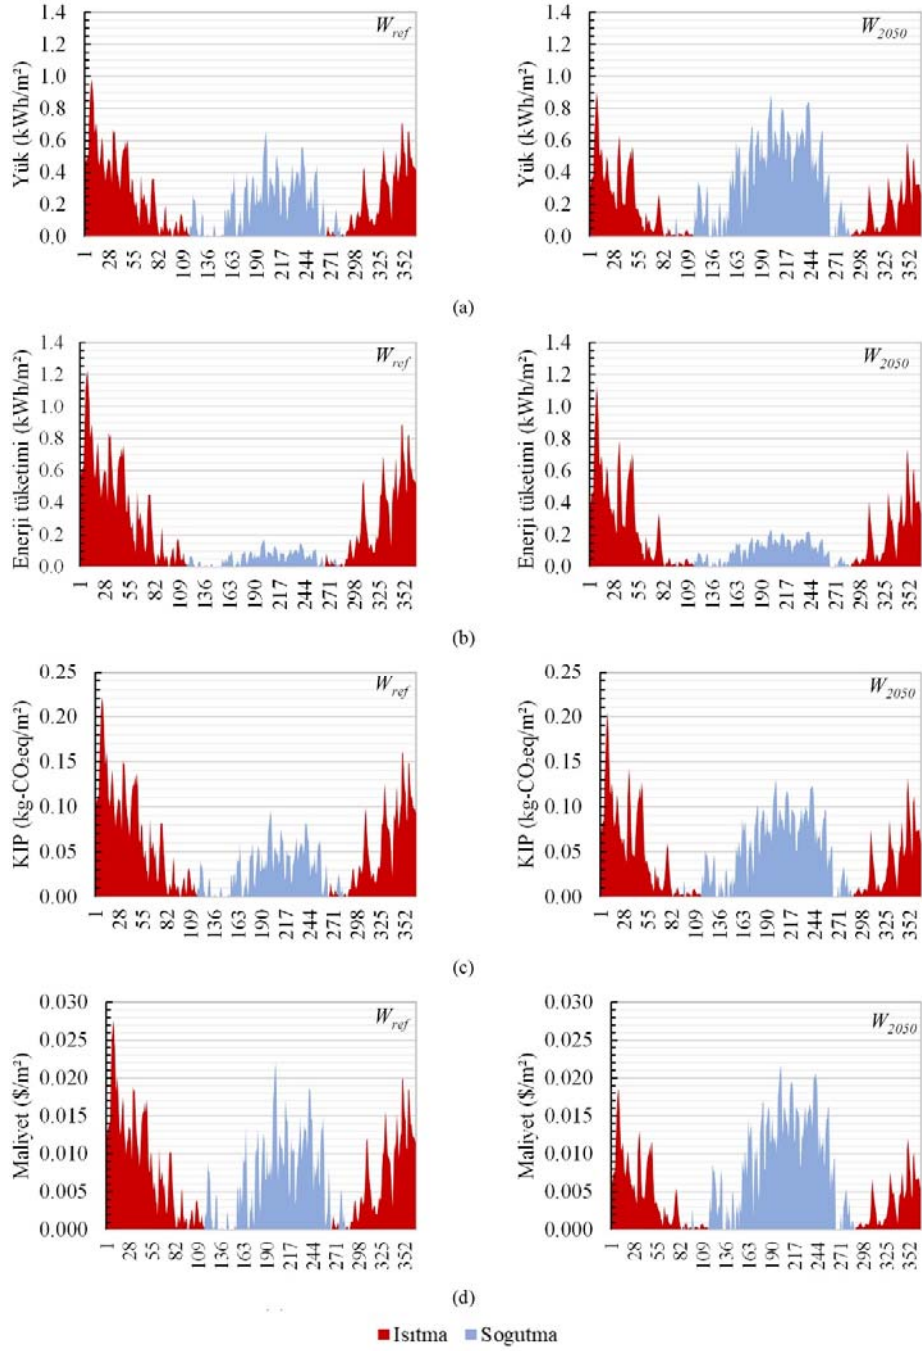
Bu kısımda, seçilen hedef değişkenler için (ısıtma yükü, soğutma yükü ve iç mekan aşırı ısınma derecesi) makine öğrenmesi yöntemleriyle geliştirilen tahmin modelleri üzerinden pencere parametrelerinin öznelik önem sonuçları sunulmuştur.

4.2.1. İstatistiksel analiz (Statistical analysis)

2025 farklı senaryonun günümüz ve 2050 yılı için performans simülasyonları yapılmış ve iki farklı veri seti üretilmiştir. Şekil 8'de tüm senaryolar için elde edilen ısı yük, enerji tüketimi, KIP ve maliyet değerleri sunulmuştur. Şekil 9'da ise bu senaryolara ilişkin \dot{IAD}_H sunulmuştur.

Hedef değişkenlerin betimsel istatistikleri ve Shapiro-Wilk normallik testi sonuçları Tablo 5'te özetlenmiştir. p-değeri < 0,05 normal dağılım olmadığı kanıtlandığından, değişkenlerin hiçbirisi normal dağılımı izlememektedir.

Hedef değişkenlerden \dot{IAD}_H ve Q_s performans göstergeleri sola-çarpık bir dağılıma sahipken, Q_1 sağa çarpıktır (Şekil 10). Referans ve 2050 yılı için oluşturulan iki veri setinde performans göstergelerinin dağılımları paralellik göstermektedir. 2025 iyileştirme senaryosunun her biri muhtemel ve kendi içinde tutarlı olduğu için hiçbir veri, aykırı gözlem olarak nitelendirilebilir olsa da ön işleme aşamasında veri setinden elenmemiştir. Spearman korelasyon katsayısı iki verinin birlikte artış veya azalış gösterme durumunu incelemek hedefiyle hesaplanmıştır (Şekil 11) Hesaplama yönteminde artışın orantısız olup olmaması gözlemlenmiştir. Hesaplamalar sonucunda girdi değişkenleri arasında anlamlı doğrusal bir ilişki gözlemlenmemiştir.



Şekil 6. W_{ref} ve W_{2050} için günlük (a) ısı yükleri ve karşılamak için gereken (b) enerji tüketimi, (c) KIP ve (d) maliyet değerleri (Daily (a) thermal loads and required (a) energy consumption, (b) global warming potential and (c) cost values for W_{ref} and W_{2050})

Girdi ve hedef değişkenlere bakıldığında, özellikle SHGC'nin, Q_s ve $\dot{I}AD_H$ arasında güçlü pozitif bir ilişki olduğu gözlemlenmiştir. Başka bir deyişle, SHGC değerindeki artış Q_s ve $\dot{I}AD_H$ değerlerindeki artış ile birlikte gözlemlenmiştir. Diğer bir yandan $U_{pencere}$ değerinin de Q_1 ile ilişkisinin güçlü bulunmuştur. Buna karşın, Q_1 , SHGC ile negatif doğrusal ilişkiye sahiptir. Test edilen bina için, PDO'nun kuzey cephesinde değişmesi herhangi bir hedef değişkeni etkilemezken Güney ve doğu cephesinde Q_s ve $\dot{I}AD_H$ ile düşük korelasyonlar gözlemlenmiştir. Hedef değişkenlerden, Q_s ve $\dot{I}AD_H$ arasında yüksek pozitif korelasyon bulunmuştur ve bu iki hedef değişkenin Q_1 ile negatif ilişkisi vardır. Son olarak, W_{ref} ve W_{2050} senaryoları için

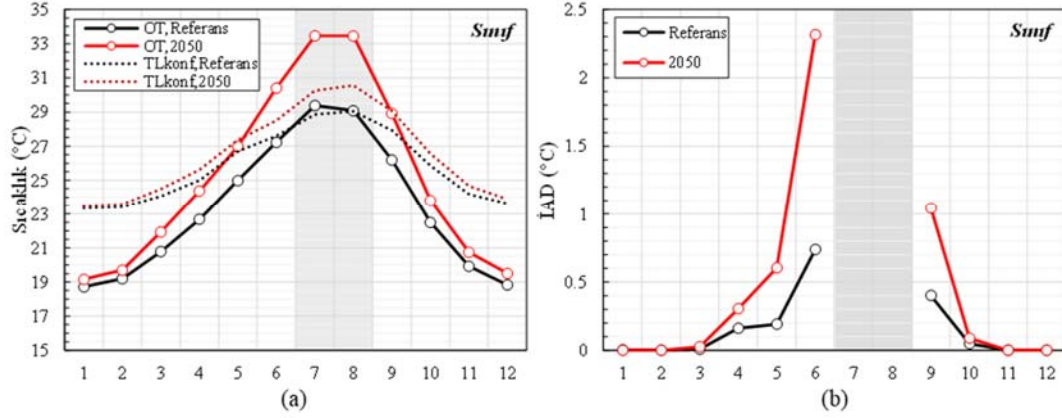
performans çıktılarının, girdiler ile ilişkisi paralellik göstermektedir. Aynı zamanda çıktı değişkenler iki sene için de çok büyük bir korelasyona sahiptir. Bunun sebebi hesaplamının orantıdan bağımsız olarak paralel artış veya azalış temelli olmasıdır. Bahsi geçen korelasyonlar istatistiksel olarak anlamlıdır ($p < 0,05$).

4.2.2. Rastgele orman değişken önem analizi (Random forest feature importances)

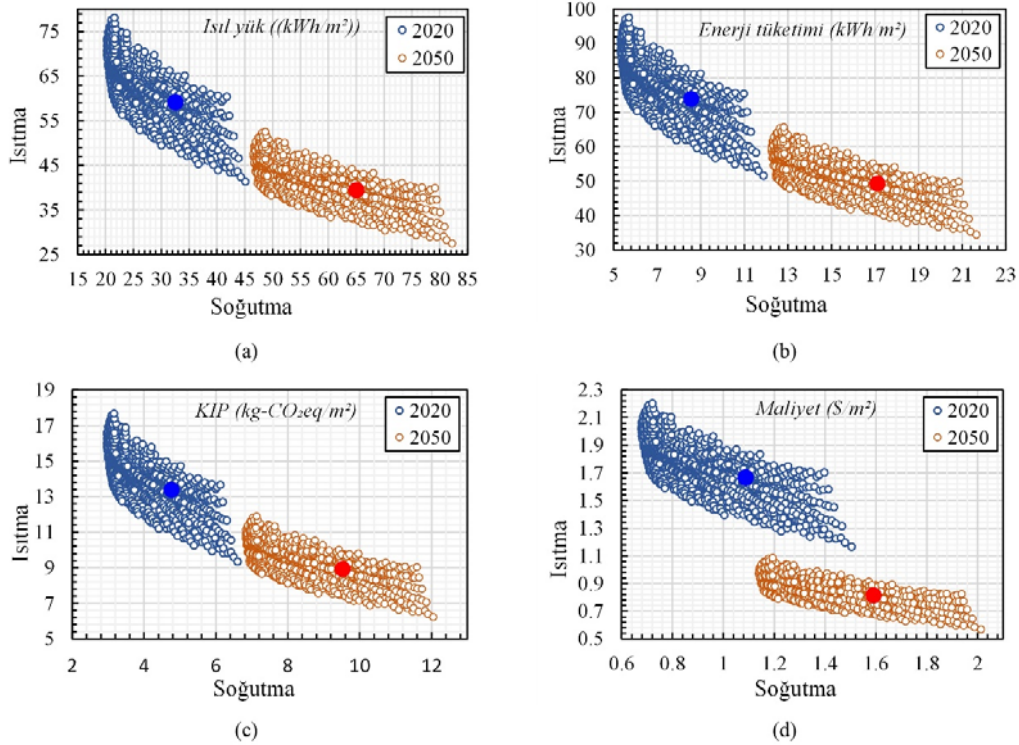
RO önem değerleri, eğitilen modelin performansı göz önünde bulundurularak değerlendirilmez. Bu sebeple, tahmin model

Tablo 4. Yıllık enerji tüketimi, KIP ve maliyet değerleri (a) ısıtma, (b) soğutma
(Annual energy consumption, global warming potential and cost values (a) heating, (b) cooling)

(a)					
Isıtma	Yük (kWh/m ²)	Kazan verimi	Enerji tüketimi (kWh/m ²)	KIP (kg-CO ₂ eq/m ²)	Maliyet (\$/m ²)
2020	59,17	80%	73,96	13,39	1,6683
2050	39,50	80%	49,38	8,94	0,8158
(b)					
Soğutma	Yük (kWh/m ²)	COP	Enerji tüketimi (kWh/m ²)	KIP (kg-CO ₂ eq/m ²)	Maliyet (\$/m ²)
2020	32,49	3,8	8,55	4,76	1,0859
2050	65,02	3,8	17,11	9,53	1,5917




Şekil 7. Sınıflar için aylık (a) ortalama OT değerleri ve ısı konfor sıcaklık limitleri ve (b) ortalama İAD değerleri
(Monthly classrooms' (a) average OT values and thermal comfort temperature limits and (b) average IAD values)



Şekil 8. 2025 farklı senaryo için hesaplan (a) ısı yükü, (b) enerji tüketimi, (c) KIP ve (d) maliyet değerleri (Mavi: 2020, Turuncu:2050. Büyük noktalar mevcut bina sonuçlarını temsil etmektedir.) (a) Thermal load, (b) energy consumption, (c) global warming potential and (d) cost values calculated for 2025 different scenarios (Blue: 2020, Orange: 2050, Large dots represent case study building results)

performansları her bir hedef değişken ve sene için hiper-parametreleri grid-tarama yöntemiyle optimize edilmiştir. Önem değerlerinin yorumlanmasında girdi parametreleri arasında korelasyon olmaması

önem taşımaktadır. Önem hesaplaması yapılan modellerin performansı R², MAE ve RMSE metrikleri ile çapraz doğrulama yöntemiyle hesaplanmıştır (Tablo 6). Referans yıl ve 2050 yılları için

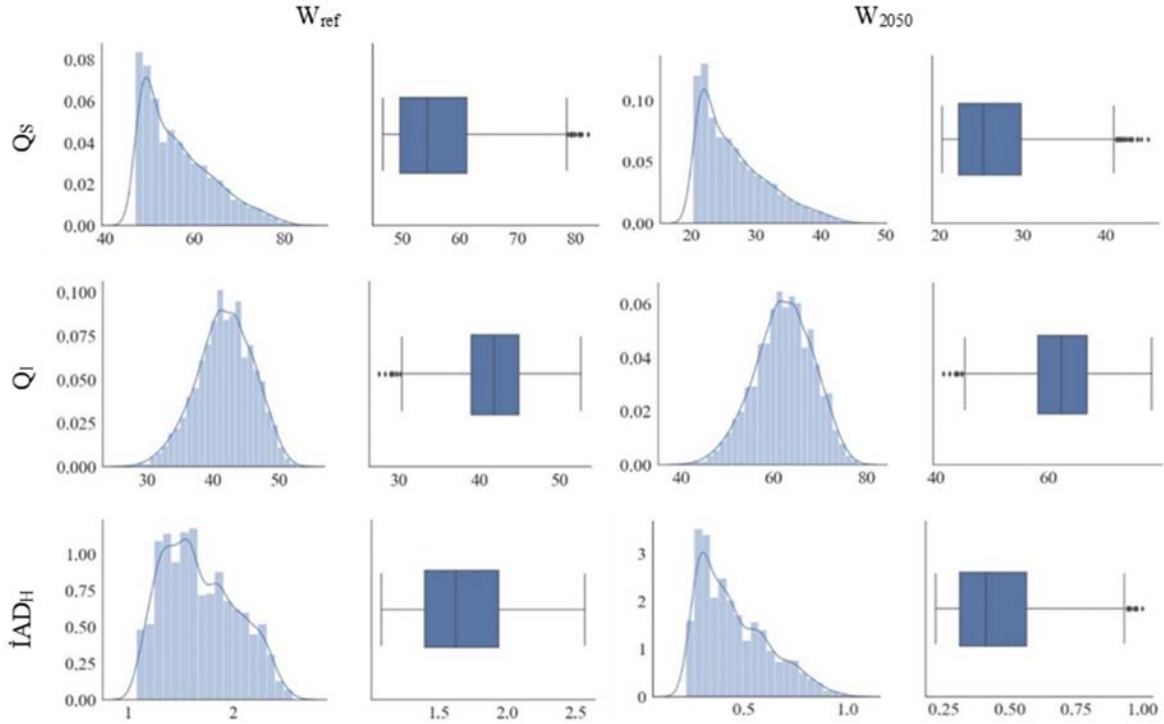


Şekil 9. 2025 farklı senaryo için hesaplan $\dot{I}AD_H$ değerleri (Mavi: 2020, Turuncu:2050. Büyük noktalar mevcut bina sonuçlarını temsil etmektedir.)

($\dot{I}AD_H$ values calculated for 2025 different scenarios (Blue: 2020, Orange: 2050. Large dots represent case study building results.))

Tablo 5. Hedef değişkenleri için betimsel istatistik ve p-değeri (Descriptive statistics and p-values for output variables)


	Parametre	Birim	Ortalama	Standart Sapma	Alt limit	Üst limit	p-değeri
W_{ref}	Q_S	kWh/m ²	26,63	5,24	20,27	45,08	0
	Q_I	kWh/m ²	61,13	6,29	41,32	78,10	1,82E-06
	$\dot{I}AD_H$	°C	0,45	0,17	0,22	0,10	0
W_{2050}	Q_S	kWh/m ²	56,24	7,83	46,60	82,23	0
	Q_I	kWh/m ²	41,75	4,27	27,53	52,56	6,2E-07
	$\dot{I}AD_H$	°C	1,68	0,35	1,09	2,56	0



Şekil 10. Hedef değişkenlerinin dağılımı (Output variable distributions)

tahmin edilen Q_S değerleri, gerçek değerlerinden RMSE'e göre sırasıyla %4 ve %3 sapmaktadır. Tahmin edilen Q_I değerleri gerçek değerlerinden sadece referans yıl için %2, 2050 yılı için ise %1 oranla sapmaktadır. Ortalama $\dot{I}AD_H$ değeri her iki sene için de %2 hata payı 2080

ile tahmin edilmiştir. Değerlendirmeler sonucunda modellerin tahmin performansı güçlü bulunmuş ve beraberinde değişken önem analizi incelenmiştir. Her bir tahmin modeli için girdi değişkenlerin önem değerleri 10-kat geçerlilik yöntemiyle hesaplanmıştır (Şekil 12).



Şekil 11. Girdi değişkenlerin, referans yılı ile 2050 yılı için hedef değişkenler ile korelasyon matrisi
(Correlation matrix of input variables with target variables for the reference year and 2050)

Tablo 6. Çapraz doğrulama yöntemiyle hesaplanan model performans değerleri, Sonuçlar ortalama ± standart sapma değerleriyle verilmiştir

(Model performance values calculated by cross validation method. Results are given with mean ± standard deviation values)

	Parametre	R ²	MAE	RMSE
W _{ref}	Q _s	0,927 ± 0,063	0,843 ± 0,097	1,132 ± 0,098
	Q _i	0,970 ± 0,026	0,679 ± 0,125	0,933 ± 0,167
	İAD _H	0,996 ± 0,003	0,007 ± 0,001	0,009 ± 0,001
W ₂₀₅₀	Q _s	0,936 ± 0,052	1,158 ± 0,164	1,619 ± 0,167
	Q _i	0,971 ± 0,025	0,444 ± 0,084	0,613 ± 0,112
	İAD _H	0,987 ± 0,025	0,022 ± 0,013	0,027 ± 0,016

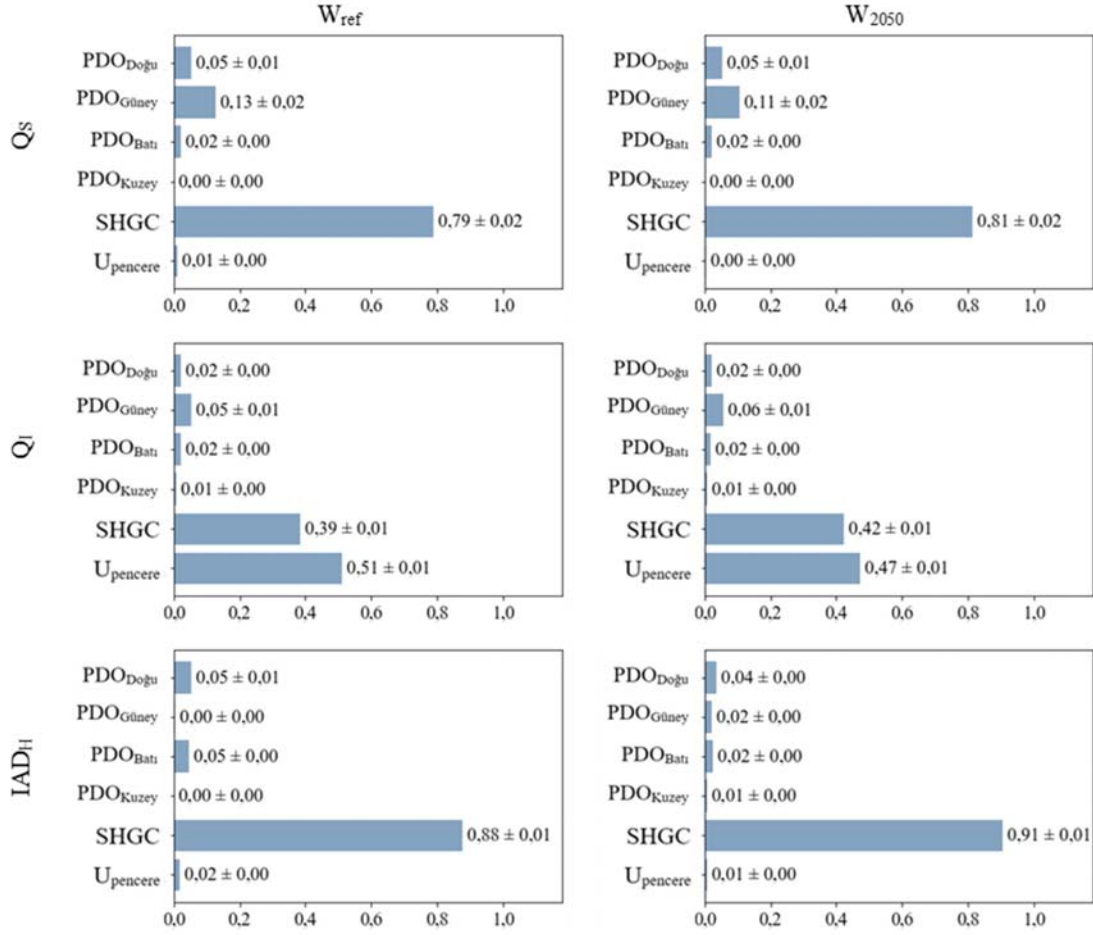
Hesaplamalar sonucunda çalışılan vaka için, Q_s performansını etkileyen girdi değişkenler arasında SHGC değeri baskın gelmektedir. Q_s için tahmin başarısı yaklaşık %80 oranında SHGC değerleriyle ile açıklanabilirken, %13 ile PDO_{Güney} takip etmektedir. Q_i için SHGC ve U_{pencere} en önemli iki parametre olarak gözlenmiştir. W_{ref} ve W₂₀₅₀ için SHGC ve U_{pencere} toplamda yaklaşık %88 öneme sahiptir. W_{ref} tahminlerinde bu iki değişken arasındaki makas %12 iken W₂₀₅₀ için sadece %5'tür, İAD_H değerleri için Q_s'ye paralel olarak en baskın girdi değişken SHGC'dir. SHGC'yi takip eden en önemli iki parametrenin PDO_{Doğu} ve PDO_{Bati} olduğu gözlemlenmiştir.

5. Sonuçlar (Conclusions)

Bu çalışmada, iklim değişikliğinin tipik bir ortaokul binasının enerji tüketimine ve kullanıcı ısı konforuna etkileri sunulmuş ve sonrasında bu binanın pencere parametrelerini temel alan iyileştirme alternatiflerinin etkinliği makine öğrenmesi kullanılarak değerlendirilmiştir. Oluşturulan 2050 yılı iklim verilerine göre iklim değişikliği sonucunda yıllık IDG değerleri 460°C-gün azalacak, yıllık SDG değerleri ise 365°C-gün artacaktır. Yıllık ortalama T_D 2,7°C yükselerek 16,2°C'ye ulaşacaktır. Bu artış yaz aylarında daha belirgin olacak, örneğin Haziran ayı için ortalama T_D 3,1°C artarak 21,4°C'den

24,5°C'e çıkacaktır. Yıllık ortalama KYR değerinde ise sınırlı bir değişim beklenmektedir. Artan sıcaklıklar bina enerji dengesini etkileyecektir. İç ortam ile dış ortam arasındaki sıcaklık farkına bağlı kayıplarda (opak yüzeylerden ve camlardan konduksiyon ile ısı taşınımı, mekanik havalandırma ve infiltrasyon) önemli bir azalma olacaktır. Bu azalmanın sonucunda bina ısıtma yükü 19,7 kWh/m² (33%) azalarak 59,2'den 39,5'e düşecektir. Ofis ve öğretmen odaları için soğutma yükü 32,5 kWh/m² (100%) artarak 32,5'den 65,0'a yükselecektir. Artan sıcaklıkların diğer bir beklenen etkisi de aşırı ısınmanın daha da önemli bir risk faktörü haline gelecek olmasıdır. Her ne kadar Ankara için en sıcak iki ay olan Temmuz ve Ağustos aylarında sınıflar kullanılsa da mevcutta Mayıs, Haziran ve Eylül aylarında bir miktar aşırı ısınma (İAD_M=0,19°C, İAD_H=0,74°C, İAD_E=0,40°C) gözlenmektedir. 2050 yılında bu aylar için beklenen aşırı ısınma (İAD_M=0,60°C, İAD_H=2,32°C, İAD_E=1,04°C) yaklaşık üç katına çıkacaktır. Sadece doğal havalandırmanın kullanımı sınıflarda ısı konforun sağlanmasında yetersiz kalacaktır.

Pencere parametrelerinin vaka binasının performansına etkisini incelemek üzere detaylıca modellenen bina için birbirinden bağımsız altı pencere parametresi (U_{pencere}, SHGC ve dört farklı cephedeki PDO) kullanılarak 2025 farklı senaryo üretilmiştir. Bu senaryoların



Şekil 12. Çapraz doğrulama yöntemiyle hesaplanan değişken önem değerleri, Sonuçlar ortalama ± standart sapma değerleriyle verilmiştir (Feature importance values calculated by cross validation method, Results are given as mean ± standard deviation values)

hem referans yılı hem de 2050 için simülasyonları yapılmış ve performans göstergeleri (Q_s, Q_i ve İAD_H) hesaplanmıştır. Üretilen veri, istatistiksel analizlere tabi tutularak pencere parametreleri ve performans göstergeleri arasında korelasyonlar incelenmiştir. SHGC ile Q_s ve İAD_H arasında ve U_{pencere} ile Q_i arasında güçlü pozitif ilişki gözlemlenmiştir. Diğer taraftan, Q_i ile SHGC arasında negatif bir ilişki görülmüştür. Ayrıca, güney ve doğu cephesinde PDO değeri, Q_s ve İAD_H ile düşük korelasyon göstermiştir.

Üretilen veri ile her bir performans göstergesi RO tahmin modelleri eğitilmiş, eğitilen RO modellerinin (en düşük R² değeri 0,927 olacak şekilde) yüksek tahmin kapasitesine sahip olduğu görülmüştür. Bu RO modelleri, öznelik önemi hesaplaması için kullanılmıştır. Öznelik önemi, pencere parametrelerinin performans göstergeleri için görece önemini ifade eder. Önem değerlerine bakıldığında, SHGC'nin seçilen altı parametre arasında en önemlisi olduğu gözlemlenmiştir. Diğer bir yandan PDO_{Kuzey} değişkeninin iyileştirme senaryolarında en az öneme sahip olduğu görülmüştür. Q_s için RO öznelik önem hesaplamalarında PD OGüney değeri, SHGC'den sonra en önemli ikinci parametredir. PD OGüney artışı Q_s artışını beraberinde getirmektedir. Bu sonuç, vaka binasında soğutma sistemine sahip mekanların güney cephede konumlanması ile ilişkilendirilebilir. Q_s için 2050 yılında SHGC öneminde %2'lik bir artış gözlemlenmiştir. Bu, iklim değişikliği ile yükselen yıllık ortalama KYR değerine ve bu sebeple cam yüzeylerden enerji kazanımının yükselişiyle ilişkilendirilebilir. Diğer bir yandan, Q_i performansı önemli ölçüde SHGC ve U_{pencere} değerlerine bağlıdır. Bu iki parametre aynı zamanda Q_i ile orta derecede korelasyona sahiptir. İyileştirme senaryolarında

Q_i, U_{pencere} değerinin azalması ve SHGC değerinin artması ile azaltılabilir. Son olarak, iyileştirme senaryolarında İAD_H'yi etkileyen ve önem sırasında SHGC'yi takip eden parametreler PDO_{Doğu} ve PDO_{Batı}'dır. PD OGüney'in daha düşük önem değerine sahip olması İAD_H hesaplanan zonların yönelimi ile açıklanabilir. İAD_H sadece sınıflar için hesaplanmış olup, toplamda 76 sınıftan sadece 6'sı güney cephesine bakmaktadır. Güney cephesinde ise ağırlıklı olarak İAD_H hesaplamalarına dahil edilmeyen ofis ve öğretmen odaları konumlanmış olduğu için PD OGüney, İAD_H'yi etkilememiştir.

Çalışmada örneklenen simülasyonlara dayalı veri üretme ve makine öğrenmesi ile öznelik önem analizi yöntemi, farklı konumlardaki çeşitli bina tipleri için farklı girdi parametrelerinin performans göstergeleri ile ilişkisini analiz etmekte kullanılabilir.

Teşekkür (Acknowledgement)

Bu araştırma, Orta Doğu Teknik Üniversitesi GAP-303-2021-10674 kodlu bilimsel araştırma projesi ödeneği ile desteklenmiştir. Yazarlar, Tolga Tamer'e maliyet hesaplarındaki katkıları, Naz Dino'ya ise düzeltme okuması için teşekkür eder.

Kaynaklar (References)

1. NASA, Global Climate Change: Vital Signs of the Planet, 2021.
2. Smith P.F., Architecture in a climate of change : A guide to sustainable design, Routledge, 2005.
3. Altun M., Meral Akgül Ç., Akçamete A., Effect of envelope insulation on building heating energy requirement, cost and carbon footprint from

- a life cycle perspective, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 35, 147-164, 2020.
4. Rode P., Burdett R., Soares Gonçalves J. C., Buildings: investing in energy and resource efficiency, Towards a green economy: pathways to sustainable development and poverty eradication, United Nations Environment Programme, 331-373, 2011.
 5. International Energy Agency, *World Energy Outlook 2021*, IEA, Paris, 2021.
 6. de Wilde P., Coley D., The implications of a changing climate for buildings, *Build Environ*, 55, 1-7, 2012.
 7. Gürsel Dino I., Meral Akgül Ç., Impact of climate change on the existing residential building stock in Turkey: An analysis on energy use, greenhouse gas emissions and occupant comfort, *Renew Energy*, 141, 828-846, 2019.
 8. IEA, *The Future of Cooling: Opportunities for energy-efficient air conditioning*, 2018.
 9. Meral Akgül Ç., Gürsel Dino İ., Climate change impact assessment in residential buildings utilizing RCP4.5 and RCP8.5 scenarios, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 3, 1665-1683, 2020.
 10. Tamer T., Gürsel Dino I., Meral Akgül Ç., Data-driven, long-term prediction of building performance under climate change: Building energy demand and BIPV energy generation analysis across Turkey, *Renewable and Sustainable Energy Reviews*, 162, 112396, 2022.
 11. Grynning S., Gustavsen A., Time B., Jelle B.P., Windows in the buildings of tomorrow: Energy losers or energy gainers?, *Energy Build*, 61, 185-192, 2013.
 12. Cuce E., Riffat S.B., A state-of-the-art review on innovative glazing technologies, *Renewable and Sustainable Energy Reviews*, 41, 695-714, 2015.
 13. Inanici M.N., Demirbilek F.N., Thermal performance optimization of building aspect ratio and south window size in five cities having different climatic characteristics of Turkey, *Build Environ*, 35, 41-52, 2000.
 14. Amaral A.R., Rodrigues E., Gaspar A.R., Gomes Á., A thermal performance parametric study of window type, orientation, size and shadowing effect, *Sustain Cities Soc*, 26, 456-465, 2016.
 15. Gürsel Dino İ., Binalarda Güneş Kontrol Yöntemlerinin Optimizasyon Temelli Performans Değerlendirilmesi, *GU J Sci, Part C*, 5 (3), 71-87, 2017.
 16. Yıldız Y., Özbalta T.G., Durmuş Arsan Z., Impact of Window-to-Wall Surface Area for Different Window Glass Types and Wall Orientations on Building Energy Performance: A Case Study for a School Building Located in Izmir, Turkey, *MEGARON / Yıldız Technical University, Faculty of Architecture E-Journal*, 6, 30-38, 2011.
 17. Bojić M., Yik F., Application of advanced glazing to high-rise residential buildings in Hong Kong, *Build Environ*, 42, 820-828, 2007.
 18. Akkose G., Meral Akgul C., Gursel Dino I., Educational building retrofit under climate change and urban heat island effect, *Journal of Building Engineering*, 40, 102294, 2021.
 19. Feng G., Chi D., Xu X., Dou B., Sun Y., Fu Y., Study on the Influence of Window-wall Ratio on the Energy Consumption of Nearly Zero Energy Buildings, *Procedia Engineering*, 205, 730-737, 2017.
 20. Kim S., Zadeh P.A., Staub-French S., Froese T., Cavka B.T., Assessment of the Impact of Window Size, Position and Orientation on Building Energy Load Using BIM, *Procedia Engineering*, 1424-1431, 2016.
 21. Singh M.C., Garg S.N., Jha R., Different glazing systems and their impact on human thermal comfort-Indian scenario, *Build Environ*, 43, 1596-1602, 2008.
 22. Perez Y.V., Capeluto I.G., Climatic considerations in school building design in the hot-humid climate for reducing energy consumption, *Appl Energy*, 86, 340-348, 2009.
 23. Allab Y., Pellegrino M., Guo X., Nefzaoui E., Kindinis A., Energy and comfort assessment in educational building: Case study in a French university campus, *Energy Build*, 143, 202-219, 2017.
 24. Pérez-Lombard L., Ortiz J., Pout C., A review on buildings energy consumption information, *Energy Build*, 40, 394-398, 2008.
 25. Zomorodian Z.S., Tahsildoost M., Hafezi M., Thermal comfort in educational buildings: A review article, *Renewable and Sustainable Energy Reviews*, 59, 895-906, 2016.
 26. Kafatygiotou M.C., Serghides D.K., Thermal comfort of a typical secondary school building in Cyprus, *Sustain Cities Soc*, 13, 303-312, 2014.
 27. Ascione F., Bianco N., De Masi R.F., Mauro G.M., Vanoli G.P., Energy retrofit of educational buildings: Transient energy simulations, model calibration and multi-objective optimization towards nearly zero-energy performance, *Energy Build*, 144, 303-319, 2017.
 28. Tahsildoost M., Zomorodian Z.S., Energy retrofit techniques: An experimental study of two typical school buildings in Tehran, *Energy Build*, 104, 65-72, 2015.
 29. Ascione F., Bianco N., De Masi R.F., De' Rossi F., Vanoli G.P., Energy retrofit of an educational building in the ancient center of Benevento. Feasibility study of energy savings and respect of the historical value, *Energy Build*, 95, 172-183, 2015.
 30. Niemelä T., Kosonen R., Jokisalo J., Cost-optimal energy performance renovation measures of educational buildings in cold climate, *Appl Energy*, 183, 1005-1020, 2016.
 31. de Wilde P., Tian W., Predicting the performance of an office under climate change: A study of metrics, sensitivity and zonal resolution, *Energy Build*, 42, 1674-1684, 2010.
 32. Waddicor D.A., Fuentes E., Sisó L., Salom J., Favre B., Jiménez C., Azar M., Climate change and building ageing impact on building energy performance and mitigation measures application: A case study in Turin, northern Italy, *Build Environ*, 102, 13-25, 2016.
 33. Dolinar M., Vidrih B., Kajfež-Bogataj L., Medved S., Predicted changes in energy demands for heating and cooling due to climate change, *Physics and Chemistry of the Earth*, 35, 100-106, 2010.
 34. Hamdy M., Hensen J.L.M., Ranking of dwelling types in terms of overheating risk and sensitivity to climate change, 14th International Conference of IBPSA - Building Simulation 2015, BS 2015, Conference Proceedings 15, 2142-2149, 2015.
 35. van Hooff T., Blocken B., Hensen J.L.M., Timmermans H.J.P., Reprint of: On the predicted effectiveness of climate adaptation measures for residential buildings, *Build Environ*, 83, 142-158, 2015.
 36. Guan L., The influence of internal load density on the energy and thermal performance of air-conditioned office buildings in the face of global warming, *Archit Sci Rev*, 58, 162-173, 2015.
 37. Pierangioli L., Cellai G., Ferrise R., Trombi G., Bindi M., Effectiveness of passive measures against climate change: Case studies in Central Italy, *Build Simul*, 10, 459-479, 2017.
 38. Cellura M., Francesco G., Longo S., Mistretta M., Tumminia G., Effect of Climate Change on Building Performance: the Role of Ventilative Cooling, International Building Performance Simulation Association (IBPSA) Conference, San Francisco, CA, 2017.
 39. Tian Z., Zhang X., Wei S., Du S., Shi X., A review of data-driven building performance analysis and design on big on-site building performance data, *Journal of Building Engineering*, 41, 2352-7102, 2021.
 40. van den Brom P., Meijer A., Visscher H., Actual energy saving effects of thermal renovations in dwellings—longitudinal data analysis including building and occupant characteristics, *Energy Build*, 182, 251-263, 2019.
 41. Fowlie M., Greenstone M., Wolfram C., Do energy efficiency investments deliver? Evidence from the Weatherization Assistance Program, *Quarterly Journal of Economics*, 133, 1597-1644, 2018.
 42. Liang J., Qiu Y., James T., Ruddell B.L., Dalrymple M., Earl S., Castelazo A., Do energy retrofits work? Evidence from commercial and residential buildings in Phoenix, *J Environ Econ Manage*, 92, 726-743, 2018.
 43. Marasco D.E., Kontokosta C.E., Applications of machine learning methods to identifying and predicting building retrofit opportunities, *Energy Build*, 128, 431-441, 2016.
 44. Thrampoulidis E., Mavromatidis G., Lucchi A., Orehounig K., A machine learning-based surrogate model to approximate optimal building retrofit solutions, *Appl Energy*, 281, 116024, 2021.
 45. Wang J.C., A study on the energy performance of school buildings in Taiwan, *Energy Build*, 133, 810-822, 2016.
 46. Ouf M.M., Issa M.H., Energy consumption analysis of school buildings in Manitoba, Canada, *International Journal of Sustainable Built Environment*, 6, 359-371, 2017.
 47. Walter T., Sohn M.D., A regression-based approach to estimating retrofit savings using the Building Performance Database, *Appl Energy*, 179, 996-1005, 2016.
 48. Hamilton I.G., Summerfield A.J., Shipworth D., Steadman J.P., Oreszczyn T., Lowe R.J., Energy efficiency uptake and energy savings in English houses: A cohort study, *Energy Build*, 118, 259-276, 2016.
 49. Zhang L., Data-driven building energy modeling with feature selection and active learning for data predictive control, *Energy Build*, 252, 111436, 2021.
 50. Tsanas A., Xifara A., Accurate quantitative estimation of energy performance of residential buildings using statistical machine learning tools, *Energy Build*, 49, 560-567, 2012.
 51. Roudsari M.S., Pak M., Ladybug: a parametric environmental plugin for grasshopper to help designers create an environmentally-conscious

- design, 13th International IBPSA Conference, Lyon, France, 3128-3135, 2013.
52. Pedregosa F., Michel V., Grisel O., Blondel M., Prettenhofer P., Weiss R., Vanderplas J., Cournapeau D., Pedregosa F., Varoquaux G., Gramfort A., Thirion B., Grisel O., Dubourg V., Passos A., Brucher M., Perrot M., Duchesnay É., Scikit-learn: Machine Learning in Python, *Journal of Machine Learning Research*, 12, 2825-2830, 2011.
 53. Belcher S.E., Hacker J.N., Powell D.S., Constructing design weather data for future climates, *Building Services Engineering Research and Technology*, 26, 49-61, 2005.
 54. Hensen J.L.M., Lamberts R., *Building performance simulation for design and operation*, Routledge, 2012.
 55. Hamdy M., Carlucci S., Hoes P.J., Hensen J.L.M., The impact of climate change on the overheating risk in dwellings—A Dutch case study, *Build Environ*, 122, 307-323, 2017.
 56. ASHRAE, Standard 55-2010, Thermal environmental conditions for human occupancy, 2010.
 57. Amasyali K., El-Gohary N.M., A review of data-driven building energy consumption prediction studies, *Renewable and Sustainable Energy Reviews*, 81, 1192-1205, 2018.
 58. Breiman L., Friedman J.H., Olshen R.A., Stone C.J., *Classification and Regression Trees*, CRC, 1984.
 59. Kotsiantis S.B., Decision trees: A recent overview, *Artif. Intell. Rev.*, 39, 261-283, 2013.
 60. Breiman L., Random Forests, *Mach Learn*, 45, 5-32, 2001.
 61. Kohavi R., A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection, 1995.
 62. ASHRAE, Standard 90.1-2013, Energy standard for buildings except low rise residential buildings, 2013.
 63. Wan K.K.W., Li D.H.W., Pan W., Lam J.C., Impact of climate change on building energy use in different climate zones and mitigation and adaptation implications, *Appl Energy*, 97, 274-282, 2012.
 64. Jenkins D.P., Singh H., Eames P.C., Interventions for large-scale carbon emission reductions in future UK offices, *Energy Build*, 41, 1374-1380, 2009.
 65. Ecoinvent Centre, Ecoinvent Database, (2012).
 66. Atilgan B., Azapagic A., Assessing the environmental sustainability of electricity generation in Turkey on a life cycle basis, *Energies*, 9, 31, 2016.
 67. Ascione F., Bianco N., De Stasio C., Mauro G.M., Vanoli G.P., Multi-stage and multi-objective optimization for energy retrofitting a developed hospital reference building: A new approach to assess cost-optimality, *Appl Energy*, 174, 37-68, 2016.
 68. Salata F., Ciancio V., Dell'Olmo J., Golasi I., Palusci O., Coppi M., Effects of local conditions on the multi-variable and multi-objective energy optimization of residential buildings using genetic algorithms, *Appl Energy*, 260, 114289, 2020.
 69. Rosso F., Ciancio V., Dell'Olmo J., Salata F., Multi-objective optimization of building retrofit in the Mediterranean climate by means of genetic algorithm application, *Energy Build*, 216, 109945, 2020.
 70. Pilechiha P., Mahdavejad M., Pour Rahimian F., Carnemolla P., Seyedzadeh S., Multi-objective optimisation framework for designing office windows: quality of view, daylight and energy efficiency, *Appl Energy*, 261, 114356, 2020.