



## Enerji Verimli Bina Tasarımında Kural Tabanlı Yöntem Yardımıyla Isıtma ve Soğutma Yüklerinin Tahminlemesi

Arş. Gör. Merve ERTOSUN YILDIZ<sup>1</sup>, Prof. Dr. Figen BEYHAN<sup>2</sup>, Doç. Dr. Muhammed Kürşad UÇAR<sup>3</sup>

*merveertosun@gazi.edu.tr, fbeyhan@gazi.edu.tr, mucar@sakarya.edu.tr*

<sup>1</sup> Mimarlık Bölümü, Mimarlık Fakültesi, Gazi Üniversitesi, Ankara, Türkiye

<sup>2</sup> Mimarlık Bölümü, Mimarlık Fakültesi, Gazi Üniversitesi, Ankara, Türkiye

<sup>3</sup> Elektrik-Elektronik Mühendisliği, Mühendislik Fakültesi, Sakarya Üniversitesi, Sakarya, Türkiye

### ÖZET

Türkiye’de bina sektörü ülkenin nihai enerji tüketiminin yaklaşık %34’ünden sorumludur. Binaların enerji talebinin bilinmesi, enerji verimli bina tasarım yaklaşımında önemli bir rol oynamaktadır. Makine öğrenim teknikleri, son zamanlarda mimarlık disiplininde sıklıkla binaların enerji talep tahmininde kullanılmaktadır. Bu çalışmanın amacı, bina tasarımında yer alan birtakım parametrelerin ısıtma ve soğutma yüklerine etkisini keşfetmek için kural tabanlı bir yöntem geliştirmek ve sonucunda enerji verimliliğinin sağlanmasına hizmet etmektir. İlk olarak, literatürden elde edilen veri setine özellik seçme işlemi uygulanmış ve her bir parametre için ısıtma ve soğutma yükleri hesaplanarak etkisine göre sıralanmıştır. Binaların toplam yüksekliği, duvar alanı ve çatı alanının performansı etkileyen önemli özellikler olduğu saptanmıştır. Daha sonra, karar ağacı modeli aracılığıyla kural tabanlı tahmin modelleri oluşturulmuştur. Geliştirilen ısıtma ve soğutma yükü modellerinin R performans değerleri sırasıyla 0.92 ve 0.91’dir. Isıtma ve soğutma yükü tahmini için önerilen kural tabanlı yöntem, basit ve anlaşılır bir yaklaşım olarak pratikte uygulanabilir.

**Anahtar Kelimeler:** Enerji Verimliliği, Isıtma ve Soğutma Yükü, Makine Öğrenmesi, Karar Ağaçları

### ABSTRACT

The building sector in Turkey is responsible for about %34 of the energy consumption of the country. The energy demand of buildings plays an important role in energy-efficient building design. Machine learning techniques have been used for energy forecasting on buildings. The aim of this study is to develop a rule-based method to explore the effects of building design parameters on heating and cooling loads and to serve energy efficiency. Firstly, the feature selection was applied to the data set from the literature. The heating and cooling load for each parameter were calculated and ranked according to their effects. Then, rule-based models were created by the decision tree. The R performance values of the developed heating and cooling load models are 0.92 and 0.91, respectively. The proposed rule-based method for heating and cooling load is feasible practically as a simple and understandable approach.

**Keywords:** Energy Efficiency, Heating and Cooling Load, Machine Learning, Decision Trees

### 1. GİRİŞ

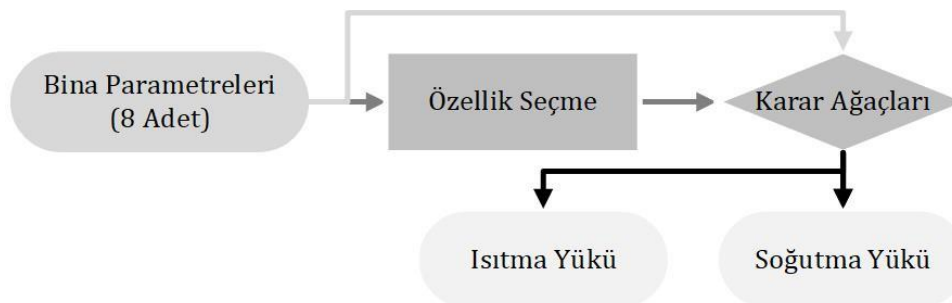
Dünyada enerji tüketiminin artması, çevre üzerinde uzun süreli olumsuz etkilere neden olmaktadır. Önemli boyutta enerji tüketiminden sorumlu olan bina sektörü, gelişmiş ülkelerde iklim değişikliğiyle mücadelede öncelikli çalışma alanıdır. Binalarda enerji verimliliğinin sağlanmasında, tasarım aşamasında alınan kararların önemli bir etken olduğu bilinmektedir. Bina enerji simülasyon araçları yaptığı analizlerle, enerji verimli binaların tasarımını kolaylaştırmak amacıyla yaygın olarak kullanılmaktadır. Ancak, simülasyon modellerinin karmaşıklığı ve bina hakkında ayrıntılı bilgi/girdi gereksinimi, kullanıcılar için caydırıcı olabilmektedir (Batish & Agrawal, 2020).

Bilinen özelliklere dayanarak öğrenilen verilerden yapılan tahminler üzerine odaklanmak makine öğrenimi, birçok disiplinde olduğu gibi mimarlık disiplinde de kullanım alanı bulmuştur. Makine öğrenimi tekniklerini kullanmanın temel avantajı, nispeten yüksek bir hesaplama performansına ve uygulama kolaylığına sahip olmalarıdır (Gao et al., 2019). Ayrıca, karmaşık bir bina geometrisi modeli yerine yalnızca tahmin değişkenleri için parametrik girdiler gerektirdiğinden, kullanıcı için daha kısa sürede etkin sonuçlar sunmaktadır (Batish & Agrawal, 2020). Literatürde yer alan bir çalışmada, bina enerji talep modellemesi için bir karar ağacı yöntemi önerilmiştir. Bu yöntemle, Japonya'daki konut binalarına bina enerji kullanım yoğunluğu düzeylerini tahmin etmek amaçlanmıştır. Sonuçlar, karar ağacı yönteminin kullanımının bina enerji talep seviyelerini doğru bir şekilde sınıflandırabildiğini ve tahmin edebildiğini, binalarda enerji performansını etkileyen önemli faktörleri sıralayabildiğini göstermiştir (Yu et al., 2010). Binaların ısıtma soğutma yüklerini tahmin etmeyi hedefleyen farklı bir çalışmada destek vektör regresyonu (SVR), yapay sinir ağı (YSA), sınıflandırma ve regresyon ağacı, ki-kare otomatik etkileşim dedektörü gibi çeşitli makine öğrenim teknikleri uygulanmıştır. Sonuçlar, enerji verimli binaların tasarımlarını kolaylaştırmak için önerilen tekniklerin uygulanabilirliğini desteklemektedir (Chou & Bui, 2014). Ayrıca, ofis binalarında kullanıcı davranış tahmin modellerini oluşturmak amacıyla bir çalışma yapılmıştır. Karar ağacı modeli aracılığıyla, kullanıcı davranışının bina HVAC enerji tüketimi üzerindeki etkisi incelenmiş ve farklı iklim koşullarındaki binalarda tahmin sonuçlarında büyük farklılıklar olduğu görülmüştür (Zhao et al., 2014). Konut binalarına yönelik gerçekleştirilen bir çalışma, ısıtma ve soğutma yüküne etkileyen tasarım parametrelerini belirlemek için makine öğrenme yöntemlerini değerlendirmeyi amaçlamıştır. Uygun veri seti hazırlandıktan sonra, on altı makine öğrenme yöntemi içinden, sınıflandırmaya dayalı bir model olan rassal orman ile kural tabanlı tahmin modellerinin daha iyi performans gösterdiği görülmüştür (Gao et al., 2019). Çalışmalar, makine öğrenimi ile binaların enerji talebini belirlemenin oldukça hızlı ve güvenilir olduğunu göstermektedir (Ahmad et al., 2018; Amasyali & El-Gohary, 2018; Bourdeau et al., 2019; Seyedzadeh et al., 2018).

İlgili literatüre dayanarak çalışmanın amacı, bina tasarım parametrelerinin ısıtma soğutma yüklerine etkisini keşfetmek amacıyla kural tabanlı bir yöntem geliştirmek ve tasarım sürecinde alınacak kararlar ile binalarda enerji verimliliğinin sağlanmasına hizmet etmektir. Bu amaçla on iki binaya ait sekiz tasarım parametresinin çeşitli senaryolar üzerinden simüle edilmesiyle oluşturulan 768 veri kullanılmıştır. İlk olarak, veri setine özellik seçme işlemi uygulanmıştır. Her bir parametre için ısıtma ve soğutma yük değerleri hesaplanmış ve parametreler etkisine göre sıralanmıştır. Performans değerlendirme kriterlerine göre tahmin modeli için mümkün olan en az verinin kullanılmasıyla kural tabanlı modeller oluşturulmuştur.

## 2. MATERYAL VE YÖNTEM

Çalışma, ilk olarak 8 bina parametresi giriş verisi olarak kullanılmıştır. Bu veriler içinden özellik seçme algoritması yardımıyla sonuç verisine etkileyen önemli özellikler seçilmiştir. Belirlenen özellik matrisleriyle, ısıtma-soğutma yükünün tahmini için karar ağaçları yardımıyla kural tabanlı modeller oluşturulmuştur (Şekil 1).



Şekil 1. Akış Diyagramı

## 2.1. Verilerin Toplanması

Çalışmada UCI makine öğrenimi veri deposunda yer alan açık kaynak veri seti kullanılmıştır (Tsanas & Xifara, 2012a, 2012b) Ecotect'te simüle edilen aynı hacme (771.75 m<sup>3</sup>) sahip on iki bina üzerinden yürütülmüştür. "3.5 x 3.5 x 3.5" boyutlarında bir küp modül olarak belirlenmiş ve 18 modül farklı şekillerde bir araya getirilerek 12 yapı formu oluşturulmuştur. Yüzey alanları ve boyutları farklılaşan ancak aynı tip malzeme kullanılan yapı formlarının simülasyon girdilerinde, bina kullanıcılarının/bina faaliyetlerinin hareketsiz olduğu varsayılmıştır. Konaklama amacıyla tasarlanan binaların, bağıl kompaktlık, yüzey alanı, duvar ve çatı alanları, yükseklik, yönelim, cam yüzey alanları ve dağılımlarından oluşan sekiz girdi parametresi ve ısıtma ve soğutma yükünden oluşan iki çıktı parametresi ile toplam 768 veri üzerinden çalışma yürütülmüştür. Girdi değişkenleri olarak adlandırılan tasarım parametreleri x ile; çıktı değişkenleri olarak adlandırılan ısıtma soğutma yükleri de y ile ifade edilmektedir (Tablo 1.)


**Tablo 1.** Verilerin Dağılımı

Veri seti			n=768		
			Ort		Std
Girdi (x)	X1	Bağıl Kompaktlık	0,76	±	0,11
	X2	Yüzey Alanı	671,71	±	88,09
	X3	Duvar Alanı	318,50	±	43,63
	X4	Çatı Alanı	176,60	±	45,17
	X5	Toplam Yükseklik	5,25	±	1,75
	X6	Yönlenme	3,50	±	1,12
	X7	Cam Alanı	0,23	±	0,13
	X8	Cam Alanı Dağılımı	2,81	±	1,55
Çıktı (y)	Y1	Isıtma Yüğü	22,31	±	10,09
	Y2	Soğutma Yüğü	24,59	±	9,51

**Ort** Ortalama, **Std** Standart Sapma

Bina parametrelerinden,

- Bağıl kompaktlık (RC/relative compactness) binanın hacminin, yüzey alanına oranıdır. Aynı hacme ve farklı form biçimlenişlerine sahip binaları karşılaştırmaya yaramaktadır (Şekil 2).  
 $RC = 6V^{2/3} \cdot A^{-1}$   $\longrightarrow$  V: binanın hacmi; A: binanın yüzey alanı
- Binanın yüzey alanı, binanın duvar, çatı ve döşeme/zemin alanlarının toplamını;
- Cam yüzey alanı, cam, çerçeve ve kanattan oluşan kaba açıklık kullanılarak ölçülen toplam alanı;
- Cam alanı dağılımı ise, cam yüzey alanının tüm bina içindeki dağılımını gösterir.



**Şekil 2.** Bina formları ve bağıl kompaktlık değerleri (Chou & Bui, 2014)

Senaryolar oluşturulurken, binalar kuzey, doğu, güney ve batı olmak üzere dört şekilde yönlendirilmiştir. Cam yüzey alanları, yapıların zemin alanlarının %10, %25 ve %40'ını oluşturacak şekilde üç çeşit ve her cam alanı için 1) Her cephede %25 cam alanı; 2) Kuzey cephesinde %55, diğer cephelerde %15; 3) Doğu cephesinde %55, diğer cephelerde %15; 4) Güney cephesinde %55, diğer cephelerde %15; 5) Batı cephesinde %55, diğer cephelerde %15 olmak üzere beş farklı şekilde simüle edilmiştir. Ek olarak dört cephede de hiç cam alanı olmayan kütleler oluşturulmuş ve böylece toplamda  $(12 \times 3 \times 5 \times 4) + (12 \times 4) = 768$  bina incelenmiştir. Bina simülasyonlarında, iç mekân koşulları, nem %60, hava akış hızı 0.30 m/s, sıcaklık: 19-24 °C aralığında, aydınlatma seviyesi 300 lx ve kullanıcılar 0.6 clo giysili olarak girilmiştir. Çalışma süresi hafta içi 15-20 saat ve hafta sonları 10-20 saat olarak belirlenmiştir (Tsanas and Xifara 2012).

## 2.2. Özellik Seçme

Özellik Seçimi (Feature Selection), veri kümesi içerisinde yer alan özelliklerinden en etkili olan altkümenin seçimi olarak tanımlanabilir (Budak 2018). Veri setindeki özelliklerin sonuç performansına göre değerlendirilerek en etkili ve önemli özelliklerin seçilmesi, analiz sürecinde uygulamacıya kolaylık sağlamaktadır. Bu amaçla, yürütülen çalışmada özellik seçimi algoritması olan Spearman Korelasyon Katsayısı kullanılmıştır. Sekiz özellik, ısıtma ve soğutma yükü tahmininde elde edilen korelasyon değerine göre sıralanmıştır. Her iki yük tahmini için de, sonuçla en çok ilişkili özellik toplam yükseklik olarak görülmüştür. Daha sonra sırasıyla, çatı alanı, bağıl kompaktlık, yüzey alanı, duvar alanı, cam alanı, cam alanı dağılımı ve yönlendirme parametreleri sonuç çıktılarını etkilemektedir.

**Tablo 2.** Özelliklerin Sıralaması

ÖN	Özellikler	R	
		Isıtma Yükü	Soğutma Yükü
5	Yükseklik	0,86	0,86
4	Çatı alanı	0,80	0,80
1	Bağıl kompaktlık	0,62	0,65
2	Yüzey alanı	0,62	0,65
3	Duvar alanı	0,47	0,42
7	Cam alanı	0,32	0,29
8	Cam alanı dağılımı	0,07	0,05
6	Yönlendirme	0,00	0,02

**ÖN:** Özellik Numarası, **R:** Korelasyon Katsayısı

## 2.3. Karar Ağaçları

Karar ağaçları, tahmin uygulamaları için uygulanan popüler bir makine öğrenme yöntemidir (Amasyali & El-Gohary, 2018). Köklerden yapraklara büyüyen bir ağacın fikrinden esinlenmiştir. Bir karar ağacı modelinde, her düğüm bir özelliği temsil eder, ağacın her dalı bir özellik için farklı bir değeri temsil eder. Her düğümde, bir girdi değişkeni üzerindeki belirli bir koşul dikkate alınarak bir test gerçekleştirilir ve dallar, tahmin edilen çıktının olası bir değerini belirlemek için yaprak düğümlere ulaşılan kadar bölünmeye devam eder. Karar ağacı yöntemi, hem erken tasarım aşamasında hem de kullanım sonrası çalışmalar için uygulanan tekniklerdendir (Bourdeau et al., 2019). Gömülü sistemlere uygulanabilir olması, karmaşıklığı az olacak şekilde algoritma üretilebilmesi sebebiyle bu çalışmada modelleme için karar ağacı yöntemi tercih edilmiştir.

#### 2.4. Performans Değerlendirme Süreci

Makine öğrenmesi ile model oluşturulduktan sonra modelin performansının değerlendirilmesi gerekmektedir. Tahmin modellerinin performansı, Ortalama Mutlak Yüzde Hata (MAPE), Ortalama Karakök Sapması (RMSE), Ortalama Mutlak Sapma (MAD), Korelasyon Katsayısı (R), Açıklayıcılık Katsayısı ( $R^2$ ) ve Ortalama Hata Karesi (MSE) gibi çoklu değerlendirme kriterleri kullanılarak karşılaştırılır (Amasyali & El-Gohary, 2018; Zheng, 2015). R ve  $R^2$  değerlerinin 1'e yakın olması MAPE, RMSE, MAD, SH ve MSE'nin 0'a yakın olması beklenir. Elde edilen sonuçlar, tahmin modelinin mümkün olan en az girdi verileriyle geliştirilmesine yön vermektedir.

Literatürde yer alan veri setinden elde edilen 768 veri, eğitim ve test olmak üzere iki parçaya bölünmüş ve karar ağacı modeli ile analiz edilmiştir. Toplam verinin %80'i modeli eğitmek için kullanılmış, kalan %20'lik kısım ile ise oluşturulan model test edilmiştir (Tablo 3).

**Tablo 3.** Veri setinin eğitim ve test dağılımı

Veri Seti	Eğitim (%80)	Test (%20)	Toplam
Isıtma	615	153	768
Soğutma	615	153	768

### 3. TAHMİN SONUÇLARI

Enerji verimli bina tasarımına hizmet edebilmek amacıyla, tasarım aşamasındaki binaların ısıtma soğutma yüklerinin tahmini için karar ağacı tabanlı bir kural dizisi oluşturmak bu çalışmanın amacını oluşturmaktadır. Bu amaçla ilk olarak Spearman Korelasyon Katsayısı kullanılarak özellik seçme işlemi yapılmış ve özellikler, sonuca etkisine göre sıralanmıştır (Tablo 2). Oluşturulan modelde bina parametrelerinden oluşan özelliklerin farklı R değerlerine sahip olması, her özelliğin yüklerle etkisinin farklı olduğunun göstergesidir.

Konut binalarının hem ısıtma hem soğutma yükü tahmini için belirlenen her özellik ile karar ağacı oluşturulmuş ve performansları değerlendirme kriterlerine göre incelenmiştir. Isıtma yükü değerlerine yönelik tahmin sonuçları Tablo 4.' te görülmektedir.

**Tablo 4.** Isıtma yükü performans değerleri

Özellikler		Performans Değerlendirme Kriterleri						
ÖS	ÖY	MAPE	RMSE	MAD	SH	R	$R^2$	MSE
1	13	17,70	4,57	3,48	4,60	0,86	0,74	20,91
2	25	17,20	4,37	3,32	4,40	0,85	0,73	19,12
<b>3</b>	<b>38</b>	<b>13,27</b>	<b>3,53</b>	<b>2,52</b>	<b>3,55</b>	<b>0,92</b>	<b>0,85</b>	<b>12,47</b>
4	50	13,27	3,53	2,52	3,55	0,92	0,85	12,47
5	63	13,27	3,53	2,52	3,55	0,92	0,85	12,47
6	75	12,90	3,54	2,51	3,56	0,92	0,84	12,50
7	88	12,90	3,54	2,51	3,56	0,92	0,84	12,50
8	100	12,90	3,54	2,51	3,56	0,92	0,84	12,50

**ÖS:** Özellik Sayısı, **ÖY:** Özellik Yüzdesi

Tabloya göre ilk üç özellik olan yükseklik, çatı alanı ve bağıl kompaktlık parametreleri ile ısıtma yükü tahmin performansları farklılaşmıştır. İlk üç özellikten sonra eklenen binaların yüzey alanı (dördüncü özellik) ve duvar alanı (beşinci özellik) parametreleri, performans sonuçlarında herhangi bir değişiklik oluşturmamıştır. Binanın cam yüzeylerinin alanının değerlendirilmeye eklenmesi, performans sonuçlarında ufak değişimlere yol açmıştır. Binaların cam alanı dağılımı ile bina yönelmesi parametrelerinin ise sonuç performans değerlerini etkilemediği görülmektedir.

**Tablo 5.** Soğutma yükü performans değerleri

Özellikler		Performans Değerlendirme Kriterleri						
ÖS	ÖY	MAPE	RMSE	MAD	SH	R	R <sup>2</sup>	MSE
1	13	12,85	4,12	3,09	4,15	0,86	0,75	17,01
2	25	11,99	3,80	2,84	3,82	0,87	0,75	14,44
<b>3</b>	<b>38</b>	<b>10,12</b>	<b>3,11</b>	<b>2,40</b>	<b>3,13</b>	<b>0,91</b>	<b>0,83</b>	<b>9,64</b>
4	50	10,12	3,11	2,40	3,13	0,91	0,83	9,64
5	63	10,12	3,11	2,40	3,13	0,91	0,83	9,64
6	75	9,87	3,17	2,38	3,19	0,91	0,84	10,06
7	88	9,87	3,17	2,38	3,19	0,91	0,84	10,06
8	100	9,87	3,17	2,38	3,19	0,91	0,84	10,06

**ÖS:** Özellik Sayısı, **ÖY:** Özellik Yüzdesi

Tablo 5.' te soğutma yükü değerlerine yönelik tahmin sonuçları verilmiştir. Tabloya göre yükseklik, çatı alanı ve bağıl kompaktlık parametreleri binalarınsoğutma yükü tahmin performans değerlerini etkilemiştir. Bu özelliklere, sırasıyla binaların yüzey alanı ve duvar alanı parametrelerinin eklenmesi performans sonuçlarına herhangi bir etki oluşturmamıştır. Binanın cam yüzeylerinin alanı parametresinin eklenmesiyle toplam altı özellik üzerinden model oluşturulmuş ve değerlendirilmeye alınmış ve sonuç değerlerinde minimal derecede farklılıklar gözlemlenmiştir. Son iki parametrenin (binaların cam alanı dağılımı ile bina yönelmesi) eklenmesi, ilk altı parametre ile elde edilen sonuç performans değerlerini farklılaştırmamıştır.

#### 4. TARTIŞMA VE SONUÇ

Makine öğrenimi teknikleri, karmaşık girdi ve çıktı ilişkisini ele alma biçimi nedeniyle her disiplinde olduğu gibi mimarlık disiplini de literatürde yerini almıştır. Yapılan çalışma, binaların, duvar alanı, cam yüzey alanı, çatı alanı gibi fiziksel parametrelerinin kullanılarak, ısıtılması ve soğutulması için gerekli enerji yükünün kabul edilebilir hata payları ile öngörülebildiğini göstermektedir. Sekiz bina parametresinin ısıtma ve soğutma yükleri üzerindeki istatistiksel ilişkinin incelendiği bu çalışma sonucunda, toplam bina yüksekliği, duvar alanı ve çatı alanının performansı etkileyen önemli özellikler olduğu saptanmıştır. Cam yüzey alanı, her iki çıktı değişkeni ile de en fazla korelasyona sahip olmadığı görülmüştür. Simülasyon aracı yardımıyla yeni bir binanın yeniden modellenerek enerji performansını belirlemek yerine kural tabanlı yaklaşım olarak karar ağaçları tasarım sürecinde mimarlar ve diğer sektör paydaşlarının kullanabileceği pratik bir uygulama olabilir. Bu çalışmanın bulguları, makine öğrenimi ile enerji tahminine odaklanan literatürdeki bulgularla uyumludur (Chou & Bui, 2014; Fan et al., 2014; Moayedi & Mosavi, 2021; Seyedzadeh et al., 2018)

Enerji talep tahmini, binaların enerji verimliliğine hizmet etmesi açısından önemlidir. Makine öğrenim teknikleri girdi olarak yalnızca değişkenlerin parametrik değerlerini



gerektiğinden, tasarım aşamasında karar destek araçları için uygundur. Farklı tekniklerin performansı, kullanılan girdi parametreleri, eğitim için mevcut verilerin türü/kalitesi, bir tekniğin belirli bir model tipine uygunluğu vb. gibi faktörlere bağlı olarak modelden modele değişmektedir. Performans açısından hiçbir teknik diğerlerinden daha iyi değildir. Bu çalışmada, konut binalarının enerji performansının tahmini için bir makine öğrenim yöntemi önerilmiştir. Birtakım fiziksel bina parametreleri ile yapılan bu çalışma tasarım aşamasında binaların enerji performansını tahmin edebilmesi açısından faydalı görülmektedir. Değişen makine öğrenim tekniklerine, bina tipine, kullanım amacına ve parametrelerine bağlı olarak sonuçların değişebileceği de unutulmamalıdır. Isıtma ve soğutma yükü tahmini için önerilen kural tabanlı yöntemin, basit ve anlaşılır bir yaklaşım olarak pratikte kullanımının hızlı ve verimli olduğu düşünülmektedir. Daha sonraki çalışmalarda metodoloji, iklim koşulları, kullanıcı davranışı gibi parametreleri kapsayacak şekilde genişletilebilir.

## 5. KAYNAKÇA

- Ahmad, T., Chen, H., Guo, Y., & 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. <https://doi.org/10.1016/j.enbuild.2018.01.017>
- Amasyali, K., & El-Gohary, N. M. (2018). A review of data-driven building energy consumption prediction studies. In *Renewable and Sustainable Energy Reviews* (Vol. 81, pp. 1192–1205). Elsevier Ltd. <https://doi.org/10.1016/j.rser.2017.04.095>
- Batish, A., & Agrawal, A. (2020). Building Energy Prediction for Early Design Stage Decision Support: A Review of Data-driven Techniques. *Proceedings of Building Simulation 2019: 16th Conference of IBPSA*, 16, 1514–1521. <https://doi.org/10.26868/25222708.2019.211032>
- Bourdeau, M., Zhai, X. qiang, Nefzaoui, E., Guo, X., & Chatellier, P. (2019). Modeling and forecasting building energy consumption: A review of data-driven techniques. *Sustainable Cities and Society*, 48, 101533. <https://doi.org/https://doi.org/10.1016/j.scs.2019.101533>
- Budak, H. (2018). Özellik Seçim Yöntemleri ve Yeni Bir Yaklaşım. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 22(Özel), 21. <https://doi.org/10.19113/sdudfbed.01653>
- Chou, J. S., & Bui, D. K. (2014). Modeling heating and cooling loads by artificial intelligence for energy-efficient building design. *Energy and Buildings*, 82, 437–446. <https://doi.org/10.1016/j.enbuild.2014.07.036>
- Fan, C., Xiao, F., & 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. <https://doi.org/10.1016/j.apenergy.2014.04.016>
- Gao, W., Alsarraf, J., Moayedi, H., Shahsavari, A., & Nguyen, H. (2019). Comprehensive preference learning and feature validity for designing energy-efficient residential buildings using machine learning paradigms. *Applied Soft Computing Journal*, 84, 105748. <https://doi.org/10.1016/j.asoc.2019.105748>
- Moayedi, H., & Mosavi, A. (2021). Suggesting a Stochastic Fractal Search Paradigm in Combination with Artificial Neural Network for Early Prediction of Cooling Load in Residential Buildings. *Energies*, 14(6), 1649. <https://doi.org/10.3390/en14061649>
- Seyedzadeh, S., Rahimian, F. P., Glesk, I., & Roper, M. (2018). Machine learning for estimation of building energy consumption and performance: a review. In *Visualization in Engineering* (Vol. 6, Issue 1). <https://doi.org/10.1186/s40327-018-0064-7>
- Tsanas, A., & Xifara, A. (2012a). *UCI Machine Learning Repository: Energy efficiency Data Set*. <https://archive.ics.uci.edu/>  
<https://archive.ics.uci.edu/ml/datasets/energy+efficiency>
- Tsanas, A., & Xifara, A. (2012b). Accurate quantitative estimation of energy performance



- of residential buildings using statistical machine learning tools. *Energy and Buildings*, 49, 560–567. <https://doi.org/10.1016/j.enbuild.2012.03.003>
- Yu, Z., Haghghat, F., Fung, B. C. M., & Yoshino, H. (2010). A decision tree method for building energy demand modeling. *Energy and Buildings*, 42(10), 1637–1646. <https://doi.org/10.1016/j.enbuild.2010.04.006>
- Zhao, J., Lasternas, B., Lam, K. P., Yun, R., & 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. <https://doi.org/10.1016/j.enbuild.2014.07.033>
- Zheng, A. (2015). Evaluating Machine Learning Models. In S. Cutt (Ed.), *O'Reilly Media, Inc.* (1st ed.). <https://edu.heibai.org/evaluating-machine-learning-models.pdf>