

## ADABOOST.R2 REGRESYON ALGORİTMASI İLE KONUTLARIN ISITMA VE SOĞUTMA YÜKLERİNİN TAHMİN EDİLMESİ

Ayşe Merve ACILAR

Dr. Öğr. Üyesi, Necmettin Erbakan Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, [m.acilar@erbakan.edu.tr](mailto:m.acilar@erbakan.edu.tr), Konya/Türkiye

### ÖZET

Kısıtlı kaynaklardan elde edilen enerjinin verimli kullanımı hem bizim hem geleceğimiz için oldukça önemlidir. Enerjiyi en çok tüketen sektörlerin başında bina sektörü gelmektedir. Bina sektörü içerisinde en büyük paya %75 ile konutlar sahiptir. Bundan dolayı enerji verimliliği yüksek konutların inşa edilmesi, enerji ihracatı oldukça yüksek olan ülke ekonomimiz içinde önem arz etmektedir. Enerji ve Tabii Kaynaklar Bakanlığı tarafından hazırlanan “2017-2023 Ulusal Enerji Verimliliği Eylem Planı” çerçevesinde Bina ve Hizmetler sektörü için 12 adet eylem planı belirlemiştir. 2. Eylem Planına göre “Mevcut Binaların Enerji Kimlik Belgesi Sahiplik Oranının Artırılması” hedeflenmektedir. Yeni konutların tasarım esnasında EnergyPlus, EcoTech vb. simülasyon programları kullanılarak enerji tüketimleri tahmin edilebilmektedir. Ancak mevcut konutların pahalı simülasyon yazılımları ile tasarlanmasına gerek kalmadan, belirlenen parametre değerlerinin girdi olarak kullanılacağı (Binanın yüzey alanı, çatı alanı, cam alanı, cephesi vb.) makine öğrenmesi algoritmaları ile daha az maliyetle, daha kısa sürede ve programı kullanım tecrübesi ve uzmanlığı gerektirmediğinden daha pratik bir şekilde konutların enerji tüketimleri hesaplanabilir. Bu çalışmada, konutların enerji tüketimini en çok etkileyen ısıtma ve soğutma yüklerinin tahmini için ADABOOST.R2 algoritmasını kullanan yeni bir yaklaşım önerilmiş ve deneysel çalışmalar sonucu kullanılabilirliği gösterilmiştir.

**Anahtar Kelimeler:** Enerji verimliliği, konut ısıtma yükü, konut soğutma yükü, Regresyon, AdaBoost.R2

### HEATING AND COOLING LOAD ESTIMATION OF RESIDENTIAL BUILDINGS USING ADABOOST.R2 REGRESSION ALGORITHM

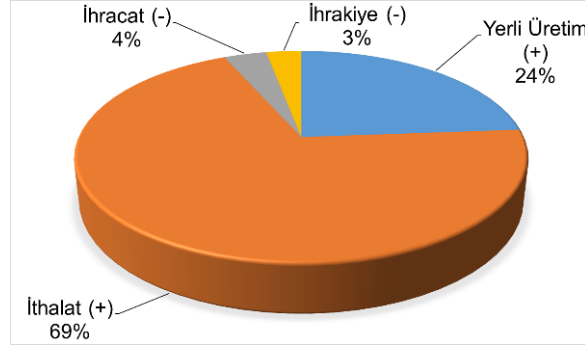
#### ABSTRACT

The efficient use of energy obtained from limited sources is very important for both us and our future. The building sector comes first among the sectors that consume energy the most. The largest share in the building sector is residential buildings with 75%. For this reason, the construction of high energy-efficient residential buildings is important in our economy, which has a high energy import. Within the framework of the “2017-2023 National Energy Efficiency Action Plan” prepared by the Ministry of Energy and Natural Resources, 12 action plans were determined for the Building and Services sector. According to the Action Plan 2, “Increasing Ownership Rate of the Energy Identity Certificate of Existing Buildings” is targeted. During the design of new buildings, energy consumption can be estimated by using simulation programs, for example, EnergyPlus, EcoTech, etc. However, the energy consumption of the existing residences could be calculated using machine learning algorithms, without the need for expensive simulation software programs. In this study, a new approach using the ADABOOST.R2 algorithm has been proposed for the estimation of the heating and cooling loads that affect the energy consumption of the residential building. According to experimental results, the AdaBoost.R2 algorithm is an effective and stable algorithm that can be used for this purpose.

**Keywords:** Building energy evaluation Heating load Cooling load, Regression, AdaBoost.R2

## 1.GİRİŞ

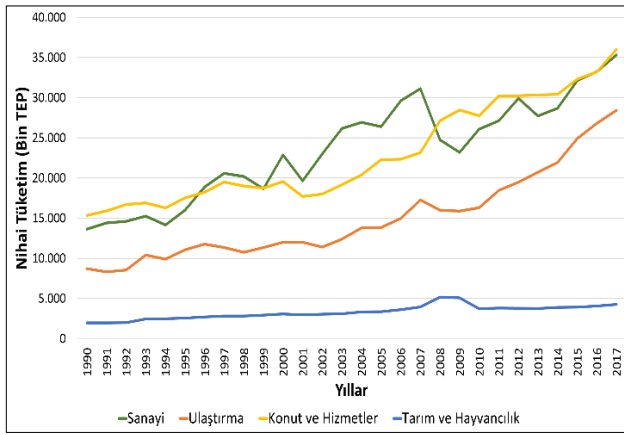
Enerjinin verimli kullanımı tüm dünyada olduğu gibi ülkemiz içinde oldukça önemlidir. Artan nüfus ve gelişen sanayi sebebiyle ülkemizin enerji tüketimi hızla artmaktadır. Ancak enerji üretimimizin aynı hızı yakalayamaması (Şekil-1) ve enerji ihtiyacının yurt dışı kaynaklardan karşılanması zorunluluğu ülke ekonomisini olumsuz şekilde etkilemektedir. Bu kapsamda enerji masraflarının düşürülmesiyle elde edilen tasarruf, enerji ithalatının azalmasına sebep olacağı için büyük önem arz etmektedir.




Şekil-1: 2018 yılına ait enerji arz dağılım grafiği (“Enerji İşleri Genel Müdürlüğü - 2018 Yılı Ulusal Enerji Denge Tabloları,” n.d.)

Enerji tasarruf/verim potansiyeli en yüksek olan sektör ise binalardır (Yüksekkaya, 2016). Ayrıca toplam ve nihai enerji tüketimi incelendiğinde son on yıl için en yüksek paya da bina sektörünün sahip olduğu görülmektedir (Şekil-2). TÜİK 2000 yılı bina sayım verilerine göre bina tiplerinin bina stoku içindeki oranı (Şekil-3) incelendiğinde %75’ni konutların oluşturduğu görülmektedir (Keskin, 2010). Tüm bu veriler doğrultusunda binaların enerji verimlilikleri ile ilgili düzenlemelerin yapılması kaçınılmazdır. 2 Mayıs 2007 tarihli Resmi Gazete’de yayımlanan 5627 sayılı Enerji Verimliliği Kanununun yürürlüğe girmesinden sonra, farklı Bakanlıklar tarafından çok sayıda yönetmelik, genelge, tebliğ yayımlanarak Türkiye’nin enerji verimliliği mevzuat çerçevesi oluşturulmuştur.

05.12.2008 tarihli ve 27075 sayılı Resmi Gazete’de yayımlanan AB’nin 2002/91/EC sayılı “Binaların Enerji Performansı Direktifi” temel alınarak hazırlanan Binalarda Enerji Performansı Yönetmeliği (BEP Yönetmeliği) yayımlanmış, 09.10.2008 tarihli ve 27019 sayılı Resmî Gazete’de yayımlanan Binalarda Isı Yalıtım Yönetmeliği’ni yürürlükten kaldırmış ve 2010 ve 2011 yıllarında revizyona tabi tutulmuştur. Yürürlüğe giriş tarihi itibarıyla yeni yapılacak binaların yanı sıra mevcut binalar da yönetmelik kapsamına dâhil edilmiştir. Yönetmelik gereğince binaların enerji performanslarının “A” ile “G” sınıfları arasında etiketlenerek belgelendirilmesi çalışmaları başlamıştır. Yönetmeliğin yayımlanmasından önce yapı ruhsatı alınmış “mevcut binalar” için EVK’nın yayımlandığı yıldan 10 yıl sonrasına kadar süre verilmiştir. Yeni binalar için asgari “C Sınıfı” belge alabilme koşullarına sahip olmak zorunlu olup, mevcut binalar için böyle bir zorunluluk bulunmamaktadır (Yüksekkaya, 2016). Enerji ve Tabii Kaynaklar Bakanlığı, 1 Ocak 2020 itibarıyla binalar veya bağımsız bölümlere ilişkin alım, satım ve kiralama işlemlerinde enerji kimlik belgesi düzenlenme şartının aranacağını bildirmiştir.



Şekil-2: Sektörlere Göre Nihai Enerji Tüketiminin Yıllara Göre Dağılımı (“Çevresel Göstergeler - Sektörlere göre nihai enerji tüketimi,” n.d.)



Şekil-3: TUİK 2000 Bina Sayımına göre Bina Tiplerinin Bina Stoku İçindeki Oranı (Keskin, 2010)

Literatürde, binaların enerji performansının belirlenmesiyle ilgili çalışmalar mevcuttur. Yaman ve Gökçen (Yaman & Gökçen, 2006), İYTE-Urla- İzmir’de bulunan İdari Bina’nın enerji performansı, statik ve dinamik metotlar ile hesaplamışlardır. Statik hesaplama metodu olarak TS 825 standardını, dinamik metot olarak da CIBSE (Chartered Institution of Building Services Engineers-İngiltere) Admittance Method (Isıl girişkenlik) ve ASHRAE (The American Society of Heating, Refrigerating and Air-Conditioning Engineers-ABD) Heat Balance (Isıl Denge) isimli iki metodu kullanmış, bu metotların kıyaslamasını yapmış ve ASHRAE ile gerçeğe daha yakın sonuçlar elde ettiklerini ifade etmişlerdir. Çelik ve ark. (Çelik, Yılmaz, & Corgnati, 2011), İstanbul, Ankara, Erzurum, Muğla ve Mardin illeri için toplam 75 senaryo oluşturmuş, BEP-TR Ulusal Bina Enerji Performansı Hesaplama Yöntemi ile parametrik analiz yapmış ve konutların enerji tüketiminin parametrelere duyarlılığını test etmişlerdir. Namlı ve ark. (NAMLI & Yücel, 2018) 127 binaya ait nitelikleri kullanarak özgün bir veri seti oluşturmuş ve yapay sinir ağı, Bayes Sınıflandırıcı, k-en yakın komşu ve C4.5 algoritmaları ile ısıtma sınıfını tespit etmeye çalışmıştır. Sonuçta YSA’nın en iyi sonucu verdiğini rapor etmişlerdir. Tsanas ve ark. (Tsanas & Xifara, 2012) konutlara ait sekiz adet girdi değişkeninin ısıtma ve soğutma yükü üzerindeki etkilerini incelemek için istatistiksel bir makine öğrenme çerçevesi önermişlerdir. Isıtma ve soğutma yükünü etkileyen en önemli değişkenleri bulmak için parametrik ve parametrik olmayan istatistiksel analiz araçlarından faydalanmışlardır. Daha sonra çıkış yüklerini tahmin etmek için doğrusal regresyon ve rastgele orman algoritması kullanmışlar ve sonuçlarını kıyaslamışlardır. Deneysel sonuçlara göre ısıtma yükü her iki algoritma tarafından soğutma yüküne göre daha isabetli bir şekilde tahmin edilmiştir. İki yük tahmini için de rastgele orman algoritması daha doğru sonuçlar üretmiştir. Bu çalışmanın literatüre diğer bir katkısı ise, oluşturdukları veri setini Irvine Üniversitesine ait makine öğrenme deposuna (UCI Machine Learning Repository) “Enerji Verimliliği (Energy efficiency)” ismiyle yükleyerek diğer araştırmacıların kullanımına sunmaları olmuştur. Veri kümesi ile ilgili daha ayrıntılı bilgi makalenin Materyal ve Metot bölümünde verilmiştir. Gümüştü ve ark. (Gümüştü, Tenekeci, Beşli, İlhan, & Aslan, 2018) da çalışmalarında bu veri setini kullanmışlardır. Ancak sürekli çıkışlara sahip olan veri setinin çıkışlarını ayrıklaştırarak işlemi bir sınıflandırma problemine dönüştürmüşler ve çözüm için k-en yakın komşuluk, Destek Vektör Makineleri (DVM) ve Karar Ağaçları kullanılmasını önermişlerdir. Sonuçta, en iyi sınıflandırma başarısını karar ağacı algoritması ile elde ettiklerini beyan etmişlerdir. Aynı veri kümesi üzerindeki başka bir araştırma da Peker ve ark. (Peker, Özkara, & Kesimal, 2017) tarafından yapılmıştır. Makine öğrenmesi algoritmalarından regresyon algoritmaları (Destek Vektör Makinesi (SVM) Regresyonu, Doğrusal Regresyon, Rasgele Orman Regresyonu ve En Yakın Komşu Regresyonu) kullanılmıştır ve elde edilen sonuçlar karşılaştırılmıştır. En başarılı algoritma Rastgele Orman

Regresyon algoritması olmuştur. Yine aynı veri kümesi üzerinde Gao ve ark. (Gao, Alsarraf, Moayedi, Shahsavari, & Nguyen, 2019) korelasyon tabanlı özellik seçim algoritması kullanmışlar ve sonuç olarak duvar yüzeyi, yüzey alanı, konut cephe yönü ve cam alan dağılımının başarıyı en çok etkileyen özellikler olduğunu tespit etmişlerdir. Özellik seçimi sonrası oluşturulan yeni veri kümesine WEKA ortamında 16 farklı algoritma uygulamışlardır. Algoritmalarından performans değeri en iyi olanlardan üç tanesi Tablo-7’de verilmiştir. Urdaneta ve ark. (Urdaneta, Zapata, & Contreras, 2017) konutların enerji tüketimini tahmin etmek için bulanık mantık tabanlı bir model önermişlerdir. Castelli ve ark. (Castelli, Trujillo, & Vanneschi, 2015) konutların ısıtma ve soğutma yüklerini tahmin etmek için GSGP isimli genetik programlama tabanlı bir yöntem geliştirmişlerdir. Yerel arama ve doğrusal ölçeklendirme metotlarını da önerdikleri yönteme ekleyerek, HYBRID (genetik programlama + yerel arama) ve HYBRID-LIN(genetik programlama + yerel arama + doğrusal ölçeklendirme) iki çözüm daha üretmişlerdir. HYBRID-LIN aralarında en iyi sonucu veren algoritma olmuştur. Bu son iki çalışmada veri seti olarak enerji verimliliğini kullanmışlardır.

Çalışmanın ikinci bölümünde kullanılan materyal ve metotlar hakkında bilgiler verilmiştir. Üçün bölümde ADABOOST.R2 algoritması kullanılarak konutların ısıtma ve soğutma yüklerinin tahmini için yapılan deneysel çalışma sunulmuş, benzer çalışmalardaki sonuçlar ile kıyaslanmıştır. Son olarak sonuç bölümünde çalışmanın genel bir değerlendirmesi yapılmıştır.

## 2. MATERYAL METOT

### 2.1 Kullanılan Veri Kümesi

Bu çalışmada, Tsanas ve ark. (Tsanas & Xifara, 2012) tarafından oluşturulan ve UCI veri tabanından alınan *Enerji Verimliliği* (<https://archive.ics.uci.edu/ml/datasets/energy+efficiency>) veri kümesi kullanılmıştır. Tsanas ve ark.(Tsanas & Xifara, 2012) her biri 771.75 m<sup>3</sup> hacme sahip, yüzey alanları ve boyutları birbirinden farklı 768 konutu, 8 farklı nitelik ile karakterize etmiş ve Ecotect simülasyon yazılımını kullanarak konutlara ait ısıtma soğutma yüklerini hesaplamışlardır. Veri kümesinde yer alan nitelikler ve tanımlayıcı istatistik değerleri Tablo 1’de verilmiştir.

Tablo-1: Enerji Verimliliği Veri Kümesinin Tanımlayıcı İstatistik Değerleri

Nitelik	Minimum	Maksimum	Ortalama	Ortanca	Std.Sapma	Açıklama
X1	0,62	0,98	0,76	0,75	0,11	Bağlı Yoğunluk
X2	514,50	808,50	671,71	673,75	88,09	Yüzey Alanı
X3	245,00	416,50	318,50	318,50	43,63	Duvar Alanı
X4	110,25	220,50	176,60	183,75	45,17	Çatı Alanı
X5	3,50	7,00	5,25	5,25	1,75	Toplam Yükseklik
X6	2,00	5,00	3,50	3,50	1,12	Konut Cephe Yönü
X7	0,00	0,40	0,23	0,25	0,13	Cam Alanı
X8	0,00	5,00	2,81	3,00	1,55	Cam Alan Dağılımı
Y1	6,01	43,10	22,31	18,95	10,09	Isıtma Yükü
Y2	10,90	48,03	24,59	22,08	9,51	Soğutma Yükü

## 2.2 AdaBoost.R2 Algoritması

AdaBoost (Freund & Schapire, 1995) zayıf öğrencileri bir araya getirerek güçlü bir öğrenci oluşturan bir topluluk sınıflandırıcı yöntemidir. Her bir iterasyonda temel öğrenci adı verilen basit bir öğrenme algoritması çağırır ve öğrenciye hatası ile ters orantılı bir ağırlık katsayısı atar. Ağırlık katsayılarına bağlı ağırlıklı oylama sonucunda çözüm elde edilir. AdaBoost algoritması sınıflandırma problemlerinin çözümü için önerilmiştir. Drucker (Drucker, 1997) tarafından regresyon problemlerine uyarlanmış ve algoritmanın bu sürümü literatürde AdaBoost.R2 olarak anılmaya başlanmıştır. Algoritmanın sözde kodu Tablo 2’de verilmiştir.

Tablo 2: AdaBoost.R2 algoritmasının sözde kodu(Drucker, 1997)

### AdaBoost.R2 Algoritması

**Giriş:**  $m$  nitelikten ve  $n$  örnekten oluşan Veri kümesi: DS

$$// DS = \{(X_i, y_i) : X_i = \{x_1, x_2, \dots, x_m\} \text{ ve } y_i \in R, i = 1, \dots, n\}$$

$N$  : Maksimum iterasyon sayısı

**Öğrenci :** Öğrenci algoritması // karar ağacı kullanıldı.

**Başlangıç:** Her bir eğitim örneğinin ağırlığını 1 olarak ata,  $w_i = 1, i = 1, \dots, n$

**Tekrar et**  $t=1$ 'den  $N$ 'ye kadar

1. Her bir eğitim örneği için olasılık hesapla:  $p_i = w_i / \sum w_i$
2. Bir tane  $t$  isminde bir öğrenci oluştur. Bu öğrenci bir hipotezi yerine getirsin:
3. Her bir eğitim örneği için  $h_t$ 'yi işlet ve tahmini çıkış  $y_i^p(x_i)$ 'yi hesapla
4.  $L$  kayıp fonksiyonunu kullanarak,  $L_i = L[|y_i^p(x_i) - y_i|]$  hatasını hesapla

$$D = \sup |y_i^p(x_i) - y_i| \quad i = 1, \dots, n$$

$L$  kayıp fonksiyonunu olarak 3 adet farklı fonksiyon kullanılabilir:

- $L_i = \frac{|y_i^p(x_i) - y_i|}{D}$  (linear)
- $L_i = \frac{|y_i^p(x_i) - y_i|^2}{D^2}$  (square law)
- $L_i = 1 - e^{\left[\frac{-|y_i^p(x_i) - y_i|}{D}\right]}$  (exponential)

5. Ortalama kaybı (average loss) hesapla:  $\bar{L} = \sum_{i=1}^N L_i p_i$
6.  $t$  öğrencisinin güvenilirliğini hesapla:  $\beta_t = \frac{\bar{L}}{1 - \bar{L}}$
7. Eğer ( $\bar{L} > 0.5$ ) ise,  $N=t-1$  yap ve döngüden çık // ( $\bar{L} < 0.5$  olduğu sürece işlem devam etsin)
8. Ağırlıkları güncelle :  $w_i = w_i \beta^{[1-L_i]}$

$X_i$  örneği için, N adet öğrenciden elde edilen kümülatif tahmin  $h_f(i)$ 'yi hesapla:

$$h_f(i) = \inf \left\{ y_i \in Y : \sum_{t:h \leq y} \log(1/\beta_t) \geq \frac{1}{2} \sum_t \log(1/\beta_t) \right\}$$

**Çıkış:**  $X$  için  $h_f$  tahmini çıkış değerleri

### 2.3.Kullanılan Başarı Değerlendirme Ölçütleri

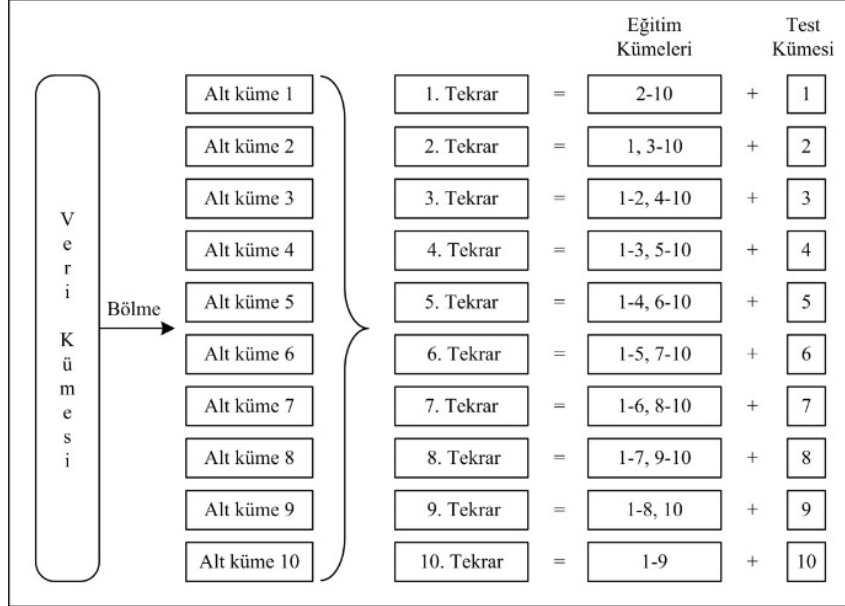
Bu çalışmada çözümü aranan sorun bir regresyon problemidir. Bu yüzden regresyon algoritmalarının başarı performansları kıyaslanırken sıklıkla kullanılan dört adet ölçüt ile ilgili bilgiler Tablo 3'de verilmiştir.

Tablo 3: Başarı Ölçütleri ve Formülleri

Simgesi	Açıklaması	Formülü
MSE	Hataların Karelerinin Ortalaması (Mean Squared Error )	$\frac{1}{n} \sum_{s=1}^N (y_{tahmin(s)} - y_{gercek(s)})^2$
RMSE	Hataların Karelerinin Ortalamasının Karekökü Root (Mean Squared Error )	$\sqrt{\frac{1}{n} \sum_{s=1}^N (y_{tahmin(s)} - y_{gercek(s)})^2}$
MAE	Hataların Mutlak Değerlerinin Ortalaması (Mean Absolute Error )	$\frac{1}{n} \sum_{s=1}^N  y_{tahmin(s)} - y_{gercek(s)} $
$R^2$	$R^2$ Değeri	$1 - \frac{\sum_{s=1}^N (y_{tahmin(s)} - y_{gercek(s)})^2}{\sum_{s=1}^N (y_{gercek(s)} - \bar{y}_{gercek(s)})^2}$

Başarı ölçütlerinden MSE, MAE ve RMSE hata oranları ile ilgili oldukları için düşük değerleri makbuldür. Ancak  $R^2$  değeri, gerçek çıkış ile algoritmanın ürettiği tahmin değerinin ne kadar uyumlu, ne kadar örtüştüğünün bir göstergesidir ve -1 ile +1 arasında bir değer alır. +1'e ne kadar yakınsa, iki değişken arasında o kadar pozitif tam yönlü bir ilişki vardır. +1 olması durumunda ise algoritma tüm çıkış değerlerini bilmiş demektir.

Şekil-4: 10-kat çapraz doğrulama işlemi



Bu çalışmada, algoritmaların veriyi ezberlemesini (overfitting) engellemek için 10-kat çapraz doğrulama yöntemi kullanılmıştır. Bu yönteme göre veri set 10 adet alt kümeye ayrılır. Bu alt kümelerden bir tanesi test, geriye kalan 9 küme ise eğitim için kullanılır. Algoritma eğitim kümesi kullanılarak eğitilir, hiç görmediği test kümesindeki veriler kullanılarak da başarısı ölçülür. Bu işlem 10 farklı alt küme ve test kümesi için sırasıyla tekrarlanır. Böylece her bir verinin en az bir kez test kümesinde yer alması sağlanır. Sonuç olarak test kümeleri için 10 adet işlemin ortalaması alınarak sistemin başarısı hesaplanır. Bu işlemin grafik gösterimi şekil-4'de verilmiştir.

### 3. DENEYSEL ÇALIŞMA

Bu çalışmada AdaBoost.R2 algoritması ile konutların ısıtma ve soğutma yüklerinin tahmin edilmesi amaçlanmıştır. Veri kümesi olarak, ayrıntıları Tablo-1'de verilen Tsanas ve ark. (Tsanas & Xifara, 2012) tarafından oluşturulup UCI'ye yüklenen oluşturulan, *Enerji Verimliliği* veri kümesi kullanılmıştır. Çalışma, Python 3.7.4 dili ile gerçekleştirilmiştir. Kütüphane olarak *sklearn.ensemble* içindeki *AdaBoostRegressor* ("sklearn.ensemble.AdaBoostRegressor — scikit-learn 0.22.1 documentation," n.d.) kullanılmıştır. Isıtma ve soğutma yükleri için AdaBoost.R2 elde edilen sonuçlar rastgele orman algoritması, doğrusal regresyon ve yapay sinir ağları algoritmalarından elde edilen sonuçlar ile kıyaslanmış ve sırasıyla Tablo-4'de ve Tablo-5'de sunulmuştur. Algoritmalara ait saçılma grafikleri de sırası ile Şekil-5 ve Şekil-6'da verilmiştir.

Tablo-4: Isıtma yükü tahmini için algoritmaların başarı ölçütleri ortalaması (10 kez çapraz doğrulama)

Algoritma Adı	MSE	RMSE	MAE	$R^2$
<i>AdaBoost.R2</i>	<b>0.248</b>	<b>0.498</b>	<b>0.323</b>	<b>0.998</b>
Rastgele Orman	0.283	0.532	0.351	0.997
Yapay Sinir Ağları	0.745	0.863	0.640	0.993

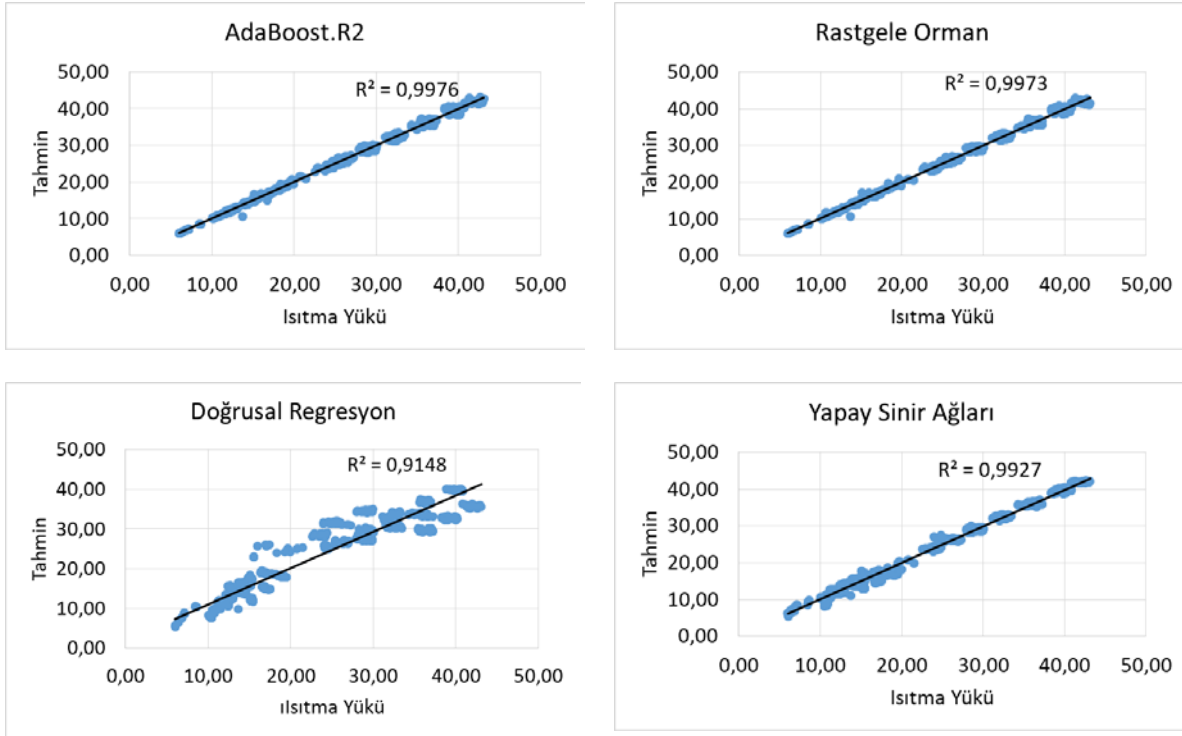
Doğrusal Regresyon	8.668	2.944	2.088	0.915
--------------------	-------	-------	-------	-------

Tablo-5: Soğutma yükü tahmini için algoritmaların başarı ölçütleri ortalaması (10 kez çapraz doğrulama)

Algoritma Adı	MSE	RMSE	MAE	R <sup>2</sup>
<b>AdaBoost.R2</b>	<b>2.236</b>	<b>1.495</b>	<b>0.805</b>	<b>0.975</b>
Rastgele Orman	3.007	1.734	1.086	0.967
Doğrusal Regresyon	10.274	3.205	2.259	0.886
Yapay Sinir Ağları	11.300	3.362	2.427	0.875

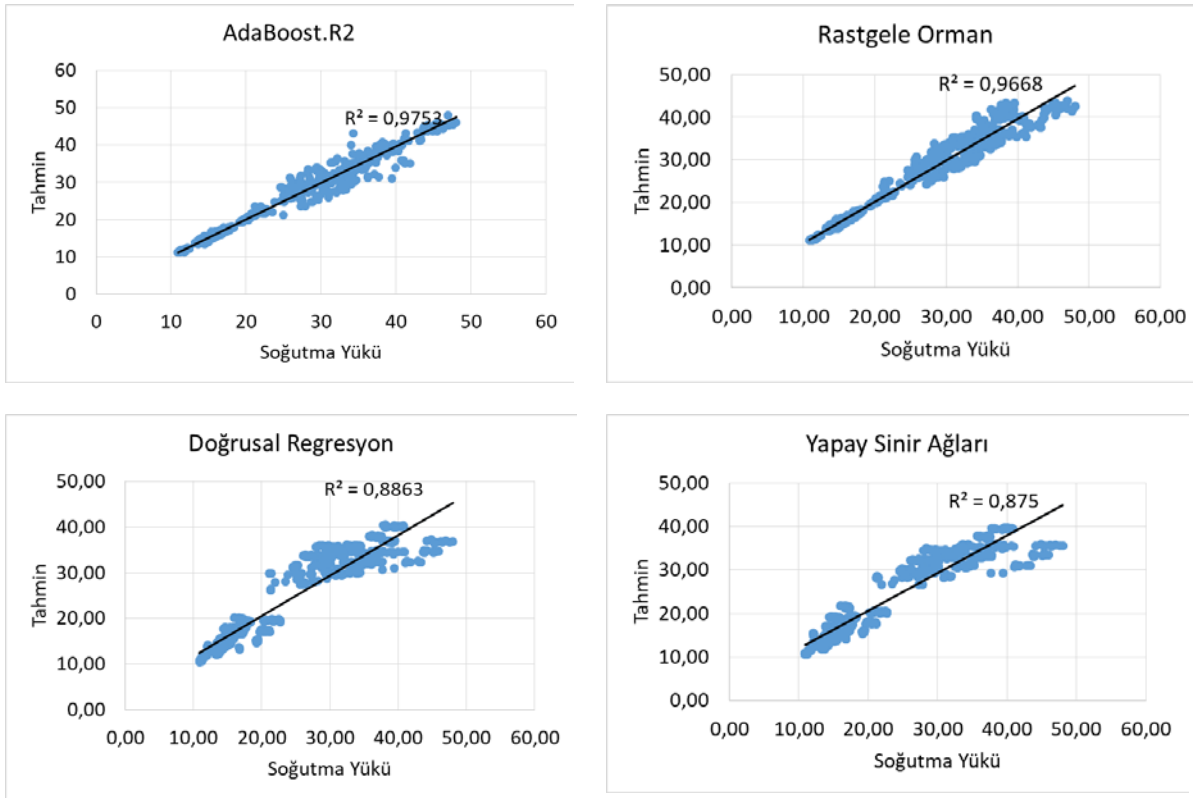
DeneySEL çalışmada kullanılan algoritmalara ait parametre değerleri şu şekildedir: AdaBoost.R2 algoritmasında temel öğrenici olarak ağaç yapısı kullanılmıştır. Öğrenici sayısı 25, öğrenme oranı 0,05 olarak ayarlanmıştır.  $L$  kayıp fonksiyonu üssel (*exponential*) olarak seçilmiştir. Rastgele Orman algoritmasında ağaç sayısı 100 olarak belirlenmiş ve altkümeler 5'den küçük olduğunda bölünmemiştir. Doğrusal regresyonda Ridge düzeltmesi kullanılmış ve alpha değeri olarak 0,019 alınmıştır. Yapay sinir ağlarında gizli katman sayısı 11, maksimum iterasyon sayısı 300 olarak ayarlanmış, aktivasyon fonksiyonu ReLu, eğitim algoritması olarak da L-BFGS-B kullanılmıştır.

8



Şekil-5: Isıtma yükü tahmininde kullanılan algoritmalara ait saçılma grafikleri





Şekil-6: Soğutma yükü tahmininde kullanılan algoritmalara ait saçılma grafikleri

Isıtma yükü tahmini için, grafik ve sonuçlar incelendiğinde algoritmaların tümünün %90 üzerinde  $R^2$  değerine sahip olduğu görülmektedir. Ancak tüm başarı ölçütlerinde en iyi sonuçları AdaBoost.R2 algoritması vermiştir. Onu Rastgele Orman algoritması takip etmektedir. En kötü sonuçlar ise doğrusal regresyon algoritmasına aittir. Soğutma yükü tahmini için algoritma sıralamasında benzer bir durum söz konusu olmasına rağmen yapay sinir ağları ve doğrusal regresyonun  $R^2$  değerleri %90 altında çıkmıştır ve başarı oranları ısıtma yükü tahminine göre, tüm algoritmalar için daha düşüktür. Ama AdaBoost.R2’de bu düşüş daha az yaşanmıştır. O yüzden tahmin işlemi için daha istikrarlı bir algoritma olduğu sonucuna varılmıştır.

Ayrıca, ısıtma ve soğutma yükü tahmini için enerji verimliği veri kümesini kullanmış literatürde ulaşılan yöntemler ile AdaBoost.R2 yöntemin kıyaslama sonuçları, yöntemin genel bir değerlendirilmesinin yapılabilmesi için incelenmiştir. Öncelikle, Tablo-6’da bu çalışmada kullanılan enerji verimliği veri kümesini oluşturan Tsanas ve ark.’nın (Tsanas & Xifara, 2012) RF ve IRLS algoritmalarını kullanarak, 100x10 kat çapraz doğrulama sonucu elde ettiği sonuçlar ile AdaBoost.R2 algoritmasının 100x10 kat çapraz doğrulama sonucu elde ettiği sonuçlar MSE başarı ölçütüne göre kıyaslanmıştır. Kıyaslama sonucu AdaBoost.R2’nin daha doğru ve daha istikrarlı sonuçlar elde ettiği görülmüştür.

Tablo-6: RF ve IRLS (Tsanas & Xifara, 2012) ile AdaBoost.R2 MSE başarı ölçütüne göre kıyaslanması (100x10kat çapraz doğrulama)

Algoritma İsimleri	Isıtma Yüğü (MSE±Std)	Soğutma Yüğü (MSE±Std)	Yükü
RF	1.03 ± 0.54	6.59 ± 1.56	
IRLS	9.87 ± 2.41	11.46 ± 3.63	
AdaBoost.R2	<b>0,265±0,0033</b>	<b>2.656 ±0,18</b>	

Literatürde ulaşılan diğer algoritmalar ile AdaBoost.R2'nin enerji verimliliği veri kümesi için 10 kez çapraz doğrulama sonuçlarına göre kıyaslaması Tablo-7'de verilmiştir.

Tablo-7: Literatürde ulaşılan diğer algoritmalar ile AdaBoost.R2 algoritmasının kıyaslanması (10 kat çapraz doğrulama)

Algoritma Adı	Isıtma Yüğü				Soğutma Yüğü			
	MSE	RMSE	MAE	R <sup>2</sup>	MSE	RMSE	MAE	R <sup>2</sup>
AdaBoost.R2 (Kullanılması Önerilen)	<b>0.248</b>	0.498	0.323	0.998	<b>2.236</b>	1.495	0.805	0.975
RF (RF'')(Gao et al., 2019)	-	<b>0.239</b>	<b>0.190</b>	-	-	<b>0.620</b>	<b>0.409</b>	-
RDT(Gao et al., 2019)	-	0.354	0.236	-	-	0.847	0.600	-
AMT(Gao et al., 2019)	-	0.544	0.409	-	-	1.330	0.998	-
Fuzzy model (Urdaneta et al., 2017)	-	1.217	-	-	-	1.745	-	-
RF Regresyon(Peker et al., 2017)	0.482	0.694	0.422	-	3.202	1.789	1.339	-
GSGP(Castelli et al., 2015)	1.02	-	1.31	-	3.61	-	1.47	-
HYBRID (Castelli et al., 2015)	0.78	-	1.26	-	3.38	-	1.37	-
HYBRID-LIN (Castelli et al., 2015)	0.47	-	0.51	-	3.33	-	1.18	-

Tablo incelendiğinde, Gao ve ark. tarafından önerilen RF'' ve RDT algoritmalarından sonra en iyi sonuçların AdaBoost.R2 algoritmasının verdiği görülmektedir. Gao ve arkadaşlarının daha başarılı olmasının sebebinin, korelasyon tabanlı bir özellik seçimi algoritmasını ön işlem olarak kullanmaları olduğu düşünülmektedir. Genel olarak incelendiğinde ise, tüm algoritmaların ısıtma yükünü soğutma yüküne göre daha iyi tahmin ettiği görülmektedir. Tsanas ve ark. bunun sebebinin, oluşturdukları algoritmada yer alan niteliklerin ısıtmayı daha iyi karakterize eden nitelikler olması şeklinde açıklamaktadırlar.

Sonuç olarak, AdaBoost.R2 algoritması içinde barındırdığı öğrenici topluluğu mekanizmasından dolayı, verimli sonuçlar elde ettiği görülmüştür.

#### 4.SONUÇ

Bir konutun enerji verimliliği, tükettiği enerji miktarı ile yakından ilişkilidir. Konutlarda tüketilen enerjinin büyük bir kısmını, iç ortamdaki konfor koşullarını devam ettirebilmek için harcanan ısıtma ve soğutma yükleri oluşturur (Kalfa, 2014). Bu çalışmada konut daha tasarım aşamasında iken, konuta ait belli değerler kullanılarak simülasyonu yapılmadan AdaBoost.R2 algoritması ile konuta ait ısıtma ve soğutma yüklerinin tahmin edilmesi işlemi gerçekleştirilmiştir. Böylelikle, çeşitli alternatifler denenerek kolay ve daha az maliyetli bir şekilde enerjiyi en verimli şekilde kullanan bina tasarımının gerçekleştirilmesi sağlanmıştır.

Deneysel sonuçlar göstermiştir AdaBoost.R2 algoritması bu amaçla kullanılabilir etkin ve istikrarlı bir algoritmadır.

## KAYNAKLAR

- Castelli, M., Trujillo, L., & Vanneschi, L. (2015). Prediction of Energy Performance of Residential Buildings : A Genetic Programming Approach Prediction of energy performance of residential buildings : a genetic programming approach. *Energy and Buildings*, 102, 67–74. <https://doi.org/10.1016/j.enbuild.2015.05.013>
- Çelik, B. Ç., Yılmaz, A. Z., & Corgnati, S. P. (2011). Konut Binaları Enerji Sertifikasyonunda Isıtma Ve Soğutma Enerjisi İhtiyacının Bina Parametrelerine Duyarlılık Analizi: Bep-Tr Hesaplama Metodolojisi İle Değerlendirme. In *X.Ulusal Tesisat Mühendisliği Kongresi* (pp. 781–792). İzmir.
- Çevresel Göstergeler - Sektörlere göre nihai enerji tüketimi. (n.d.). Retrieved February 13, 2020, from <https://cevreselgostergeler.csb.gov.tr/sectorlere-gore-nihai-enerji-tuketimi-i-85804>
- Drucker, H. (1997). Improving regressors using boosting techniques. *14th International Conference on Machine Learning*, 107–115. Retrieved from [http://www.researchgate.net/publication/2424244\\_Improving\\_Regressors\\_using\\_Boosting\\_Techniques/file/3deec51ae736538cec.pdf%5Cnhttp://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.31.314](http://www.researchgate.net/publication/2424244_Improving_Regressors_using_Boosting_Techniques/file/3deec51ae736538cec.pdf%5Cnhttp://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.31.314)
- Enerji İşleri Genel Müdürlüğü - 2018 Yılı Ulusal Enerji Denge Tabloları. (n.d.). Retrieved February 15, 2020, from <https://www.eigm.gov.tr/tr-TR/Sayfalar/2018-Yili-Ulusal-Enerji-Denge-Tabloları>
- Freund, Y., & Schapire, R. E. (1995). A decision-theoretic generalization of on-line learning and an application to boosting. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 904(1), 23–37. [https://doi.org/10.1007/3-540-59119-2\\_166](https://doi.org/10.1007/3-540-59119-2_166)
- 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. <https://doi.org/10.1016/j.asoc.2019.105748>
- Gümüşçü, A., Tenekeci, M. E., Beşli, N., İlkhan, M. A., & Aslan, E. (2018). Harran Üniversitesi Mühendislik Dergisi Yapılarda Isıtma ve Soğutma Yükü Sınıfların Makine Öğrenme Yöntemleri ile Belirlenmesi Determination of Building Heating and Cooling Load Classes by Machine Learning Methods, 02, 60–66.
- Kalfa, M. S. (2014). *Türkiye İklim Bölgelerinde Konut Binaları için Isıtma ve Soğutma Yüklerinin Belirlenmesinde Kullanılabilir Bir Yaklaşım*. Karadeniz Tekni Üniversitesi. <https://doi.org/10.1038/132817a0>
- Keskin, T. (2010). *Binalar Sektörü Mevcut Durum Değerlendirmesi Raporu Hazırlayan: Tülin Keskin*.
- NAMLI, E., & Yücel, M. (2018). Yapay Zekâ Modelleri İle Betonarme Yapılara Ait Enerji Performans Sınıflarını Tahmini. *Uludağ University Journal of The Faculty of Engineering*, 22(3), 325–346. <https://doi.org/10.17482/uumfd.332320>
- Peker, M., Özkaraca, O., & Kesimal, B. (2017). Enerji Tasarruflu Bina Tasarımı İçin Isıtma ve Soğutma Yüklerini Regresyon Tabanlı Makine Öğrenmesi Algoritmaları İle Modelleme. *Bilişim Teknolojileri Dergisi*, 443–449. <https://doi.org/10.17671/gazibtd.310154>
- sklearn.ensemble.AdaBoostRegressor — scikit-learn 0.22.1 documentation. (n.d.). Retrieved

February 17, 2020, from <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.AdaBoostRegressor.html>

- Szokolay, S. (2004). *Introduction to Architectural Science: The Basis of Sustainable Design, First Edition*. Architectural Press, Oxford.
- Tsanas, A., & Xifara, A. (2012). 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>
- Urdaneta, S., Zapata, E., & Contreras, J. (2017). Fuzzy model for estimation of energy performance of residential buildings. *International Journal of Applied Engineering Research*, 12(11), 2766–2771.
- Yaman, M. C., & Gökçen, G. (2006). Statik Ve Dinamik Hesaplama Metodları İle Binalarda Enerji Performans Değerlendirmesi, Ölçüm Değerleri İle Karşılaştırılması. In *IX Ulusal Tesisat Mühendisliği Kongresi* (pp. 509–525).
- Yenilenebilir Enerji Genel Müdürlüğü. (2018). *Ulusal Enerji Verimliliği Eylem Planı 2017-2023*.
- Yüksekkaya, T. (2016). *Binalarda Enerji Verimliliği: AB ve Türk Mevzuatı El Kitabı*.