

Enerji Tasarruflu Bina Tasarımı için Isıtma ve Soğutma Yüklerini Regresyon Tabanlı Makine Öğrenmesi Algoritmaları ile Modelleme

Musa PEKER¹, Osman ÖZKARACA^{2*}, Betül KESİMAL³

^{1,2,3} Bilişim Sistemleri Mühendisliği, Muğla Sıtkı Koçman Üniversitesi, Muğla Türkiye

musa@mu.edu.tr, osmanozkaraca@mu.edu.tr, betulkesimal@posta.mu.edu.tr

(Geliş/Received:02.05.2017; Kabul/Accepted:03.08.2017)

DOI: 10.17671/gazibtd.310154

Özet— Günümüzde bilişim teknolojileri hemen hemen her alanda kullanılmaktadır. Enerji sektörü de bu alanlardan birisidir. Nüfusun gün geçtikçe artmasıyla birlikte bina sayısı ve binaların enerji talebi de artmıştır. Enerji talebini hafifletmenin bir yolu enerji tasarrufu özelliklerine sahip verimli binalar tasarlamaktır. Bu çalışmada sekiz giriş değeri (nispi yoğunluk, yüzey alanı, duvar alanı, çatı alanı, toplam yükseklik, yönlendirme, cam alanı ve cam alanı dağılımı) ve iki çıkış değeri (ısıtma yükü (HL), soğutma yükü (CL)) olan bir veri setinin, makine öğrenmesi algoritmaları kullanarak analizi yapılmıştır. Amaç, konutların ısıtma ve soğutma yükünü tahmin edebilen bir model oluşturmaktır. Bu parametrelerin doğru bir şekilde tahmin edilmesi, enerji tüketiminin daha iyi kontrol edilmesini kolaylaştırmakta ve ayrıca, enerji piyasasında önemli bir sorun olarak görülen enerji ihtiyacına daha iyi uyan enerji tedarikçisinin seçiminde yardımcı olmaktadır. Bu kapsamda, veri seti analiz edilirken makine öğrenmesi algoritmalarından regresyon algoritmaları (Destek Vektör Makinesi (SVM) Regresyonu, Doğrusal Regresyon, Rasgele Orman Regresyonu ve En Yakın Komşu Regresyonu) kullanılmıştır. İki çıkış değeri için sonuçlar deneysel olarak her algoritma için ayrı ayrı hesaplanmış ve elde edilen sonuçlar karşılaştırılmıştır. Çıkan sonuçlara göre analiz yaptığımız veri seti için, tahmin başarımları açısından en yakın sonucu bulan algoritma Rastgele Orman Regresyon algoritması olmuştur.

Anahtar Kelimeler— Enerji performansı, Regresyon, SVM regresyon, Lineer regresyon, Rastgele orman regresyon

Modeling heating and cooling loads by regression-based machine learning techniques for energy-efficient building design

Abstract— Today, information technology is used almost in every field. The energy sector is one of these areas. As the population grew day by day, the number of buildings and the energy demands of the buildings increased. One way to decrease energy demand is to design efficient buildings with energy-saving features. In this study, an analysis of a data set which has eight input values (relative compactness, surface area, wall area, roof area, overall height, orientation, glazing area and glazing area distribution) and two output values (heating load (HL), cooling load (CL)), has been carried out using machine learning algorithms. The aim is to create a model that predicts the heating and cooling load of the houses. Accurate estimation of these parameters facilitates controlling of energy consumption and also helps in selecting an energy supplier that better suits the energy requirement, which is considered a significant problem in the energy market. In this context, when analyzing the data set, regression algorithms (Support Vector Machine (SVM) Regression, Linear Regression, Random Forest Regression and Nearest Neighbor Regression) are used among machine learning algorithms. For the two output values, the results have been calculated experimentally for each algorithm and the results have been compared. For the data set we analyzed according to the results, the algorithm that found the closest result in terms of prediction success is Random Forest regression algorithm.

Keywords— Energy Performance, Regression, SVM Regression, Linear Regression, Random Forest Regression

1. GİRİŞ (INTRODUCTION)

Dünyamızda son yüzyılda artan enerji ihtiyacına karşın iklim ve eko sistem değişikliği insanlığa büyük bir tehdit oluşturmaktadır. Bu nedenle ülkeler ciddi politikalar ve çözüm yolları arayışına girmeye başlamışlardır. Örneğin; İngiltere, 2050 yılına kadar karbon emisyonlarında yüzde 80 oranında bir azalma sağlamayı taahhüt etmektedir. Bu zorlukları gidermek için, enerji tüketiminin azaltılması ve sürdürülebilir, düşük karbonlu yaşam biçimlerinin hızlandırılması gerekir [1].

Bunun yanında küreselleşen dünya ve rekabet şartlarının artmasıyla birlikte enerji, ekonomide önemli bir rol oynamaktadır. Talep açısından baktığımızda enerji, tüketicilerin faydalarını arttırmak için satın aldıkları bir ürün niteliği taşımaktadır. Arz açısından bakıldığında ise enerji, sermaye ve emek gibi önem arzeden bir üretim faktörü olma özelliğindedir. Ayrıca enerji, birçok tüketim ve üretim faaliyetlerinde gerekli bir parametre olduğu için, ülkelerdeki sosyal refahın oluşturulmasında ve ekonomik gelişmeler açısından kritik ve belirleyici bir konuma sahiptir [2].

Kaynakların hızla tükendiği dünyamızda, harcanan enerji miktarının hızla artması ve buna bağlı olarak ekosistem dengesinin bozulması sonucu, enerji kullanımını üzerinde yeni yaklaşımların ve çalışmaların oluşmasına neden olmuştur [3]. Enerji üretiminin tükenebilir ve dışa bağımlı kaynaklardan elde edildiği gelişmekte olan ülkelerde arz-talep arasındaki oluşan farklardan dolayı enerjinin maliyetinin giderek arttığı ve ülkeleri daha bağımlı hale getirdiği görülmektedir. Bu nedenle ülkeleri bağımlı kılan enerjinin tüketiminde en iyi yöntemleri kullanarak tasarruf edilmesi çok önemli bir zorunluluktur [4]. Enerji'nin etkin bir şekilde kullanımı, enerji maliyetlerinin ekonomi üzerindeki yükünün hafifletilmesi, israfın önlenmesi ve çevrenin korunması için enerji kaynaklarının ve enerjinin kullanımında verimliliğin artırılması amacı ile özellikle gelişmiş ve gelişmekte olan ülkeler çeşitli önlemler almaya başlamışlardır. Örneğin Türkiye'de bu bahsedilen amaçlar için 02 Mayıs 2007 tarihinde 5627 sayılı "Enerji Verimliliği Kanunu" çıkarmıştır [5].

Enerji atıkları ve çevre üzerindeki kalıcı olumsuz etkileri üzerine gittikçe artan kaygılar nedeniyle binaların enerji performansı (EPB) konusuna ilişkin önemli bir araştırma grubu bulunmaktadır [6] [7]. Dahası, Avrupa ülkelerindeki binalar, 2002/91/EC sayılı Avrupa Yönergesini takiben, enerji verimliliği açısından yasal asgari şartlara uymakla yükümlüdürler [7]. 1994 yılından 2004 yılına kadar Avrupa ve Kuzey Amerika'da bina enerji tüketimi sırasıyla yılda %1.5 ve %1.9 oranında artmıştır. Bina enerji tüketiminin son 20 yılda % 10'dan fazla arttığı Çin'de enerji piyasasında daha da büyük bir artış meydana geldiği görülmektedir [7]. Yapılan araştırma raporları incelendiğinde son yıllarda enerji tüketimi artmıştır [8]. Bu nedenle enerji tasarrufu özelliklerine sahip verimli bina tasarımı ve bu

uygulamaları destekleyen yardımcı araçlar binaların enerji kullanımını hafifletmede yardımcı olabilir. Literatür incelendiğinde özellikle bu alanda yapılmış benzer çalışmalara ulaşmak mümkündür. Son yıllarda özellikle stokastik problemleri çözmek için kullanılan zeki ve makine öğrenme yöntemleri ile gerçekleştirilen çalışmaların çok iyi sonuçlar verdiği bilinmektedir. Benzer şekilde konutların enerji performansının makine öğrenmesi algoritmaları kullanılarak gerçekleştirilen çalışmalara ilginin arttığı görülmektedir [9] [10]. Örneğin, Castelli vd. tarafından yapılan çalışmada konutların enerji performansını genetik algoritmalar kullanılarak tahmin edilmiştir [9]. Elde edilen sonuçlara göre en doğru tahminin HYBRID-LIN algoritması ile olduğu görülmüştür. Wei vd. kentsel bina enerji analizi için, kullanılan 6 makine öğrenmesi algoritmasından (Tam doğrusal, Lasso, Mars, SVM, bagging Mars ve boosting) en iyi sonucu parametrik olmayan modellerin (Mars, SVM, bagging Mars ve boosting) verdiği görülmüştür [11]. Tian tarafından yapılan çalışmada bina enerji analizi oransal marjinal varyans ayrışma (PMVD), LMG ve Rastgele Orman algoritmaları kullanılarak incelenmiştir [12]. Bing Dong vd. [13] tropikal bölgede bina enerji tüketimini tahmin etmek için SVM algoritmasını kullanmıştır. De Wilde vd. bir ofisin iklim değişikliği altındaki enerji performansını öngörmek için MARS-meta modelini kullandı [14]. Tian vd. kampüs binasının termal performansını değerlendirmek için ACOSSO yöntemini uyguladılar [15]. Eisenhower vd. bir binanın enerji performansını değerlendirmek için destek vektör makinesine dayalı hassasiyet analizi yaptı [16].

Fazel Khayatian ve arkadaşları İtalya'nın Lombardy bölgesinin enerji performansı sertifikası açık kaynaklı veri tabanından [17] elde ettikleri kayıtlı binaların enerji sertifikalarındaki büyüklükleri yapay sinir ağları metodu ile işleyerek ısı talebi göstergelerinin tahmin edilmesi üzerine gerçekleştirdikleri çalışmada, giriş parametrelerin yaklaşık % 95'inin ± 3 güven aralığına düştüğünü ortaya koymuşlardır [10].

Deqing Zhai ve arkadaşları ortam sıcaklığı ve hızı gibi kapalı çevre parametrelerine göre ısıtma, havalandırma ve iklimlendirme (HVAC) sistemi gibi binalardaki yüksek enerji talebi bileşenlerini değerlendiren bir çalışma gerçekleştirmişlerdir. Çalışmada termal laboratuvardaki deney sonuçlarından eğitilecek şekilde seçilen veriler Aşırı Öğrenme Makinesi yöntemi ile işlenmiştir. Çalışmada, verilen fiziksel çevresel parametreler, HVAC sistemlerinin Hava Kontrol Ünitesindeki aşırı öğrenme algoritması modelinden enerji sarfiyatı seviyesini öngörebilmektedir [18].

Literatür incelemesi yapıldığında çalışmaların kullandığı birçok kapsamlı veri tabanlarına ulaşmak mümkündür. Örneğin Eva Blomqvist ve Patrik Thollander isimli araştırmacılar daha önce var olmayan mevcut enerji verimliliği önlemlerinin, bir entegre veri tabanı ile aşılması yolunda gerçekleştirmiş oldukları çalışmada, İsveç Enerji Ajansı'ndan ve ABD'de Enerji Enstitüsünün

Endüstriyel Değerlendirme Merkezlerinden elde ettikleri enerji verimliliği verilerini entegre eden yeni bir veri tabanı oluşturmuşlardır [19].

Yapılan çalışmada sekiz giriş ve iki çıkış değerinden oluşan bir veri seti üzerinde, konutların ısıtma ve soğutma yükünü tahmin edebilen bir model oluşturulmuştur. Analiz aşamasında Orange veri madenciliği programı kullanılmış olup, makine öğrenmesi algoritmalarından Regresyon algoritmaları kullanılmıştır.

2. MATERYAL VE YÖNTEM (MATERIALS AND METHODS)

2.1. Veri Seti (Data Set)

Yapılan çalışmada Athanasios Tsanas ve Angeliki Xifara isimli araştırmacıların sundukları Tablo 1'deki veri seti kullanılmıştır. Veri seti 768 örnek ve bir gerçek değerli cevabı tahmin etmeyi amaçlayan 8 özellikten oluşmaktadır. Her bir örnek ayrı bir bina içindir [20, 21]. Veri kümesi, binaların farklı bina parametrelerine sahip olan enerji verimliliği ölçümlerini içerir. Ölçülen iki enerji verim parametresi vardır: ısıtma yükü(HL) ve soğutma yükü(CL).

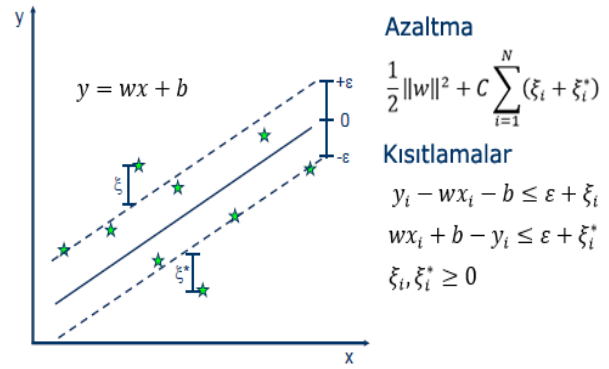
HL, sıcaklığın bir kabul edilebilir aralıkta muhafaza edilmesi için bir boşluğa eklenmesi gereken ısı enerjisinin miktarı; CL, sıcaklığı kabul edilebilir bir aralıkta tutmak için bir boşluktan (soğutma) alınması gereken ısı enerjisinin miktarı olarak tanımlanmaktadır [22]. Termal yükler olarak da bilinen HL ve CL, binanın yapısını ve izolasyonunu (taban, duvar, tavan ve tavan dâhil) ve binanın cam ve gökyüzü ışıklarını (boyut, performans, gölgeleme ve gölgelendirme temelinde) dikkate alır. HL ve CL önemli parametrelerdir ve ekonomik anlamda ciddi bir etkisi olduğu düşünülmektedir [23]. Çünkü bu tahminlerde yapılan hatalar enerji israfı anlamına gelmektedir ve HL ve CL'yi doğru bir şekilde tahmin etmek ciddi miktarda tasarruf sağlayabilir, fakat gerçekleştirilmesi zor bir iş olarak görülmektedir. Çoğu HVAC tasarımı, HVAC profesyonelinin kişisel tavsiyesine dayanmaktadır ve bu nedenle de öznel bir işlem yapılmaktadır. Bu durumda da hatalara açık olma ihtimali bulunmakta ve herhangi bir standart oluşturulamamaktadır. Böyle bir perspektifte, HL ve CL'yi doğru bir şekilde öngörmek için güvenilir hesaplama araçları çok talep görmektedir.

Tablo 1. Veri kümesi [20, 21]

Özellikler	Açıklama	Olası Değerlerin Sayısı
X1	Nispi yoğunluk	12
X2	Yüzey Alanı	12
X3	Duvar Alanı	7
X4	Çatı Alanı	4
X5	Toplam Yükseklik	2
X6	Yönlendirme	4
X7	Cam Alanı	4
X8	Cam Alanı Dağılımı	6
Y1	Isıtma Yükü	586
Y2	Soğutma Yükü	636


2.2. SVM Regresyon (SVM Regression)

SVM regresyon algoritması, çekirdek işlevlerine dayandığı için parametrik olmayan bir tekniktir. SVM regresyonunda amaç elde edilecek $f(x)$ fonksiyonu ile gerçek y_i çıktı değerlerinin en fazla ϵ miktarı kadar sapma ile tahmin edilmesi ve bulunan bu fonksiyona paralel olan ve eğitim girdilerini kapsayan iki düzlem arasındaki mesafenin minimum yapılmasıdır. Hataları görmezden gelen ve gerçek değer belli bir mesafesinde bulunan kayıp fonksiyonunu tanımlamaya dayanır. Bu tür bir işleme sıklıkla - epsilon yoğunluk kaybı işlevi denir. Şekil 1, epsilon yoğun bantlı tek boyutlu doğrusal regresyon fonksiyonunun bir örneğini göstermektedir. Değişkenler, eğitim noktalarında hataların maliyetini ölçmektedir. Bunlar, grubun içindeki tüm noktalarda sıfırdır [24].



Şekil 1. SVM Regresyon [24]

SVM regresyonu, yüksek boyutlu özellik uzayında hassas olmayan kayıp kullanarak doğrusal gerileme gerçekleştirir ve aynı zamanda model karmaşıklığını en aza indirgeyerek azaltmaya çalışır. Bu, hassas olmayan bölge dışındaki eğitim örneklerinin sapmasını ölçmek için (negatif olmayan) boşluk değişkenleri getirerek tanımlanabilir. Çekirdek fonksiyonları, verileri doğrusal ayırmayı gerçekleştirmek için daha yüksek bir boyutsal özellik alanına dönüştürür. Şekil 2'de doğrusal olmayan SVM örneği verilmiştir. Örnekte mevcut uzay çekirdek fonksiyonları sayesinde daha yüksek boyutlu bir uzaya taşınmaktadır. Bu şekilde doğrusal olmayan problemlerin çözümü sağlanmaktadır.



Şekil 2. Çekirdek fonksiyonları ile daha büyük bir uzaya geçme [24]

2.3. Linear Regresyon (Linear Regression)

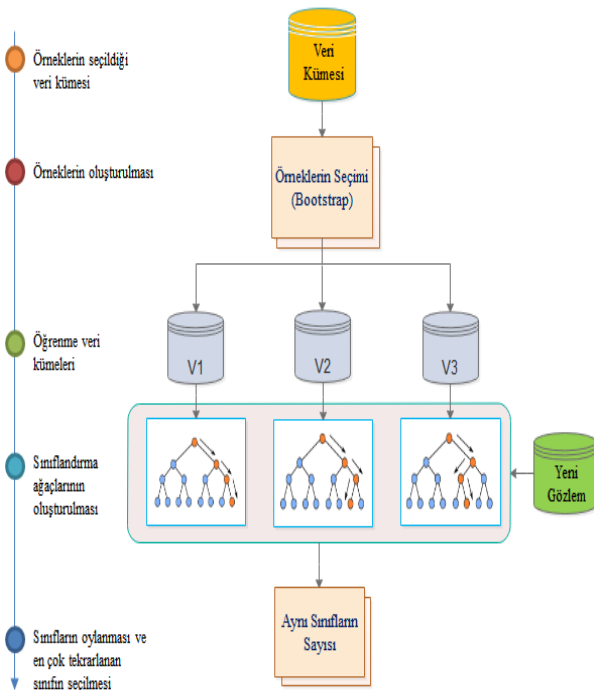
Linear regresyon bir veya birden fazla (bağımsız) değişken ile başka bir (bağımlı) değişken arasındaki bağlantıyı modellemek için kullanılan bir yöntemdir. Linear regresyonun amacı verilmiş olan x 'leri ve y 'leri kullanarak w değerlerini bulmaktır. w değerleri bulunduğundan sonra artık y değeri bilinmeyen ama x değerleri verilmiş olan bir veri ile y değeri hesaplanabilmektedir [25]. Bu nedenle linear regresyon aşağıdaki şekilde formülü edilebilir:

Her zaman $x_0 = 1$ olmak koşuluyla;

$$f(x) = \sum w_i x_i = wx \quad (1)$$

2.4. Rastgele Orman Regresyon (Random Forest Regression)

Rastgele orman regresyon algoritmasında daha fazla sayıda ağaç türetildiğinde daha yüksek model performansı elde edilmesi beklenmekle birlikte ağaç sayısındaki artışın veri setinin türü ve büyüklüğü ile bağlantılı olarak her zaman daha yüksek performans elde etmeyi garanti etmediği söylenebilir [26]. Bu nedenle farklı sayılarda ağaç türetilerek model performanslarının karşılaştırılması tavsiye edilmektedir. Modelin dezavantajları arasında tek bir karar ağacında olduğu gibi ortaya çıkan sonucun ağaç yapısı ile görsel olarak sunumunun mümkün olmaması ve modelin karmaşıklığı nedeniyle çok sayıda karar ağacının değerlendirilmesine ait işlem adımlarının görülmesine imkân vermemesi bulunmaktadır [27]. Şekil 3'de Rastgele Orman Algoritmasının işlem adımları sunulmaktadır.



Şekil 3. Rastgele orman algoritmasının akış şeması

2.5. kNN Regresyon (kNN Regression)

kNN algoritması teorik ve basit sınıflandırma yöntemlerinden biridir. kNN sınıflandırıcı $f(X) = k_i/k$ şeklinde tanımlanmış olup burada $k_i \in c_i$, X 'in k komşuluğunda c_i sınıfında yer alan örneklerin sayısını ifade etmektedir. Bu algoritmada sınıflandırılacak olan yeni örneğe eğitim setinden en yakın mesafedeki k tane örneğe bakılır. Bu k örnek çoğunluk olarak hangi sınıfa dâhil edilmiş ise yeni örnek de o sınıfa dâhil edilmektedir [28]. Örnekler arasındaki mesafe değerleri hesaplanırken genellikle Öklid ölçütü kullanılır. Bu ölçütü iki nokta arasındaki mesafe aşağıdaki gibi hesaplanır.

$$d = \sqrt{\sum_{i=1}^k (x_i - y_i)^2} \quad (2)$$

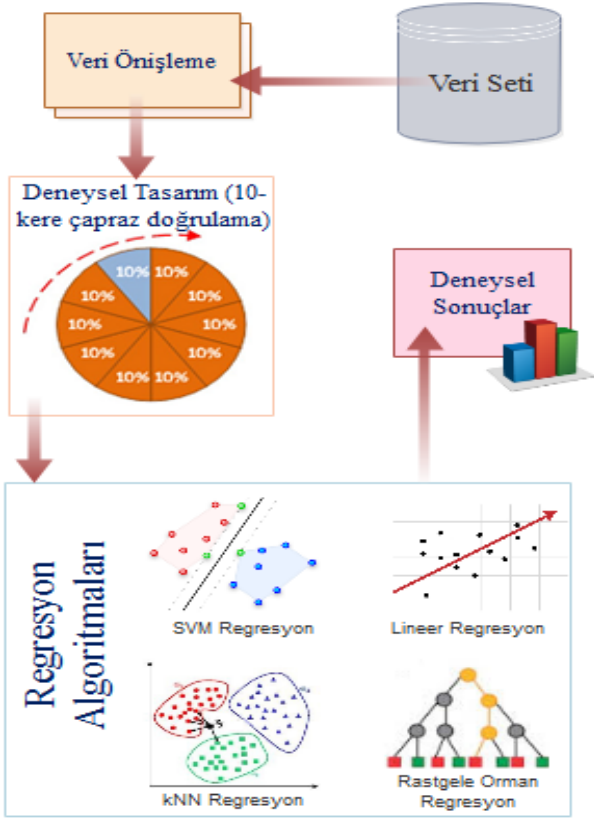
kNN regresyonunun basit bir uygulaması, en yakın k komşusunun sayısal hedefinin ortalamasını hesaplamaktır. kNN regresyonu, kNN sınıflaması ile aynı mesafe ölçütlerini kullanır.

2.6. Deneysel Uygulama (Experimental Application)

Önerilen sistemin blok diyagramı Şekil 4'de sunulmaktadır. İlk aşamada sınıflandırma işlemlerinin daha verimli yapılması için verilere 0-1 arasında normalizasyon işlemi uygulanmıştır. Normalizasyon yöntemi olarak aşağıdaki denklem 3'de verilen Min-Max yöntemi kullanılmıştır.

$$x' = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (3)$$

Bu eşitlikte x' , normalize edilmiş veriyi; x_i , girdi değerini; x_{min} , girdi seti içerisinde yer alan en küçük sayıyı; x_{max} , girdi seti içerisinde yer alan en büyük sayıyı ifade etmektedir. Normalizasyon aşamasından sonra Deneysel Tasarım aşamasına geçilmiştir.



Şekil 4. Önerilen sistemin blok diyagramı

Deneysel Tasarım aşamasında Eğitim-Test verilerinin seçimi aşamasına geçilmiştir. Bu aşamada 10 kere çapraz doğrulama yöntemi kullanılmıştır. Sonraki aşamada regresyon işlemleri gerçekleştirilmiştir. Bu aşamada 4 farklı regresyon algoritması ile deneyler gerçekleştirilmiştir. Bu algoritmalar; SVM Regresyon, Lineer Regresyon, Rastgele Orman (RF) Regresyon ve *kNN* Regresyon algoritmalarıdır.

Son aşamada ise önerilen modelin etkinliği test etmek için istatistiki değerlendirme ölçütlerinden yararlanılmıştır. Bu aşamada ortalama karesel hata (MSE), kök ortalama kare hatası (RMSE) ve ortalama mutlak hata (MAE) gibi çok sayıda değerlendirme yöntemi kullanılmıştır.

3. DENEYSEL SONUÇLAR (EXPERIMENTAL RESULTS)

Önerilen yöntemin uygulanması ile elde edilen sonuçlar Tablo 2 ve Tablo 3'te sunulmuştur. Tablo 2'de ısıtma yükü tahmini için elde edilen sonuçlar paylaşılmıştır. Buna göre en iyi sonuçlar RF Regresyon algoritması ile elde edilmiştir. Diğer algoritmalar da iyi sonuç vermekle beraber en kötü sonuç SVM Regresyon algoritması ile elde edilmiştir. RF algoritmasına en yakın başarı oranı *kNN* Regresyon algoritması ile elde edilmiştir. Tablo 3'de soğutma yükü tahmini için elde edilen sonuçlar paylaşılmıştır. Buna göre en iyi sonuçlar yine RF Regresyon algoritması ile elde edilmiştir. Diğer algoritmalar da iyi sonuç vermekle beraber en kötü sonuç SVM Regresyon algoritması ile elde edilmiştir. RF

algoritmasına en yakın başarı oranı *kNN* Regresyon algoritması ile elde edilmiştir.


Tablo 2. Isıtma yükü tahmini için elde edilen sonuçlar

Method	MSE	RMSE	MAE
SVM Regresyon	9.301	3.050	2.439
Linear Regresyon	8.666	2.944	2.074
RF Regresyon	0.482	0.694	0.422
<i>kNN</i> Regresyon	4.665	2.160	1.512


Tablo 3. Soğutma yükü tahmini için elde edilen sonuçlar

Method	MSE	RMSE	MAE
SVM Regresyon	15.736	3.967	3.186
Linear Regresyon	10.263	3.204	2.240
RF Regresyon	3.202	1.789	1.339
<i>kNN</i> Regresyon	5.189	2.278	1.313


Şekil 5 ve Şekil 6'da tahmin edilen çıkış değerleri ile gerçek çıkış değerleri grafiksel olarak sunulmaktadır. Şekil 7 ve Şekil 8'de ise tahmin edilen çıkış değerleri ile gerçek çıkış değerleri arasındaki regresyon grafikleri sunulmaktadır. Grafiklerde görüldüğü gibi hem ısıtma yükü hem de soğutma yükü için RF Regresyon algoritması ile hedef değerlerin iyi derecede tahmin edildiği görülmektedir.



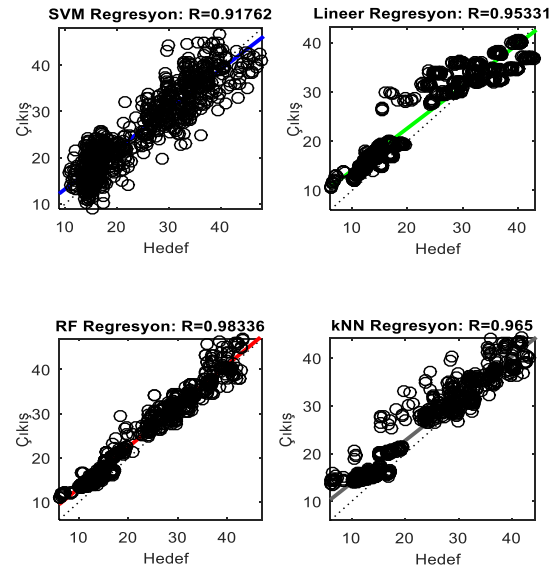
Şekil 5. Isıtma yükü için gerçek çıkış değerleri ile RF Regresyondan elde edilen değerlerin karşılaştırılması



Şekil 6. Soğutma yükü için gerçek çıkış değerleri ile RF Regresyondan elde edilen değerlerin karşılaştırılması



Şekil 7. Isıtma yükü için elde edilen Regresyon grafikleri



Şekil 8. Soğutma yükü için elde edilen Regresyon grafikleri

4. SONUÇLAR VE TARTIŞMA (RESULTS AND DISCUSSION)

Bu çalışmada enerji tasarruflu bina tasarımı için ısıtma ve soğutma yüklerini regresyon tabanlı makine öğrenmesi algoritmaları ile bir modelleme çalışması gerçekleştirilmiştir. Önerilen yöntemde makine öğrenmesinin önemli aşamalarından olan veri ön işleme, veri dağılımı belirleme, regresyon ve performans değerlendirme adımları bulunmaktadır. Binaların farklı bina parametrelerine sahip olan enerji verimliliği ölçümlerini içeren veri kümesi üzerinde yapılan çalışmada, iki enerji verim parametresinin tahmini gerçekleştirilmiştir. Isıtma yükü ve soğutma yükünün tahmin edildiği çalışmada en iyi sonuçları Rastgele Orman algoritması vermiştir. İlerleyen çalışmalarda ısıtma ve soğutma yüklerini en çok etkileyen giriş parametrelerinin tespiti için öznetelik seçme algoritmalarından yararlanılacaktır. Ayrıca daha kapsamlı bir veri seti üzerinde de deneylerin tekrarlanması ve elde edilen sonuçların bu çalışmada elde edilen sonuçlarla da karşılaştırılması hedeflenmektedir.

KAYNAKLAR (REFERENCES)

- [1] Summary of analysis using the National Energy Efficiency Data-Framework (NEED), https://www.gov.uk/government/uploads/system/uploads/attachmen_t_data/file/437093/National_Energy_Efficiency_Data-Framework_NEED_Main_Report.pdf, 20.04.2017.
- [2] G. Özyurt, K. Karabalık, "Enerji verimliliği, binaların enerji performansı ve Türkiye'deki durum", *TMMOB İnşaat Mühendisleri Odası Türkiye Mühendislik Haberleri*, 457(54), 32-34, 2009.
- [3] E. Göçmen, Ş. Özdemir, "Farklı Tip Aydınlatma Aygıtlarının Harmonik Etkilerinin Karşılaştırılması", *V. Enerji Verimliliği ve Kalitesi Sempozyumu*, Kocaeli, 261-265, 2013.
- [4] C. Perdahçı, U. Hanlı, "Verimli Aydınlatma Yöntemleri", *3E Elektrotech Dergisi*, 323-327, 2010.
- [5] M. Beerepoot, M. Sunikka, "The contribution of the EC energy certificate in improving sustainability of the housing stock", *Environment and Planning B: Planning and Design*, 32(1), 21-31, 2005.
- [6] Z. Yu, F. Haghighat, B. C.M. Fung, H. Yoshino, "A decision tree method for building energy demand modeling", *Energy and Buildings*, 42(10), 1637-1646, 2010.
- [7] W.G. Cai, Y. Wu, Y. Zhong, H. Ren, "China building energy consumption: situation, challenges and corresponding measures", *Energy Policy*, 37(6), 2054-2059, 2009.
- [8] National Academy of Sciences; National Academy of Engineering; National Research Council, **Real Prospects for Energy Efficiency in the United States**, Washington: The National Academies Press, 2010.
- [9] M. Castelli, L. Trujillo, L. Vanneschi, A. Popovic, "Prediction of energy performance of residential buildings: A genetic programming approach", *Energy and Buildings*, 102, 67-74, 2015.
- [10] F. Khayatian, L. Sarto ve G. Dall'O', "Application of neural networks for evaluating energy performance certificates of residential buildings", *Energy and Buildings*, 125, 45-54, 2016.
- [11] L. Wei, E.A. Silva, R. Choudhary, Q. Meng, S. Yang, "Comparative study on machine learning for urban building energy analysis", *Procedia Engineering*, 121, 285-292, 2015.
- [12] W. Tian, "A review of sensitivity analysis methods in building energy analysis", *Renewable and Sustainable Energy Reviews*, 20, 411-419, 2013.
- [13] B. Dong, C. Cao, S. E. Lee., "Applying support vector machines to predict building energy consumption in tropical region", *Energy and Buildings*, 37(5), 545-553, 2005.
- [14] P. Wilde, W. Tian, "Predicting the performance of an office under climate change: A study of metrics, sensitivity and zonal resolution" *Energy and Buildings*, 42(10), 1674-1684, 2010.
- [15] W. Tian, P. Wilde, "Uncertainty and sensitivity analysis of building performance using probabilistic climate projections: A UK case study", *Automation in construction*, 20(8), 1096-1109, 2011.
- [16] B. Eisenhower, Z. O'Neill, V.A. Fonoberov, I. Mezić, "Uncertainty and sensitivity decomposition of building energy models", *Journal of Building Performance Simulation*, 5(3), 171-184, 2012.
- [17] Open Data Lombardia, <https://www.dati.lombardia.it/>, 24.04.2017.

- [18] D. Zhai, Y. C. Soh, W. Cai, "Operating Points as Communication Bridge between Energy Evaluation with Air Temperature and Velocity based on Extreme Learning Machine (ELM) Models", IEEE 11th Conference on Industrial Electronics and Applications, Hefei, CHINA, 712-716, 2016.
- [19] E. Blomqvist, P. Thollander, "An integrated dataset of energy efficiency measures published as linked open data", *Energy Efficiency*, 8(6), 1125-1147, 2015.
- [20] A. Tsanas, A. Xifara, "Accurate quantitative estimation of energy performance of residential buildings using statistical machine learning tools", *Energy and Buildings*, 49, 560-567, 2012.
- [21] A. Xifara, "Energy efficiency Data Set", <https://archive.ics.uci.edu/ml/datasets/Energy+efficiency>, 19.04.2017.
- [22] Y. Arima, R. Ooka, H. Kikumoto, "Proposal of typical and design weather year for building energy simulation", *Energy and Buildings*, 139, 517-524, 2017.
- [23] J. Lei, K. Kumarasamy, K. T. Zingre, J. Yang, M. P. Wan, E.-H. Yang, "Cool colored coating and phase change materials as complementary cooling strategies for building cooling load reduction in tropics", *Applied Energy*, 190, 57-63, 2017.
- [24] Support Vector Machine - Regression (SVR), http://www.saedsayad.com/support_vector_machine_reg.htm, 19.04.2017.
- [25] N. Demir, "Lineer Regresyon'a Giriş", <http://www.necatidemir.com.tr/2015/09/lineer-regresyona-giris-bolum-1/>, 19.04.2017.
- [26] L. Breiman, "Random Forests", <https://www.stat.berkeley.edu/~breiman/randomforest2001.pdf>, 19.04.2017
- [27] M. Akman, Y. Genç, H. Ankaralı, "Random Forests Methods and an Application in Health Science", *Turkiye Klinikleri Journal of Biostatistics*, 3(1), 36-48, 2011.
- [28] H. Sökün, H. Kalkan, B. Cetişli, "Classification of physical activities using accelerometer signals", **20th Signal Processing and Communications Applications Conference**, Mugla, Turkey, 2012.