

Yapılarda Isıtma ve Soğutma Yükü Sınıflarının Makine Öğrenme Yöntemleri ile Belirlenmesi

Abdülkadir Gümüştü, Mehmet Emin Tenekeci, Nurettin Beşli, Mehmet Akif İlkhan, Emrah Aslan, Sami Abamor

Harran Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Şanlıurfa

Geliş Tarihi: 24.02.2018

Kabul Tarihi: 31.10.2018

Özet

Son zamanlarda fosil yakıtların tükenmesiyle beraber enerji verimliliği kavramı oldukça önem kazanmıştır. Özellikle kapalı alanlarda enerji tüketimi en fazla ısıtma ve soğutma işlemleri için harcanmaktadır. Enerji fiyatları da göz önünde bulundurulduğunda insanlar artık ısı yalıtımlı binaları tercih etmektedir. Bu yüzden yapıların enerji sınıflarının doğru olarak belirlenmesi oldukça önem arz etmektedir. Bu çalışmada yapılardaki ısıtma ve soğutma yükü sınıflarının k-en yakın komşuluk (k-EK), Destek Vektör Makineleri (DVM) ve Karar Ağaçları yöntemleri ile belirlenmesi önerilmektedir. Böylelikle oluşturulan modellere yapı özellikleri girilerek herhangi bir ölçüm yapmadan yapıların ısıtma ve soğutma yükü sınıfları tahmin edilebilecektir. Bu amaçla UCI veri havuzundan enerji verimliliği veri seti kullanılarak k-en yakın komşuluk, destek vektör makineleri ve karar ağaçları yöntemleri ile sınıf tahminleri yapılmıştır. Bu çalışmada soğutma yükü sınıfı tahmini ve ısıtma yükü sınıfı tahmini ayrı ayrı yapılmış olup sınıflandırma başarı oranı hesaplanırken Birini Dışarıda Bırak Çapraz Doğrulama (BDBÇD) yöntemi kullanılmıştır. Sonuçlar yapıların ısıtma ve soğutma yükü sınıfları tahminlerinin makina öğrenme algoritmaları tarafından başarılı şekilde yapıldığını göstermektedir.

Anahtar kelimeler: Enerji Verimliliği; Isıtma Yükü; Soğutma Yükü, k-en yakın komşuluk.

Determination of Building Heating and Cooling Load Classes by Machine Learning Methods

Abstract

Recently, the concept of energy efficiency has become very important with the depletion of fossil fuels. Especially in closed areas, energy consumption is mostly spent for heating and cooling processes. When energy prices are taken into consideration, people prefer heat-insulated buildings. Therefore, it is very important that the energy classes of the structures are determined correctly. In this study, it is suggested to determine the heating and cooling load classes by k-nearest neighbour (k-NN), Support Vector Machine (SVM) and Decision Tree methods. In this way, structure properties can be entered to model and the heating and cooling load classes of the structures can be predicted without making any measurements. For this purpose, class predictions were made by the k-nearest neighbour, support vector machine and decision tree methods by using the energy efficiency data set from the UCI Machine Learning Repository. In this study, estimation of cooling load class and heating load class were made separately and the classification success rate was calculated by using Leave One Out Cross Validation (LOOCV).. The results show that estimation of the heating and cooling load classes of buildings is successfully done by machine learning algorithms.

Keywords: Energy Efficiency, Heating Load, Cooling Load, k-nearest neighbour.

1. Giriş

Fosil enerji kaynaklarının hızla tükendiği ve enerji ihtiyacının hızla arttığı Dünyamızda “Enerji Verimliliği” kavramı her geçen gün önemini arttırmaktadır [1]. Bu bağlamda yeşil binalar, yeşil sanayi, akıllı şebekeler ve pasif evler gibi kavramlarında kullanımının arttığı ve bu konularda

hükümetlerin de ciddi düzenlemeler yaptığı görülmektedir [2]. Gerek fosil enerji kaynaklarının tükenmesi gerekse çevreye olan duyarlılığın artması ile beraber alternatif ve çevreye kısmen daha az zarar veren enerji kaynakları temel enerji kaynakları olarak kullanılması birçok devlet tarafından teşvik edilmektedir. Alternatif enerji

kaynaklarının daha yaygın kullanmasının yanında enerji tüketimini en aza indirmek amacı ile enerji verimliliği uygulamaları da aynı anda birçok ülke de teşvik edilmektedir.

Türkiye’de de enerji verimliliği konusunda çalışmalar sürdürölmektedir. Türkiye İstatistik Kurumu’nun verilerine göre; ölkemizin nüfusu 2040 yılında 92 milyon olması beklenmektedir. Bu açıdan artan nüfusun artan enerji ihtiyaçları olacağı öngörülmektedir. Ölkemizde sektörel enerji kullanımını dağılımı Tablo 1’de verilmiştir [3].

Tablo 1. Türkiye’de Tüketilen Enerjinin Sektörel Dağılımı.

Sektör	Tüketim Oranı	Tahmini Tasarruf Potansiyeli
Sanayi	%39	%20-25
Konut	%30	%30-35
Ulaşım	%21	%15-20
Tarım	%5	-
Kayıp vb.	%5	-

Tablo 1’deki veriler incelediğinde ölkemizde en fazla enerji tüketilen sektör sanayi olarak görölmektedir. Sanayi sektörünü konut sektörü takip etmekte olup bu sektörde tahmin edilen en fazla tasarruf potansiyeline sahiptir. Bu açıdan bakıldığında konutlarda enerji verimliliği konusunda ölkemiz olarak ciddi enerji tasarrufu sağlayabiliriz. Bu yüzden 2008 yılında Binalarda Enerji Performansı Yönetmenliği yayınlanmıştır. Bu yönetmenlik ile binalara enerji kimlik belgesi verilerek binaların enerji verimlilikleri sınıflandırılacaktır. Sınıflandırma işlemi binalarda gerekli ölçümler yapılarak verilecek olup mevcut binalarda da aynı işlemlerin yapılacağı düşünöldüğünde ciddi bir iş yükü ortaya çıkmaktadır. Bu çalışmada bir yapının ısıtma ve soğutma yük sınıflarının herhangi bir ölçüm yapmadan, binaların bazı özelliklerini girerek makine öğrenme algoritmaları ile tahmin edilmesi önerilmektedir.

Böylelikle yapılarda ölçüm yapılmadan mimari tasarım aşamasında enerji verimliliği konusunda fikir sahibi olunması sağlanacaktır. Bu çalışmada önerilen model ile yapılarda mimari tasarım aşamasında yapının genel bilgileri girilerek yapının ısıtma ve soğutma yük sınıfları konusunda tahmin

yürütölmektedir. Bu bağlamda, Kaliforniya Üniversitesi Makine Öğrenme ve Akıllı Sistemler Merkezi’nden (UCI) alınan Enerji Verimliliği veri setindeki ısıtma ve soğutma yükleri ayrı ayrı sınıflandırılmıştır. Makina öğrenme algoritması olarak k-en yakın komşuluk sınıflandırma yöntemi (k-EK), destek vektör makineleri ve karar ağaçları uygulanmış ve Birini Dışarıda Bırak Çapraz Doğrulama (BDBÇD) yöntemi ile sonuçlar doğrulanmıştır.

Literatürde konu ile ilgili birçok çalışma yapılmıştır. Gasparella ve ark. [4] farklı pencere yapıları ile enerji verimliliğinin arasındaki ilişkiyi belirlemeye çalışmıştır. Çalışmada özellikle binalarda pencerelerin azaltılması ile güneş ısı kazancının azalacağına vurgu yapılmaktadır. Bu çalışmada da cephelerin cam yüzeyi alanları ve oranları parametreleri göz önünde bulundurulmuştur. Chua ve ark. [5] matematiksel modelleme ile yapılardaki enerji verimliliği tahmini çalışmaları yapmıştır. Bunun yanında enerji verimliliği tahmini problemine istatistiksel yaklaşımlar ile çalışmalarda yapılmıştır [6]. Matematiksel ve istatistiksel yaklaşımların yanında enerji verimliliği belirleme problemine makine öğrenme yöntemleri ile yaklaşan çalışmalarda yapılmıştır [7-10]. Örneğin Gilan ve ark. [9] yaptıkları çalışmada mimari çizim aşamasındaki yapılardaki enerji verimliliği parametrelerini pahalı simölasyon yazılımları ile yapmak yerine gauss işlemi ile tahmin etmeye çalışmış ve başarılı sonuçlar elde etmiştir. Yaptığımız çalışmada da aynı problem üzerine odaklanılmış olup, enerji verimliliği veri setindeki değer tahmini problemi sınıflandırma problemine dönüştürölerek daha etkin bir çözüm yolu bulmaya çalışılmıştır. Bunun yanında bu çalışmada da kullanılan enerji verimliliği veri seti kullanılarak akıllı şebekelerin alt yapısını oluşturmak amacı ile binalardaki enerji verimliliği parametreleri yapay sinir ağları ile tahmin edilmiştir [10]. Elde edilen sonuçlar birçok makina öğrenme algoritması ile karşılaştırılmıştır. Bu çalışmada [10]’dan farklı olarak enerji verimliliği veri setindeki değer tahmini problemi sınıflandırma problemine indirgenmiştir.

Makalenin geri kalan kısmı şu şekilde organize edilmiştir. Bölüm 2’de önerilen yöntemde kullanılan bütün algoritmalar özetlenmiştir. Bölüm 3’de ise önerilen yöntemin işlem adımları detaylıca

ele alınmıştır. Bölüm 4’de Önerilen yöntem ile elde edilen sonuçlar verilmiştir ve sonuçlar irdelenerek çalışmanın performansı değerlendirilmiştir.

2. Materyal ve Yöntem

Bu çalışmada yapılardaki ısıtma ve soğutma yükleri k-en yakın komşuluk, Destek vektör makineleri ve karar ağaçları algoritmaları ile sınıflandırılmıştır. Bu bölümde sınıflandırma yapılırken kullanılan veri seti, sınıflandırma algoritmaları ve çapraz doğrulama yöntemleri özetlenmiştir.

2.1. Veri Seti

Yapılardaki ısıtma ve soğutma yükleri özellikle enerji maliyetlerinin artması ve artan nüfus ile beraber artan enerji ihtiyaçları ile beraber son zamanlarda önemi artan kavramlar haline gelmiştir. Yapıların ısıtma ve soğutma yükleri hesaplanırken ölçümler yapılmakta ve kullanılan malzeme, pencere alanlarının büyüklüğü, yalıtım malzemesi ve buna benzer bazı parametrelere göre farklılıklar göstermektedir.

Bu çalışmada UCI veri havuzunda yer alan ve Oxford Üniversitesi Endüstri ve Uygulamalı Matematik Merkezi tarafından oluşturulan Enerji Verimliliği veri seti kullanılmıştır [11]. Çalışmada kullanılacak veri setinde yapıların genel özelliklerine karşılık yapıların ısıtma ve soğutma yükleri bulunmaktadır. Veri seti oluşturulurken 12 adet farklı yapı formu ele alınmış olup, tüm yapılar 771,75 m³ hacme sahiptir. Simülasyon sonuçları hesaplanırken binaların Atina, Yunanistan’da olduğu ve her konutta 70 W tüketen 7 kişi yaşadığı varsayılmıştır. İç oda koşullarında ise nem %60, hava akış hızı 0,30 metre/saniye, aydınlatma şiddeti 300 lux olarak ayarlanmıştır. Tablo 2’de bu çalışmada kullanılan enerji verimliliği veri setlerinin hangi niteliklerden oluştuğu ve niteliklerin açıklamaları listelenmiştir.

Tablo 2. Enerji verimliliği veri setinin niteliklerinin açıklamaları.

Veri Niteliği	Açıklaması
Bağlı Kompaktlık	Yapının dış mimarisinin bütünlüğünü belirten parametre
Yüzey Alanı	Yapının dış yüzey alanı
Duvar Alanı	Yapının toplam duvar alanı
Çatı Alanı	Yapının toplam çatı alanı
Yapı Yüksekliği	Yapının toplam yüksekliği
Yapının Yönlenmesi	Yapının cephe yönelmesi
Cam Alanı	Yapının toplam cam alanı
Cam Alan Dağılımı	Yapının cam alanlarının toplam yapının dış alanlarına oranı

Veri seti toplam 768 örnekten ve 8 nitelikten oluşmaktadır. Bunun yanında veri setinde çıkış olarak ısıtma yükü ve soğutma yükü değerleri nümerik olarak verilmektedir. Bu çalışmada verilen bu değerler belirli eşikleme değerleri ile A sınıfı, B sınıfı ve C sınıfı şeklinde derecelendirildi. Bu işlem ısıtma ve soğutma yükleri için ayrı ayrı uygulandı. Tablo 3’de eşikleme değerleri listelenmiştir.

Tablo 3. Enerji verimliliği veri setinin sınıflara bölünmesi.

Yük Türü	Eşik Değerleri
Isıtma	< 20,26 - A
	20,26 - 31,46 - B
	>31,46 - C
Soğutma	< 22,98 - A
	22,98 - 34,63 - B
	>34,63 - C

Isıtma ve soğutma yükleri için eşik değerleri hesaplanırken Otsu algoritması kullanılmış olup mümkün olan en iyi sınıflar arası dağılım sağlanmıştır.

2.2. Sınıflandırma Yöntemleri

Makina öğrenme algoritmaları günümüzde birçok alanda kullanılmaktadır [12-13]. Bu çalışmada yapılardaki ısıtma ve soğutma yükleri 3 farklı sınıflandırma yöntemi ile sınıflandırılmıştır. Bu bölümde kullanılan sınıflandırma yöntemleri özetlenmiştir.

2.2.1. k-En Yakın Komşuluk ile Sınıflandırma Yöntemi

k-EK sınıflandırma algoritması basitliği ve kullanım kolaylığı gibi avantajları sayesinde birçok alanda sıklıkla kullanılan sınıflandırma metotların başında gelmektedir [14].

k-NN sınıflandırma algoritmasında eğitim aşamasında eğitim verisindeki örnekler koordinat düzlemine yerleştirilerek sınıfları ile ilişkilendirilir. Daha sonra kurulan koordinat düzlemine test için kullanılacak örnek yerleştirilir. k değeri kadar test verisinin en yakın komşularına bakılarak test verisinin sınıfı belirlenir. Test verisinin sınıfı, komşu örnekler en çok hangi sınıfa ait ise ilgili sınıfa ait olduğu tahmin edilir. k-NN sınıflandırma algoritmasının çalıştırılması için kullanıcı tarafından dışarıdan bir k değeri girilmesi gerekmektedir. k değerinin yanında kullanıcı tarafından uzaklık hesaplama ölçütünün de belirlenmesi gerekmektedir. Bu çalışmada k değeri 1 olarak seçilip, komşuluk uzaklık hesabı öklid uzaklığa göre hesaplanmıştır.

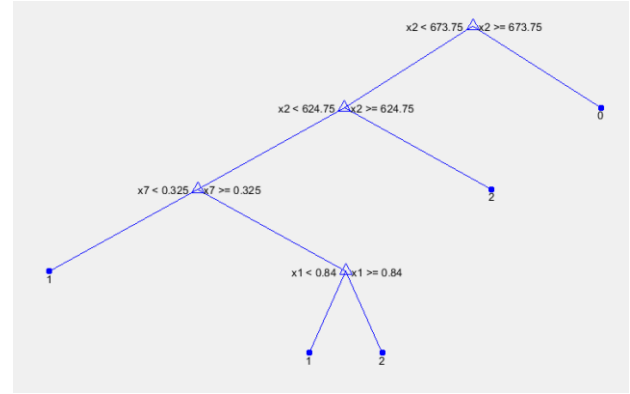
2.2.2. Destek Vektör Makineleri ile Sınıflandırma Yöntemi

Destek Vektör Makineleri özellikle ikili sınıflandırmada oldukça yaygın kullanılmaktadır. Bu yöntem, sınıflandırma problemlerinin çözümü için Vapnik tarafından geliştirilmiştir [15]. Destek Vektör Makineleri yönteminin en önemli avantajı işlem süresinin kısa olmasıdır. Bu özelliğinden dolayı DVM, çok fazla örneğe sahip veri setlerinde tercih edilmektedir.

2.2.3. Karar Ağaçları ile Sınıflandırma Yöntemi

Sınıflandırma ve değer tahmini amacı ile kullanılan karar ağaçları, anlaşılmasının ve yorumlanmasının kolay olması sebebiyle kullanımı oldukça yaygın olan makine öğrenme algoritmalarındandır. Bir karar ağacı modeli kök, düğüm, dal ve yaprak elemanlarından oluşmaktadır. Eğitim veri seti ile Şekil 1'deki gibi bir karar ağacı modeli oluşturulur. Eğitim verisi ile oluşturulan ağaç yapısının başarı oranının hesaplanması için test veri setindeki örnekler nitelik değerlerine göre oluşturulan ağaç

yapısı ile sınıflandırılır. Bu çalışmada kullanılan karar ağacı algoritması C4.5 algoritmasıdır [16].




Şekil 1. Örnek Karar Ağacı Yapısı

Şekil 1'deki örnek ağaç yapısında da görüldüğü üzere öncelikle test veri setindeki x2 niteliği göz önünde bulundurulmaktadır. x2 niteliğinin değerine göre örnek 0 şeklinde sınıflandırılabilir veya diğer niteliklerinin sorgulanmasına devam edilebilir. Bu şekilde tüm test verileri sınıflandırılmış olur.

2.3. Birini Dışarıda Bırak Çapraz Doğrulama

Makine öğrenme algoritmaları ile sınıflandırma, kümeleme ve değer tahmini yaparken test verilerinin ve eğitim verilerinin nasıl belirleneceği başarı ölçütlerini etkileyecek en önemli unsurların arasında gelir. Başarı ölçütlerini daha nesnel bir şekilde hesaplamak için çapraz doğrulama yöntemleri önerilmiştir [17]. k-katlamalı çapraz doğrulama ve birini dışarıda bırak çapraz doğrulama yöntemleri literatürde en sık kullanılan doğrulama yöntemleri arasında sayılabilir. Bu çalışmada birini dışarıda bırak çapraz doğrulama yöntemi kullanılmıştır. BDBÇD yöntemi Şekil 2'de görselleştirilmiştir.




Şekil 2. Birini Dışarıda Bırak Çapraz Doğrulama

Şekil 2'de kırmızı renk ile belirtilen örnekler ilgili iterasyondaki test verisini temsil etmektedir. Geriye

kalan renksiz örnekler ise eğitim verisini temsil etmektedir. Bu yöntemde bir adet örnek, test verisi olarak kullanılmak üzere dışarıda bırakılıp geriye kalan örneklerde eğitim verisi olarak belirlenmiştir. Daha sonra eğitim verisi ile oluşturulan modelin başarı oranı bir adet test verisi ile hesaplanmaktadır. Bu işlem iteratif olarak örnek sayısı kadar tekrarlanarak örnek sayısı kadar başarı oranı hesaplanmaktadır. Hesaplanan başarı oranlarının aritmetik ortalamaları alınarak doğrulanmış başarı oranı hesaplanabilir.

3. Yapılarda Isıtma ve Soğutma Yükü Sınıfların Makine Öğrenme Yöntemleri ile Belirlenmesi

Bu çalışmada yapılardaki ısıtma ve soğutma yükü sınıfları, Şekil 3'de gösterilen işlem adımlarına tabii tutularak belirlenmiştir.



Şekil 3. Veri Setine Uygulanan İşlem Adımları.

Sınıflandırma algoritmalarının sonuçları Tablo 4'de belirtilen karmaşıklık matrisi ile çok daha detaylı gösterilebilmektedir.

Tablo 4. Karmaşıklık Matrisi

		Tahmin Değerleri	
		A	B
Gerçek Değerler	A	TP	FN
	B	FP	TN

Tablo 5. Yapılardaki Isıtma Yükünün Sınıflandırılmasında Sınıflandırma Algoritmalarının Karşılaştırılması

Sınıflandırma Algoritmaları	Doğruluk	Duyarlılık	Özgüllük	Hassasiyet
k-EK	0.898	0.726	0.964	0.885
DVM	0.931	0.849	0.954	0.844
Karar Ağaçları	0.988	0.982	0.989	0.965

Tablo 5'de görüldüğü üzere yapılardaki ısıtma yükünün sınıflandırılmasında, karar ağaçları başarı parametreleri bakımından diğer sınıflandırma algoritmalarına göre daha iyi performans sağlamaktadır.

Bunun yanında bu çalışmada sınıflandırma algoritmalarının performanslarını değerlendirebilmek için başarı ölçütü olarak Eşitlik (1-4)'de ifade edilen Doğruluk, Duyarlılık, Özgüllük ve Hassasiyet parametreleri kullanılmaktadır. Bu parametreler Tablo 4'de belirtilen katsayılarla hesaplanmaktadır.

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (2)$$

$$\text{Özgüllük} = \frac{FP}{FP+TN} \quad (3)$$

$$\text{Hassasiyet} = \frac{TP}{TP+FP} \quad (4)$$

Sınıflandırma algoritmalarının başarı parametreleri, 2.8 GHz frekansa sahip Intel Core i7 işlemci, 8 GB RAM bulunan bir bilgisayarda hesaplanmıştır.

4. Tartışma ve Sonuç

Yapılardaki ısıtma ve soğutma yükü sınıflarının makine öğrenme yöntemleri ile belirlenmesi için k-EK, DVM ve karar ağaçları olmak üzere 3 farklı sınıflandırma algoritması enerji verimliliği veri setine uygulanmıştır. Sınıflandırma algoritmaları işlem süresi, doğruluk oranı, duyarlılık, özgüllük ve hassasiyet açısından karşılaştırılmıştır. Karşılaştırma sonucunda yapılardaki ısıtma ve soğutma yükünü en hızlı ve en başarılı sınıflandırabilen makine öğrenme algoritması belirlenecektir.

Tablo 5'de sınıflandırma algoritmaları, ısıtma yükünün sınıflandırılmasında doğruluk, duyarlılık, özgüllük ve hassasiyet parametreleri bakımından karşılaştırılmıştır.

Tablo 6'da sınıflandırma algoritmaları, soğutma yükünün sınıflandırılmasında doğruluk, duyarlılık, özgüllük ve hassasiyet parametreleri bakımından karşılaştırılmıştır.

Tablo 6. Yapılardaki Soğutma Yükünün Sınıflandırılmasında Sınıflandırma Algoritmalarının Karşılaştırılması

Sınıflandırma Algoritmaları	Doğruluk	Duyarlılık	Özgüllük	Hassasiyet
k-EK	0.873	0.786	0.917	0.828
DVM	0.884	0.778	0.944	0.889
Karar Ağaçları	0.921	0.874	0.944	0.881

Tablo 6'da verilen sınıflandırma başarı parametreleri göz önünde bulundurulduğunda soğutma yükü sınıflandırması için karar ağaçları sınıflandırma algoritması en başarılı sonuçlar verdiği gözlemlenmiştir.

Tablo 7'de ise ısıtma ve soğutma yükleri sınıflandırmasında sınıflandırma algoritmalarının sağladıkları ortalama başarı parametreleri karşılaştırılmıştır.

Tablo 7. Yapılardaki Isıtma ve Soğutma Yüklerinin Ortalama Sınıflandırma Başarı Değerleri Karşılaştırılması

Sınıflandırma Algoritmaları	Doğruluk	Duyarlılık	Özgüllük	Hassasiyet
k-EK	0.885	0.756	0.940	0.856
DVM	0.907	0.813	0.949	0.866
Karar Ağaçları	0.954	0.928	0.966	0.923

Tablo 7 incelendiğinde ısıtma ve soğutma yüklerinin sınıflandırılmasında en başarılı sınıflandırma algoritmasının karar ağaçları olduğu gözlemlenmektedir. k-EK sınıflandırma algoritmasının ise en düşük başarı oranına sahip olduğu görülmektedir. Tablo 8'de sınıflandırma algoritmaları, ısıtma ve soğutma yüklerinin sınıflandırılmasında işlem süreleri bakımından karşılaştırılmıştır.

Tablo 8. Yapılardaki Isıtma ve Soğutma Yüklerinin Sınıflandırılmasında İşlem Sürelerinin Karşılaştırılması

Sınıflandırma Algoritmaları	Isıtma Yükü Sınıflandırma	Soğutma Yükü Sınıflandırma
k-EK	11.32 sn	11.47 sn
DVM	51.97 sn	53.33 sn
Karar Ağaçları	0.520 sn	0.490 sn

İşlem sürelerinin karşılaştırıldığı Tablo 8'de de görüldüğü üzere işlem sürelerinde de en başarılı sınıflandırma algoritması karar ağaçları olarak sonuçlar elde edilmiştir.

Yapılan bu çalışmada elde edilen sonuçlara göre yapılardaki ısıtma ve soğutma yüklerinin makine öğrenme algoritmaları ile tahmin edilmesi işleminde doğruluk, duyarlılık, özgüllük, hassasiyet ve işlem süreleri bakımından en başarılı sınıflandırma algoritması karar ağaçları olarak belirlenmiştir. k-EK sınıflandırma algoritması bu sınıflandırmada ikinci en iyi süreyi sağlamış fakat sınıflandırma başarı oranlarında bu çalışmada el alınan üç farklı sınıflandırma algoritması arasında en kötü sonucu veren algoritma olmuştur. Bu çalışmada karşılaştırmaya dahil edilen diğer sınıflandırma algoritması DVM ise süre bakımından yapılardaki ısıtma ve soğutma yüklerinin sınıflandırılmasında başarısız olduğu gözlemlenmektedir. Bunun yanında başarı parametreleri göz önünde bulundurulduğunda bu çalışma da ele alınan sınıflandırma algoritmaları arasında ikinci en iyi sınıflandırma başarı oranını sağladığı görülmektedir.

Kaynaklar

- [1] Aydın M, "Enerji Verimliliğinin Sürdürülebilir Kalkınmadaki Rolü: Türkiye Değerlendirmesi" Yönetim Bilimleri Dergisi 14,28: 409-441, 2016.

- [2] L. Perez-Lombard, J. Ortiz, C. Pout, (2008). A review on buildings energy consumption information. *Energy and buildings*, 40(3), 394- 398, 2008.
- [3] Özyurt, G., 2009. Enerji Verimliliği, Binaların Enerji Performansı ve Türkiye'deki Durum, *Türkiye Mühendislik Haberleri Dergisi*, 457.Sayısı, s. 32, Ankara.
- [4] A. Gasparella, G. Pernigotto, F. Cappelletti, P. Romagnoni and P. Baggio, "Analysis and modelling of window and glazing systems energy performance for a well insulated residential building", *Energy and Buildings*, vol. 43, no. 4, pp. 1030-1037, 2011.
- [5] KJ. Chua, SK. Chou, (2011). A performance-based method for energy efficiency improvement of buildings. *Energy Conversion and Management*, 52(4), 1829-1839.
- [6] M. Caldera, SP. Corgnati, M. Filippi, (2008). Energy demand for space heating through a statistical approach: application to residential buildings. *Energy and Buildings*, 40(10), 1972-1983.
- [7] A. Gupta, M. Kohli and N. Malhotra, "Classification based on Data Envelopment Analysis and supervised learning: A case study on energy performance of residential buildings", 2016 IEEE 1st International Conference on Power Electronics, Intelligent Control and Energy Systems (ICPEICES), 2016.
- [8] Castelli, L. Trujillo, L. Vanneschi and A. Popovič, "Prediction of energy performance of residential buildings: A genetic programming approach", *Energy and Buildings*, vol. 102, pp. 67-74, 2015.
- [9] Safarzagdegan Gilan, N. Goyal and B. Dilkina, "Active Learning in Multi-objective Evolutionary Algorithms for Sustainable Building Design", *Proceedings of the 2016 on Genetic and Evolutionary Computation Conference - GECCO '16*, 2016.
- [10] Ö. Ertugrul and Y. Kaya, "Smart city planning by estimating energy efficiency of buildings by extreme learning machine", 2016 4th International Istanbul Smart Grid Congress and Fair (ICSG), 2016.
- [11] A. Tsanas, A. Xifara, (2012). Accurate quantitative estimation of energy performance of residential buildings using statistical machine learning tools. *Energy and Buildings*, 49, 560-567.
- [12] A. Gumuscu, K. Karadag, M. Tenekeci and I. Aydilek, "Genetic algorithm based feature selection on diagnosis of Parkinson disease via vocal analysis", 2017 25th Signal Processing and Communications Applications Conference (SIU), 2017.
- [13] K. Karadag and M. Ozerdem, "Classification of ECoG patterns related to finger movements with wavelet based SVM methods", 2014 22nd Signal Processing and Communications Applications Conference (SIU), 2014.
- [14] Cover T, Hart P, "Nearest Neighbor Pattern Classification" *IEEE Transactions On Information Theory* 13:21–27, 1967.
- [15] V. Vapnik, "The nature of statistical learning theory," Springer-Verlag: New York, 1995.
- [16] J.R. Quinlan, C4.5: Programs for Machine Learning (Morgan Kaufmann, San Mateo, CA, 1993).
- [17] Maron, O. and Moore, A. W. Hoeffding races: Accelerating model selection search for classification and function approximation. In Cowan, J. D., Tesauro, G., and Alspector, J., editors, *Advances in Neural Information Processing Systems*, volume 6, pages 59–66. Morgan Kaufmann Publishers, Inc. (1994).