

Yapıların Isıtma ve Soğutma Yükünün Yapay Zeka ile Tahmini

Pelin Canbay*, Hüseyin Taş

*Kahramanmaraş Sütçü İmam Üniversitesi, Mühendislik-Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü,
Kahramanmaraş, Türkiye*

*pelincanbay@ksu.edu.tr^{ID}, htas19318@gmail.com^{ID}

Makale gönderme tarihi:24.08.2022, Makale kabul tarihi:26.10.2022

Öz

Küresel ısınma günümüzün en önemli problemlerinden biri haline gelmiştir. Bu durumun en büyük sebebi problemin etkilerini artık çok daha fazla hissetmemizdir. Küresel ısınma, atmosfere salınan gazların neden olduğu sera gazı etkisinin sonucunda, dünya üzerinde yıl boyunca kara, deniz ve havada ölçülen ortalama sıcaklıklarda görülen artıştır. Birçok alanda olumsuz etkileri görülen küresel ısınmanın en büyük sebebi insan faaliyetleridir. Bu faaliyetlerden en önemlisi elektrik tüketimi, ısınma ve taşımacılık için yakılan fosil yakıtlardır. Küresel ısınmanın olumsuz etkilerine daha fazla maruz kalmamak ve daha sağlıklı bir dünyada yaşamak için sürdürülebilir temiz enerji kaynaklarına yönelmeli ve enerjiyi verimli kullanmalıyız. Yapı sektörü enerji alanında önemli bir paya sahiptir. Binaların enerji verimliliği, ısıtma ve soğutma talebinin sistematik olarak azaltılmasıyla sağlanabilmektedir. Bu çalışmada, yeni yapıların mimari tasarımını değerlendirerek yapıların ısıtma ve soğutma yükünü tahmin eden, tek çıktı ve çok çıktı regresyon yöntemleri kullanarak yapay zeka tabanlı bir çözüm önermekteyiz. Literatürde genellikle tek çıktı regresyon analizinin tercih edilmesi ile çözülmeye çalışılan bu gibi problemler için çalışmamızda çok çıktı analizlerin kullanımının daha uygun olacağı hem yapılan uygulamalar ile hem de araştırmalar ile sunulmuştur. Geleneksel makine öğrenmesi yöntemlerinin tek çıktı ve çok çıktı regresyon analizinde kullanıldığı çalışmamızda, probleme uygun parametreler ve katmanlar ile tasarlanan bir derin sinir ağı ile hem tek çıktı hem çok çıktı regresyon analizinde en yüksek başarı elde edilmiştir. Bu vesile ile enerji tüketimi bakımından yüksek maliyetli yapıların tespiti sonucunda daha enerji verimliliği yüksek yapıların inşa edilmesine öncelik verilmesi amaçlanmıştır.

Anahtar Kelimeler: Binalarda ısıtma/soğutma yükü, enerji verimliliği, yapay zeka

Prediction of Heating and Cooling Loads of Buildings by Artificial Intelligence

Abstract

Global warming has become one of the most important problems of our day. The biggest reason for this is that we feel the effects of the problem much more now. Global warming is the increase in the average temperatures measured in land, sea and air throughout the year as a result of the greenhouse gas effect caused by the gases released into the atmosphere. The biggest cause of global warming, which has negative effects in many areas, is human activities. The most important of these activities is fossil fuels burned for electricity consumption, heating and transportation. In order not to be more exposed to the negative effects of global warming and to live in a healthier world, we must turn to sustainable clean energy sources and use energy efficiently. The construction sector has an important share in the energy field. The energy efficiency of buildings can be achieved by systematically reducing the heating and cooling demand. In this study, we propose an artificial intelligence-based solution using single-output and multi-output regression methods to estimate the heating and cooling load of buildings by evaluating the architectural design of new buildings. For such problems, which are generally tried to be solved by the preference of single-output regression analysis in the literature, it has been presented in our study with both applications and research that the use of multi-output analyzes would be more appropriate. In our study, in which traditional machine learning methods were used in single-output and multi-output regression analysis, the highest success was achieved in both single-output and multi-output regression analysis with a deep neural network designed with parameters and layers suitable for the problem. Hereby, it is aimed to give priority to the construction of buildings with higher energy efficiency as a result of the determination of high cost structures in terms of energy consumption.

Keywords: Artificial intelligence, energy efficiency, heating/cooling load in buildings

Research article/Araştırma makalesi
DOI:10.29132/ijpas.1166227

GİRİŞ

Küresel ısınma, özellikle fosil yakıtların (kömür, petrol ve gaz) yakılması ve büyük ölçekli ormansızlaştırma gibi, en önemlisi karbondioksit olan sera gazlarının atmosferde büyük miktarlarda emisyonuna neden olan, insan faaliyetlerinin iklim üzerindeki etkisine atıfta bulunan bir ifadedir (John Houghton, 2005). Küresel ısınma, kuraklık, hastalıklarda artış, şiddetli yağışlar, seller, orman yangınları gibi birçok olumsuz etkiye sebep olmaktadır. 21. Yüzyılda üzerinde tartışılan en önemli çevre sorunu küresel ısınmadır.

Dünya genelinde hızlı nüfus artışı ile birlikte her geçen gün enerjiye olan talep artmaktadır. Artan bu talebi karşılamak için fosil yakıtlar kullanılmakta ve enerjinin büyük bir kısmı ülkemize dışarıdan ithal edilmektedir. Fosil yakıt kullanımında ortaya çıkan sera gazının etkisiyle de küresel ısınma hız kazanmakta ve dünya her geçen gün biraz daha tahrip olmaktadır. Küresel enerji tüketiminin %40'lık kısmını inşa edilen yapılar oluşturmaktadır. Bu tüketimin sonucunda açığa çıkan karbon ayak izi, ulaşım araçlarının tamamında ortaya çıkan karbon ayak izi miktarından kat ve kat fazladır. Bu yüzden binalarda enerji verimliliğinin maksimum seviyede olması gerekmektedir. Küresel olarak kullanılan enerjinin büyük bir çoğunluğu binalar tarafından tüketilmektedir. Tablo 1'de, T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı'ndan alınmış (T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, 2019) enerjinin sektörel olarak kullanımı gösterilmektedir.


Tablo 1. Enerjinin sektörel dağılımı

Yıllar	1990	1995	2000	2005	2010	2015	2016	2017	2018
Enerji ürünleri arzı	52.46	62.96	79.42	88.67	105.8	129.1	136.2	145.3	143.6
Çevrim ve enerji sektörü	10.22	12.44	17.83	18.34	26.04	29.67	31.65	33.52	34.51
Sanayi	13.64	15.98	22.87	26.41	26.07	32.15	33.25	35.32	36.22
Ulaştırma	8.72	11.07	12.01	1.84	16.31	24.93	26.81	28.42	28.45
Mesken ve hizmetler	15.35	17.51	19.55	22.28	27.76	32.32	33.22	36.01	33.07
Tarım ve hayvancılık	1.95	2.55	3.07	3.35	3.73	3.93	4.05	4.27	4.38
Enerji dışı tüketim	2.54	3.08	3.45	4.09	5.31	5.65	6.99	7.32	6.29

Tablo 1'de görüldüğü üzere Türkiye'de 2018 yılında kullanılan enerjinin %38'lik kısmı binalar ve konutlar tarafından kullanılmaktadır. Binalarda ise kullanılan enerjinin %85'lik kısmı ısıtma ve soğutma amacıyla kullanılmaktadır ve bu değer sadece

Türkiye'de 2019 yılında toplamda 9,3 milyonun üzerinde olduğu düşünülmektedir. Bu rakamlara bakıldığında binalarda uygulanacak enerji verimliliğinin ne denli önemli olduğu ortaya çıkmaktadır.

Binaların ısıtma ve soğutma yükünü daha verimli hale getirebilmek için binanın mimarı yapısı önemli bir yer tutmaktadır. Binanın güneşe olan açısı, binadaki cam alanı, binanın toplam yüzey alanı gibi parametreler büyük önem taşımaktadır. Örneğin ofis binalarında, yıllık enerji tüketiminin yaklaşık %20'si aydınlatma kaynaklı olduğundan dolayı, binanın güneş ışığından doğal aydınlatmadan faydalanması büyük önem taşımaktadır. Bu yüzden binanın güneşe göre konumu ısıtma yüküne ve aydınlatmaya fayda sağlamaktadır. Binaların cam alanı ve dağılımı da enerjinin etkin kullanılmasında büyük önem taşımaktadır. İnşa edilen cam alanı ve dağılımı sayesinde ihtiyaç duyulan enerjinin büyük bir kısmı güneşten sağlanabilmektedir. Eğer cam alanı ve dağılımı dengesiz ise güneşten alınan verim az olabilmektedir veya çok fazla güneş enerjisi geldiğinden dolayı bina çok fazla ısı almaktadır. Bu nedenle de soğutma yükü artmaktadır. Binanın güneşe olan konumu, cam alanı ve dağılımı ısıtma ve soğutma yükünü büyük oranda etkilemektedir. Bu yüzden güneşten en optimum şekilde faydalanmak gerekmektedir. Şekil 1'de binanın güneşe olan ilişkisi (Yöntem, S. T, 2016) gösterilmektedir.



Şekil 1. Binanın konumu ve güneş ile ilişkisi

Bu çalışmada University of California, Irvine Machine Learning Repository'den alınmış, simüle edilen 12 farklı bina şekli kullanılarak toplamda 768 örnekten elde edilen veri seti (University of

Research article/Araştırma makalesi
 DOI:10.29132/ijpas.1166227

California Machine Learning Repository, 2012) kullanılmıştır. Bu veri seti binaya ait bazı mimari özellikleri içermektedir. Çalışmamızda, bu veri setinden yararlanarak binaların mimari yapısına bağlı olarak, daha inşa edilmeden, binalar için gerekli olan ısıtma ve soğutma yükünü tahmin eden yapay zeka tabanlı bir çözüm sunmaktayız. Hem ısıtma ve soğutma yükünü ayrı birer regresyon problemi olarak hem de iki değeri birlikte çoklu-çıkıtlı (multi-output) regresyon problemi olarak bu çalışmada, geleneksel makine öğrenmesi yöntemleri ile ele almış bulunmaktayız. Böylece ısıtma ve soğutma yükleri arası bağlantının da kesilmeden değerlerin tek çıktıda tahminlemesini yapay zeka yöntemleri ile gerçekleştirmiş bulunmaktayız. Ek olarak, probleme uygun bir Derin Sinir Ağları (Deep Neural Network-DNN) mimarisi geliştirilerek hem tek çıktılı hem çok çıktılı bir regresyon modeli tasarlanmış ve geliştirilen bu model ile diğer yöntemlerden daha başarılı sonuçlar elde edilmiştir. Böylece binaların inşa edilmeden önce ne kadar enerjiye ihtiyaç duyacağı tespit edilip enerji verimliliğini artırıcı ve bu yapıların çevreye vereceği zararı azaltıcı önlemlerin erkenden alınabilmesi için yapay zekadan faydalanılabilecektir.

İLGİLİ ÇALIŞMALAR

Bu bölümde, binalarda ısıtma ve soğutma yükünü tahmin eden yapay zeka tabanlı çalışmalar incelenmiş, çalışmamız ile benzer ve farklı yönleri açıklanmıştır.

Peker M. ve arkadaşları (Peker M., Özkaraca O. ve Kesimal B. 2017), binalarda ısıtma ve soğutma yüklerini tahmin etmek amacıyla yapmış oldukları regresyon tabanlı makine öğrenmesi çalışmalarında 4 farklı algoritma üzerinden eğitim gerçekleştirmişlerdir. KNN, SVM, Lineer Regresyon ve Random Forest algoritmalarını kullanmışlardır. Yazarlar çalışmalarında bizim de çalışmamızda kullanmış olduğumuz veri kümesini kullanmışlardır. Çalışmada ısıtma ve soğutma yükleri için ayrı ayrı olarak model eğitimi gerçekleştirmişlerdir. Çalışmalarında binaların ısıtma ve soğutma yükünü tahmin etmede en başarılı model Random Forest algoritması kullanılarak elde edilmiştir.

Turhan C. ve arkadaşları (Turhan C., Gökçen G. ve Kazanasmaz T., 2013), yapay sinir ağları ile İzmir'deki çok katlı binaların toplam enerji tüketiminin tahmin edilmesine yönelik bir çalışma gerçekleştirmişlerdir. Bu çalışmalarında İzmir'de

bulunan 3 değişik ilçedeki (Konak, Karabağlar ve Balçova) 5 ile 11 kat arasındaki 148 binadan toplamış olduğu verileri kullanmışlardır. Bu veri setinde bina kat sayısı, alan-hacim oranı, yalıtım varlığı, toplam duvar ısı geçirgenlik katsayısı, toplam dış yüzey alanı, imar durumu ve cam ve ısıtma sistem tipi gibi özellikler yer almaktadır. Bu özellikler üzerinden makine öğrenmesi tabanlı bir yapay zeka modeli geliştirmişlerdir.

Roy S. S. ve arkadaşları (Roy, S. S., Samui, P., Nagtode, I., Jain, H., Shivaramkrishnan, V. and Mohammadi-Ivatloo, B., 2020), binalarda ısıtma ve soğutma yükünü tahmin etmek için çalışmamızda kullanmış olduğumuz veri setini kullanarak bir çalışma gerçekleştirmişlerdir. Bu çalışmalarında Gaussian process, Linear Regression, ANN, RBF network ve SVM algoritmaları kullanmışlardır. Bu veri setini kullanarak makine öğrenmesi tabanlı regresyon modeli geliştirmişlerdir. Isıtma ve soğutma yükü için ayrı ayrı modeller eğitilen çalışmada, en başarılı algoritma Linear Regression olmuştur.

Moayedi H. ve arkadaşları (Moayedi, H., Bui, D. T., Dounis, A., Lyu, Z., and Foong, L. K., 2019), binalarda ısıtma ve soğutma yükünü tahmin etmek için çalışmamızda kullanmış olduğumuz veri setini kullanarak bir çalışma gerçekleştirmişlerdir. Bu veri setini kullanarak makine öğrenmesi tabanlı regresyon modeli geliştirmişlerdir. Bu çalışmalarında LazyLWL, Alternating Model Tree, Random Forest ElasticNet, MLP Regressor ve RBF Regressor algoritmalarını kullanmışlardır. Isıtma ve soğutma yükleri için ayrı ayrı olarak model eğitimi gerçekleştirmişlerdir. Isıtma ve soğutma yükü için en başarılı olan algoritma Random Forest algoritması olmuştur.

Çalışmamızda literatürden farklı olarak ısıtma ve soğutma yükleri, geleneksel makine öğrenmesi yöntemleri ile hem ayrı ayrı regresyon problemi olarak ele alınmış hem de çoklu-çıkıtlı (multi-output) regresyon problemi olarak, çıktılar arası ilişkinin korunması sağlanarak birlikte tahminlenmiştir. Yapılan uygulamalara ek olarak problemin DNN kullanılarak da değerlendirilmesi yapılmış ve hem tek çıktılı regresyon modellerinden hem de çok çıktılı modellerden elde edilen mevcut sonuçlardan daha başarılı tahmin modeli tasarlanan DNN modeli ile elde edilmiştir.

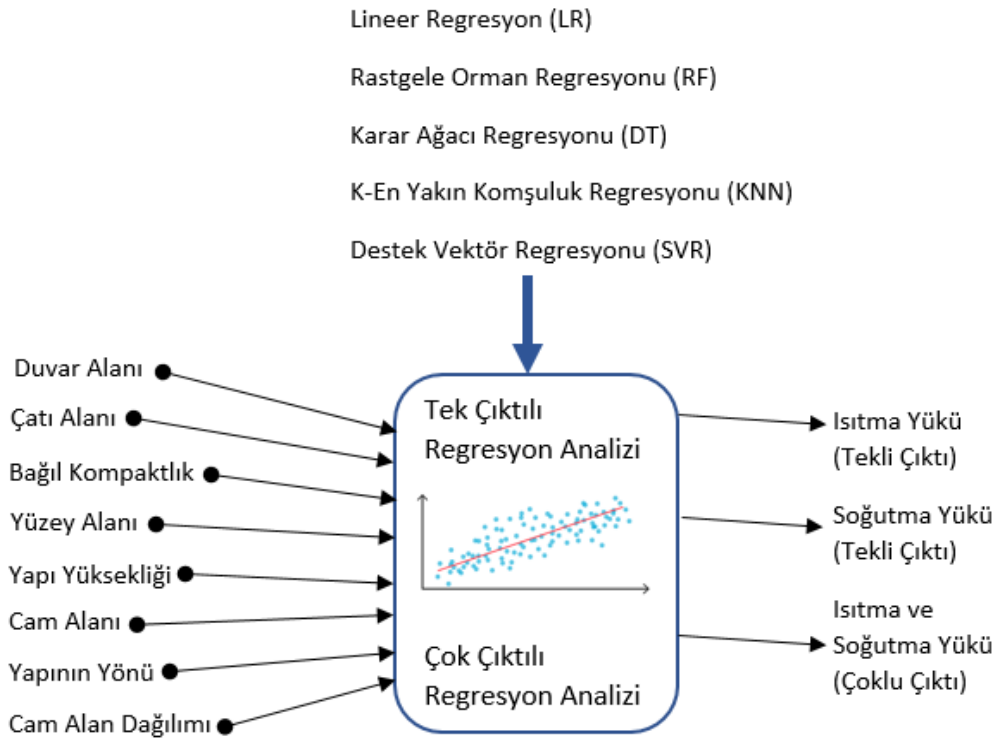
Research article/Araştırma makalesi
DOI:10.29132/ijpas.1166227

MATERYAL VE METOD

Bu çalışmada, literatürde çok hedefli (Appice, A. and Džeroski, S., 2007), çok değişkenli (Breiman, L. and Friedman, J. H. (1997) veya çok yanıtli (Similä, T. and Tikka, J., 2007) regresyon olarak da bilinen çok çıktılı (multioutput) regresyon, birden çok gerçek değerli çıktı/hedef değişkenini aynı anda tahmin etmek amacıyla kullanılmıştır. Tekli regresyondaki çıktılar arası bileşik bağımlılıkları göz ardı etme durumu çok çıktılı yöntemlerde olmadığından, çok çıktılı regresyon yöntemlerinin genel olarak tek çıktılı yöntemlerle karşılaştırıldığında daha iyi bir tahmin performansı sağlandığı ve çıktılar arası ilişkinin korunduğu birçok çalışma tarafından kanıtlanmıştır (Borchani, H., Varando, G., Bielza, C. and Larranaga, P., 2015; Han, Z., Liu, Y., Zhao, J. and Wang, W., 2012).

Çalışmamızda kullanılan modelin eğitilmesi aşamasında ise geleneksel makine öğrenmesi

yöntemlerinden Lineer Regresyon (Linear Regression - LR), Rastgele Orman (Random Forest - RF), Karar Ağacı Regresyonu (Decision Tree Regressor- DT), K-En Yakın Komşuluk Regresyonu (K-Nearest Neighbor Regression – KNN) ve Destek Vektör Regresyonu (Support Vector Regression – SVR) algoritmaları hem tek değer tahminlemede hem de çoklu değer tahminlemede kullanılarak veri seti üzerinden eğitim işlemi gerçekleştirilmiştir. Ayrıca problem uygun parametreler ve katmanlar ile tasarlanan bir DNN modeli ile de hem tek çıktılı regresyon analizinde hem çok çıktılı regresyon analizinde geleneksel yöntemlere göre de daha yüksek doğrulukta tahminleme yapılmıştır. Bu aşama, veri seti içerisindeki öznitelikler arasındaki gizli ilişkileri ortaya çıkararak ısıtma ve soğutma yükünü bir formüle oturtur. Çalışmamızda kullanılan geleneksel modellerin akışı Şekil 2'de yer almaktadır.



Şekil 2. Geleneksel modellerin işlem akışı

Kullanmış olduğumuz algoritmaların optimize edilebilir parametrelerinin güncellenmesi ile başarı oranının artırılması kısmen sağlanabilmektedir. Çalışmamızda, GridSearchCv algoritması kullanılarak makine öğrenmesi algoritmalarının başarı oranını maksimum hale getirecek parametre

kombinasyonun bulunmasını sağlanmıştır. En iyi parametre kombinasyonu bulunduktan sonra bu kombinasyon ile tekrar model eğitimi gerçekleştirilmektedir.


Geleneksel makine öğrenmesi yöntemlerinin çok çıktılı performanslarını kıyaslamak ve ele

Research article/Araştırma makalesi
DOI:10.29132/ijpas.1166227

aldığımız probleme daha başarılı bir çözüm sunabilmek için tasarladığımız DNN modelinin parametreleri kaba kuvvet yöntemi ile belirlenmiş olup, en uygun parametreler Tablo 2’de verilmiştir. Geliştirilen modelin mimarisi Şekil 3’te sunulmuştur.

Tablo 2. DNN modelinde kullanılan parametreler

Parametre Adı	Parametre Değeri
Aktivasyon Fonksiyonu	Rectifier Linear Unit (relu)
Kernel Başlangıcı	Normal Dağılım
Optimizasyon Fonksiyonu	Adam
Epochs	1000
Batch Boyutu	64
Kayıp Fonksiyonu	MSE



Şekil 3. Kullanılan DNN modelinin mimarisi

University of California, Irvine Machine Learning Repository sitesinde yer alan Oxford Üniversitesi Endüstri ve Uygulamalı Matematik Merkezi tarafından oluşturulan Enerji Verimliliği veri seti çalışmamızda binalardaki ısıtma ve soğutma yükünün tahminlenebilmesi amacıyla kullanılmıştır. Bu veri seti farklı bina parametrelerine sahip olan 768 örnek, 8 öznitelik ve 2 çıktıdan oluşan bir veri setidir. Bu veri setinde duvar alanı, binanın yüzey alanı, binanın yönü, binanın cam alan dağılımı, cam alanı, binanın toplam yüksekliği, çatı alanı ve bağlı kompaktlık gibi bina ile ilgili farklı özellikler içermektedir. Veri seti orijinalinde öznitelik isimleri X1, X2 şeklinde isimlendirilmiştir. Çalışmamızda veri setine ait doküman incelenerek öznitelik isimleri değiştirilmiştir. Veri setindeki her bir örnek (sattır), farklı binalara ait özellikleri içermektedir. Tablo 3’te,


kullanılan veri setinde bulunan öznitelikler açıklanmaktadır.

Tablo 3. Kullanılan veri seti ve özellikleri

Öznitelikler	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

Research article/Araştırma makalesi
DOI:10.29132/ijpas.1166227


Binalardaki ısıtma ve soğutma yükünün hesaplanması için uygulanan işlemlerin akışı Şekil 4'te sunulmuştur.



Şekil 4. Kullanılan işlemler akışı

Veri ön işleme makine öğrenmesi modelini kurmadan önce veri setindeki aykırı değerleri kaldırma, eksik verileri düzenleme ve verileri dönüştürme gibi işlemleri kapsamaktadır. Veri ön işleme aşlında veri setini modele girebilmesi için hazır hale getirir ve yapay zeka modelinin başarısı için önemlidir. Çünkü, veri setinde eksik veri

bulunması veya aykırı veriler bulunması modelin başarı oranını düşürmektedir. Çalışmamızda, veri seti ön işleme adımında aykırı değer analizi ve eksik değer analizi gibi işlemler yapılmıştır. Yapılan ön işleme sonucunda veri setinde eksik veri olmadığı görülmüştür. Veri setinde aykırı değer analizi sonucunda aykırı değer tespit edilmemiştir. Ayrıca kullanılan yöntemlerin performansını arttırmak ve daha standart sonuçlar elde edebilmek için veri seti StandartScaler fonksiyonu ile ölçeklendirilmiştir. Öznitelikler arasındaki korelasyona bakarak veri içindeki ilişkileri görebilmek için veri setine görselleştirme işlemi uygulamaktayız. Şekil 5'te verideki öznitelikler arasındaki ilişkiyi gösteren grafik yer almaktadır. Bu grafiğe bakıldığında binanın toplam yüksekliğinin (Overall Height) ısıtma yüküne %89 ve soğutma yüküne %90 pozitif yönde etkisi olduğu gibi, öznitelikler arası ve kullanılan öznitelikler ile hedef değişkenler arası ilişki görülebilmektedir.



Şekil 5. Korelasyon Grafiği

Önerilen yöntemdeki 10-katlı çapraz doğrulama ile kullanılan modellerin doğruluk oranları sınanmaktadır. Böylece modellerin başarısı tek bir

ayrım için değil on farklı ayırım için test edilmiş olmaktadır. Sonuç olarak 10 kat çapraz doğrulama modelin başarısının doğruluk değerinin rastgele olup

Research article/Araştırma makalesi
 DOI:10.29132/ijpas.1166227

olmadığını sınamakta ve bize doğrulanmış başarı oranını vermektedir.

Uygulamalar 2.40 GHz Intel Core i5-9300H işlemci, 16GB RAM ve windows10 işletim sistemine sahip bir sistem ve Anaconda dağıtımı üzerinden jupyter lab kullanılarak Python programlama dili ile gerçekleştirilmiştir. Kullanılan modellerin test edilme aşamasında ise model eğitimi gerçekleştirildikten sonra modelin başarı oranı test edilmektedir. Bu aşamada regresyon performans metrikleri kullanılarak modelin başarı oranı bulunmaktadır.

Regresyon Modeli Performans Ölçüm Metrikleri

Ele aldığımız problem özelinde kurmuş olduğumuz modellerin performans başarısını bilmek önem arz etmektedir. Regresyon algoritmalarının performanslarının ölçülmesi için çoğunlukla MSE (Hata Karelerinin Ortalaması), RMSE (Kök Ortalama Karekök Hatası), MAE (Ortalama Mutlak Hata) ve R² Score (R kare) metrikleri kullanılmaktadır. Sırasıyla eşitlik (1), (2), (3) ve (4)'te verilen metrikler çalışmamızda kullandığımız modellerin başarısını ölçmek ve karşılaştırma yapabilmek için kullanılmıştır.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (1)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (2)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3)$$

$$R^2 = 1 - \frac{SS_{RES}}{SS_{TOT}} = 1 - \frac{\sum_i (y_i - \hat{y}_i)^2}{\sum_i (y_i - \bar{y}_i)^2} \quad (4)$$

DENEYSEL SONUÇLAR VE TARTIŞMA

Çalışmamızda öncelikle, DT, RF, LR, KNN ve SVR algoritmaları hem tek çıktılı hem çok çıktılı yapıda kullanılarak binaların 8 farklı özelliği üzerinden, binaların ısıtma ve soğutma için ihtiyaç duyacakları enerji tüketimini tahminleyen yapay zeka modelleri eğitilmiştir. Değerlendirdiğimiz bu modeller için en iyi hiperparametre kombinasyonu GridSearchCv algoritması ile tespit edildikten sonra

ilgili parametreler ile modeller oluşturulmuştur. Oluşturulan tüm modellerimizin başarısı 10 katlı çapraz doğrulama ile test edilmiştir. Önerilen yöntemler ile elde edilen sonuçlar Tablo 4, Tablo 5 ve Tablo 6'da gösterilmektedir.

Tablo 4. Isıtma yükü tahmini için elde edilen sonuçlar

Method	MSE	MAE	RMSE	SCORE
LR	9,15	2,18	3,02	0,91
RF	0,24	0,35	0,49	0,99
DT	0,38	0,42	0,62	0,99
KNN	5,36	1,46	2,31	0,95
SVR	7,97	1,88	2,82	0,92

Tablo 5. Soğutma yükü tahmini için elde edilen sonuçlar

Method	MSE	MAE	RMSE	SCORE
LR	9,89	2,19	3,14	0,89
RF	2,97	1,07	1,72	0,96
DT	4,09	1,14	2,02	0,95
KNN	6,25	1,61	2,50	0,93
SVR	10,62	2,12	3,25	0,88

Tablo 6. Çok çıktılı Regression yöntemi için ısıtma ve soğutma yükü tahmininde edilen sonuçlar


Method	MSE	MAE	RMSE	SCORE
LR	9,52	2,18	3,08	0,90
RF	1,97	0,75	1,40	0,98
DT	2,90	0,83	1,71	0,96
KNN	5,80	1,53	2,41	0,94
SVR	9,29	2,01	3,05	0,90

Tablo 4, Tablo 5 ve Tablo 6 incelendiğinde, belirlenen ölçekler bakımından tek çıktılı ve çok çıktılı regresyon modelleri arasında belirgin bir fark bulunmadığı görülmektedir. Değerlendirilen modeller eğitildikten sonra en başarılı sonuçlar, her iki regresyon yaklaşımında da RF algoritması üzerinden alınmıştır. RF regresyon algoritması, ele alınan problemin çözümüne yönelik çok sayıda karar ağacı oluşturarak çalışan bir topluluk öğrenme yöntemidir (Utku, A. and Can, U., 2022). RF, bir veri kümesinin çeşitli alt kümelerinde bir dizi karar ağacı işletir ve bu veri kümesinin tahmin doğruluğunu iyileştirmek için karar ağaçlarının sonuçlarının ortalamasını alır. Bu durum da nispeten az sayıda verisi bulunan ve dağılım çeşitliliği çok olmayan,

Research article/Araştırma makalesi
 DOI:10.29132/ijpas.1166227

çalışmamızda kullandığımız gibi veri kümelerinde RF algoritması ile daha başarılı sonuçlar elde edilmesini sağlamaktadır. Şekil 6 ve Şekil 7'de

tahmin edilen çıkış değerleri ile gerçek değerler arasındaki regresyon grafikleri sunulmuştur.



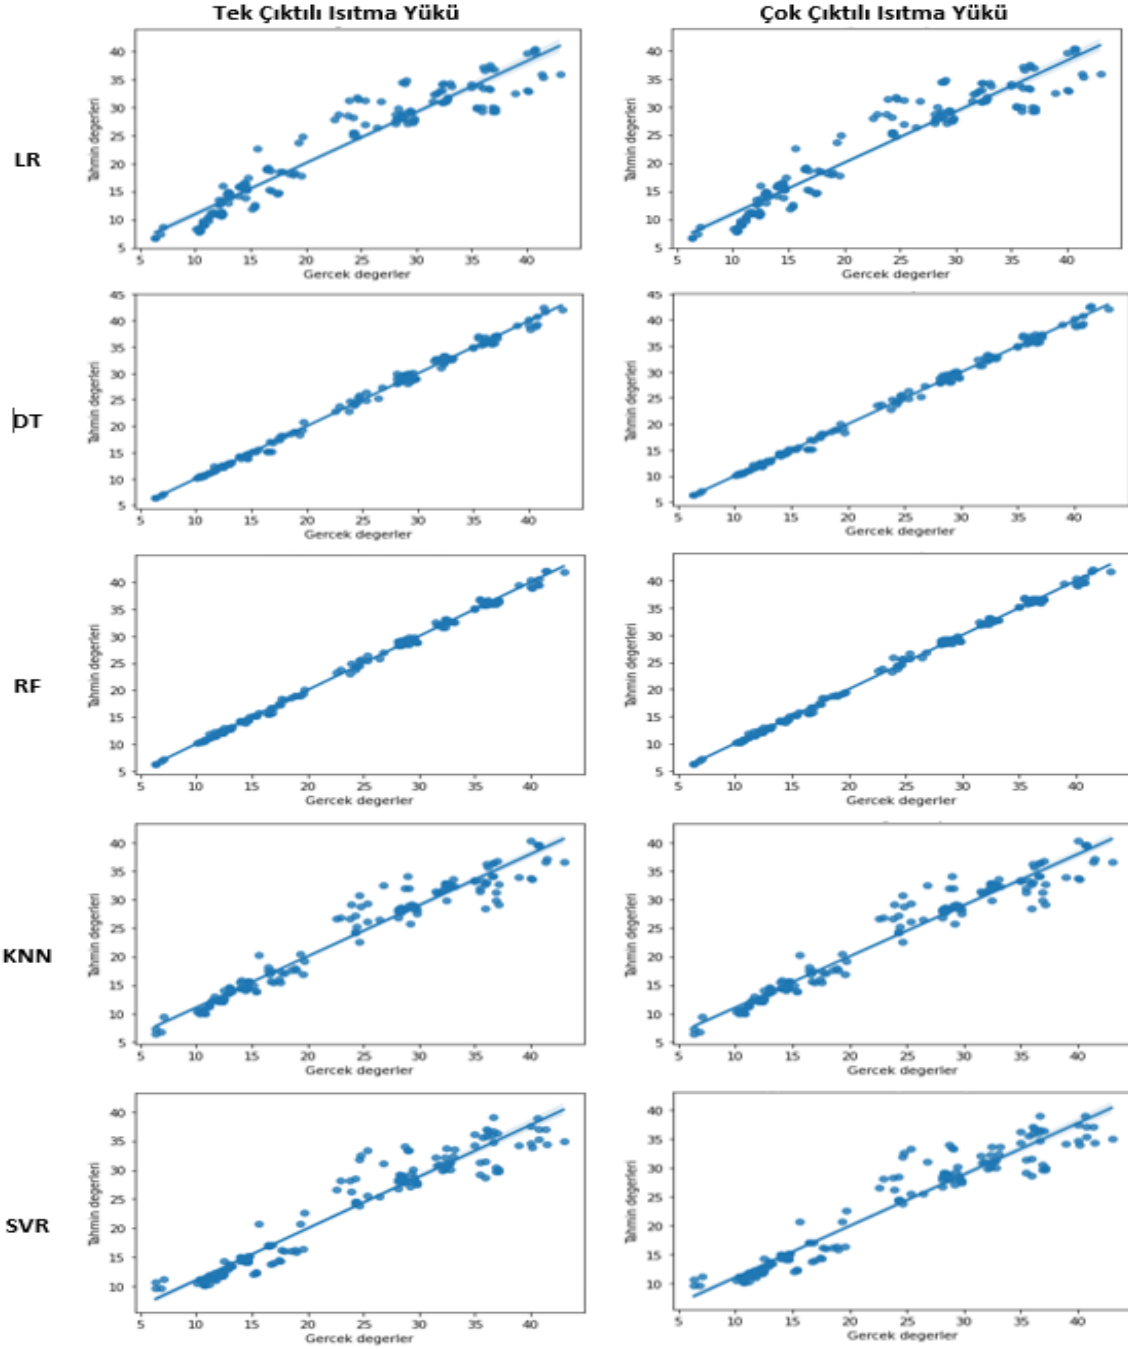
Şekil 6. Soğutma yükü için elde edilen regresyon grafikleri (tekli regresyon sonuçları solda, çoklu regresyon sonuçları sağda)

Çalışmamızda da geleneksel makine öğrenmesi yöntemlerinden en iyi sonucu veren algoritmanın RF olması, RF algoritmasının yetersiz dağılımı daha iyi yönetebilmesine bağlanmıştır. Diğer kullanılan

Research article/Araştırma makalesi
DOI:10.29132/ijpas.1166227

algoritmalar da başarı olarak yakın performans göstermektedir. RF algoritmasına göre sonuçları değerlendirirsek, tek çıktılı regresyon ile ısıtmadan elde edilen score değeri yüzde 99, soğutmadan elde edilen score değeri yüzde 96 ile ortalamada yüzde

97,5 başarı elde edilmiştir. Bu değer çok çıktılı regresyondan elde edilen başarı ile kıyaslandığında, çok çıktılı regresyon ile yüzde 0,5 oranında bir yükseliş gözlemlenebilmektedir.



Şeki1 7. Isıtma yüğü için elde edilen regresyon grafikleri (tekli regresyon sonuçları solda, çoklu regresyon sonuçları sağda)

Research article/Araştırma makalesi
DOI:10.29132/ijpas.1166227


Tablo 7. Tasarlanan DNN modelinin tekli ve çoklu çıktı sonuçları

	Method	MSE	MAE	RMSE	SCORE
ISITMA	RF	0,24	0,35	0,49	0,99
	Tasarlanan DNN modeli	0,21	0,34	0,46	0,99
SOĞUTMA	RF	2,97	1,07	1,72	0,96
	Tasarlanan DNN modeli	1,32	0,71	1,15	0,98
ÇOK ÇIKTILI	RF	1,97	0,75	1,40	0,98
	Tasarlanan DNN modeli	0,40	0,46	0,63	0,99


Tablo 7’de görülebileceği üzere, Tasarlanan DNN modeli ile hem tek çıktılı Tasarlanan DNN modelinin mse kayıp değerinin eğitim süresince, eğitim ve test setindeki değişimini gösteren grafik Şekil 8’de sunulmuştur.

Yapay Sinir Ağları, verilen örnekler üzerinden öğrenme gerçekleştiren, örneklerin değerlerine göre ağırlıklarını güncelleyerek problem ve verilen

örneklerle uygun çözüm üreten bir makine öğrenmesi algoritmasıdır. Sinir ağları arasındaki katmanların artırılması ve katmanlar arası yapılan işlemlerin çeşitlendirilmesi ile geliştirilen DNN modelleri ile birçok problem ve veri kümesi üzerinde çok daha başarılı sonuçlar elde edilmesine vesile olmuştur. Çalışmamızda tasarlamış olduğumuz DNN modeli 1000 döngü (epoch) sonucunda kullandığımız verinin probleme ne uygun çözümünü öğrenmiştir. Tasarlanan model hem tek çıktılı regresyon analizinde (ısıtma ve soğutma yüklerinin ayrı ayrı öğrenilmesinde) hem de çok çıktılı regresyon analizinde geleneksel modellerden daha yüksek başarılı, daha düşük hatalı sonuçlar elde edilmiştir. Şekil 9’da tasarlanan DNN modeli ile elde edilen tek çıktılı ve çok çıktılı ısıtma/soğutma yüklerinin dağılım grafikleri sunulmuştur.



Şekil 8. Tasarlanan DNN modelinin öğrenme süreci



Şekil 9. Tasarlanan DNN modeli ile elde edilen sonuçların dağılım grafiği

SONUÇ

Isıtma yükü, sıcaklığın bir kabul edilebilir aralıkta muhafaza edilmesi için bir boşluğa eklenmesi gereken ısı enerjisinin miktarı; soğutma yükü, sıcaklığı kabul edilebilir bir aralıkta tutmak için bir boşluktan (soğutma) alınması gereken ısı enerjisinin miktarı olarak tanımlanmaktadır. Isıtma ve soğutma yükünü etkileyen birçok parametre vardır. Özellikle yapıların mimarisi ve konumu bu konuda oldukça önem arz etmektedir. Binalarda ısıtma ve soğutma yüklerinin önceden tahmin edilebilmesi bu yüklerin maliyetinde büyük bir tasarruf sağlanmasına olanak sunacaktır. Bu sebeple, eski bina verilerine dayalı olarak yeni binaların ısıtma ve soğutma yükünün en az hata oranı ile tahmin edilmesi büyük önem taşımaktadır. Yapay zeka algoritmaları ile regresyon analizi kullanılarak tahminlenebilecek bu gibi problemlerin çözümünde literatürde genellikle tek çıktılı çözümler tercih edilmiştir. Oysaki ısıtma ve soğutma yükü gibi hem girilen bina özelliklerine hem de birbirine bağlı değerlerin tespiti için çok çıktılı regresyon analizlerinin yapılmasının daha uygun olduğu birçok çalışma ile ispatlanmıştır. Çalışmamızda, yapılarda ısıtma ve soğutma yükünü daha iyi tahminlenebilmesi için geleneksel makine öğrenmesi yöntemleri ile çok çıktılı ve tek çıktılı regresyon yöntemleri kullanılarak karşılaştırmalı uygulamalar gerçekleştirilmiştir. Yapılan karşılaştırmalar sonucunda, çok çıktılı regresyon problemlerinde çıktılarının bir arada tahminlenmesi ile daha anlamlı sonuçlar elde edildiği gözlemlenmiştir. Geleneksel yöntemlere ek olarak hem tek çıktılı hem çok çıktılı regresyon analizi için, ele alınan problem ve kullanılan verilere uygun bir DNN modeli tasarlanmıştır. Tasarlanan model ile hem tek çıktılı (ısıtma ve soğutma yüklerinin ayrı ayrı tahminlendiği) hem çok çıktılı regresyon analizinde tasarlanan DNN modeli ile, diğer yöntemlere oranla çok daha düşük hata oranlarında sonuçlar elde edilmiştir. Tasarlanan DNN modeli ile elde edilen tahminleme başarısının 0,99 değerlerine ulaşması, yapılarda ısıtma ve soğutma yükünün daha yapılar inşa edilmeden yüksek başarı ile tahminlenebileceğini göstermiştir. Kullanılan veri seti daha fazla genişleterek daha karmaşık algoritmalar ile farklı yapılar için de sonuçlar almak ileriki çalışmalarda hedeflenmektedir.

ÇIKAR ÇATIŞMASI BEYANI

Yazarlar bu çalışmada herhangi bir şekilde çıkar çatışması olmadığını beyan eder.

ARAŞTIRMA VE YAYIN ETİĞİ BEYANI

Yazarlar bu çalışmada araştırma ve yayın etiğine uyduğunu beyan eder.

KAYNAKÇA

- Appice, A. ve Džeroski, S. (2007). Stepwise induction of multi-target model trees. In European conference on machine learning (pp. 502-509). Springer, Berlin, Heidelberg.
- Borchani, H., Varando, G., Bielza, C. and Larranaga, P. (2015). A survey on multi-output regression. Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery, 5(5), 216-233.
- Breiman, L. ve Friedman, J. H. (1997). Predicting multivariate responses in multiple linear regression. Journal of the Royal Statistical Society: Series B (Statistical Methodology), 59(1), 3-54.
- Han, Z., Liu, Y., Zhao, J. ve Wang, W. (2012). Real time prediction for converter gas tank levels based on multi-output least square support vector regressor. Control Engineering Practice, 20(12), 1400-1409.
- Houghton, J. (2005). "Global warming". In: Reports On Progress In Physics, 68(6), p. 1343.
- Moayed, H., Bui, D. T., Dounis, A., Lyu, Z. ve Foong, L. K. (2019). Predicting heating load in energy-efficient buildings through machine learning techniques. Applied Sciences, 9(20), 4338.
- Peker M., Özkaraca O. ve Kesimal B. (2017). Enerji tasarruflu bina tasarımı için ısıtma ve soğutma yüklerini regresyon tabanlı makine öğrenmesi algoritmaları ile modelleme. Bilişim Teknolojileri Dergisi, 10(4), 443-449.
- Roy, S. S., Samui, P., Nagtode, I., Jain, H., Shivaramakrishnan, V. ve Mohammadi-Ivatloo, B. (2020). Forecasting heating and cooling loads of buildings: A comparative performance analysis. Journal of Ambient Intelligence and Humanized Computing, 11(3), 1253-1264.
- Similä, T. ve Tikka, J. (2007). Input selection and shrinkage in multiresponse linear regression. Computational Statistics & Data Analysis, 52(1), 406-422.
- T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı (2019), URL: <https://cevreselgostergeler.csb.gov.tr/sectorleregore-toplam-enerji-tuketimi-i-85800>.
- Turhan C., Gökçen G. ve Kazanasmaz T. (2013). Yapay sinir ağı ile İzmir'deki çok katlı binaların toplam enerji tüketimlerinin tahmin edilmesi.

Research article/Araştırma makalesi
DOI:10.29132/ijpas.1166227

- University of California Machine Learning Repository (2012), URL: <https://archive.ics.uci.edu/ml/datasets/energy+efficiency>.
- Utku, A. ve Can, U. (2022). Machine Learning-Based A Comparative Analysis for Air Quality Prediction. 30th Signal Processing and Communications Applications Conference (SIU), 2022, pp. 1-4, doi: 10.1109/SIU55565.2022.9864701.
- Yöntem, S. T. (2016). Çevre Dostu Binalarda Enerji Verimliliği Örnek Uygulamalar. Binalarda Enerji Verimliliğinin Artırılması İçin Teknik Yardım Projesi, 1, 39.