

Atf İçin: Kayacı Çodur M, 2021. Ulaştırma Enerji Talebinin Yapay Sinir Ağları ile Modellenmesi. İğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 11(4): 2706-2715.

To Cite: Kayacı Çodur M, 2021. Transportation Energy Demand Modeling with Artificial Neural Networks. Journal of the Institute of Science and Technology, 11(4): 2706-2715.

Ulaştırma Enerji Talebinin Yapay Sinir Ağları ile Modellenmesi

Merve KAYACI ÇODUR^{1*}

ÖZET: Ülkelerin enerji talepleri teknolojinin gelişmesi, şehirleşme arzusu, sanayileşme ve sürekli nüfus artışına paralel olarak hızla değişmektedir. Türkiye'de son birkaç yılda ulaştırma sektöründe enerji kullanımı önemli derecede artış göstermiştir. Bu nedenle, enerji yönetimi ve tahmini, çevre güvenliği ve yaklaşan ekonomik refah için kritik önem taşımaktadır. Son yıllarda enerji taleplerinin belirlenmesi çalışmaları hız kazanmıştır. Bununla birlikte talep seviyelerini en doğru şekilde tahmin edebilmek için en uygun modelin seçilmesi gerekmektedir. Bu çalışmada, Yapay Sinir Ağları kullanılarak Türkiye'nin ulaştırma enerji talebini tahmin etmek için farklı modeller kurulmuştur. Yıl, nüfus, yakıt fiyatı, gayri safi yurt içi hasıla, ton-km, araç-km ve yolcu-km olarak belirlenen girdi parametreleri 1975 ve 2019 yılları arasındaki veriler dikkate alınarak seçilmiştir. Parametrelerin farklı kombinasyonlarının kullanıldığı modeller arasından en iyi model elde edilmeye çalışılmıştır. Yakıt fiyatı, nüfus ve ton-km verileri ile en iyi model kurulmuş olup bu modelin en düşük hata ve en yüksek R² değerlerine sahip olduğu sonucuna ulaşılmıştır.

Anahtar Kelimeler: Enerji Talebi, Modelleme, Ulaştırma Sektörü, Yapay Sinir Ağları

Transportation Energy Demand Modeling with Artificial Neural Networks

ABSTRACT: Energy demands of countries are changing rapidly in parallel with development, industrialization, urbanization, the spread of technology, prosperity, and population growth. Energy use in the transport sector in the last few years, Turkey has shown a significant increase. Therefore, energy management and predicting are critically important to environmental safety and the upcoming economic well-being. In recent years, studies to determine the energy demand have accelerated. In Addition, in order to estimate the demand levels in the most accurate way, the most appropriate model should be selected. In this study, different models for predicting Turkey's transport energy demand by using artificial neural networks have been established. Population, oil prices, gross domestic product, ton-km, vehicle-km, and passenger-km are selected as parameters by considering 1975 and 2016 data. The best model is tried to be obtained with the models in which different parameters are used together. The best model was established with the oil price, population, ton-km and it was determined that this model had the lowest error and highest R² values.

Keywords: Energy Demand, Modelling, Transportation Sector, Artificial Neural Network

¹Merve KAYACI ÇODUR ([Orcid ID: 0000-0003-1459-9678](https://orcid.org/0000-0003-1459-9678)), Erzurum Teknik Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Endüstri Mühendisliği Bölümü, Erzurum, Türkiye

*Sorumlu Yazar/Corresponding Author: Merve KAYACI ÇODUR, e-mail: merve.codur@erzurum.edu.tr

GİRİŞ

Tüm Dünyada enerji talebi çeşitli sosyal ve ekonomik gelişmeler nedeniyle gittikçe artmaktadır. Benzer şekilde, Türkiye'de artan nüfus, kentleşme ve sosyo-ekonomik gelişmeler, ülkenin birçok sektörü için enerji talebinde hızlı bir artışa neden olmaktadır. Ekonomik gelişmeler, ulusal ve uluslararası ürün taşıma faaliyetlerini hızlandırarak lojistik ve taşımacılık sektöründeki yoğunluğu artırmaktadır. Son yıllarda Türkiye ekonomisindeki gelişmelerle birlikte, nüfusun ve refahın artması ile insanların şahsi araçlara sahip olma ve seyahat etme eğilimlerinde kademeli olarak değişiklikler gözlemlenmektedir. Bunun yanında pandemi sürecinde şahsi araçlara sahip olma isteğinin artması otomobil sahipliğinde artışa neden olmaktadır. Tüm bu gelişmeler neticesinde ulaşım alanında artan yoğunluk, Ülkemizin ulaştırma enerjisi talebindeki artışı tetiklemiştir.

Türkiye, sınırlı enerji kaynakları ve giderek artan enerji ihtiyacı nedeniyle enerji ithalatına bağımlı bir ülkedir. Özellikle bu bağımlılık taşımacılık sektöründe daha da belirgindir. Doğal gaz ve petrol ülkenin enerji ithalatında önemli bir paya sahip olup bunların büyük bir kısmı yıllık olarak sırasıyla % 98 ve % 91 civarında ithal edilmektedir (Sönmez ve ark., 2017).

Enerji planlaması çalışmaları, hükümetlerin gelecekteki enerji ihtiyacını karşılayabilmesi için uygun stratejik planlar geliştirmesi ve doğru miktarda kaynak belirlemesi açısından ilk ve önemli aşamadır. Bu sayede enerji kaynakları daha verimli bir şekilde kullanılabilir. Türkiye'deki enerji ihtiyacının belirlenmesi Enerji ve Tabii Kaynaklar Bakanlığı (ETKB) aracılığıyla gerçekleştirilmiştir. Ayrıca, ülkede her beş yılda bir, yeni ismiyle Kalkınma Bakanlığı (KB) enerji sektöründen oluşan tüm sektörler için uzman kurumların desteğiyle bir iyileştirme stratejisi sunmaktadır. ETKB, Türkiye'de KB'nın sunduğu büyüme hedeflerine göre enerji talebi ve üretim tahminleri sunmaktadır. Enerji gereksinimi tahminleri sanayileşme, kalkınma, koruma, teknoloji ve kentleşme gibi çeşitli unsurlara bağlıdır. İstatistikler, her yıl bir önceki yıla göre performans ışığında değiştirilmektedir (Hepbasli ve ark., 2002; Hepbasli ve Ozalp, 2003; Anonim, 2020b).

Yolcu, yük taşımacılığı ve kişisel seyahat için enerjiyi korumak, ülke düzeyindeki planlamaya bağlı olarak sosyal kalkınmayı ve ekonomik durumu desteklemek için çok önemli bir sorundur. Her ulusun benzersiz öncelikleri ve enerji üretimi, kullanımı ve muhafazası için çeşitli ihtiyaçları vardır. Bu durum enerjiyle ilişkili planlamanın önemini artırır. Dünyada pek çok ülke ulaşım enerji talebini karşılamak amacıyla geleceğe yönelik tahminlerde bulunmak ve sağlıklı tahminler oluşturmak istemekte, bu yönde çalışmalarını sürdürmektedir. Enerji planlaması çalışmaları, geçmiş, günümüz ve gelecekteki enerji kullanımının bilinmesini gerektirir (Haldenbilen ve Ceylan, 2005).

Literatürde enerji talep tahmini için çeşitli modelleme teknikleri kullanılmış ve ulaştırma sektöründe enerji talebi modellemesini etkileyen çeşitli bağımsız parametreler ele alınmıştır. Bunlar genellikle Gayri Safi Yurt İçi Hasıla (GSYİH), nüfus, yıllık araç-km, gelir, araç sayısı, ithalat, ihracat gibi unsurlardır. Belirli unsurların büyüklüğü zaman zaman zor olup bu tür değişkenlerin enerji talebi modellemesi ve tahmini üzerindeki etkisi de benzer şekilde önemli olmayabilir. Çizelge 1' de son yıllarda ulaşım sektörüne özgü enerji talep tahmini ile ilgili yapılan çeşitli çalışmalara yer verilmiştir.

Literatürde yapılan çalışmalara bakıldığında tahmine dayalı modelleme tekniklerinden yapay sinir ağları, regresyon modelleri, bulanık mantık ve meta-sezgisel algoritmaların sık kullanılan yöntemler arasında olduğu görülmektedir. Yapılan çalışmalarda ele alınan yöntemler ile birlikte tahmin parametreleri de farklılık göstermekte olup nüfus, GSYİH, taşıt sayısı ve yol uzunluğu parametreleri tahmin modellerinin kurulmasında sıklıkla kullanılmaktadır. Ancak bahsi geçen çeşitli model parametrelerinin etkinliklerinin belirlenmesi ve birbirleriyle etkileşimlerinin tanımlanması karmaşık bir

hal almaktadır. Dahası, Türkiye'nin dinamik ekonomik yapısı ile değişkenlik gösteren yakıt fiyatı gibi nadir kullanılan parametrelerin etkisi de göz ardı edilemez hale gelmiştir.

Çizelge 1. Ulaşım Enerjisi Tahmini ile ilgili son yıllarda yapılan çalışmalar

Referans	Çalışma alanı/ Tahmin yılı	Kullanılan Yöntem	Girdiler (Bağımsız Değişkenler)
Dhakal (2003)	Nepal/2005-2020	Uzun Dönem Enerji Alternatifleri Planlama Sistemi	Araç sayısı, Araç-km, Yakıt Ekonomisi, Doluluk Oranı
Haldenbilen ve Ceylan (2005)	Türkiye/2001-2020	Genetik Algoritma	Nüfus, GSYİH, Araç-km
Haldenbilen (2006)	Türkiye/2004-2020	Lineer ve Polinomiyal Zaman Serileri, Genetik Algoritma	Yıl, GSYİH, Nüfus, Araç-km
Murat ve Ceylan (2006)	Türkiye/2002-2020	Yapay Sinir Ağları	GSYİH, Nüfus, Araç-km
Ceylan ve ark. (2008)	Türkiye/2006-2025	Meta-sezgisel Harmoni Arama Algoritması	Nüfus, GSYİH, Araç-km
Yan ve Crookes (2009)	Çin/2005-2030	Uzun Dönem Enerji Alternatifleri Planlama Sistemi	Araç sayısı, Yıllık Ortalama Günlük Trafik, Yakıt ekonomisi
Zhang ve ark. (2009)	Çin/2010-2020	Kısmi En Küçük Kareler Regresyonu	GSYİH, Kentleşme Oranı, Ulaşım ve Taşıma Sektörü Ciro
Shabbir ve Ahmad (2010)	Pakistan/2000-2030	Uzun Dönem Enerji Alternatifleri Planlama Sistemi	Araç Sayısı, Nüfus, Yol-km, Doluluk Seviyesi, Yolcu-km, Yakıt Verimliliği
Limanond ve ark. (2011)	Tayland/2010-2030	Log-lineer Regresyon Modeli ve İleri beslemeli Yapay Sinir Ağları	Nüfus, Kayıtlı Araç Sayısı, GSYİH
Geem (2011)	Güney Kore/2025	Çoklu Doğrusal Regresyon, Yapay Sinir Ağları	Nüfus, Petrol Fiyatı, Kayıtlı Araç Sayısı, Yolcu-km
Başkan ve ark. (2012)	Türkiye/2006-2025	Karınca Kolonisi Algoritması	Nüfus, GSYİH, Araç-km
Forouzanfar ve ark. (2012)	İran/2006-2021	Genetik Algoritma	Nüfus, Kayıtlı Araç Sayısı, GSYİH
Sönmez ve ark. (2017)	Türkiye/2014-2034	Yapay Arı Kolonisi Algoritması	Nüfus, GSYİH, Araç-km
Ceylan ve Bulkan (2018)	Türkiye/2017-2023	Hibrit ANFIS-Parçacık Sürü Optimizasyonu	Nüfus, GSYİH, Araç-km, Kayıtlı Araç Sayısı
Sahraei ve ark. (2021)	Türkiye/2020-2030	Çok Değişkenli Uyarlanabilir Regresyon Modeli	Yakıt Fiyatı, Ton-km

Bu çalışmanın amacı, Türkiye'nin ekonomik sistemini etkileyen en önemli etkenlerden biri olan ulaştırma enerji talebi ve yapısını belirlemek üzere uygun ulaştırma enerjisi talep modelleri geliştirmektir. Enerji talebini tahmin etmek için bağımsız değişkenlerin öngörülmesi çalışmanın ilk aşamasını oluşturmaktadır. Tahmin çalışmaları ile ilgili modellerde sıklıkla kullanılan YSA'nın başlıca avantajları hata toleransına sahip olması ve örneklerle öğrenebilmesidir. Bu çalışmada belirlenen çeşitli girdi parametreleri ile 11 farklı YSA modeli kurulmuştur. Modelleme sonrasında, bulunan en iyi model yapısı ile ulaşım enerjisi tahmin edilmiştir. Bu çalışmanın önemli özelliklerinden biri de yakıt fiyatlarını modele dâhil ederek bulunan modelin tahmin gücünün önceki çalışmalardan daha yüksek olduğunu göstermektedir.

MATERYAL VE METOT

Verilerin Toplanması


Çalışmada kullanılacak olan verilerin belirlenmesi için öncelikle literatür incelenmiştir. Daha sonra uzmanlardan alınan görüşler sayesinde daha önce kullanılmayan fakat etkisi olabileceği düşünülen veriler belirlenmiştir. Böylece aday değişkenler seçilmiş ve çeşitli devlet kurumlarından uygun

periyodik bilgiler toplanmıştır. Bu çalışmada kullanılan veriler Türkiye İstatistik Kurumu (TÜİK), Dünya Bankası (DB) ve Karayolları Genel Müdürlüğü'nden (KGM) temin edilmiştir (Anonim 2020a, Anonim 2020c, Anonim 2020d). Yolcu-Km (Bir yolcunun bir kilometre mesafeye taşınmasıyla elde edilen trafik ölçü birimi), Ton-Km (Bir ton yükün bir kilometre mesafeye taşınmasıyla elde edilen trafik ölçü birimi) ve Araç-Km (bir motorlu taşıtın bir kilometre boyunca hareket etmesi ile elde edilen trafik ölçü birimi) verileri KGM'den temin edilmiştir. GSYİH verisi (bir ülkenin belirli bir yıl için ürettiği toplam mal ve hizmetlerin ölçüsü) ve yakıt fiyatı (dünya çapında ve ulusal ekonomik performans açısından önemli göstergelerden biri) TÜİK'ten alınmıştır. Son olarak, ülke nüfusu için DB kaynakları kullanılmıştır. Çalışmada; bağımsız değişkenler yıl, nüfus, yakıt fiyatı, GSYİH, ton-km, araç-km ve yolcu-km olarak belirlenmiş olup 1975 ve 2019 yılları arasındaki veriler kullanılmıştır.

Yapay Sinir Ağları

Yapay sinir ağları, insan beyninin özelliklerini kazanmayı öğrenerek yeni bilgiler elde etmek ve yeni bilgiler öğrenmek için geliştirilen bilgisayar sistemleri olarak tanımlanabilir. YSA, insanların mikrobiyoloji bilimine meraklı olma ve bu konuda öğrenilen bilgileri bilgisayara aktarma arzusuyla başlamıştır. YSA'lar, verilerden uyarlamalı olarak örnekler çıkarabilen esnek doğrusal olmayan modeller sınıfıdır. YSA'nın uygulanabilir sayıda doğrusal olmayan veri grubuna izin veren, sinir ağlarının deneyimlerinden belirleyebildiği ve herhangi bir karmaşık işlevsel bağlantıyı tahmin edebildiği görülmektedir. Analitik olarak örnek gözlem ve tahminler için çeşitli fonksiyonlar kullanılmaktadır (Gonzalez ve Zamarreno, 2005). Ulaşım sektöründeki enerji talebini tahmin etmek için bu alanda birçok başarılı çalışma bulunmaktadır (Gonzalez ve Zamarreno, 2005; Kalogirou ve Bojic, 2000).

Birçok model farklı türlerde önerilse de, ulaşımda enerji talebiyle ilgili en popüler model ileri beslemeli ağ modeli türüdür. YSA modelinde, bağımsız değişkenler girdi olarak ve bağımlı değişkenler ise çıktı olarak adlandırılır. Girdi önem tablosu, her bir girdi sütununun kavramsal önemini gösterir. Giriş sütununun önemi, giriş kaldırıldıktan ve ağ tarafından kullanılmadıktan sonra ağ performansındaki bozulma olarak hesaplanır (Çodur ve Tortum, 2015). YSA'lar paralel olarak çalışan ve sinapslarla birbirine bağlanan çok sayıda düğüm içermektedirler. Bir sinir ağının en büyük avantajı, karmaşık doğrusal olmayan ilişkileri bir blok kutu gibi ilişkinin doğasına ilişkin ön varsayımlar olmaksızın modelleyebilme yeteneğidir (Murat ve Ceylan, 2006). YSA'lar, örüntü tanımlama, tanıma, konuşma, görme, kontrol sistemi ve sınıflandırma dâhil olmak üzere farklı uygulama alanlarındaki karmaşık problemleri çözmek için başarıyla uygulanmıştır. Bugün YSA'lar, geleneksel bilgisayarlar veya insanlar için zor olan problemleri çözmek üzere eğitilebilir. Diğer bir deyişle YSA'lar, istenen bilgiyi doğrudan veriden çıkararak geleneksel yaklaşımın sınırlamalarını başarılı bir şekilde aşmaktadır. Bir sinir ağının temel işlem ögesi nörondur. Temel olarak, bir biyolojik nöron diğer kaynaklardan girdi alır, bunları bir şekilde birleştirir, sonuç üzerinde genellikle doğrusal olmayan bir işlem gerçekleştirir ve ardından son sonucu çıkarır.



Şekil 1. Yapay Sinir Ağ Yapısı Örneği

Şekil 1 genel olarak kullanılan tipik bir yapay sinir ağı modelini göstermektedir. En temel yapay sinir ağı girdi, gizli katman, çıktı, ağırlıklar, birleştirme fonksiyonu ve aktivasyon fonksiyonu olmak üzere 6 ana bileşenden oluşmaktadır. Giriş düğümleri (x_1, x_2, \dots, x_n) bağımsız parametrelerden oluşmakta, çıkış noktasında ise bağımlı değişken (y) yer almaktadır. Giriş düğümleri tarafından elde edilen bilgileri işlemek için uygun doğrusal olmayan transfer fonksiyonlarına sahip gizli kutular kullanılmaktadır. Bu çalışmada, her bir girdi o girdiyi işlem elemanına bağlayan ağırlık değeriyle (w_{ij}) çarpılarak, Eşitlik 1'de verilen toplama fonksiyonu aracılığıyla birleştirilmiştir.

$$n_j = \sum_i x_i w_{ij} + b_j \quad (1)$$


Bu bağlamda, j . inci nörona gelen net girdi hesaplanır. Burada her girdi kendi ağırlığı ile çarpılarak toplanır. Böylece ağa gelen net girdi j . nörona ait eşik değerinin eklenmesiyle bulunmuş olur. Hücreye gelen net girdiyi işleyerek hücrenin bu girdiye karşı üreteceği çıktı ise aktivasyon fonksiyonu ile belirlenir. Bu çalışmada, YSA'da çok katmanlı algılayıcı modelinde yaygın olarak kullanılan ve yapılan denemeler sonucunda en iyi sonucu veren Sigmoid Aktivasyon Fonksiyonu kullanılmıştır.

Yapay Sinir Ağları ile Modelleme

Yapay Sinir Ağı modelinde kullanılacak olan girdi ve çıktı verileri öncelikle bir minimaks algoritması kullanılarak 0-1 aralığında normalize edilmiştir. Daha sonra tasarım kısmına geçildiğinde en iyi ağ yapısına sahip modeller belirlenmiştir. Eğitim aşaması YSA'nın en önemli aşamalarından biridir. Model verilerinin %70'i eğitim, %15'i doğrulama ve %15'i test verisi olarak kullanılmıştır. Ayrıca eğitim algoritması olarak Levenberg-Marquardt kullanılmıştır.

$$Y = f_2 \left\{ [W_2] f_1 \left[[W_1] \begin{bmatrix} GSYİH \\ Nüfus \\ Yıllar \\ Araç - km \\ Ton - km \\ Yolcu - km \\ Yakıt Fiyatı \end{bmatrix} + [b_1] \right] + [b_2] \right\} \quad (2)$$

Eşitlik (2)'de; Y ulaştırma enerjisini, W_1 ve W_2 ağırlık matrislerini, b_1 ve b_2 eşik değer vektörlerini göstermektedir. Geri yayılım eğitim algoritmasının etkinliği, gizli katmandaki nöronların sayısına bağlı olduğundan; gizli katmandaki çeşitli sayıda nöronlu (1'den 29'a kadar) modeller test edilmiştir. Şekil 2, bu çalışmada kullanılan örnek bir YSA model yapısını göstermektedir.



Şekil 2. Ulaştırma enerjisinin tahmininde kullanılan parametrelere ait örnek YSA yapısı

Şekil 2' de görüldüğü gibi, girdi değişkenleri bağımsız değişkenlerdir ve ulaştırma enerjisinin tahmininde etkili olduğu daha önce yapılan farklı çalışmalardan belirlenen verilerdir. Çıktı kısmında yer alan ulaştırma enerjisi ise bağımlı değişken olarak modelleme sonucunda elde edilecek veridir.

BULGULAR VE TARTIŞMA

Bu bölümde ulaştırma enerjisini tahmin etmek için 11 farklı YSA modeli oluşturulmuş ve gerçek değerlere en yakın olan model, gelecekteki ulaşım sektöründeki enerji talebini tahmin etmek için kullanılmıştır. Modellerde kullanılan verilere ve geliştirilen model yapılarına ilişkin genel bilgiler Çizelge 2'de verilmiştir. Model çözümünde Alyuda Neuro Intelligence paket programı, Intel i7 3.40 GHz işlemci 8 GB belleğe sahip bilgisayar kullanılarak sonuçlar elde edilmiştir.

Çizelge 2. Ulaştırma Enerjisinin tahmininde kullanılan farklı girdilere sahip modeller ve yapıları

Modeller	Kullanılan değişkenler	Model Yapıları	Çıktı
Model 1	Yıl, GSYİH, Nüfus, Ton-km, Taşıt-km, Yolcu-km, Yakıt Fiyatı	7x4x1	Ulaştırma Enerjisi
Model 2	Yıl, GSYİH, Nüfus	3x6x1	
Model 3	GSYİH, Nüfus, Ton-km	3x8x1	
Model 4	Nüfus, Yakıt Fiyatı, Ton-km	3x6x1	
Model 5	Nüfus, Yakıt Fiyatı, Araç-km	3x4x1	
Model 6	Nüfus, Yakıt Fiyatı, Yolcu-km	3x8x1	
Model 7	GSYİH, Nüfus, Araç-km	3x7x1	
Model 8	GSYİH, Nüfus, Yolcu-km	3x6x1	
Model 9	GSYİH, Yakıt Fiyatı, Ton-km	3x3x1	
Model 10	GSYİH, Yakıt Fiyatı, Araç-km	3x5x1	
Model 11	GSYİH, Yakıt Fiyatı, Yolcu-km	3x7x1	

Türkiye'nin ulaştırma sektöründeki enerji talebi YSA modelleri kullanılarak tahmin edilmiştir. Modellerin hataları Mutlak Hata (MH), Mutlak Bağlı Hata (MBH) ve belirleme katsayısı (R^2) terimleri ile belirlenmiştir. MH, sinir ağının eğitiminin "kalitesini" gösteren bir hata değeridir. Sinir ağının hedef çıktı değerleriyle (E_{obs}) mevcut çıktı değerlerinin (E_{pre}) farkının mutlak değerinin alınmasıyla hesaplanmaktadır. Ağ hatası ne kadar küçükse, ağ o kadar iyi eğitilmiştir. MBH, gerçek ve tahmin edilen çıktı değerleri arasındaki farkın seçilen çıktı sayısına bölünmesiyle hesaplanır. Belirleme katsayısı, bağımsız değişkenlerin açıklama oranını göstermektedir. Bir diğer ifade ile bağımlı değişkenin bağımsız değişkenler tarafından açıklanan varyans oranını temsil etmektedir. Kurulan modellerin başarısı Eşitlik (3)-(5)'te verilen çeşitli istatistiksel hata yöntemleri ile analiz edilmiş ve sonuçlar Çizelge 3'te verilmiştir. Ele alınan istatistiksel ölçütler eğitim, doğrulama ve test aşamasında bulunan değerlerin genelini kapsamaktadır.

$$MH = |E_{obs} - E_{pre}| \quad (3)$$

$$MBH = \frac{1}{n} \sum_{i=1}^n MH \quad (4)$$

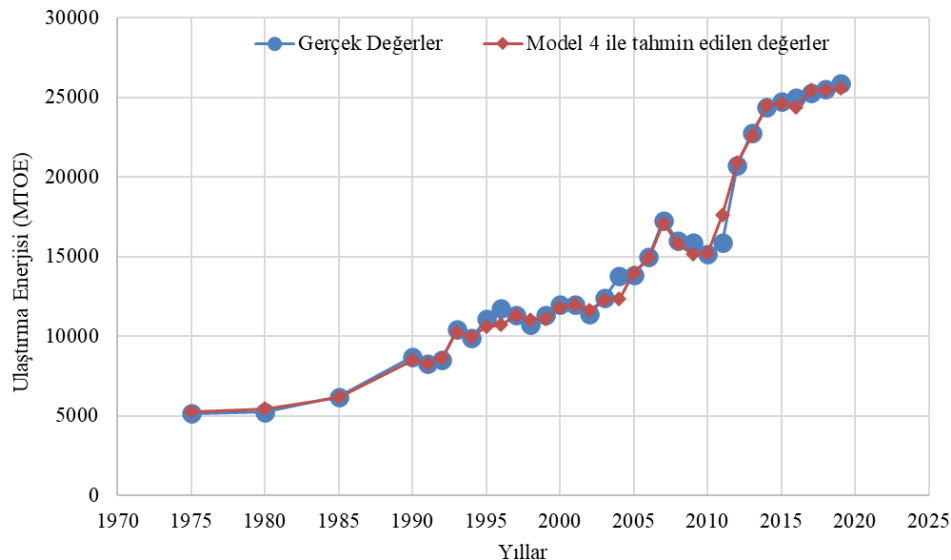
$$R^2 = 1 - \frac{\sum_{i=1}^n MH^2}{\sum_{i=1}^n (E_{obs} - E_{obs})^2} \quad (5)$$

MH ve MBH'nin model başarısı için 0'a yakın değerler alması istenmektedir. Çizelge 3'ten görüldüğü gibi MH ve MBH hata değerlerinin en küçük R^2 değerinin ise en büyük olduğu nüfus, yakıt fiyatı ve ton-km girdilerine sahip 4. model en başarılı tahmin modeli olarak görülmektedir. Bu durum, bu modelin tahmin çalışması açısından güvenilirliğini pekiştirmektedir.

Çizelge 3. Kurulan farklı modellere ait R^2 ve hata değerleri

	Model 1	Model 2	Model 3	Model 4	Model 5	Model 6	Model 7
R^2	0,994879	0,959021	0,98961	0,995294	0,992579	0,984661	0,992418
MH	276,016	898,251	285,501	246,571	454,039	463,404	435,021
MBH	0,025	0,076	0,021	0,020	0,035	0,037	0,035
	Model 8	Model 9	Model 10	Model 11			
R^2	0,99194	0,989353	0,995146	0,926793			
MH	452,089	477,833	302,753	1306,72			
MBH	0,038	0,040	0,025	0,100			


Türkiye'nin ulaştırma enerji talebinin yıllara göre dağılımı ve en iyi olarak belirlenen Model 4'ün tahmin ettiği değerler Şekil 3'te verilmiştir.



Şekil 3. Türkiye'nin ulaştırma enerjisinin gerçek ve model 4 ile tahmin edilen değerlerinin grafiği

Ulaştırma Enerjisinin Tahmini

Türkiye'nin ulaştırma enerjisini doğru bir şekilde tahmin etmek için, öncelikle en iyi modeli en etkili parametrelerle kurmak gerekir. Bu nedenle çalışma içerisinde 11 adet farklı model kurulmuş ve hata terimlerinin en düşük R^2 değerinin en büyük olduğu Model 4 seçilmiştir. Geleceğe yönelik tahminde dördüncü model kullanılmış ve ileriye yönelik belirli yıllarda elde edilen veriler Şekil 4'te verilmiştir.



Şekil 4. Türkiye'nin ulaştırma enerjisinin Model 4 ile tahmini

Şekil 4'te verilen grafik modeller arasında en iyi seçilen model 4 kullanılarak çizilmiştir. Grafik; Model 4'e ait nüfus, yakıt fiyatı ve ton-km değerlerine dayalı olarak 2020'den 2030'a kadar tahmin edilen ulaştırma enerjisi talep büyüklüklerini göstermektedir. Buna göre enerji talebi 2020 yılında 26000 mtoe civarında olacağı tahmin edilmektedir. Görüldüğü gibi, söz konusu talebin 29200 mtoe değerine ulaştığı 2030 yılına kadar bu eğilim giderek artmaktadır.

Model 4 ile bulunan sonuçlar literatürde bulunan farklı yöntemler ile elde edilen tahmin çalışmaları ile doğrulanmaktadır. Örneğin Sönmez ve arkadaşlarının çalışmasında kullandıkları senaryo 1'de eksponansiyel model, senaryo 2'de ise lineer ve eksponansiyel modeller kullanılarak hesaplanmış değerlerle uyum içerisinde olduğu görülmektedir (Sönmez ve ark., 2017). Başkan ve arkadaşlarının yaptığı çalışmada ise gelecek tahmini için kullanılan quadratic model sonuçları bu çalışmanın sonuçlarına yakındır (Başkan ve ark., 2012). Ceylan ve arkadaşlarının HASTADE modeli kullanarak elde ettikleri projeksiyon verileri ile kurdukları lineer ve eksponansiyel modellerin çıktıkları yine çalışmamızdakine yakındır. Görüldüğü gibi yapılan bu çalışmayla kurulan 4. Model literatürde yayımlanmış çalışmalarla kurulan modelleri destekler nitelikte olup bu modelin başarısı bir kere daha ortaya konulmuştur.

SONUÇ

Türkiye'de özellikle son yıllarda sanayileşme alanında gerçekleşen ciddi atılımlar ile birlikte gelen kentleşme girişimleri neticesinde enerji talebinde artış meydana gelmiştir. Türkiye, birincil enerji kaynakları açısından büyük ölçüde dışa bağımlıdır. Türkiye'nin toplam enerji harcamalarının yaklaşık %25'ini ulaşım sektörü oluşturmaktadır. Son yıllarda gerçekleşen nüfus artışı ve ekonomik büyüme ülkenin ulaştırma enerjisi talebinde de artışa neden olmuştur. Dolayısıyla, ulaştırma sistemlerinin daha etkin bir şekilde tasarlanması, planlanması ve kullanılması için gelecekteki enerji talebinin güvenilir ve gerçekçi bir şekilde belirlenmesi gerekmektedir. Ancak tahmin verilerinin yol gösterici nitelikte olması için modelin doğru kurulması kritik öneme sahiptir.

Kurulan modeller arasında nüfus, yakıt fiyatı ve ton-km parametrelerine sahip olan Model 4, en yüksek belirleme katsayısına (R^2) ve düşük hata terimlerine sahip, en iyi performansı gösteren model olarak belirlenmiştir. Çalışmanın sonraki aşamasında seçilen Model 4 kullanılarak ileriye yönelik Türkiye'nin ulaştırma enerji talebi tahmin edilmiştir.

Bu çalışmanın özellikle Türkiye gibi enerjisinin büyük kısmını dışarıdan ithal eden ülkeler için faydalı olması öngörülmektedir. Enerji kullanımı için gerçekçi planlar yapmanın yanı sıra; bu çalışma, güneş enerjisi kullanan dünyadaki diğer ülkeler için kaynakların doğru kullanımına katkı sağlayacaktır. Öte yandan, enerji talebine yönelik uygun modelleme çalışmaları, hükümetleri stratejik planlar yapmaya ve enerji kaynaklarının kullanımını daha etkin hale getirmeye yönlendirebilir.

Daha sonra yapılacak çalışmalar için farklı modelleme teknikleri kullanılabilir. Ayrıca YSA'nın farklı tahminleme modelleri ile birlikte çalıştığı hibrit modeller ile daha iyi sonuçlar elde edilebilir.

Çıkar Çatışması

Makalenin planlanması, yürütülmesi ve yazılması sırasında herhangi bir çıkar çatışması olmadığını beyan ederim.

Yazar Katkısı

Tüm çalışmanın makalenin tek yazarı olarak tarafımdan yapıldığını beyan ederim.

KAYNAKLAR

- Anonim, 2020a. Dünya Bankası Açık Erişim Veri Merkezi (<https://data.worldbank.org/country/turkey?locale=tr>).
- Anonim, 2020b. Dünya Enerji Birliği, Türk Milli Komitesi, Ankara.
- Anonim, 2020c. Türkiye Karayolları Genel Müdürlüğü, Ankara.
- Anonim, 2020d. Türkiye İstatistik Kurumu, Ankara.
- Başkan O, Haldenbilen S, Ceylan H, Ceylan H, 2012. Estimating transport energy demand using ant colony optimization. *Energy Sources, Part B: Economics, Planning and Policy*, 7(2): 188–199.
- Ceylan H, Ceylan H, Haldenbilen S, Baskan O, 2008. Transport energy modeling with meta-heuristic harmony search algorithm, an application to Turkey. *Energy Policy*, 36: 2527–2535.
- Ceylan Z, Bulkan S, 2018. Türkiye ulaşım kaynaklı enerji ihtiyacının hibrit ANFIS-PSO metodu ile tahmini. *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 18: 740-750.
- Çodur MY, Tortum A, 2015. An artificial neural network model for highway accident prediction: a case study of Erzurum, Turkey. *Promet–Traffic&Transportation*, 27(3): 217-225.
- Dhakal S, 2003. Implications of transportation policies on energy and environment in Kathmandu Valley, Nepal. *Energy Policy*, 31(14): 1493–1507.
- Forouzanfar M, Doustmohammadi A, Hasanzadeh S, Shakouri GH, 2012. Transport energy demand forecast using multi-level genetic programming. *Appl Energy*, 91(1): 496–503.
- Geem WZ, 2011. Transport Energy Demand Modeling of South Korea Using Artificial Neural Network. *Energy Policy*, 39(8): 4644-4650.
- Gonzalez PA, Zamarreno JM, 2005. Prediction of hourly energy consumption in buildings based on a feedback artificial neural network. *Energy and Buildings*, 37(6): 595-601.
- Haldenbilen S, Ceylan H, 2005. Genetic algorithm approach to estimate transport energy demand in Turkey. *Energy Policy*, 33(1): 89-98.
- Haldenbilen S, 2006. Fuel price determination in transportation sector using predicted energy and transport demand. *Energy Policy*, 34(17): 3078–3086.

- Hepbasli A, Oturanc G, Kurnaz A, Ergin E, Genc A, Iyit N, 2002. Simple correlations for estimating the energy production of Turkey. *Energy Sources*, 24(9): 855-867.
- Hepbasli A, Ozalp N, 2003. Development of energy efficiency and management implementation in the Turkish industrial sector. *Energy Convers Manag*, 44(2): 231-249.
- Kalogirou S, Bojic M, 2000. Artificial neural networks for the prediction of the energy consumption of a passive solar building. *Energy*, 25(5): 479–491.
- Limanond T, Jomnonkwao S, Srikaew A, 2011. Projection of future transport energy demand of Thailand, *Energy Policy*, 39(5): 2754-2763.
- Murat ŞY, Ceylan H, 2006. Use of artificial neural networks for transport energy demand modeling. *Energy Policy*, 34: 3165-3172.
- Sahraei MA, Duman H, Çodur MY, Eyduran E, 2021. Prediction of transportation energy demand: Multivariate Adaptive Regression Splines. *Energy*, 224.
- Shabbir R, Ahmad SS, 2010. Monitoring urban transport air pollution and energy demand in Rawalpindi and Islamabad using leap model. *Energy*, 35(5): 2323–2332.
- Sönmez M, Akgüngör AP, Bektaş S, 2017. Estimating transportation energy demand in Turkey using the artificial bee colony algorithm. *Energy*, 122: 301–310.
- Yan X, Crookes RJ, 2009. Reduction potentials of energy demand and GHG emissions in China's road transport sector. *Energy Policy*, 37(2): 658–668.
- Zhang M, Mu H, Li G, Ning Y, 2009. Forecasting the transport energy demand based on PLSR method in China. *Energy*, 34(9): 1396–1400.