



TÜRKİYE'DEKİ DEMİRYOLU ENERJİ TÜKETİMİNİN YAPAY SİNİR AĞLARI İLE TAHMİN EDİLMESİ

¹Emre KUŞKAPAN , ²Merve Kayacı ÇODUR , ³Muhammed Yasin ÇODUR 

^{1,3}Erzurum Teknik Üniversitesi, Mühendislik ve Mimarlık Fakültesi, İnşaat Mühendisliği Bölümü, Erzurum, TÜRKİYE

²Erzurum Teknik Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Endüstri Mühendisliği Bölümü, Erzurum, TÜRKİYE

³College of Engineering and Technology, American University of the Middle East, KUWAIT

¹emre.kuskapan@erzurum.edu.tr, ²merve.codur@erzurum.edu.tr, ³Muhammed.Codur@aum.edu.kw

(Geliş/Received: 10.05.2021; Kabul/Accepted in Revised Form: 31.12.2021)

ÖZ: Dünya genelinde hızla tükenen enerji kaynaklarını korumaya yönelik birtakım tedbirler alınmaktadır. Özellikle ulaşım araçlarında enerji verimliliğinin artırılması amacıyla sürdürülebilir enerji kaynaklarına yönelim giderek artmaktadır. Yapılan bu çalışmada ülkemizdeki demiryolu taşıtlarının son 43 yıldaki hat uzunluğu, yolcu sayısı ve yük miktarı değerleri esas alınarak toplam enerji tüketim miktarları incelenmiştir. Yapay sinir ağları yöntemi ile oluşturulan 5 farklı model için tükenen enerji miktarı ile tahmin edilen enerji miktarları korelasyon katsayıları, R^2 , mutlak hata ve mutlak bağıl hata ölçütleri Levenberg-Marquardt ve Conjugate Gradient Descent algoritmaları kullanılarak karşılaştırılmıştır. Girdi olarak yolcu sayısı ve yük miktarı alınan 3 numaralı modelin doğruluk değerleri ve hata ölçütleri daha iyi çıkmıştır. Çalışmada elde edilen sonuçlara göre enerji tüketim miktarının en çok yük miktarı daha sonra ise yolcu sayısı ile ilişkisi olduğu hat uzunluğu ve yıllardaki değişimin daha az etkili olduğu ortaya konmuştur. Bu çalışmada elde edilen veriler ile gelecek dönemlerdeki demiryollarında taşınması planlanan yolcu sayısı ve yük miktarı kullanılarak harcanabilecek enerji miktarı tespit edilebilecektir. Tespit edilen enerji miktarı sayesinde sürdürülebilir enerji kaynaklarına yönelim yapılarak önemli miktarda tasarruf sağlanabilecektir.

Anahtar Kelimeler: Enerji tüketimi, Demiryolu ulaştırması, Yapay sinir ağları

Prediction of Railway Energy Consumption in Turkey Using Artificial Neural Networks

ABSTRACT: A number of measures are being taken to protect the rapidly depleted energy resources around the world. The trend towards sustainable energy resources is increasing, especially in order to improve energy efficiency in transportation vehicles. In this study, the total energy consumption amounts of the railway vehicles were examined based on the line length, number of passengers and the amount of cargo in the last 43 years in our country. For 5 different models created by the artificial neural networks method, the amount of consumed energy and estimated energy amounts were compared using the correlation coefficients, R^2 , absolute error and absolute relative error criteria using Levenberg-Marquardt and Conjugate Gradient Descent algorithms. In the model 3, where the number of passengers and the amount of cargo were used as inputs, accuracy values and error criteria were better. According to the results obtained in the study, it was revealed that the amount of energy consumption is mostly related to the amount of load and then the number of passengers, and the change in line length and years is less effective. With the data obtained in this study, it will be possible to determine the amount of energy that can be spent by using the number of passengers planned to be transported on the railways in the future

periods and the amount of cargo. Thanks to the determined amount of energy, a significant amount of savings can be achieved by focusing on sustainable energy resources.

Keywords: *Energy consumption, Rail transport, Artificial neural networks*

GİRİŞ (INTRODUCTION)

Demiryolu taşımacılığı çevreye duyarlı ve diğer ulaşım türlerine göre daha güvenilir bir ulaşım türüdür. Osmanlı Devleti'nin son dönemlerinde ve Türkiye Cumhuriyeti'nin ilanından itibaren 1950'li yıllara kadar demiryolu taşımacılığına ciddi ölçüde önem vermiştir. Fakat 1948 yılından itibaren devlet, ulaşım politikasında ABD'nin de yönlendirmesi ile kara yollarının inşasına ağırlık vermiştir. Cumhuriyetin ilk yıllarında yolcu taşımacılığının %42'si demiryolu ile sağlanmakta iken, günümüzde bu oran %2'lere düşmüştür. Benzer şekilde cumhuriyetin ilk yıllarında yük taşımacılığının %68'i demiryolu ile sağlanmakta iken bu oran günümüzde %5'lere kadar düşmüştür. Bu durum karayolu taşıtlarının temin edilmesi ve bu taşıtların enerji ihtiyacının karşılanabilmesi sebebiyle dışa bağımlılığı artırmıştır.

Herhangi iki nokta arasında ulaşım sağlanırken çeşitli faktörlere bağlı olarak birden fazla ulaşım seçeneği oluşabilmektedir. Örneğin uzun mesafelerde ulaşım süresi daha önemli ise havayolu ulaşımı tercih edilebilmektedir. Fakat kıtalar arası yolculuklarda maliyet daha önemli ise denizyolu ulaşımı önemli bir seçenek olarak ortaya çıkmaktadır. Orta mesafeli ulaşımlarda ise karayolu veya demiryolu tercih edilebilmektedir. Fakat demiryolu taşımacılığı karayolu taşımacılığına göre enerji tüketimi açısından oldukça avantajlıdır (Cansız ve Ünsalan, 2019; Solak, 2013). Bununla birlikte gelişen teknoloji ile birlikte uzun mesafelerde havayoluna alternatif olabilecek yüksek hızlı trenler de kullanılmaya başlanmıştır. Trenlerin hızı arttığı için enerji tüketimleri de artmış olsa da havayoluna göre ekonomik olarak daha uygun maliyetlidir. Tüm bu durumlar demiryolu taşımacılığını ön plana çıkarmaktadır.

Demiryolu ulaşımının daha iyi planlanabilmesi için geleceğe yönelik bazı tahminler yapılması önemlidir. Bu tahminler; yatırımların belirlenmesi, ortaya çıkacak maliyetlerin öngörülmesi ve enerji politikalarına yön verilmesini sağlamaktadır. Özellikle enerji tüketimi konusunda yapılacak olan tahminler doğrultusunda kullanılan enerji türünün değiştirilmesi, yerli veya sürdürülebilir enerji kaynaklarına yönelimi artırabilmektedir. Bununla birlikte enerji tüketiminin çeşitli modeller kurularak veya analiz yöntemleri ile incelenerek enerji tüketimin tahmini veya optimizasyonu sağlanabilmektedir (Arıkan ve diğ., 2020; Acampora ve diğ., 2006; Gonzalez-Gil ve diğ., 2014; Liu ve Golovitcher, 2003).

Literatürde demiryolu sistemlerinin enerji tüketimlerini inceleyen çeşitli çalışmalar mevcuttur. Jong ve Chang (2005) Taiwan'da bulunan elektrikli trenlerin yakıt tüketiminin tahmin edilmesi amacıyla simülasyon modeli kurmuşlardır. Bu tahmin modelinde tren dinamikleri kullanılmıştır. Model sonucunda tren yükleri, yolcu sayısı, tren hızı ve çekiş gücü gibi faktörleri içeren bir optimizasyon problemi elde edilmiştir. Wang ve diğerleri (2014) Çin'de ulaşım sektörü için harcanan enerjiyi ulaşım türlerine göre ele almışlardır. Mevcut durum incelenerek 2030 yılı için harcanacak olan enerji tüketimini tahmin etmişlerdir. Zhao ve diğerleri (2017) ise demiryolu taşıtlarında enerji tüketimini en aza indirmek amacıyla tren yörüngesi ve zaman çizelgesini barındıran bir optimizasyon algoritması geliştirmişlerdir. Elde edilen sonuçlarda optimizasyon işleminin enerji tüketimini önemli ölçüde azaltılabileceği ortaya konmuştur. Bai ve diğ., (2014) Çin demiryolu hatlarında meydana gelen enerji tüketiminin tahmin edilebilmesi için bulanık tahmine dayalı bir kontrol yaklaşımı gerçekleştirmişlerdir. Yapılan analiz sonucunda demiryolu taşıtlarının istasyonlardaki çalışma süresinin azaltılarak ciddi düzeyde enerji tasarrufu sağlanacağı belirtilmiştir. Coiret ve diğ., (2017) demiryolu taşıtlarının yokuş yukarı veya aşağı yönde hareketlerinin olması durumunda oluşacak enerji tüketim farklılıklarını sayısal modellerle incelemişlerdir. Zhang ve diğerleri (2019) Çin'de yer alan Pekin ve Şangay kentleri arasındaki demiryolu hattındaki enerji tüketimini incelemişlerdir. Enerji tüketiminin azaltılabilmesi için zaman çizelgesi ile ilişkili bir optimizasyon algoritması kurmuşlardır. Çalışma sonucunda ise optimizasyon işleminin uygulanması durumunda enerji tüketiminin ciddi oranda azaltılabileceği tahmin edilmiştir. Sakin (2019) yapay sinir ağları, çok değişkenli lineer regresyon ve logaritmik regresyon yöntemlerini kullanarak

demiryollarında enerji tüketim tahminini yapmıştır. Hata değerleri ve korelasyon katsayısı açısından yapay sinir ağlarının diğer yöntemlere göre daha iyi sonuçlar verdiği tespit edilmiştir. Ren ve diğ., (2020) demiryollarında harcanan enerji miktarını veri madenciliği yöntemleriyle analiz etmişlerdir. Analiz sonuçları ile gerçek değerlerin birbiri ile uyumlu olduğu ortaya konmuştur. Buna göre istatistiksel analize dayalı değişkenlerin enerji tüketiminin incelenmesinde doğru şekilde uyarlanabileceği yorumu yapılmıştır.

Yapılan bu çalışmada ise ülkemizdeki demiryolu enerji tüketiminin yıllara göre değişimi incelenmiştir. Mevcut çalışmalar genellikle tek tren için veya birkaç yılı kapsayacak şekilde farklı koşullarda meydana gelen enerji tüketimini ele alırken bu çalışma uzun yıllara ait verileri ve tüm demiryolu hattındaki enerji tüketimini ele almıştır. 1977-2019 yılları arasında demiryolu hat uzunluğu, yıllık yolcu sayısı, yük miktarı ve toplam enerji tüketim verileri kullanılarak harcanan enerji miktarı tahmin edilmiştir. Bu girdiler enerji tüketiminde en etkili faktörler olarak düşünüldüğü için 1977'den beri her yıl kayıt altına alınmıştır. Tahmin işleminde yapay sinir ağları yöntemi kullanılmıştır. Bu yöntemin tercih edilmesindeki amaç; geleneksel yöntemlere kıyasla daha doğru sonuçlar ortaya koymasıdır. Enerji tüketiminin tahmin edilmesi ülkemizin enerji politikalarını yönlendirmesi adına önemlidir. Bu sayede enerji tüketim miktarı esas alınarak enerji kaynağı türleri arasında değişiklikler yapılabilir ve böylece yerli ve sürdürülebilir kaynaklara yönelim artabilir. Bu açıdan çalışmanın içeriğinin politika uygulayıcılara bir yön gösterici olacağı düşünülmektedir.

MATERYAL ve YÖNTEM (MATERIAL and METHOD)

Çalışma alanı (Study area)

Çalışmada Türkiye'deki demiryolu hatları ve bu hatlara ait yolcu, yük ve enerji verileri kullanılmıştır. Ülkemizdeki demiryolu taşımacılığını düzenleyen, işleten ve kontrol eden resmi kurum Türkiye Cumhuriyeti Devlet Demiryolları (TCDD)'dir. TCDD 2020 yılı itibarıyla 11590 km konvansiyonel hat ve 1213 km yüksek hızlı hat olmak üzere toplam 12803 km ulusal demiryolu ağı üzerinde işletmecilik yapmaktadır. Bu hatlar üzerinde son bir yılda yaklaşık 246 bin yolcu taşınmıştır. Yine bu hatlar üzerinde son bir yılda yaklaşık 34 bin ton yük taşınmıştır. Konvansiyonel hatların yaklaşık %39'u, yüksek hızlı demiryolu hatlarının ise tamamı elektrikli (TCDD, 2021). Aşağıda Şekil 1'de Türkiye'ye ait demiryolları ağı ve hatların özelliklerini içeren harita yer almaktadır.



Şekil 1. Türkiye Demiryolları haritası.

Figure 1. Railways map of Turkey.

Demiryolu ulaşım ağlarına yapılan yatırımların artırılması ve hizmet kalitesinin yükselmesi ile son yıllarda demiryolunu tercih eden kişi sayısında ciddi artış olmuştur. Benzer şekilde yük taşımacılığında demiryoluna talep zaman zaman dalgalanmalar yaşasa da genel olarak artış eğilimindedir. Demiryolu ulaşımına talepteki bu artış, TCDD yetkililerini hat sayısının artırılmasına ve yol ağlarının genişletilmesine yönlendirmektedir. Bu kapsamda da demiryolu ulaşımına yapılan yatırımların artırılması sağlanmaktadır. Demiryolu ulaşımındaki bu hareketlilikler enerji tüketiminin de artmasına sebep olmaktadır. Enerjinin daha verimli kullanılabilmesi ve yatırımların daha etkili şekilde yapılabilmesi için enerji tüketim değerlerinin iyi şekilde incelenmesi gereklidir. Ülkemizde enerji tüketiminin %19.8'i ulaştırma sektörüne aittir. Demiryollarında yolcu taşımacılığında, 1 yolcu için kilometre başına ortalama 101 kcal enerji tüketilmektedir. Yük taşımacılığında ise 1 ton yük için kilometre başına ise ortalama 320 kcal enerji harcanmaktadır. Demiryolu karayoluna göre yaklaşık 4 kat, havayoluna göre 20 kat daha az enerji tüketmektedir (ÇŞB, 2021).

Yapay sinir ağları (Artificial neural networks)


Yapay sinir ağları, insan beyninin ağ yapısını, hatırlama ve öğrenme özelliklerini örnek olarak oluşturulan matematiksel modellerin kullanıldığı bilgisayar sistemleridir. Yapay zekâ teknolojisinin her geçen gün daha fazla gelişmesi ve kullanımının artması yapay sinir ağlarının uygulama alanlarını da geliştirmiştir. Özellikle var olan veriler kullanılarak görülmemiş çıktılar için bilgi üretebilme özelliği sayesinde analiz, sınıflandırma, tahmin, tanıma, yorumlama ve ilişkilendirme gibi konularda oldukça kullanışlıdır (Çodur ve Tortum, 2009; Erdoğan ve Kaya, 2020).

İnsan sinir hücresinin çalışma prensibi ile çalışan bir yapay sinir ağı hücresi; girdiler ($x_1, x_2, x_3, \dots, x_n$), ağırlıklar ($w_1, w_2, w_3, \dots, w_n$), birleştirme fonksiyonu, aktivasyon fonksiyonu ve çıktı (y) olmak üzere beş temel bileşenden oluşur (Haykin 1999). Şekil 2'de yapay bir sinir hücresinin elemanları verilmiştir. Girdiler yapay sinir hücresine dış ortamdan gelen bilgileri gösterirken ağırlıklar ise gelen bilginin etkisini ve önemini göstermektedir. Dış ortamdan alınan girdiler ağırlıkları ile hücreye bağlanarak net girdi değeri hesaplanır. Net girdi değerinin hesaplanmasında çeşitli metodlar vardır. Bu çalışmada; her bir girdi, o girdiyi işlem elemanına bağlayan ağırlık değeriyle (w_{ij}) çarpılarak, Eşitlik 1'de verilen toplama fonksiyonu aracılığıyla birleştirilmiştir.

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

Hücreye gelen net girdi değeri aktivasyon fonksiyonunda işlenerek hücrenin bu girdiye karşı üreteceği çıktı değeri hesaplanır. Bu çalışmada, yapay sinir ağları da çok katmanlı algılayıcı modelinde yaygın olarak kullanılan ve yapılan denemeler neticesinde en iyi sonucu veren Sigmoid fonksiyonu kullanılmıştır. Bu fonksiyon Eşitlik 2’de verilmiştir.


$$F(net) = \frac{1}{1+e^{-net}} \quad (2)$$



Şekil 2. Yapay sinir hücresi

Figure 2. Artificial neuron

Yapay sinir ağları mimari olarak giriş katmanı, ara (gizli) katman ve çıkış katmanı olmak üzere üç ana katmandan oluşmaktadır. Bilgiler girdi katmanından ağa iletdikten sonra ara katmanda ağırlık değerleri kullanılarak çıktı katmanına gönderilir. Bir yapay sinir ağı tek bir katmandan oluşuyorsa tek katmanlı sinir ağı, birçok gizli katmandan ve nöronlardan oluşuyorsa çok katmanlı sinir ağı denmektedir (Çodur ve Tortum, 2015; Veri bilimi okulu, 2021). Günümüzde, farklı kullanım alanlarına uygun birçok yapay sinir ağı modeli geliştirilmiştir. Bu ağ yapıları içerisinde en yaygın kullanım alanı bulan ve çalışmamızda da kullanılan çok katmanlı ileri beslemeli yapay sinir ağlarıdır. Aşağıda Şekil 3’de çok katmanlı ileri beslemeli bir yapay sinir ağlarının genel yapısı gösterilmektedir.



Şekil 3. Çok katmanlı ileri beslemeli yapay sinir ağları

Figure 3. Multilayer feedforward ANN

Yapay sinir ağları yapısının temel amacı beklenen değer ile çıktı değeri arasındaki hatayı minimum yapacak ağı kurulmasıdır. Bu bağlamda oluşturulan modellerin performanslarının incelenmesinde çeşitli ölçütler yer almaktadır. Bunlardan ilki olan korelasyon katsayısı, bağımsız değişkenler arasındaki

ilişkinin yönünü ve büyüklüğünü ifade eder. R^2 değeri ise deneysel verilerin doğrusal bir eğriye ne kadar iyi uyduğunu ortaya koyan bir ölçüttür. Mutlak hata (MH) değeri iki sürekli değişkenin arasındaki farkın ölçüsüdür. Diğer bir ifade ile her gerçek değer ile veriye en uygun çizgi arasındaki ortalama dikey mesafedir (Kuşkapan ve Çodur, 2021; Qi ve diğ., 2020). Mutlak bağıl hata (MBH) ise gerçek ve tahmin edilen çıktı değerleri arasındaki farkın seçilen çıktı sayısına bölünmesiyle hesaplanır (Jalali ve Nouri, 2008; Fang ve diğ., 2011). A_j ; gerçek değerler, e_j ; gerçek değer ile tahmin edilen değerlerin farkının mutlak değeri üzere MH ve MBH ölçütleri aşağıdaki Eşitlik 3 ve 4'deki gibi hesaplanır.

$$MH = \frac{1}{n} \sum_{j=1}^n |e_j| \quad (3)$$

$$MBH = \frac{1}{n} \sum_{j=1}^n \frac{|e_j|}{|A_j|} \quad (4)$$

Yapay sinir ağları analizi yapılırken iki farklı algoritma kullanılmıştır. Bunlardan ilki olan Levenberg-Marquardt (LM) algoritması doğrusal olmayan en küçük kareler problemlerini çözmek için kullanılır. Sönümlü en küçük kareler yöntemi olarak da adlandırılmaktadır. Bu algoritma sistem kaynaklarını diğer algoritmalara göre daha fazla kullanmasına karşın ağırlık eğitimi daha kısa sürede gerçekleşmektedir. Algoritmada; birim matrisi I , kombinasyon katsayısı μ , Jacobian matrisi J , hata vektörü e olmak üzere ağırlık vektörü w aşağıda Eşitlik 5'teki gibi hesaplanmaktadır (Çırak, 2012; Bilski ve diğ., 2020).

$$\Delta w = (J^T J + \mu I)^{-1} J^T e \quad (5)$$

Yapay sinir ağları için kullanılan diğer yöntem ise Conjugate Gradient Descent (CGD) algoritmasıdır. Bu algoritma; LM algoritmasına benzer ağırlıklandırılmalarla birleştiren pratik bir yaklaşım geliştirmiştir. Ardışık güncelleme vektörlerinin birbirine dik olmasını amaçlamaktadır. CGD için iki faktör arasındaki farkın karesine bağlı olarak değişen hata fonksiyonu Eşitlik 6'da verilmektedir. Burada $e(t)$ değeri iki etmeden oluşan ağırlık farklarını ifade ederken $E(t)$ değeri hatayı minimize etmeyi amaçlamaktadır (Kavuran, 2020; Kavuran ve diğ., 2017; Wei ve diğ., 2020).

$$E(t) = \frac{1}{2} e(t)^2 \quad (6)$$

ARAŞTIRMA BULGULARI ve TARTIŞMA (RESEARCH FINDINGS and DISCUSSION)

Literatürde yapılan çalışmalara bakıldığında ele alınan yöntemler ile birlikte tahmin parametrelerinde de farklılıklar görülmektedir (He ve diğ., 2010; Solak, 2013; Wang ve diğ., 2014; Sakin 2019). Mevcut literatür ışığında elde edilen veriler değerlendirilerek girdi parametreleri üzerinde bir takım deneyler yapılmıştır. Elde edilen sonuçlar doğrultusunda yıllara bağlı hat uzunluğu, yolcu sayısı ve yük miktarı parametrelerinin çalışmada girdi parametreleri olarak kullanılmasına karar verilmiştir. Çıktı parametresi olarak toplam enerji tüketim miktarı ele alınmıştır. Bahsi geçen model parametrelerinin etkinliklerinin belirlenmesi ve birbirleriyle etkileşimlerinin tanımlanması çalışmanın önemli bir kısmını oluşturmaktadır. Dolayısıyla bu aşamada demiryolu enerji tüketimini tahmin etmek için 5 farklı yapay sinir ağı modeli oluşturulmuş ve modellerde kullanılan girdi parametrelerine ilişkin genel bilgiler Çizelge 1'de verilmiştir. Çalışma boyunca yapay sinir ağı modellerinin çözümünde Matlab 2020b programı, Intel i7 3.40 GHz işlemci 8 GB belleğe sahip bilgisayar kullanılarak sonuçlar elde edilmiştir.

Verilerin ağına sunulması aşamasında 1977-2019 yılları arasındaki veriler rasgele bir şekilde %70'i eğitim, %15'i doğrulama ve %15'i test olarak ayrılmıştır. Ağına eğitimi önceden girdi ve çıktı verileri 0-1 aralığında normalize edilmiştir. Her bir model için çıktı aynı olsa da girdiler ve ara katmanları farklı sayıdadır. Ara katman sayısı nöron giriş ve çıkış sayısından bağımsızdır. Ara katman sayısına göre de nöron sayıları da farklı olabilir. Ara katman sayısında ve bu katmanlardaki nöron sayısındaki artış


hesaplama süresine de etki edebilmektedir. Bununla birlikte meydana gelebilecek çıktılar da farklı olabilmektedir. Ağın çıktı üretebilmesi için genel yapısının belirlenmesi gerekir. Ara katmanlardaki nöronların aralığının belirlenmesi, genel yapay sinir ağı yapılarının belirlenmesinde son derece önemli bir bölümdür. Bu katmanlar dış ortamla doğrudan etkileşime girmese de, nihai çıktı üzerinde inanılmaz bir etki içerirler. Nöron sayılarının belirlenmesi için kesin bir kural olmamakla beraber genellikle belirli bir sayıdan başlanarak aşamalı artırma ile uygun sayı belirlenir. Bu sebeple ilk olarak her bir model için en uygun ağ yapısının belirlenmesi amaçlanmıştır. Bunun için eğitim aşamasında ara katman sayısı 2 ile 11 arasındaki tüm değerler için modeller 3'er kez çalıştırılmıştır. Dolayısıyla çalışmanın eğitim aşamasında toplam 150 deneme (5 model x 10 ara katman x 3 tekrar) yapılmıştır. Bu denemeler sonucu belirlenen en iyi ağ yapıları Çizelge 1'de verilmiştir.

Çizelge 1. Yapay sinir ağı için oluşturulan modeller ve detayları

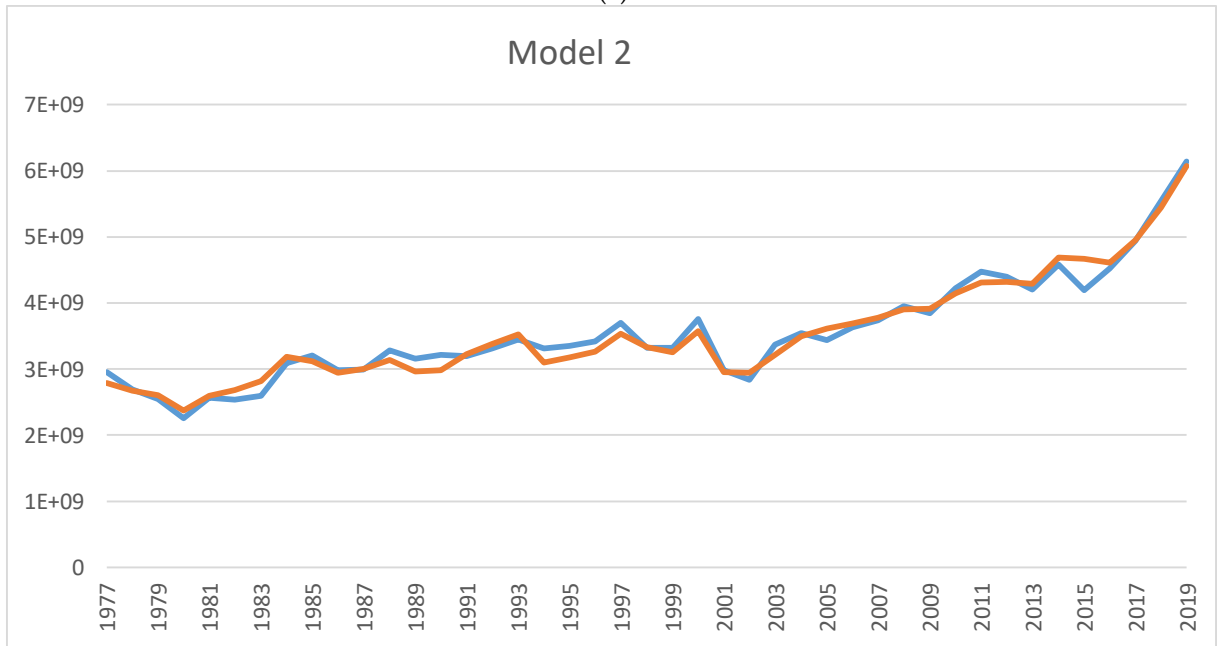
Table 1. Models created for ANN and their details

Sıra Numarası	Model Numarası	Girdiler	Ağ Yapısı	Çıktı
1	Model 1	Yıllar- Hat Uzunluğu-Yolcu Sayısı-Yük Miktarı	4*5*1	
2	Model 2	Hat Uzunluğu-Yolcu Sayısı-Yük Miktarı	3*3*1	
3	Model 3	Yolcu Sayısı-Yük Miktarı	2*5*1	Toplam enerji tüketimi
4	Model 4	Hat Uzunluğu-Yolcu Sayısı	2*7*1	
5	Model 5	Hat Uzunluğu-Yük Miktarı	2*4*1	


Her bir model için farklı algoritma uygulanabilmesi mümkündür. Bu çalışmada bir ve ikinci modellerde; LM, üç, dört ve beşinci modellerde ise CGD algoritmaları kullanılmıştır. Algoritmaların da çeşidine göre elde edilecek sonuçlar farklı olabilmektedir. Aşağıda Şekil 4'te verilen grafiklerde yapay sinir ağları kullanılarak her bir model yapısı ile elde edilen tahminler ile gerçek çıktılar ortaya konmuştur. Grafiklerdeki mavi çizgiler gerçek değerleri ifade ederken, turuncu çizgiler yapay sinir ağları tarafından tahmin edilen değerleri göstermektedir.




(a)




(b)



(c)



(d)



(e)

Şekil 4. Her bir model için gerçek değerler ve yapay sinir ağı tarafından elde edilen değerler

Figure 4. Real values and obtained by ANN values for each model

Grafikler incelendiğinde yapay sinir ağı tarafından elde edilen değerlerin gerçek değerlere oldukça yakın olduğu görülmektedir. Özellikle ilk üç modele ait tahminlerin oldukça başarılı olduğu görülmektedir. 4 numaralı modelde gerçek değerler ile tahmin edilen değerlerin daha az benzerlikte olmuştur. Tahmin değerleri ile gerçek değerlerin uyum durumunu daha iyi tespit edebilmek için korelasyon katsayıları ve R^2 değerlerini incelemek gereklidir. Korelasyon katsayısı bağımlı değişken ile bağımsız değişken arasındaki ilişkinin gücünü gösterir. R^2 değeri ise modelin genel performansını ortaya koymaktadır. Her iki ölçüt de maksimum 1 değerini alabilmektedir. Bu yüzden hem korelasyon katsayısı hem de R^2 değerinin en büyük olduğu model daha başarılı olmaktadır. Bununla birlikte MH ve MBH değerleri hata terimleri olduğu için bu değerlerin düşük çıkması istenmektedir. Bir modelin başarısı için bu değerlerin 0'a yaklaşması istenmektedir. Aşağıda Tablo 2'de her bir modele ait elde edilen korelasyon katsayısı, R^2 , MH ve MBH değerleri verilmektedir.

Çizelge 2. Modeller için korelasyon katsayıları ve R^2 değerleri

Table 2. Correlation coefficients and R^2 values for models

	Model 1	Model 2	Model 3	Model 4	Model 5
Korelasyon Katsayısı	0,987001	0,985300	0,987910	0,968830	0,983915
R^2 değeri	0,973091	0,970372	0,974697	0,936417	0,965800
MH	106645972	107936103	105984244	141899345	112777819
MBH	0,031581	0,032401	0,031501	0,043382	0,033682

Tablodaki değerler incelendiğinde tüm modeller hem korelasyon katsayısı açısından hem de R^2 açısından 1 değerine oldukça yakındır. 3 numaralı model en yüksek doğruluğa ve en düşük hata değerine sahiptir. Bununla birlikte 1 numaralı model de 3 numaralı modele oldukça yakın değerlerde çıkmıştır. Daha

sonra en iyi değerlere sahip olan model ise 2 numaralı modeldir. Bu üç model de incelendiğinde girdiler kısmında hem yolcu hem yük miktarı yer almaktadır. Yolcu ve yük miktarının enerji tüketimi ile doğrudan ilişkili olduğu ortaya konmaktadır. 3 numaralı modelde bu iki ölçüt girdi olarak yer almakta iken 1 ve 2 numaralı modellerde birinde yıllar ve hat uzunluğu diğerinde ise sadece hat uzunluğu da yolcu ve yük miktarına ilaveten girdiler kısmında yer almaktadır. Fakat bu iki ölçüt modelin doğruluk değerlerini bir miktar düşürmüştür. 4 ve 5 numaralı modellerde ise hat uzunluğuna ek olarak bir modelde yolcu sayısı diğerinde ise yük miktarı girdiler arasında yer almaktadır. Bu iki ölçütün birlikte girdi olmaması modelin doğruluk değerini düşürmüştür. Öte yandan 4 numaralı modelin doğruluk değeri daha düşük olduğu da düşünüldüğünde enerji tüketiminde yolcu sayısına göre yük miktarının daha etkili olduğu söylenebilmektedir.

SONUÇLAR (CONCLUSIONS)

Bu çalışmada ülkemizde son 43 yılda demiryolu hatlarına ilişkin hat uzunluğu, yolcu sayısı ve yük miktarına ait değişimler incelenmiştir. Yapay sinir ağında 5 farklı model için yıl, hat uzunluğu, yolcu sayısı ve yük miktarı değerleri farklı kombinasyonlarda girdi olarak kullanılmıştır. Bir yolcu için kilometre başına harcanan enerji ve 1 ton yük için kilometre başına harcanan enerji miktarları esas alınarak tüm yıllara ait enerji değerleri çıktı olarak alınmıştır. Yapay sinir ağları ile oluşturulan modellerde farklı girdi ve ara katman sayıları kullanılarak yıllara göre enerji değerleri tahmin edilmiş ve bu değerler gerçek değerler ile kıyaslanmıştır. Daha sonra modellere ait korelasyon katsayısı, R^2 , MH ve MBH değerleri hesaplanmış ve birbirleriyle karşılaştırılmaları sonucu en iyi modelin üçüncü model olduğu görülmektedir. Üçüncü modelde kullanılan girdiler enerji tüketimini tahmin etmede diğer modellere göre daha başarılı olmuştur. Öte yandan 4 ve 5 numaralı modeller incelendiğinde ise yük miktarının yolcu sayısına göre enerji tüketim miktarının tahmininde daha etkili olduğu ortaya konmuştur.

Bu çalışma, dünyada hızla tükenen enerji kaynaklarının daha verimli kullanılabilmesi adına önemli sonuçlar ortaya koymaktadır. Ülkemizin gelecek yıllarda demiryolu hatlarına yatırımda özellikle yolcu taşımacılığında sürdürülebilir enerji kaynaklarına yönelmesi önemli miktarda enerji tasarrufu sağlayabilecektir. Buna ilaveten bu çalışma verileri; demiryolu hatlarında gelecek yıllarda tahmini olarak taşınması planlanan yolcu ve yük miktarları belirlendiği takdirde ihtiyaç duyulan enerji miktarı tespit edilip buna yönelik önlemler alınmasına olanak sağlamaktadır.

KAYNAKLAR (REFERENCES)

- Acampora, G., Landi, C., Luiso, M., Pasquino, N., "Optimization of Energy Consumption in A Railway Traction System", *International Symposium on Power Electronics, Electrical Drives, Automation and Motion, Speedam*, 1121-1126, May 2006.
- Arıkan, Y., Şen, T. A., Çam, E., 2020, "Raylı Araçlarda Enerji Verimliliği Çalışması", *El-Cezeri Journal of Science and Engineering*, Cilt 7, Sayı 1, ss. 223-235.
- Bai, Y., Ho, T. K., Mao, B., Ding, Y., Chen, S., 2014, "Energy-efficient locomotive operation for Chinese mainline railways by fuzzy predictive control", *IEEE Transactions on Intelligent Transportation Systems*, Cilt 15, Sayı 3, ss. 938-948.
- Bilski, J., Kowalczyk, B., Marchlewska, A., Zurada, J. M., 2020, "Local Levenberg-Marquardt Algorithm for Learning Feedforward Neural Networks", *Journal of Artificial Intelligence and Soft Computing Research*, Cilt 10, Sayı 4, ss. 299-316.
- Cansız, Ö. F., Ünsalan, K., 2019, "Demiryolu Yük Taşımacılığının Çok Türü Rotalara Etkisinin Vaka Analizi ile İncelenmesi: Hatay-Van", *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, Cilt 8, Sayı 3, ss. 921-931.
- Coiret, A., Vandanjon, P. O., Bosquet, R., Jullien, A., 2017, "Energy consumption induced by operation phase of railways and road infrastructures", *2nd International Conference on Road and Rail Infrastructure*, 693-699.
- Çırak, G., 2012, *Yükseköğretimde Öğrenci Başarılarının Sınıflandırılmasında Yapay sinir ağları ve Lojistik*

- Regresyon Yöntemlerinin Kullanılması*, Yüksek Lisans Tezi, Ankara Üniversitesi Eğitim Bilimleri Enstitüsü, Ankara.
- Çodur, M. Y., Tortum, A., 2009, "Modelling Car Ownership in Turkey Using Neural Networks", *Proceedings of the Institution of Civil Engineers-Transport*, Cilt 162, Sayı 2, ss. 97-106.
- Çodur, M. Y., Tortum, A., 2015, "An Artificial Neural Network Model for Highway Accident Prediction: A Case Study of Erzurum, Turkey", *Promet Traffic & Transportation*, Cilt 27, Sayı 3, ss. 217-225.
- ÇŞB (Çevre Şehircilik Bakanlığı), Sektörlere Göre Toplam Enerji Tüketimi, <https://cevreselgostergeler.csb.gov.tr/sectorlere-gore-toplam-enerji-tuketimi-i-85800>, ziyaret tarihi: 20 Eylül 2021.
- Erdoğan, M., Kaya, İ., 2020, "A New Approach for Rule Estimation of Fuzzy Inference System: A Case Study for Public Transport Maintenance System", *Konya Mühendislik Bilimleri Dergisi*, Cilt 8, Sayı 4, ss. 906-915.
- Fang, X., Xu, Y., Zhou, Z., 2011, "New Correlations of Single-Phase Friction Factor for Turbulent Pipe Flow and Evaluation of Existing Single-Phase Friction Factor Correlations", *Nuclear Engineering and Design*, Cilt 241, Sayı 3, ss. 897-902.
- González-Gil, A., Palacin, R., Batty, P., Powell, J. P., 2014, "A Systems Approach to Reduce Urban Rail Energy Consumption", *Energy Conversion and Management*, Cilt 80, ss. 509-524.
- Haykin, S., 1999, "Neural Networks – A Comprehensive Foundation", *Prentice Hall*, 2. Edition, New Jersey.
- He, J.C., Wu, W.H., Xu Y.Q., 2010, "Energy consumption of locomotives in China railways during 1975–2007", *Journal of Transport Systems Engineering and Information Technology*, Cilt 10, ss. 22–7.
- Jalali, G. Z. M., Nouri, R. E., 2008, "Prediction of Municipal Solid Waste Generation by Use of Artificial Neural Network: A Case Study of Mashhad", *International Journal of Environmental Research*, Cilt 2, Sayı 1, ss. 13-22.
- Jong, J. C., Chang, E. F., 2005, "Models for Estimating Energy Consumption of Electric Trains", *Journal of the Eastern Asia Society for Transportation Studies*, Cilt 6, ss. 278-291.
- Kavuran, G., Ateş, A., Alagoz, B.B., Yeroğlu, C., 2017, "An Experimental Study on Model Reference Adaptive Control of TRMS by Error-Modified Fractional Order MIT Rule", *Control Engineering and Applied Informatics*, Cilt 19, Sayı 4, ss. 101–111.
- Kavuran, G., 2020, "Uyarlanabilir Onaylaşım Algoritması Tabanlı Senkronize Duffing Osilatörünün Donanımsal Gerçeklemesi", *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, Cilt 32, Sayı 1, ss. 57-67.
- Kuşkapan, E., Çodur, M. Y., 2021, "Examination of Aircraft Accidents That Occurred in the Last 20 Years in the World", *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, Cilt 9, Sayı 1, ss. 174-188.
- Liu, R. R., Golovitcher, I. M., 2003, "Energy-efficient Operation of Rail Vehicles", *Transportation Research Part A: Policy and Practice*, Cilt 37, Sayı 10, ss. 917-932.
- Qi, J., Du, J., Siniscalchi, S. M., Ma, X., Lee, C. H., 2020, "On Mean Absolute Error for Deep Neural Network Based Vector-to-Vector Regression", *IEEE Signal Processing Letters*, Cilt 27, ss. 1485-1489.
- Ren, J., Zhang, Q., Liu, F., 2020, "Analysis of factors affecting traction energy consumption of electric multiple unit trains based on data mining", *Journal of Cleaner Production*, Cilt 262, 121374.
- Sakin, R., 2019, *Ulaştırma Sistemlerinde Enerji Analizi Parametrelerinin Tahmin Edilmesi*, Yüksek Lisans Tezi, İskenderun Teknik Üniversitesi Mühendislik ve Fen Bilimleri Enstitüsü, Hatay.
- Solak, A. O., 2013, "Türkiye'de Ulaştırma Sektörü Enerji Tüketiminin Azaltılması: Bir Senaryo Yaklaşımı", *International Journal of Economic & Social Research*, Cilt 9, Sayı 1, ss. 125-141.
- TCDD, Faaliyet Raporu, <https://www.tcddtasimacilik.gov.tr/uploads/images/Strateji/TCDD-Tasimacilik-2019-Faaliyet-Raporu.pdf>, ziyaret tarihi: 17 Şubat 2021.
- Veri Bilimi Okulu, Yapay Sinir Ağı (Artificial Neural Network) Nedir? <https://www.veribilimiokulu.com/yapay-sinir-agiartificial-neural-network-nedir/>, ziyaret tarihi: 26 Şubat 2021.
- Wang, Y. F., Li, K. P., Xu, X. M., Zhang, Y. R., 2014, "Transport Energy Consumption and Saving in China", *Renewable and Sustainable Energy Reviews*, Cilt 29, ss. 641-655.

- Wei, Y., Zhao, M. M., Hong, M., Zhao, M. J., Lei, M., 2020, "Learned Conjugate Gradient Descent Network for Massive MIMO Detection", *IEEE Transactions on Signal Processing*, Cilt 68, ss. 6336-6349.
- Zhang, H., Jia, L., Wang, L., Xu, X., 2019, "Energy Consumption Optimization of Train Operation for Railway Systems: Algorithm Development and Real-World Case Study", *Journal of Cleaner Production*, Cilt 214, ss. 1024-1037.
- Zhao, N., Roberts, C., Hillmansen, S., Tian, Z., Weston, P., Chen, L., 2017, "An Integrated Metro Operation Optimization to Minimize Energy Consumption", *Transportation Research Part C: Emerging Technologies*, Cilt 75, ss. 168-182.